



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

**SISTEMA DE GESTIÓN DE AGUA Y ENERGÍA PARA CULTIVOS A
CAMPO ABIERTO MEDIANTE CONTROL PREDICTIVO ROBUSTO**

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA INGENIERÍA,
MENCIÓN ELÉCTRICA

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO

JAVIER IGNACIO OCARANZA SOBREVÍA

PROFESORA GUÍA:
DORIS SÁEZ HUEICHAPAN

PROFESORAS CO-GUÍA:
LINDA DANIELE
CONSTANZA AHUMADA SANHUEZA

MIEMBROS DE LA COMISIÓN:
RODRIGO PALMA BEHNKE
DANIEL SBARBARO HOFER

Este trabajo ha sido parcialmente financiado por:
ANID/FONDECYT 1220507, ANID/FONDECYT 1221392,
ISCI ANID PIA/PUENTE AFB220003, SERC-Chile ANID/FONDAP/1522A0006 y
ANID/ANILLO ATE220029

SANTIAGO DE CHILE

2023

RESUMEN DE LA TESIS PARA OPTAR
AL GRADO DE MAGÍSTER EN CIENCIAS
DE LA INGENIERÍA, MENCIÓN ELÉCTRICA
Y MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL ELÉCTRICO
POR: JAVIER IGNACIO OCARANZA SOBREVÍA
FECHA: 2023
PROF. GUÍA: DORIS SÁEZ HUEICHAPAN

SISTEMA DE GESTIÓN DE AGUA Y ENERGÍA PARA CULTIVOS A CAMPO ABIERTO MEDIANTE CONTROL PREDICTIVO ROBUSTO

En el contexto de la agricultura, en un país afectado por una “megasequía” y la extracción irresponsable de agua subterránea, existe la necesidad de optimizar el uso del agua destinada a riego, siendo crucial encontrar la cantidad que permita maximizar el rendimiento de cultivos, mientras se minimiza el uso de energía y agua. Por esto, esta tesis propone un sistema de gestión de agua y energía basado en control predictivo robusto, aplicado a cultivos en campo abierto.

Para implementar este sistema se caracteriza el comportamiento y las incertezas de la radiación solar, temperatura ambiente, velocidad del viento y precipitaciones, las cuales perturban directamente al sistema, mediante modelos difusos Takagi-Sugeno e intervalos de predicción basados en números difusos. Además, para estimar el volumen de agua disponible de la zona, se diseña un sistema hidrogeológico, que considera la dinámica de las precipitaciones, escorrentía, riego, entre otras variables de interés.

Se evalúa el desempeño del sistema de gestión bajo distintos escenarios, mostrando que utilizar intervalos de predicción dentro del controlador robusto permite compensar las incertezas de las variables climáticas, al alcanzar un rendimiento máximo para todos los cultivos, y un uso de agua y energía sustentable.

(A strange light fills the room.)
(Twilight is shining through the barrier.)
(It seems like your journey is finally over.)
*(You're filled with **DETERMINATION.**)*

Agradecimientos

Ha sido un largo y difícil trabajo, que estoy seguro, no podría haber terminado sin la ayuda de muchas muchas personas que me han dado apoyo, comprensión y buenos momentos. Primero que todo, agradezco profundamente a mi polola Isidora, que durante tanto tiempo me ha dado su comprensión, apoyo y amor, sin el cual no hubiera siquiera pasado del primer año de la carrera. Me gustaría agradecer a mi familia, a mis papás y mis hermanos, los que me han apoyado de mil maneras, desde irme a buscar al metro, hacerme un almuerzo o perdonarme por dejar todo cochino los días que mas estresado estaba, de verdad les agradezco por todo lo que han hecho y siguen haciendo por mí.

Quiero agradecerle a mis amigos (sin orden particular de preferencia) Joaquín, Maximiliano, Catalina, Pablo, Carla, Franco, Paulo y Fran, por todos los ramos que tomamos juntos, todas las salidas que tuvimos, todas las tardes que nos reímos y todos los tanques de los que corrimos. Gracias a ustedes mi estancia en la u fue tan feliz y me alegra mucho haberlos conocido a todos. También quiero agradecerles a todos los del laboratorio de control avanzado 2, Luis, Benjamín, Oscar, Felipe, Oscar, Matías, Roberto y Alvaro, por los buenos momentos, las buenas conversas y las interminables reuniones que tuvimos casi todas las semanas.

Quiero agradecerle también a las profesoras que me ayudaron durante el trabajo. A las profesoras Linda y Constanza, por el tiempo que se dieron en sugerir, corregir y enseñar, estando presentes en las mil reuniones que tuvimos, aun cuando alguno de esos avances no era tan sustanciales. Y a la profesora Doris, por su paciencia y entusiasmo al enseñarme, corregirme aun cuando le enviaba trabajos a última hora, por darme la oportunidad de participar en muchos trabajos y cursos, y por retarme por todas las faltas de ortografía que tuve (y tendré). Les agradezco enormemente su ayuda en este trabajo.

Finalmente, se agradece el apoyo de los siguientes proyectos para el desarrollo de esta tesis: Instituto Sistemas Complejos de Ingeniería (ISCI) ANID PIA/PUENTE AFB220003, Solar Energy Research Center SERC-Chile ANID/FONDAP/1522A0006, ANID/FONDECYT 1220507 “Distributed Predictive Control Strategies based on Evolving Prediction Intervals for Energy-Water Microgrids”, ANID/FONDECYT 1221392 “Enhanced Control Flexibility of Modular Multilevel Converters Through Continuous Control Set Model Predictive Control” y ANID/ANILLO ATE220029 “Water-Energy-Food nexus for urban areas in Central Chile”

Tabla de Contenido

1. Introducción	1
1.1. Motivación	1
1.2. Hipótesis	2
1.3. Objetivos	2
1.3.1. Objetivo general	2
1.3.2. Objetivos específicos	3
1.4. Estructura de la tesis	3
1.5. Publicaciones generadas	3
2. Estado del arte	4
2.1. Nexos agua-energía-alimento	4
2.1.1. Sistemas de gestión de agua y energía	5
2.2. Modelación e intervalos de predicción	8
2.3. Control predictivo robusto	11
2.4. Discusión	14
3. Marco teórico	16
3.1. Conceptos hidrogeológicos	16
3.1.1. Definición de cuencas	16
3.1.2. Definición y propiedades de los acuíferos	17
3.1.3. Ensayos de bombeo y sus aplicaciones	18
3.1.4. Cálculo del cono de descenso en pozos de extracción	22
3.1.5. Balance hídrico en una cuenca	23
3.2. Modelos difusos Takagi-Sugeno	25
3.3. Intervalos de predicción	27
3.4. Discusión	28
4. Modelación del sistema hidrogeológico, eléctrico y de los cultivos	30
4.1. Planteamiento del problema	30
4.2. Modelación del sistema hidrogeológico	31
4.2.1. Estimación del agua disponible	31
4.2.2. Modelo del estanque y bomba de extracción	34
4.2.3. Cálculo de demanda de riego	34
4.2.4. Relación entre riego y demanda hídrica	36
4.3. Modelación del sistema eléctrico	37
4.3.1. Generación fotovoltaica	37
4.3.2. Bancos de baterías	38

4.3.3.	Inversor	39
4.3.4.	Bombas de extracción	39
4.3.5.	Consumo eléctrico residencial	39
4.4.	Sistema de gestión de agua y energía	40
4.4.1.	Modelación de variables climáticas	41
4.4.2.	Sistema de gestión de agua	42
4.4.3.	Sistema de gestión de energía	45
4.5.	Discusión	47
5.	Resultados	49
5.1.	Caso de estudio	49
5.1.1.	Dimensionamiento de los componentes	49
5.1.2.	Características de los cultivos	49
5.1.3.	Parámetros de los sistemas hidrogeológicos	50
5.1.4.	Datos meteorológicos y consumo de la comunidad	50
5.2.	Resultados experimentales	51
5.2.1.	Cálculo de parámetros del acuífero	51
5.2.2.	Cálculo de la recarga	52
5.2.3.	Modelación de variables de corto plazo	54
5.2.4.	Modelación de variables de mediano plazo	57
5.2.5.	Experimentos propuestos	68
5.2.6.	Resultados del sistema de gestión de agua	69
5.2.7.	Resultados del sistema de gestión de energía considerando la demanda hídrica del WMS	72
5.3.	Discusión	76
6.	Conclusiones	78
6.1.	Trabajo futuro	81
	Bibliografía	82
	Anexos	88
	Anexo A. Estudio de suelo en la comunidad	88
	Anexo B. Optimización estructural de modelos Takagi-Sugeno	90
	Anexo C. Estimación de parámetros del filtro de Eckhardt	92

Índice de Tablas

5.1.	Parámetros de los cultivos	50
5.2.	Parámetros obtenidos al aplicar el método Cooper-Jacob.	52
5.3.	Rendimiento de los modelos a corto plazo en distintos pasos de predicción. . .	56
5.4.	Comparación de modelo Takagi-Sugeno y AR para las precipitaciones P a distintos horizontes de predicción	60
5.5.	Comparación de modelo Takagi-Sugeno, AR y Media Móvil para la recarga obtenida en 5.3 a distintos horizontes de predicción	64
5.6.	Rendimiento de los modelos a mediano plazo en distintos pasos de predicción .	67
5.7.	Resultados del WMS para los distintos experimentos propuestos	71
5.8.	Resultados del EMS para los distintos experimentos propuestos	75
C.1.	Parámetros obtenidos al estudiar el caudal de la cuenca.	93

Índice de Ilustraciones

2.1.	Diagrama representativo del nexa agua-energía-alimento	4
2.2.	Valor esperado e intervalo de predicción para un conjunto de datos y	9
2.3.	Ejemplo de control predictivo.	11
3.1.	Región de la Araucanía dividida en cuencas y sub-cuencas	17
3.2.	Esquema de un acuífero libre.	17
3.3.	Tipos de acuíferos.	18
3.4.	Esquema de un ensayo de bombeo [39]	19
3.5.	Descensos medidos sobre la curva del pozo	20
3.6.	Ejemplo del método de Cooper-Jacob para aproximar los parámetros de un acuífero	21
3.7.	Descenso en el nivel de un acuífero a una distancia r	22
3.8.	Ejemplo de balance hídrico	24
4.1.	Diagrama del proceso a lazo abierto	30
4.2.	Conjunto de sistemas hidrogeológicos para un cultivo	31
4.3.	Balance hídrico para el sistema hidrogeológico propuesto	32
4.4.	Diagrama del cálculo de la recarga	33
4.5.	Diagrama de la micro-red	37
4.6.	Esquema de control del sistema de gestión de agua y energía	40
4.7.	Diagrama de bloques de la construcción de los intervalos de predicción	42
5.1.	Prueba de gasto constante en el pozo o-451 y ajuste lineal.	52
5.2.	Separación del flujo base y escorrentía E_s al aplicar el filtro de Eckhardt sobre el caudal total Q_{total} . La escorrentía corresponde a la diferencia del área gris y la línea roja.	53
5.3.	Recarga en la cuenca R y precipitaciones P	54
5.4.	Predicción e intervalo de radiación solar R_s para distintos pasos de predicción.	55
5.5.	Predicción e intervalo de temperatura ambiente T_a para distintos pasos de predicción.	56
5.6.	Predicción e intervalo de radiación solar R_s para distintos pasos de predicción.	57
5.7.	Predicción e intervalo de temperatura ambiente T_a para distintos pasos de predicción.	58
5.8.	Predicción e intervalo de la velocidad del viento u_2 para distintos pasos de predicción.	59
5.9.	Comparación de las predicciones P a 28 días de la precipitación utilizando modelos Takagi-Sugeno y AR.	60
5.10.	Curva doble másica para los modelos Takagi-Sugeno y AR de las precipitaciones a 28 días.	61
5.11.	Predicción e intervalo de las precipitaciones a distintos pasos de predicción . .	62
5.12.	Predicciones de precipitaciones a 28 días para cada experimento	63

5.13.	Comparación de las predicciones a 28 días de la recarga utilizando modelos Takagi-Sugeno, AR y Media Móvil.	64
5.14.	Curva doble másica para los modelos Takagi-Sugeno, AR y Media Móvil para la recarga a 28 días.	65
5.15.	Predicción e intervalo de la recarga a distintos pasos de predicción	66
5.16.	Rendimiento relativo de los cultivos y volumen de riego de referencia para 70 días de simulación de cada experimento	70
5.17.	Agua estimada disponible en el acuífero para cada experimento (en diferentes colores) y recarga estimada.	70
5.18.	Estado de carga de los bancos de baterías para cada experimento (en distintos colores).	73
5.19.	Energía en la micro-red para cada experimento propuesto.	73
5.20.	Uso de la bomba de extracción según su potencia.	74
5.21.	Uso de la bomba de extracción según su potencia (acercamiento en distintos periodos de la figura 5.20).	74
A.1.	Estudio de suelo realizado en la comunidad.	89
B.1.	Algoritmo de identificación de parámetros y estructura	90
C.1.	Curva de duración de caudales en escala semilogarítmica.	92
C.2.	Curvas de recesión del caudal de la cuenca en estudio, junto a la curva de recesión maestra construida.	93

1. Introducción

1.1. Motivación

Dentro de las actividades que utilizan agua subterránea en el mundo, se estima que la agricultura consume hasta un 70 % de esta y hasta un 90 % del agua potable global [1]. Además, se espera que para el 2050 se necesite producir un 60 % más de alimento para satisfacer la demanda global [2]. Sin embargo, los aumentos en los rendimientos de los cultivos se están desacelerando en comparación con años anteriores [3], lo que plantea una amenaza para la disponibilidad de alimentos, considerando un incremento constante en la población. En este contexto, la seguridad alimentaria se convierte en un tema importante debido a la necesidad de asegurar una fuente de alimento para la población mundial en un futuro cercano, por lo que es necesario desarrollar nuevas políticas y estrategias que contribuyan aún más a mejorar la seguridad alimentaria en todo el mundo.

El problema de un aumento considerable en las prácticas agrícolas bajo un límite en el recurso hídrico reside en que, si los cultivos no se riegan adecuadamente, su desarrollo se ve comprometido, o en el peor de los casos, estos se marchitan. Por otro lado, si el agua subterránea se administra irresponsablemente, esto es, utilizar más agua de la que se recupera naturalmente por largos periodos de tiempo, puede llevar a un agotamiento del agua, una reducción del nivel de esta o causar impactos negativos en diversos ecosistemas [4]. De esta forma, es crucial encontrar un balance entre el uso de agua extraída y el riego que asegure el mejor crecimiento para los cultivos.

Similar al escenario anterior, el cambio climático también modifica la cantidad de agua subterránea disponible al cambiar el comportamiento de las precipitaciones, creando sequías o inundaciones donde antes no las había [5]. Específicamente, la zona centro-sur de Chile se encuentra en un periodo de “megasequía” desde el 2010, lo que ha reducido las precipitaciones en más de un 30 %, hecho sin precedentes en duración, intensidad y extensión territorial, donde un cuarto de este déficit se atribuye al cambio climático antrópico. Esta disminución afecta directamente el caudal de los ríos, lagos, embalses, agua subterránea, deteriora la vegetación no irrigada y aumenta la frecuencia de los incendios forestales [6]. Considerando esto, es importante reducir las emisiones de gases de efecto invernadero, para no contribuir aún más al calentamiento global. Así, el uso de energías renovables, como la generación solar o eólica, resultan convenientes para abastecer el consumo eléctrico residencial o el consumo debido al riego.

Tomando en consideración los fenómenos descritos anteriormente, es que se utiliza el concepto del nexo agua-energía-alimento [7, 8], implicando que un cambio en cualquiera de estos

recursos influirá directamente en la obtención de los otros. Por esta razón, el controlador diseñado para gestionar el uso de los recursos debe considerar cada proceso como un conjunto, en vez de fenómenos independientes.

Por consiguiente, en este trabajo se implementará un sistema de gestión de agua y energía basado en control predictivo robusto (RMPC) que permita administrar el riego de distintos cultivos, con el objetivo de maximizar su rendimiento, considerando una cantidad limitada de agua asociada a la recarga por lluvias y el uso de energía solar para alimentar los equipos necesarios. La principal ventaja de utilizar un esquema de control robusto, es que permite asegurar el cumplimiento de las restricciones (en este caso alcanzar el máximo crecimiento para todos los cultivos) a pesar de encontrarse con fuentes de incertezas, a costa de posiblemente aumentar los costos asociados a la operación. De esta forma, el sistema de gestión de agua y energía asegurará una generación de alimento en cada temporada agrícola, optimizando el uso de los recursos disponibles.

Este sistema se aplicará a distintos cultivos a campo abierto, como papas, cebollas, lechugas y maíz, situados en la comunidad Lafkenche José Painecura Hueñalihuen, en la región de La Araucanía.

1.2. Hipótesis

En el desarrollo de esta tesis, se consideran las siguientes hipótesis:

- La recarga difusa de acuíferos, en una comunidad rural indígena, puede modelarse a través de ecuaciones fenomenológicas, analizando el balance hídrico dentro de esta cuenca.
- Es posible caracterizar la incerteza de distintas variables climáticas, como los son la radiación solar, temperatura del aire, utilizando modelos difusos Takagi-Sugeno con intervalos de predicción basados en números difusos.
- El sistema de gestión agua-energía, basado en control predictivo robusto, es capaz de administrar el riego con tal de maximizar el rendimiento de todos los cultivos, considerando los recursos disponibles.
- El sistema de gestión agua-energía, basado en control predictivo robusto, cumplirá mejor las restricciones impuestas en comparación a una gestión basada en un controlador predictivo convencional.

1.3. Objetivos

1.3.1. Objetivo general

El objetivo general del trabajo consiste en diseñar y evaluar un sistema de gestión del recurso hídrico y eléctrico, considerando el uso de energías renovables y el bombeo responsable de agua subterránea, con el fin de maximizar el rendimiento de distintos tipos de cultivos al regular la frecuencia de riego, mientras se minimizan los costos de operación.

1.3.2. Objetivos específicos

A su vez, los objetivos específicos del trabajo se listan a continuación.

- Modelar el sistema hidrológico en estudio, con el fin de estimar la cantidad de agua disponible en los acuíferos y pozos.
- Construir y evaluar modelos e intervalos de predicción, que representen la dinámica e incerteza de variables climáticas no controlables como la radiación solar, temperatura, precipitaciones y velocidad del viento.
- Diseñar un sistema de gestión de agua y energía que, en conjunto a la información obtenida de los modelos, defina una frecuencia de riego que logre maximizar el rendimiento de distintos cultivos.
- Diseñar un sistema de gestión basado en control predictivo con intervalos de predicción, incluyendo modelación de incertezas dentro de las decisiones del controlador, considerando escenarios desfavorables.
- Evaluar el desempeño del sistema de gestión basado en control robusto, comparando los resultados obtenidos con un sistema de gestión convencional, analizando ventajas y desventajas del esquema de control propuesto.

1.4. Estructura de la tesis

El trabajo se estructura de la siguiente manera: En el capítulo 2 se realiza una investigación bibliográfica sobre el nexo agua-energía-alimento, la modelación de sistemas y control de micro-redes. En el capítulo 3 se encuentra el marco teórico del trabajo, donde se explican los conceptos y ecuaciones principales que se utilizan en esta tesis. El capítulo 4 explica la modelación del sistema hidrológico y eléctrico propuesto, en conjunto al algoritmo de control que se aplica sobre los modelos definidos anteriormente. En el capítulo 5 se presenta el caso de estudio, los experimentos que se simulan y los resultados obtenidos de cada uno. Finalmente, en el capítulo 6 se encuentran las principales conclusiones del trabajo realizado, en conjunto a las posibles mejoras definidas como trabajo futuro.

1.5. Publicaciones generadas

De los resultados obtenidos en esta tesis, se generaron las siguientes publicaciones:

- J. Ocaranza, D. Sáez, C. Ahumada, L. Daniele, “Energy-water management system based on robust predictive control for open-field cultivation” en preparación para ser enviada a la revista *Science of The Total Environment*
- L. Rojas, J. Ocaranza, O. Cartagena, D. Sáez, L. Daniele and C. Ahumada, “Robust Energy-Water Management System with Prediction Interval Based on Deep Learning”, *International Joint Conference on Neural Networks (IJCNN 2023)*, Queensland, Australia, June 18-23 2023.
- A. Endo, O. Cartagena, J. Ocaranza, D. Sáez and C. Muñoz, “Fuzzy and Neural Prediction Intervals for Robust Control of a Greenhouse”, *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2022)*, Padua, Italy, July 18-23, 2022.

2. Estado del arte

En el marco de esta tesis, se realiza una revisión de literatura sobre el nexo agua-energía-alimento y sus implicancias, sistemas de gestión agua-energía, modelación de sistemas y construcción de intervalos de predicción, y control predictivo robusto. Dado que existen numerosos algoritmos diseñados para cada uno de estos temas, es importante analizar cuál ha sido su desarrollo, qué problema resuelve cada uno y cuáles son las ventajas y desventajas entre ellos. A continuación, se presenta esta revisión bibliográfica.

2.1. Nexo agua-energía-alimento

El Nexo agua-energía-alimento busca analizar y comprender la relación que existe entre el consumo de agua, uso de energía y generación de alimento en distintos procesos, reconociendo que cualquier intervención en uno de estos sectores puede tener un impacto significativo en los demás [8]. La figura 2.1 muestra un ejemplo de la relación entre estas variables.

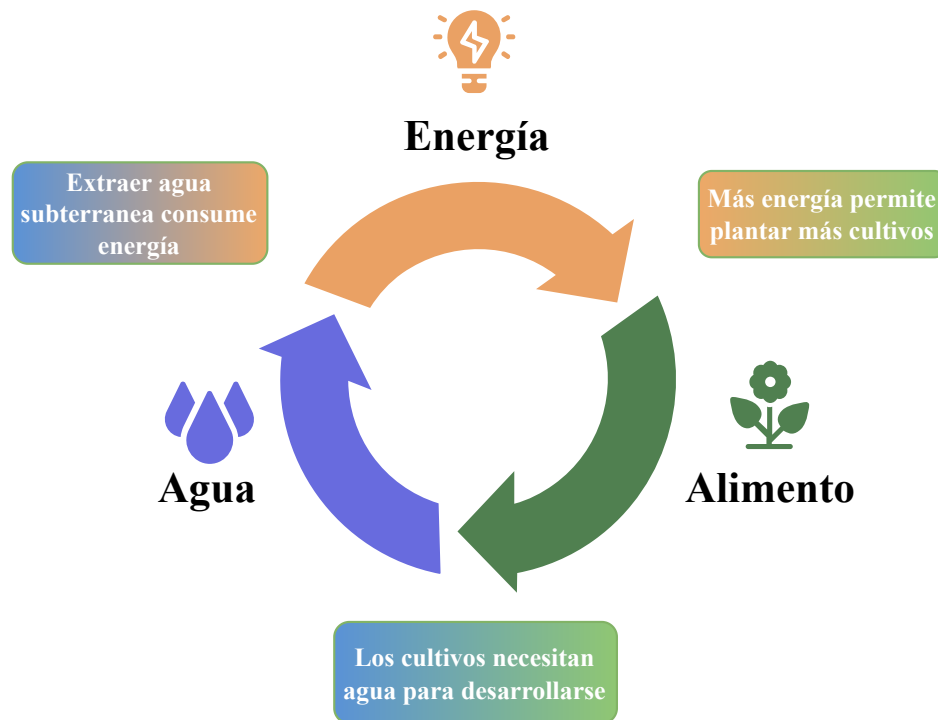


Figura 2.1: Diagrama representativo del nexo agua-energía-alimento

Debido a esto, al adoptar un enfoque de nexo, es posible identificar soluciones más eficientes

y efectivas que minimicen los conflictos y maximicen los beneficios mutuos de cada recurso [9]. Algunos de los desafíos que presenta abordar este nexo son las distintas escalas de tiempo y magnitud que presenta cada variable y el esfuerzo computacional extra que estas diferencias conllevan. [10]. Por esto, esta revisión se centra en sistemas de gestión agua-energía que aborden de alguna manera estos desafíos.

2.1.1. Sistemas de gestión de agua y energía

Se considera un sistema de gestión agua-energía como a un esquema de control que administra los recursos hídricos, como el agua subterránea o sistemas de captación de agua lluvia, y sistemas eléctricos, como la generación mediante recursos renovables, motores, bombas, entre otros [11]. El objetivo del sistema de gestión es poder aprovechar óptimamente los recursos anteriores para disminuir costos operacionales, limitar el impacto medioambiental o alargar la vida útil de los actuadores utilizados [12, 13], para esto, se estudia la dinámica y relación de cada variable para contar con la mayor cantidad de información posible, y así diseñar un controlador que alcance un buen desempeño [14].

Por ejemplo, en [15] se considera una micro-red conectada a la red eléctrica, la que debe cumplir con una demanda energética, de agua y de calor. Esta micro-red cuenta con tanques de agua, pozos y plantas desalinizadoras para la obtención y almacenamiento de agua, tanques de hidrógeno, electrolizadores, celdas de combustible y una conexión a la red para la generación, compra, venta y almacenamiento de energía, y un generador de energía y calor en conjunto a hervidores de agua para la generación de calor. Se desea reducir los costos de operación asociados al uso de energía mientras se satisface la demanda de agua, energía y calor, por lo que se considera una formulación tipo *stochastic p-robust* la cual se basa en modelar la incertidumbre de las distintas variables al considerar una distribución de probabilidad para cada una y definir escenarios posibles, así, entre más escenarios se utilicen, mejor será la caracterización de la incertidumbre. Además, esta formulación busca la combinación de escenarios más conservadora al definir una variable p que limitará que tan cercana debe ser la solución óptima de la solución factible que represente el peor caso, controlando la robustez de la solución. Por otro lado, para incluir todos los costos dentro de la optimización se utiliza el método de $\epsilon - constraint$ el cual se basa en utilizar solo un costo como función de optimización (en este caso el costo de operación) y considerar el resto de costos como restricciones del problema, acotadas por un parámetro ϵ conocido. Las principales ventajas de este trabajo son poder gestionar los recursos de manera robusta al optimizar simultáneamente las variables relacionadas con el agua y la energía, considerando la incertidumbre asociada a estas. Por otro lado, las desventajas que se observan son la complejidad adicional al considerar las restricciones asociadas a la variable p y el costo computacional extra al considerar múltiples casos según la distribución de la incertidumbre de cada variable.

En [16], se diseña un sistema de gestión de agua y energía con el objetivo de encontrar una frecuencia de riego que minimice los costos energéticos y optimice el uso del agua. Este sistema se basa en una micro-red conectada a la red, que utiliza generación fotovoltaica. Para llevar a cabo el riego, se emplea un sistema de pivote central del cual se extienden brazos con aspersores que se mueven alrededor de este, abarcando un área circular, lo que permite regar un volumen de agua diferente según los requerimientos de cada cultivo. El volumen de agua requerido para cada cultivo se calcula aproximando su evapotranspiración, mediante predicciones de radiación solar y precipitaciones. Además, se utilizan sensores para medir la

velocidad del viento, la temperatura ambiente y la humedad del suelo. Luego, estableciendo una cota inferior para la evapotranspiración, que indica el punto en el cual las plantas comienzan a marchitarse, se puede calcular el volumen mínimo de agua necesario para asegurar su crecimiento. Los costos de compra y venta de energía, así como la radiación solar y las precipitaciones, se modelan utilizando datos históricos de la zona y perfiles de costos del mercado eléctrico de Iberia, España. El horario de riego se encuentra al minimizar los costos operacionales del sistema según cuanto es el volumen de riego necesario en cada hora, la radiación solar, las precipitaciones y la humedad del suelo, la generación fotovoltaica y el precio de la compra de energía. La principal ventaja de este sistema, es que permite encontrar un horario de riego óptimo con un bajo costo computacional, ya que se realizan predicciones a un solo día, resolviendo el problema de optimización heurísticamente, en lugar de implementar un algoritmo de optimización. Sin embargo, este trabajo no considera la velocidad del viento o la humedad del aire para calcular evapotranspiración de cada cultivo, lo que podría llevar a errores cuando se define la cantidad de agua necesaria de cada uno.

En [17] se muestra un sistema de gestión de agua y energía que busca optimizar el uso de estos recursos cuando se desea regar un cultivo de tomates. El sistema se compone de una micro-red aislada con generación fotovoltaica, bancos de baterías, una bomba de extracción de agua y un tanque de almacenamiento de la misma. Se utilizan distintos relés de control que permiten conectar y desconectar la bomba, los paneles y las baterías entre sí para poder controlar cuanto tiempo estarán en funcionamiento. Para realizar la gestión, se busca cumplir la demanda de agua de los cultivos, minimizar el uso de las baterías y mantener un volumen mínimo de agua dentro del tanque de almacenamiento. Para esto, se aplica un control basado en reglas difusas que decidirá la activación de cada uno de los relés, según la energía entregada por los paneles, la energía almacenada por las baterías, el volumen de agua disponible y la frecuencia de riego que necesitan los cultivos. Además, se utilizan datos meteorológicos de la zona para aproximar la energía generada por los paneles solares y para calcular la evapotranspiración real del cultivo de tomates, lo que permitirá conocer la cantidad de agua necesaria que asegure su desarrollo. La principal ventaja de este trabajo es que se puede comprender mejor el funcionamiento del controlador, ya que se utilizan reglas cercanas al lenguaje natural. Por otro lado, las principales desventajas de este trabajo son que solo se considera el comportamiento climático actual para obtener la acción de control, sin tomar en cuenta los posibles cambios futuros, a diferencia de otros esquemas de control. Además, en situaciones donde se genere mucha energía y los bancos de baterías en conjunto a los tanques de almacenamiento estén a su máxima capacidad, el exceso de energía se perderá, al no contar con otro método de almacenamiento o una conexión a la red.

En [18] se considera una micro-red, donde se propone utilizar el agua almacenada en estanques como sistemas de almacenamiento de energía, al mover el agua a un estanque abierto en altura, para luego usar turbinas que generen electricidad cuando se mueve el agua a un estanque mas bajo, remplazando los bancos de baterías convencionales. Esta micro-red debe satisfacer una demanda eléctrica mientras administra el horario de riego de un tipo de cultivo, considerando paneles solares, turbinas de generación y conexión a la red para la obtención de energía. Para realizar la gestión de recursos se considera un sistema de control predictivo de dos etapas, que posee distintos tiempos de muestreo: La primera etapa utiliza un tiempo de muestreo de 3 días, donde define que día es mas conveniente regar, según las condiciones climáticas que habrá, como las precipitaciones, temperatura o radiación solar, y cuál debe

ser la mínima cantidad de agua dentro del estanque de almacenamiento que permita obtener la energía suficiente a través de las turbinas para los días próximos. La segunda etapa considera un tiempo de muestreo de una hora, y se encarga de definir cuando utilizar la turbina y bombas de extracción de agua, con tal que se minimicen los costos de operación y se cumpla la demanda energética y de riego. Para definir el comportamiento futuro de la demanda eléctrica, generación fotovoltaica y las condiciones climáticas, se utilizan redes neuronales recurrentes, entrenadas con datos históricos de la zona. Como se aplica un control predictivo, la función de costos no lineal se minimiza utilizando algoritmos genéticos (GA) para obtener la trayectoria óptima y así encontrar la acción de control a aplicar. Para probar el desempeño del sistema se creó un ambiente de prueba empírico y se realizaron simulaciones para analizar el comportamiento a largo plazo, concluyendo que utilizar este nuevo sistema de almacenamiento de energía, en conjunto a considerar el agua y la energía como procesos interconectados, resulta en acciones de control más eficientes y en costos de operación más bajos. Las principales ventajas de este trabajo es que aborda el nexo agua-energía-alimento al considerar el agua como fuente de consumo y generación, además de optimizar el riego para alcanzar la cota hídrica requerida, además, al utilizar redes neuronales para aproximar la potencia solar, demanda y condiciones climáticas, se obtienen predicciones que pueden representar mejor su dinámica al compararse a ecuaciones fenomenológicas. Sin embargo, este trabajo no considera los posibles errores en los modelos de predicción dadas las incertezas presentes en estas variables, lo que empeoraría el comportamiento del control predictivo, además, las funciones de costos definidas solo minimizan los costos operacionales, sin abordar en el problema de ahorro en la cantidad de agua extraída por las bombas o utilizada para el riego.

En [19] se explica un esquema jerárquico de control predictivo basado en modelos que optimiza el uso de agua y energía en el regadío de cultivos a campo abierto dentro de una comunidad al sur de Chile. Esta cuenta con paneles solares en conjunto a bancos de baterías para abastecer de energía eléctrica y acceso a acuíferos para obtener agua destinada al regadío. El esquema de control considera un *Energy-Management System* (EMS) en conjunto a un *Water-Management System* (WMS) los cuales trabajan a corto (horizonte de 48 hrs) y mediano plazo (horizonte de 28 días) respectivamente. El propósito del WMS es calcular la cantidad de agua que necesitarán los cultivos cada día, tomando en consideración el cálculo de la evapotranspiración de los cultivos en cuestión y la cantidad de agua disponible para extraer de los acuíferos. Por otro lado, el EMS recibe la cantidad de agua calculada por el WMS y, considerando la energía disponible en la micro-red, define la frecuencia de riego que satisfaga esta cota. Tanto el EMS como el WMS aplican un control predictivo basado en modelos, el cual utiliza modelos identificados autorregresivos para conocer el comportamiento de las variables meteorológicas y ecuaciones dinámicas simplificadas para caracterizar el recurso hídrico. Los principales aportes de este trabajo se encuentran en separar el controlador en dos escalas de tiempo distintas, ya que los cultivos presentan una dinámica más lenta, mientras que la parte eléctrica actúa más rápido. Por otro lado, este trabajo no considera aplicar modelos de predicción no lineales para representar el comportamiento futuro de las variables utilizadas, además, las simplificaciones realizadas en la dinámica del recurso hídrico pueden presentar diferencias importantes en una aplicación real, por lo que es necesario un diseño más preciso para apegarse más a la realidad.

En [20] se muestra un sistema de gestión de agua y energía para un invernadero en una comunidad rural. El sistema cuenta con una micro-red aislada con generación fotovoltaica

y un banco de baterías, un estanque para almacenar agua y una bomba que extrae agua desde una vertiente hasta el estanque. El sistema de gestión cuenta con 3 controladores: el controlador de las ventanas del invernadero, el sistema de gestión de agua WMS y el sistema de gestión de energía EMS. El controlador de las ventanas busca mantener el microclima del invernadero dentro dos bandas: un límite de seguridad y otro de operación, a través de un controlador predictivo con optimización difusa, que utiliza ecuaciones fenomenológicas para definir la relación entre el flujo de aire que proviene de abrir la ventana, y la temperatura y humedad dentro del invernadero. Por otro lado, el sistema de gestión de agua define la cantidad de agua que se debe regar diariamente para maximizar el rendimiento de los cultivos utilizando un control predictivo a 28 días. Este control predictivo, que considera redes neuronales tipo perceptrón multicapa para modelar la radiación, temperatura y velocidad del viento, predice la evapotranspiración futura para calcular la demanda de agua necesaria. Luego, el sistema de gestión de energía recibe la demanda de agua diaria y define un horario de riego que cumpla con esta demanda, minimizando el uso de la energía al controlar la activación de la bomba de extracción, mediante un controlador predictivo con un horizonte de 2 días. Las principales ventajas de este esquema de control se encuentran en separar el problema completo en distintos controladores, cada uno con su propio tiempo de muestreo y método de resolución, lo que permite simplificar el desarrollo de cada uno. Además, al utilizar una optimización difusa para el control de ventanas se pueden considerar restricciones suaves para las bandas definidas, lo que permite encontrar soluciones que, para una optimización convencional, no se hubieran considerado factibles. Sin embargo, las desventajas de este trabajo se observan en que no se considera el vertimiento que puede presentar la micro-red, por lo que la energía sobrante en algún instante se perdería.

Los trabajos expuestos anteriormente coinciden en la necesidad de no solo medir las variables que influyen en el sistema que se considera, sino que conocer su comportamiento futuro para obtener más información de la disponibilidad de cada recurso en cuestión. A su vez, se puede notar que entre más preciso es la predicción aplicada, el controlador entregará acciones más acorde a la situación real estudiada, lo que se vuelve fundamental si se desea aplicar uno de estos trabajos. Así, es importante estudiar distintas técnicas de modelamiento, analizando sus ventajas y desventajas referentes a precisión, esfuerzo computacional, factibilidad, caracterización de incertezas, entre otras, lo que se observa a continuación.

2.2. Modelación e intervalos de predicción

Existen distintos métodos de modelación que utilizan datos reales de entrada-salida para construir un arreglo de parámetros que logre captar la dinámica no lineal del proceso a identificar. Ejemplos de estos métodos son los modelos difusos Takagi-Sugeno y las redes neuronales, las cuales se consideran aproximadores universales, capaces de caracterizar un gran número de sistemas [21, 22]. Para este tipo de modelos es muy importante contar con una gran cantidad de datos históricos con los cuales realizar el entrenamiento, ya que los datos deben representar la mayor cantidad de puntos de operación posible de una planta, para así reproducir su dinámica bajo cualquier acción de control. Adicionalmente, la cantidad de datos dependerá de que tan a futuro se desean realizar las predicciones. El desempeño de estos modelos puede estudiarse al calcular distintas métricas de desempeño, por ejemplo el error cuadrático medio (RMSE), error absoluto medio (MAE) o el error absoluto medio porcentual (MAPE), los que indican que tan cercana es la predicción obtenida a los valores reales.

Los modelos descritos anteriormente se enfocan en predecir el comportamiento de algún sistema, sin considerar estocasticidad del mismo, así esta modelación evitaría que un modelo alcance un desempeño aceptable, debido a la naturaleza del mismo sistema. Por consiguiente, es conveniente construir intervalos de predicción, capaces de caracterizar las incertezas presentes de algún proceso, lo que permite contar con más información sobre el mismo [23]. Estos intervalos se componen por una banda inferior y superior, las que contienen un valor futuro desconocido, con cierto porcentaje de confianza [24]. Existen muchos métodos para generar estos intervalos, cuyo desempeño se suele cuantificar a través de su porcentaje de cobertura (PICP) y su porcentaje de ancho promedio (PINAW), donde se busca que el PICP se encuentre sobre a cierto valor predefinido (por ejemplo 90 %) para asegurar que el intervalo cubra la mayor cantidad de datos, mientras se minimiza el valor del PINAW para que este intervalo sea lo más acotado posible. Un intervalo de predicción, en conjunto a la predicción del valor esperado se observa en la figura 2.2.




Figura 2.2: Valor esperado e intervalo de predicción para un conjunto de datos y

De la figura 2.2 se observa que el intervalo de predicción obtenido logra envolver a los datos reales, aun cuando el valor esperado no logra predecir precisamente su dinámica.

Una aplicación de los intervalos mencionados anteriormente se observa en [25], donde se utilizan intervalos de predicción basados en modelos neuronales para predecir la temperatura ambiente de una localidad del País Vasco, y estimar la temperatura de celdas, potencia de salida y voltaje en circuito abierto de los paneles solares de la zona. Se utilizan datos históricos de temperatura para entrenar una red neuronal de tipo *feed-forward* y se realiza un análisis estadístico de la influencia de cada parámetro de la red con respecto a su salida en conjunto al error del modelo para crear los intervalos de predicción. De esta forma, se pueden calcular los intervalos para las variables que influyen en la generación solar y, utilizando las bandas superiores e inferiores de cada una, se puede aproximar la generación máxima y mínima que

tendrá el arreglo de paneles fotovoltaicos. Este modelo de intervalos presenta la ventaja de calcularse a partir del análisis de los datos utilizados, presentando un bajo costo computacional, sin embargo, el análisis estadístico toma varios supuestos sobre la distribución del error, como que este es gaussiano de media cero, independiente del error en los parámetros de la red, o que el ancho del intervalo presenta una distribución de tipo *T-student*, cuya validez dependerá de los datos utilizados.

En [26] se utilizan intervalos de predicción para modelar las incertezas de la escorrentía directa de dos cuencas en los Estados Unidos e Irán. Para construir los intervalos se utiliza el método de *lower-upper bound estimation* (LUBE) el cual consiste en una red neuronal tipo *feed-forward* con dos neuronas en la capa de salida correspondientes a los intervalos superior e inferior, luego, con cada dato del conjunto de entrenamiento se entrena la red minimizando una función de costos que dependa del porcentaje de cobertura y el ancho del intervalo, con el fin de maximizar el primero y minimizar el segundo. Así, por cada dato que entre en la red neuronal, se obtendrá directamente el intervalo del set utilizado. Usando datos históricos de escorrentía y precipitaciones provenientes de estaciones meteorológicas, se logra caracterizar las incertezas de la escorrentía en una escala de tiempo diaria y mensual. Este método se compara otro tipo de intervalos basados en redes neuronales (*Bootstrap*) mostrando que al aplicar el método LUBE, se alcanza un PICP mayor o igual, en conjunto a un PINAW más bajo, concluyendo que el último presenta un mejor desempeño. El método LUBE presenta la ventaja de calcular directamente el intervalo de predicción a partir de los datos, lo que requiere un esfuerzo computacional menor a otros métodos. Sin embargo, este algoritmo no considera una forma de generar una predicción del valor esperado, por lo que se requeriría de un modelo aparte que complemente el intervalo generado.

En [27], los autores generan predicciones e intervalos sobre el consumo de una micro-red presente en Huatacondo, Chile. Se utiliza un intervalo basado en un modelo lineal con números difusos, en conjunto a un modelo de predicción Takagi-Sugeno para construir los intervalos de predicción y el valor esperado del consumo. Los parámetros de estos métodos se encuentran al resolver un problema de optimización propuesto, que minimiza el ancho del intervalo, su porcentaje de cobertura y el error de salida del modelo al mismo tiempo. De esta forma consigue alcanzar el porcentaje de cobertura deseado junto a un ancho y error de predicción mínimo. Para resolver el problema de optimización, se propone el algoritmo de optimización *Improved Teaching Learning Based Algorithm* (ITLBO) y se compara su desempeño con el algoritmo *Particle swarm optimization* (PSO). Este método destaca en su capacidad de obtener los parámetros del modelo difuso y los del intervalo de predicción al mismo tiempo, lo que ahorraría esfuerzo computacional, además, el algoritmo de optimización propuesto ITLBO resulta en un tiempo de ejecución menor que PSO. Aun así, este método para encontrar los parámetros del modelo e intervalo no se compara con un método secuencial, donde primero se entrena un modelo y a partir de este se construya un intervalo, por lo que no se puede concluir que el método propuesto entregue mejores resultados.

El principal objetivo de modelar tanto la dinámica como las incertezas de distintas variables es el poder utilizar esta información al implementar un controlador en un sistema que se vea afectado por estas incertezas. Así, no solo se considera el comportamiento actual, sino que la dinámica futura se requiere para tomar decisiones acordes a como el sistema responderá a algún estímulo. Un esquema de control que utiliza predicciones para decidir la acción a

ejecutar es el control predictivo robusto, que se muestra a continuación.

2.3. Control predictivo robusto

El control predictivo basado en modelos (MPC) es un esquema de control óptimo que utiliza un modelo interno para generar predicciones del sistema y tomar decisiones según como se espera que este se comporte. Se calculan acciones de control futuras, aplicando la más inmediata para luego volver a realizar el procedimiento con la siguiente muestra [28]. Por ejemplo, la figura 2.3 muestra una representación del control predictivo basado en modelos.

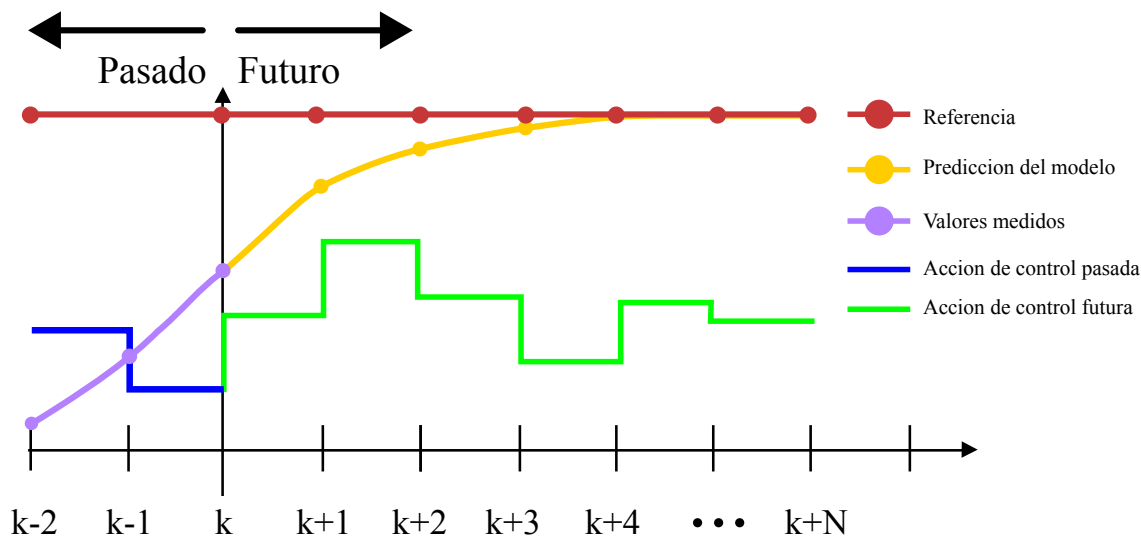


Figura 2.3: Ejemplo de control predictivo.

Para calcular las acciones de control óptimas, el MPC resuelve un problema de optimización del cual se deben definir distintos costos y restricciones, en particular, los costos pueden ser minimizar el error de seguimiento de cierta señal [29], reducir los costos de operación de un sistema [30], etc.

En [31] se describe un sistema de gestión de energía basado en MPC, donde se tiene una micro-red aislada compuesta por generación fotovoltaica, generación eólica, micro-turbinas, motores Diesel y bancos de baterías, la cual debe satisfacer cierta demanda energética predefinida. En este caso se debe decidir la cantidad de energía que entregaran las fuentes controlables (micro-turbina, motor Diesel y banco de baterías) dependiendo de la energía que generen las fuentes renovables no controlables (energía fotovoltaica y eólica) por lo que se aplica un MPC que minimizará el costo de utilizar el motor y la micro-turbina, considerando que siempre se debe cumplir la demanda energética. Para modelar el comportamiento de las fuentes no controladas y de la demanda se utilizaron datos históricos de la Red Eléctrica de España, donde cada dato fue mezclado con su valor correspondiente al año anterior para así obtener un valor distinto al real que se pueda usar como una predicción con cierto error. Al cuantificar los costos de operación de la micro-red, al aplicar el MPC se observa una reducción de hasta el 10% en comparación a otros métodos de gestión, mostrando la efectividad de aplicar un controlador predictivo. Las principales ventajas de este trabajo son la posibilidad de reducción en los costos de operación al utilizar un MPC para la gestión de

energía en la micro-red. Por otro lado, no se ahonda en el diseño de los modelos de predicción ni se considera aplicar intervalos para predecir los posibles errores, por lo que combinar este trabajo con alguna de las metodologías de modelamiento explicadas anteriormente debería entregar mejores resultados.

En [32] se utiliza un MPC para operar una micro-red de una granja de algodón, con el fin de usar eficientemente los recursos renovables disponibles, y minimizar los costos asociados a bombas de extracción de agua. La micro-red debe satisfacer una demanda de riego para los cultivos de algodón, contando con un tanque de almacenamiento de agua, bombas de extracción que mueven agua de pozos hacia el estanque y distintas fuentes de generación, como generación fotovoltaica, generadores diesel, bancos de baterías y una conexión a la red. El objetivo del MPC es coordinar el uso de todas las bombas de extracción para llenar el tanque de almacenamiento mientras se minimiza el costo de la energía utilizada, para esto, el control considera restricciones sobre un volumen mínimo y máximo de agua almacenada para asegurar el riego de los cultivos, una carga mínima y máxima de los bancos de baterías para alargar su vida útil, y mantener el balance entre energía generada y consumida en la micro-red. Los valores futuros de las fuentes de generación y la potencia utilizada por las bombas se considera conocido, siendo representados por sus datos históricos. Para probar el sistema se simulan dos escenarios: Una micro-red aislada y una conectada a la red, pero sin bancos de baterías. Además, se introducen dos perturbaciones al sistema, siendo estas las precipitaciones, que aumentan el agua disponible y disminuyen la demanda de riego, y la evaporación, que realiza el efecto contrario. El uso del MPC en la gestión de las bombas presenta una reducción de los costos de un 33% frente a una gestión manual, considerando las perturbaciones introducidas, mostrando que el MPC además es robusto frente a estas. Las principales ventajas de este trabajo son tratar la gestión de agua y energía como un conjunto dentro del MPC, lo que permite encontrar una solución óptima cumpliendo con todos los requerimientos del sistema, además, al estudiar escenarios con o sin conexión a la red, se pueden analizar el desempeño del controlador en casos que haya intermitencias en la micro-red y esta se deba desconectar. Por otro lado, las desventajas se encuentran en que no se emplea ningún modelo de predicción para aproximar el comportamiento de los componentes de la micro-red, por lo que el sistema diseñado no podría implementarse empíricamente, al no contar con un método para estimar los valores futuros. También, dentro de las perturbaciones no se consideran la incerteza presente en la generación fotovoltaica debido a la radiación solar, lo que podría afectar considerablemente a la aproximación de la energía disponible en la micro-red.

Las formulaciones de los sistemas de control anteriores no incluyen intervalos de predicción para modelar las incertezas en las variables predichas, lo que aportaría más información sobre el comportamiento de estas y permitiría definir acciones de control que actúen escenarios con incerteza. Esta estrategia se explora a continuación.

Cuando un sistema que se desea controlar presenta perturbaciones externas no modeladas de cualquier tipo, puede que un MPC presente problemas al aplicarse, ya que estas perturbaciones conllevarán a errores en las predicciones del modelo interno del MPC, lo que puede evitar que se cumplan las restricciones impuestas inicialmente. Lo anterior es particularmente importante cuando las restricciones definidas corresponden a cumplir condiciones de seguridad como rangos de movimiento o satisfacer completamente cierta demanda eléctrica, por

ejemplo. Debido a lo anterior, es posible modificar el MPC convencional para considerar la incertidumbre de algunas variables o ruido no medible en la planta dentro de la formulación de las restricciones y/o los costos del problema de optimización. Así, se puede asegurar con cierto grado de confianza que el control predictivo se mantendrá factible frente de las incertezas mencionadas anteriormente [33], de esta manera, surge el MPC robusto.

Un ejemplo de MPC robusto se encuentra en [34], donde se tiene una micro-red aislada cuya generación se conforma de energía solar, eólica y un banco de baterías que almacena la energía sobrante. Esta micro-red debe alimentar el consumo conectado a ella, lo que incluye dos desalinizadores de agua de mar. Se utiliza un control predictivo robusto de dos etapas para coordinar el uso de energía de esta micro-red. La primera etapa corresponde a utilizar ecuaciones fenomenológicas, en conjunto a la incerteza histórica presente en la generación solar y eólica, para administrar la cantidad de energía que se almacenará en las baterías, la cantidad de energía que se utilizará para las plantas desalinizadoras y cuanto tiempo se activará el generador Diesel, minimizando los costos de operación asociados a cada componente. La segunda etapa se ejecuta cuando ya se encuentran disponibles las mediciones de generación eólica y solar, donde se busca compensar los errores del modelo fenomenológico con el dato real de la etapa anterior, para que la micro-red opere de manera óptima, minimizando los mismos costos. Para modelar la incertidumbre de la generación solar y eólica se calcula el error de predicción entre la ecuación fenomenológica y datos reales históricos, utilizando el error más alto del total de muestras como el ancho de las bandas de cada intervalo y así considerar estas bandas como el peor caso de cada variable. Aplicar un control robusto, en este caso permite conocer la energía mínima presente en la micro-red en todo momento y como el controlador actúa basándonos en el peor caso, se asegura con cierta confianza que se contará con la energía necesaria para aplicar las acciones de control. Por otro lado, el método utilizado para construir los intervalos de predicción no cuenta con ningún parámetro de ajuste, por lo que si la peor medición histórica se aleja considerablemente del promedio de los datos, el intervalo resultará más ancho en comparación a otros métodos.

En [35] se diseña un control jerárquico basado en MPC robusto para gestionar el uso de energía dentro de una micro-red, minimizando sus costos de operación. La micro-red en cuestión cuenta con generación solar y bancos de baterías, además de la posibilidad de comprar energía a la red, bajo la condición de que no se puede vender a esta, además, esta micro-red debe satisfacer una demanda eléctrica residencial, considerada como una carga no controlable. Para realizar la gestión de energía se diseña un sistema de control jerárquico de dos niveles: El nivel superior se basa en un control MPC robusto que calcula la potencia de referencia que debe seguir la micro-red, que minimice los costos operacionales según el precio de compra de energía y la energía en la micro-red a futuro. Para predecir la energía disponible en la micro-red se utiliza un modelo Takagi-Sugeno que estime esta variable, en conjunta, a un intervalo de predicción, para caracterizar todas las incertezas presentes en el sistema y utilizarlos como el peor caso en el problema de optimización, además, los precios de compra de energía futuros se consideran conocidos en todo momento. El nivel inferior del control jerárquico se compone de un control basado en reglas, que manipula la carga y descarga del banco de baterías para que la potencia de la micro-red pueda seguir la referencia impuesta por el nivel superior. La base de reglas impone que, si la micro-red presenta una potencia sobre la potencia de referencia, las baterías deben cargarse para absorber la energía sobrante y en caso contrario, descargarse para compensar el déficit, esto manteniendo su potencia

de carga/descarga y estado de carga dentro de límites predefinidos. Los resultados de este trabajo muestran que, a pesar de que un sistema de gestión convencional (sin considerar las incertezas del sistema) logra operar eficientemente la micro-red, el sistema de gestión basado en MPC robusto alcanza menores costos operacionales, una respuesta más constante para la energía comprada a la red y una mejor capacidad para satisfacer la demanda. Las principales ventajas de este trabajo se encuentran en el uso de modelos e intervalos de predicción basados en datos históricos, los que permiten obtener predicciones más certeras en comparación a modelos que no cuenten con todas las no linealidades presentes. Además, al considerar las bandas del intervalo de predicción como el peor caso, permite que la función objetivo a minimizar sea lineal, lo que asegura que se pueda encontrar una acción de control asociada al mínimo global de esta. Sin embargo, la principal desventaja de este trabajo se observa en el control de nivel inferior, dado que, como no es posible la venta de energía a la red, en casos donde exista un excedente y los bancos de baterías estén a su máxima capacidad, la energía sobrante se perdería.

En general, los sistemas de control basados en MPC muestran un mejor desempeño en sistemas de gestión de energía que otros métodos más simples, donde se destaca la importancia de utilizar predicciones que describan la dinámica futura de las variables modeladas. Por esto, una buena opción es aplicar el MPC utilizando los modelos de identificación e intervalos descritos en la sección 2.2, como los modelos difusos, redes neuronales, para asegurar que las predicciones modelen la dinámica no lineal e incertezas del proceso.

2.4. Discusión

Según la investigación bibliográfica realizada, se puede notar que los sistemas de gestión agua-energía se centran en calcular la demanda de agua para los cultivos solo considerando la evapotranspiración, dejando de lado variables como la humedad o la dinámica de extracción de agua, las que influyen en este cálculo. Además, solo en dos de los trabajos estudiados se separan el sistema de control para el agua y la energía, lo que tomando en consideración que los procesos físicos de estos dos recursos presentan constantes de tiempo diferentes, da como resultado controladores más especializados que deberían entregar mejores resultados. Por otro lado, la mayoría de los sistemas de gestión revisados no consideran en el uso de modelos de predicción o consideran una ventana de tiempo pequeña en comparación al desarrollo de cultivos, lo que, aplicando algunos de los métodos de modelación de intervalos descritos (como redes neuronales o modelos difusos) permitiría conocer su dinámica e incertezas en una ventana de tiempo más amplia, con un desempeño mejor en términos de error de predicción, porcentaje de cobertura y ancho del intervalo.

Además, de la revisión se observa que aplicar un control predictivo conlleva en un mejor desempeño como sistema de gestión de agua y energía, con la ventaja de poder minimizar costos de operación. Más aún, si se cuentan con intervalos de predicción, se puede implementar un control robusto, lo que resulta más conveniente al poder definir los peores casos y tomar decisiones acordes a estos escenarios.

Luego de analizar el estado de cada tema en que se basa esta tesis, en la sección 3 se muestran los algoritmos más importantes para el desarrollo esta tesis, para luego en la sección

4, exponer el modelamiento de cada componente del sistema, en conjunto al diseño del sistema de gestión robusto de agua y energía.

3. Marco teórico

En este capítulo se detallan los conceptos principales que se utilizan en esta tesis, referentes a conceptos hidrogeológicos, modelación de sistemas e intervalos de predicción, con el fin de definir la relación de cada variable que afecta al sistema, y como estas pueden manipularse para un próximo uso dentro del sistema de gestión a diseñar.

3.1. Conceptos hidrogeológicos

A continuación, se describen distintos conceptos relacionados con la hidrogeología como la división en cuencas del terreno, la definición de acuíferos subterráneos, los ensayos de bombeo utilizados para aproximar parámetros importantes de los acuíferos, con el fin de caracterizar el recurso hídrico de una zona.

3.1.1. Definición de cuencas

Para estudiar los recursos hídricos, se suele dividir el territorio en distintas cuencas hidrográficas, las cuales se definen como las áreas donde el agua, escurre y converge hacia una misma salida, delimitadas por montañas o terrenos elevados [36]. Esta división permite trabajar con parámetros a escalas más pequeñas, pudiendo definir más específicamente como es su aporte a la cantidad de agua acumulada en cada cuenca. En la figura 3.1 se observa el área de estudio de esta tesis, correspondiente a la región de la Araucanía, Chile, dividida en distintas cuencas y sub-cuencas (destacadas en colores).

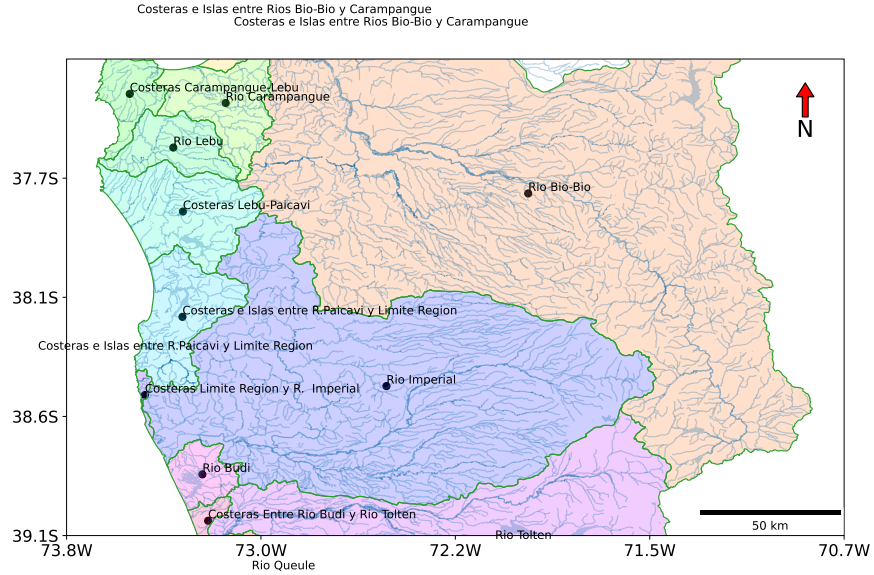


Figura 3.1: Región de la Araucanía dividida en cuencas y sub-cuencas

3.1.2. Definición y propiedades de los acuíferos

Dentro de cada cuenca, el agua se puede acumular tanto en la superficie, en ríos o lagos, como en el subsuelo, en acuíferos. Se conoce como acuífero a una unidad geológica de alta permeabilidad, capaz de transmitir y almacenar agua. El nivel de agua de estos acuíferos se conoce como nivel freático, que divide el subsuelo en una zona saturada (debajo del nivel freático) y una zona insaturada (sobre el nivel freático), denotado por un triángulo invertido, como se observa en la figura 3.2:




Figura 3.2: Esquema de un acuífero libre.

Además, los acuíferos pueden dividirse en dos categorías [37]:

- Acuíferos libres: Son los acuíferos cuyo nivel freático se encuentra en el límite de la zona

saturada. Estos acuíferos presentan una vía directa a la superficie, por lo que la presión sobre el nivel freático será la presión atmosférica.

- **Acuíferos confinados:** Son los acuíferos que se encuentran atrapados bajo presión entre dos capas impermeables, por lo que al penetrar en estos el nivel freático se elevará por sobre la zona saturada, hasta que la presión interna del acuífero iguale la presión atmosférica.

Una representación de ambos tipos de acuíferos se observa en la figura 3.3.




Figura 3.3: Tipos de acuíferos.

Al extraer agua de un pozo, la altura de bombeo aumenta a medida que disminuye el nivel de agua dentro del mismo, causando que el agua que se encuentra en el acuífero fluya hacia el pozo dada esta diferencia de presión, así, se pueden definir dos características importantes asociadas al funcionamiento de los acuíferos: la Transmisividad (T) y el Almacenamiento (S) [38].

La Transmisividad describe la facilidad con la que el agua se puede mover a través del acuífero, siendo el flujo de agua a través de un ancho unitario, bajo una unidad de gradiente hidráulico (potencial hidráulico entre dos puntos, por cada unidad de distancia). Se mide en $[\frac{m^2}{día}]$.

Por otro lado, el Almacenamiento es la capacidad de un acuífero de almacenar agua, siendo el volumen de agua que libera un acuífero por unidad de área, por unidad de cambio en la altura del agua (adimensional).

Ambos parámetros se determinan de forma experimental, realizándose ensayos de bombeo en un pozo y aplicando distintos métodos para lograr aproximar su valor. Esto se explica a continuación.

3.1.3. Ensayos de bombeo y sus aplicaciones

En ensayos de bombeo, se bombean grandes volúmenes de agua desde un pozo por un determinado periodo de tiempo, midiendo los cambios en la altura del agua en este pozo y/o en un pozo de observación cercano, bombeando desde varias horas hasta días [39]. El esquema de un ensayo de bombeo se encuentra en la figura 3.4.

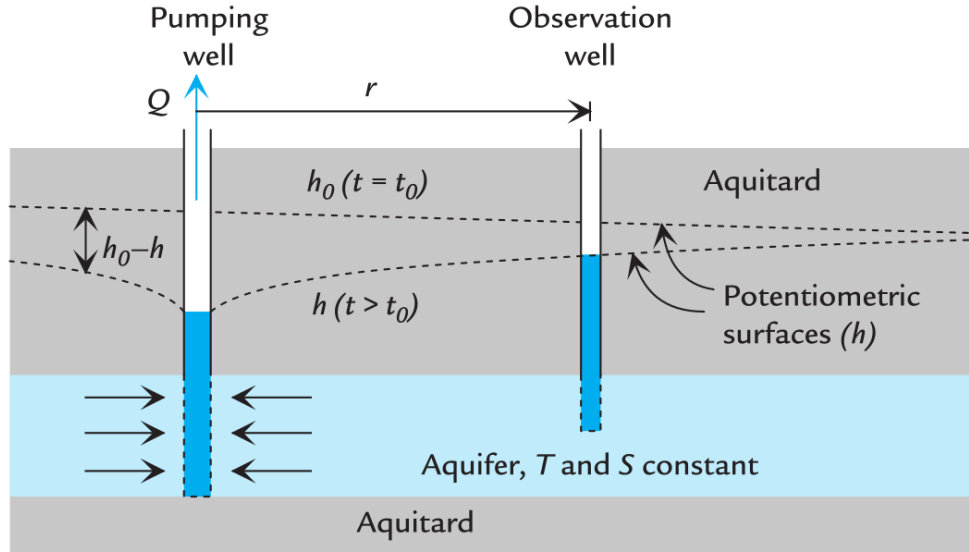


Figura 3.4: Esquema de un ensayo de bombeo [39]

En la figura 3.4 se observa el pozo de bombeo, con un caudal de extracción Q , lo que genera un descenso en el pozo de observación (de una altura h_0 hasta una altura h) a una distancia r , del cual se obtienen las mediciones.

A partir de estos ensayos es posible utilizar los datos medidos del descenso, en conjunto a distintas ecuaciones y métodos, para aproximar los valores de la Transmisividad (T) y del Almacenamiento (S). Por ejemplo, para acuíferos confinados, se puede aplicar la ecuación de Theis [40] o el método Cooper-Jacob [41], o para acuíferos libres el método de Boulton [42] o el método de Neuman [43], entre otros. En esta tesis se detallan solamente métodos asociados a acuíferos confinados, según se explica en la sección 4.

La ecuación de Theis describe una relación entre el descenso en la altura del agua de un pozo y los parámetros T y S del acuífero donde se encuentra, la que se observa en la ecuación (3.1):

$$h_0 - h = s = \frac{Q}{4\pi T} W(u) \quad (3.1)$$

$$u = \frac{R^2 S}{4Tt} \quad (3.2)$$

Aquí h_0 es la altura inicial del agua, h la altura pasado un tiempo t , s es el descenso en la altura del agua, Q el caudal de extracción y R es el radio del pozo. $W(u)$ es la función del pozo, que se calcula como:

$$W(u) = \int_u^\infty \frac{e^{-y}}{y} dy = -0.577216 - \ln(u) + \sum_{i=1}^{\infty} (-1)^{i+1} \frac{u^i}{i!i} \quad (3.3)$$

A partir de esta ecuación, para encontrar T y S se realiza el siguiente procedimiento:

1. Graficar la función del pozo $W(u)$ versus $\frac{1}{u}$ en escala logarítmica.

2. Se selecciona un punto de esta curva, anotando su valor de u y $W(u)$
3. Superponer la curva de descenso del ensayo de bombeo en escala logarítmica sobre el gráfico de $W(u)$ haciendo calzar lo mejor posible los puntos de descenso sobre la curva.
4. Se marca el punto de descenso que más se acerque al punto marcado en la curva $W(u)$ anteriormente, anotando los valores de descenso s y tiempo t . Un ejemplo de esto se observa en la figura 3.5.
5. Se utilizan todos los valores anotados en la ecuación (3.1) para despejar T y S .

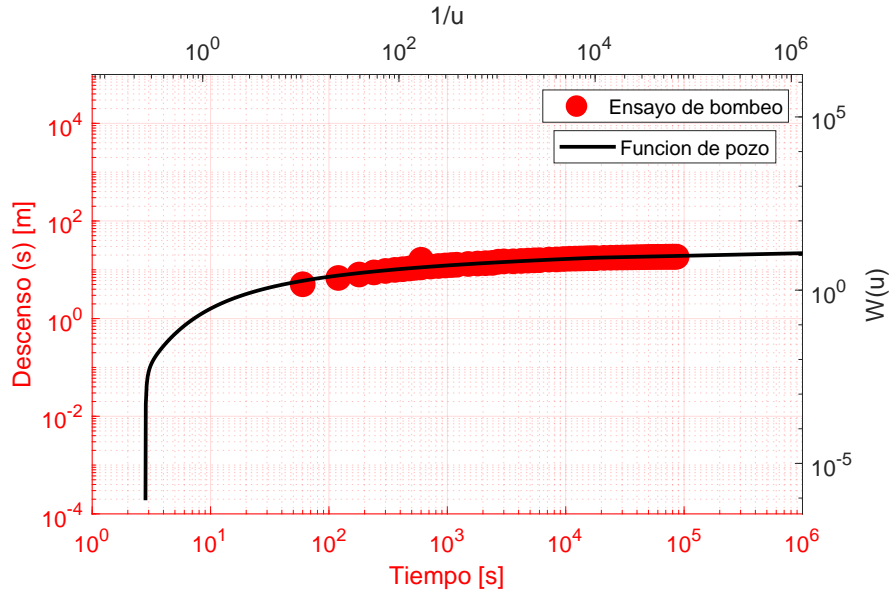


Figura 3.5: Descensos medidos sobre la curva del pozo

De la ecuación (3.3) se puede notar que si los valores que toma u son lo suficientemente pequeños (del orden de 10^{-2}), según Cooper y Jacob [41], los términos de la sumatoria pueden despreciarse para simplificar el cálculo de la función del pozo, así, el descenso en la altura del agua puede calcularse como:

$$s = \frac{Q}{4\pi T}(-0.577216 - \ln(u)) = \frac{2.3Q}{4\pi T} \log\left(\frac{2.25Tt}{R^2S}\right) \quad (3.4)$$

A partir de esta ecuación, el método para aproximar los valores de T y S es el siguiente:

1. Graficar el descenso medido durante el ensayo de bombeo en escala semilogarítmica (sobre el eje x).
2. Realizar una regresión lineal a los datos.
3. Seleccionar dos puntos (t_1, s_1 y t_2, s_2) dentro del ajuste, tales que la diferencia en tiempo entre estos cubra un ciclo logarítmico completo, denotando $\Delta s = s_2 - s_1$.
4. Calcular la Transmisividad como:

$$T = \frac{2.3Q}{4\pi\Delta s} \quad (3.5)$$

5. Extender la recta correspondiente a la regresión lineal hasta alcanzar el punto ($s = 0$, t_0).
6. Calcular el Almacenamiento como:

$$S = \frac{2.25Tt_0}{R^2} \quad (3.6)$$

Un ejemplo de este método se observa en la figura 3.6.




Figura 3.6: Ejemplo del método de Cooper-Jacob para aproximar los parámetros de un acuífero

De la figura 3.6, se observa la regresión lineal obtenida a partir de graficar los datos de descenso en escala semilogarítmica. Luego, seleccionando el rango entre los 10³ y 10⁴ [s], se obtiene un $\Delta s = 2.2$. Extendiendo la recta hasta alcanzar el $s = 0$, se obtiene un $t_0 = 0.001$. Finalmente, aplicando las ecuaciones (3.5) y (3.6), se obtienen $T = 159$ [$m^2/día$] y $S = 4.3 \cdot 10^{-4}$.

Tanto la ecuación de Theis como el método de Cooper-Jacob asumen que los datos de descenso se obtienen de un acuífero confinado, por lo que para poder aplicar estas ecuaciones y calcular los parámetros para un acuífero libre, se deben transformar los datos de referencia según la ecuación (3.7) [43]:

$$s' = s - \frac{s^2}{2b} \quad (3.7)$$

Donde s es el descenso observado en el acuífero libre, s' el descenso en el acuífero confinado equivalente y b el espesor del acuífero. Así, luego de transformar los datos de descenso, se pueden aplicar los métodos anteriores sobre s' y calcular T y S .

Luego de calcular los parámetros de un acuífero, es posible aplicar la ecuación 3.1 para conocer cuánto será el descenso en el nivel de agua de un pozo al extraer un caudal conocido bajo un tiempo determinado. Dado que pueden existir múltiples pozos en el área de estudio, es necesario analizar la influencia de cada uno en el nivel de agua del acuífero completo, como se describe a continuación.

3.1.4. Cálculo del cono de descenso en pozos de extracción

Al extraer agua subterránea durante cierto tiempo, se observa un descenso en el nivel piezométrico del acuífero, como se mencionó anteriormente. Este descenso no solo ocurre dentro del pozo, sino que se extiende como un cono a lo largo de todo el acuífero, lo que disminuiría el nivel de agua de un pozo cercano sin siquiera extraer agua del mismo, este fenómeno se conoce como cono de descenso o radio de influencia [44].

A partir de la ecuación (3.1) se puede aproximar cuál será el descenso del nivel de agua a una distancia radial r del pozo donde se extrae, como se observa en la figura 3.7.




Figura 3.7: Descenso en el nivel de un acuífero a una distancia r

Para calcular este descenso se considera que el caudal puede variar mientras se realiza la extracción. Además, en una zona con varios pozos de extracción, más de uno puede estar activo al mismo tiempo, lo que genera un descenso aún mayor en el nivel piezométrico del acuífero donde se encuentran. Entonces, para conocer el descenso bajo estas condiciones, se puede aplicar una superposición temporal [45] y/o espacial [46].

Al encontrarse valores variables para el caudal de extracción se aplica una superposición temporal, lo que permite encontrar el descenso de un pozo al haber extraído con n caudales distintos, cada uno empezando en un tiempo determinado. La ecuación (3.8) muestra el cálculo descrito.

$$s(t) = \frac{1}{4\pi T} \sum_{i=0}^n (Q_i - Q_{i-1}) W(u_i) \quad (3.8)$$

$$u_i = \frac{R^2 S}{4T(t - t_i)}$$

Donde $s(t)$ es el descenso en el tiempo t , t_i el tiempo donde inició la extracción y Q_i el caudal de extracción funcionando desde el instante t_i . Q_{-1} se considera una condición inicial

conocida dentro del problema.

Por otro lado, si se mantiene un caudal de extracción constante, pero se bombea desde N pozos a la vez, el descenso en un punto A será la suma del cono de descenso de cada pozo a la distancia del punto A , como se observa en la ecuación (3.9).

$$s_A(t) = \frac{1}{4\pi T} \sum_{i=1}^N Q_i W(u_{i,A}) \quad (3.9)$$

$$u_{i,A} = \frac{r_{i,A}^2 S}{4Tt}$$

Donde $s_A(t)$ es el descenso en el punto A para un tiempo t , Q_i el caudal de extracción del pozo i y $r_{i,A}$ la distancia del pozo i al punto A .

Luego, aplicando las ecuaciones (3.8) y (3.9) es posible conocer el descenso en el nivel piezométrico de un acuífero para cualquier número de pozos de extracción bajo cualquier caudal.

Después de definir la dinámica al extraer agua de los pozos, es necesario estudiar la influencia de la extracción sobre toda el agua de la cuenca, analizando su relación con cualquier otra fuente que aumente o disminuya la cantidad total de esta, lo que se analiza a continuación.

3.1.5. Balance hídrico en una cuenca

Para relacionar todos los fenómenos que influyen en la dinámica de una cuenca, se puede calcular el balance hídrico, que se basa en el principio de conservación de la materia, donde todo el volumen de agua que ingresa a cierto sistema debe mantenerse constante si se encuentra aislado, lo que permite conocer todos los cambios y movimientos del agua almacenada [37]. En la ecuación (3.10) se observa la relación de estas variables

$$P + Q_{in} + G_{in} = E_s + ET_R + Q_{out} + G_{out} \quad (3.10)$$

Donde P son las precipitaciones, que se refieren al volumen de agua que cae en la superficie por medio de lluvias y se mide en milímetros por unidad de tiempo ([mm/día] por ejemplo). La escorrentía directa (E_s) es todo el flujo de agua proveniente de las precipitaciones que se desliza por la superficie de la tierra y aumenta el caudal de los ríos, cuyo valor irá disminuyendo cuando cesan las lluvias y el flujo desemboque en algún lugar [47].

ET_R es la evapotranspiración real, la cual es un concepto que engloba la evaporación del agua presente en la superficie en conjunto a la transpiración de la vegetación, así, la evapotranspiración será todo el volumen de agua que vuelva a la atmósfera de forma gaseosa [48].

Finalmente, Q_{in} , Q_{out} , G_{in} y G_{out} hacen referencia a todo el volumen de agua no considerado en ninguna de las variables anteriores, que entran o salen del sistema. Específicamente, Q_{in} y Q_{out} son el volumen de agua superficial de entrada y salida respectivamente, y G_{in} y G_{out} el volumen de agua subterránea.

En la figura 3.8 se observa gráficamente la entrada y salida de volumen de agua en una cuenca al considerar precipitaciones, escorrentía, evapotranspiración y un flujo subterráneo.

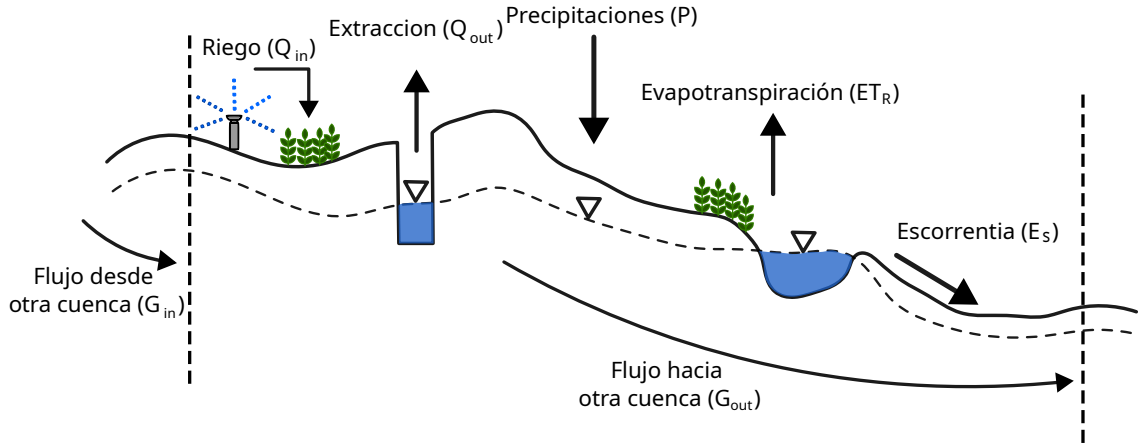


Figura 3.8: Ejemplo de balance hídrico

Para calcular la evapotranspiración real se introduce el concepto de evapotranspiración potencial (ET_p) el cual hace referencia al valor máximo que puede tomar la evapotranspiración, la que se alcanza en condiciones ideales para los cultivos en términos de agua disponible y condiciones climáticas adecuadas, dependiendo de la humedad del suelo (H_s) [48]. Así, la ET_R se calculará según la ecuación (3.11).

$$ET_R(k) = \begin{cases} H_s(k-1) + P(k) + Q_{in}(k) - E_s(k) & \text{si } H_s(k) < ET_p(k) \\ ET_p(k) & \text{si } H_s(k) \geq ET_p(k) \end{cases} \quad (3.11)$$

De esta forma, si la humedad del suelo es menor a la evapotranspiración potencial, la planta utilizará toda el agua actualmente en el suelo, siendo su evapotranspiración real la humedad actual, más toda el agua que entra en esta capa de suelo (P y Q_{in}), menos el agua que escurre sobre la superficie (E_s). Por otro lado, cuando la humedad del suelo supere el valor de la evapotranspiración potencial, entonces el valor real será limitado por esta, ya que la potencial actúa de valor máximo en condiciones ideales. La evapotranspiración potencial puede calcularse a partir de distintas variables climáticas como la humedad del aire, velocidad del viento, entre otras [48], como también obtenerse de alguna estación pluviométrica dentro de una cuenca.

Similar al caso anterior, la escorrentía E_s se puede calcular al estudiar su relación con otra variable medible, el caudal total. Dentro de una cuenca, se define el caudal total (Q_{total}) como el volumen total de agua presente en todos los ríos de la zona, el cual puede aumentar o disminuir según la cantidad de precipitaciones en un determinado periodo de tiempo. Este caudal se puede separar en la escorrentía directa y el flujo base (Q_b), donde el último representa el volumen de agua que siempre se encuentra presente en estos ríos, independiente de si hay precipitaciones, ya que este flujo se alimenta netamente de agua subterránea. Así, el caudal total estará definido por:

$$Q_{total} = Q_b + E_s \quad (3.12)$$

Para separar E_s y Q_b del caudal total se puede aplicar el filtro digital Eckhardt [49], el cual se basa en considerar el flujo base como una señal de baja frecuencia y la esorrentía como una perturbación de alta frecuencia, así, al aplicar un filtro pasa-bajo al caudal total histórico de la cuenca, se puede conocer el valor del flujo base Q_b y, a partir de la ecuación (3.12), la esorrentía directa. Este uso de este filtro se observa en la ecuación (3.13):

$$Q_b(k) = \frac{(1 - BFI_{\text{máx}}) \alpha Q_b(k-1) + (1 - \alpha) BFI_{\text{máx}} Q_{\text{total}}(k)}{1 - \alpha BFI_{\text{máx}}} \quad (3.13)$$

Siendo $BFI_{\text{máx}}$ el índice máximo del flujo base y α la constante de recesión, cuyos valores se pueden aproximar utilizando datos históricos del caudal total obtenidos de estaciones pluviométricas, según [50] y [51], respectivamente. Luego, el valor de E_s se obtiene aplicando las ecuaciones (3.12) y (3.13).

Las variables expuestas anteriormente deben conocerse en cada instante para realizar todos los cálculos necesarios referentes al volumen de agua en una cuenca y más aún, si se desea conocer el comportamiento a futuro de cada una, es necesario identificarlas con modelos de predicción que permitan modelar su dinámica no lineal y poder aplicarla en algún esquema de control. Para esto, se utilizan modelos Takagi-Sugeno, debido a que son aproximadores universales, explicados a continuación.

3.2. Modelos difusos Takagi-Sugeno

Un modelo difuso Takagi-Sugeno [52] está compuesto por una base de reglas de la forma:

$$\begin{aligned} R_r : \text{Si } z(k-1) \text{ es } MF_{z_1}^r \text{ y } \dots \text{ y } z(k-n) \text{ es } MF_{z_n}^r \\ \text{entonces } y_r(k) = p_0^r + p_1^r z(k-1) + \dots + p_n^r z(k-n) \end{aligned} \quad (3.14)$$

Siendo R_r la r -ésima regla del modelo, $Z(k) = [z(k-1), \dots, z(k-n)]$ las entradas del modelo, $MF_{z_i}^r$ los conjuntos difusos, n el número de entradas al modelo y p_i^r las constantes de las consecuencias del modelo.

Dado que las funciones de pertenencia de cada conjunto difuso se consideran gaussianas, se pueden calcular como:

$$\mu_r(k) = \exp\left(\frac{-(Z(k) - \bar{m}_{MF_z^r})^2}{2\sigma_{MF_z^r}^2}\right) \quad (3.15)$$

Los parámetros $\sigma_{MF_z^r}$ y $\bar{m}_{MF_z^r}$ se calculan utilizando algún algoritmo de *clustering* difuso, como *Fuzzy C-means* [53], siendo estos la desviación estándar y centro de cada cluster respectivamente.

A partir de estas funciones de pertenencia, se define el grado de activación de cada regla (w_r):

$$w_r(k) = \text{oper}(\mu_r(z(k-1)), \dots, \mu_r(z(k-n))) \quad (3.16)$$

Y al normalizar cada w_r , se obtienen los grados de activación normalizados, como se observa a continuación:

$$h_r(k) = \frac{w_r(k)}{\sum_{l=1}^{N_r} w_l(k)} \quad (3.17)$$

Así, la salida del modelo, correspondiente a la predicción, se calcula como la ponderación de cada salida local y_r , junto a su grado de activación normalizado. como se observa en la ecuación (3.18).

$$\hat{y}(k) = \sum_{r=1}^{N_r} h_r(Z(k)) \cdot y_r(Z(k)) \quad (3.18)$$

Finalmente, los parámetros de la consecuencia se calculan aplicando el método de mínimos cuadrados [54], por lo que se define:

$$X = \begin{bmatrix} h_1(1) & \cdots & h_{N_r}(1) & h_1(1) \cdot z(0) & \cdots & h_{N_r}(1) \cdot z(0) & \cdots & h_{N_r}(1) \cdot z(1-n) \\ \vdots & & & & \ddots & & & \vdots \\ h_1(t) & \cdots & h_{N_r}(t) & h_1(t) \cdot z(t-1) & \cdots & h_{N_r}(t) \cdot z(t-1) & \cdots & h_{N_r}(t) \cdot z(t-n) \\ \vdots & & & & \ddots & & & \vdots \\ h_1(N) & \cdots & h_{N_r}(N) & h_1(N) \cdot z(N-1) & \cdots & h_{N_r}(N) \cdot z(N-1) & \cdots & h_{N_r}(N) \cdot z(N-n) \end{bmatrix} \quad (3.19)$$

$$\vec{P} = [p_0^1 \quad p_0^2 \quad \cdots \quad p_0^{N_r} \quad p_1^1 \quad p_1^2 \quad \cdots \quad p_n^{N_r}]^T \quad (3.20)$$

$$\vec{Y} = [y(1) \quad \cdots \quad y(N)]^T \quad (3.21)$$

Siendo N el número de datos disponibles. Luego, los parámetros de las consecuencias se calculan como:

$$\vec{P} = (X^T \cdot X)^{-1} X^T \cdot \vec{Y} \quad (3.22)$$

Para construir un modelo difuso $T\&S$ a partir de un set de N datos entrada-salida del sistema que se desea identificar, se utiliza la siguiente metodología:

- Dividir los datos en tres conjuntos: entrenamiento, test y validación.
- Utilizar el conjunto de entrenamiento para calcular los parámetros del modelo difuso (premisas y consecuentes).
- Utilizar el conjunto de Test para optimizar la estructura del modelo difuso (número de *clusters* y regresores).
- Utilizar el conjunto de validación para calcular métricas y cuantizar el desempeño de las predicciones.

Un ejemplo de métrica para evaluar el modelo difuso T&S es la raíz del error cuadrático medio (RMSE), que se calcula según la ecuación (3.23).

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y(k) - \hat{y}(k))^2} \quad (3.23)$$

Además de querer conocer el valor esperado de algún sistema, también es importante caracterizar la incertidumbre del mismo, para tener más información al momento de decidir algún tipo de acción sobre estos. Con este fin se desarrollan intervalos de predicción, los que se detallan a continuación.

3.3. Intervalos de predicción

Los intervalos de predicción permiten caracterizar las incertezas de algún sistema o proceso, al contar con una banda superior e inferior, las cuales acotan los valores predichos futuros, asegurando con cierto grado de confianza que estos valores se encontrarán dentro del intervalo [23]. Un tipo de intervalo basado en modelos difusos T&S es el método de números difusos [55] en el cual los parámetros de las consecuencias del modelo difuso se definen como números difusos, representados por un centro m y un spread s , como se observa en la ecuación (3.24).

$$p_i^r = [m_i^r - \underline{s}_i^r, m_i^r + \overline{s}_i^r] \quad (3.24)$$

Así, utilizando estos parámetros en la ecuación (3.14) se pueden construir dos nuevas salidas locales para el modelo difuso, una superior y otra inferior, siendo estas la salida lineal afín del modelo difuso, más la nueva combinación lineal asociada a los parámetros \underline{s}_i , \overline{s}_i , como se observa en las ecuaciones (3.25) y (3.26).

$$\widehat{y}_r(k) = \sum_{i=1}^n m_i^r Z(k) + m_0^r + \sum_{i=1}^n \overline{s}_i^r Z(k) + s_0^r \quad (3.25)$$

$$\underline{\widehat{y}}_r(k) = \sum_{i=1}^n m_i^r Z(k) + m_0^r - \sum_{i=1}^n \underline{s}_i^r Z(k) - s_0^r \quad (3.26)$$

Luego, las bandas superior e inferior del intervalo se calculan multiplicando estas nuevas salidas locales con su respectivo grado de activación normalizado, según las ecuaciones (3.27) y (3.27).

$$\widehat{y}(k) = \sum_{r=1}^{N_r} h_r \widehat{y}_r(k) \quad (3.27)$$

$$\underline{\widehat{y}}(k) = \sum_{r=1}^{N_r} h_r \underline{\widehat{y}}_r(k) \quad (3.28)$$

Para encontrar el valor de los *spreads* se resuelve el siguiente problema de optimización:

$$\min_{\underline{s}_i^r, \overline{s}_i^r} \eta_1 PINAW + e^{-\eta_2 (PICP - (1-\alpha)\%)} \quad (3.29)$$

Donde η_1 y η_2 son constantes de ajuste para cada costo, α determina el porcentaje de cobertura deseado (si $\alpha = 10$, el porcentaje de cobertura será $(1 - \alpha) = 90\%$), el PINAW es el ancho promedio normalizado del intervalo y el PICP el porcentaje probable de cobertura. Estos dos últimos se calculan como [24]:

$$PINAW = \frac{1}{NR} \sum_{k=1}^N (\widehat{y}(k) - \underline{\widehat{y}}(k)) \quad (3.30)$$

$$R = \max \{y(k)\} - \min \{y(k)\}$$

Y

$$PICP = \frac{1}{N} \sum_{k=1}^N c_k \quad (3.31)$$
$$c_k = \begin{cases} 1 & \text{si } \underline{\hat{y}}(k) \leq y(k) \leq \bar{\hat{y}}(k) \\ 0 & \text{si no} \end{cases}$$

La función objetivo de la ecuación (3.29) está diseñada para que la componente exponencial haga de restricción suave sobre el PICP y así poder alcanzar la cobertura deseada. Luego, cuando esta cobertura se alcance, el costo de la función a minimizar dependerá únicamente del PINAW, por lo que se reducirá el ancho del intervalo manteniendo esta cobertura mínima. De esta forma, se pueden encontrar los parámetros que alcancen el PICP mínimo deseado y minimicen el PINAW al mismo tiempo.

3.4. Discusión

En este capítulo se explicaron las bases teóricas de distintos tópicos en los que se trabajará. En principio, se hace un repaso de conceptos hidrogeológicos básicos, como cuencas y acuíferos, que permiten familiarizarse mejor con toda la modelación hidrogeológica aplicada en esta tesis. Luego se explicó la importancia de los ensayos de bombeo, los que permiten aproximar la Transmisividad y Almacenamiento de un acuífero a través de distintos métodos de ajuste. Estos parámetros permiten conocer el cono de descenso de un acuífero, el cual define el nivel de agua en todos los pozos que se encuentran en este, permitiendo encontrar una ecuación capaz de caracterizar este descenso. Finalmente, se describe el método de balance hídrico, para conocer todos los procesos que afectan el flujo de agua en una cuenca, como las precipitaciones, escorrentía, evapotranspiración, etc. En particular, se muestra un algoritmo para calcular la escorrentía de una cuenca utilizando datos del caudal total, los que se pueden obtener a partir de mediciones en estaciones pluviométricas. Este análisis resulta fundamental en el desarrollo de esta tesis, ya que permite modelar las dinámicas del sistema hidrogeológico y así poder utilizarlas más adelante en el sistema de gestión.

Luego, se describen los modelos difusos Takagi-Sugeno, los que permiten identificar la dinámica de un sistema no lineal utilizando datos históricos de entrada/salida. Estos modelos se componen de una base de reglas que cuenta con un antecedente, el cual relaciona la entrada del modelo (regresores) con los conjuntos difuso del modelo, y un consecuente, el cual corresponde a una combinación lineal entre estos regresores y parámetros constantes, que definen una salida local. Así, ponderando cada salida local por el grado de activación normalizado de la regla a la que pertenecen, se puede obtener la salida global que aproxima el sistema en cuestión.

Similar al caso anterior, se describe el método de números difusos para crear intervalos de predicción, el cual se compone de un modelo difuso como el descrito anteriormente, donde los parámetros de las consecuencias se definen con un centro y un *spread* (m, s). Así se pueden obtener dos salidas locales asociadas al *spread* superior e inferior, correspondientes a las bandas del intervalo y, ponderando por los grados de activación normalizados, se obtiene el intervalo de predicción global.

Los ensayos de bombeo, cálculo del cono de descenso y balance hídrico se utilizan para

definir el comportamiento del modelo hidrogeológico, caracterizar las variables climáticas involucradas en el sistema y así diseñar el sistema de gestión de agua y energía. En el siguiente capítulo se explicarán estos pasos.

4. Modelación del sistema hidrogeológico, eléctrico y de los cultivos

4.1. Planteamiento del problema

El propósito de este trabajo es diseñar un esquema de control que administre el uso de agua y energía para sistemas de riego de cultivos, optimizando el uso de los recursos disponibles de la zona. El concepto principal se basa en alcanzar una operación sustentable, en especial en términos de agua, al utilizar un volumen limitado que evite la sobre extracción, mientras se restringe el impacto que genera el bombeo en el ecosistema y así sentar las bases para una futura coordinación de múltiples micro-redes, que afectarán considerablemente la dinámica hídrica de su cuenca, tanto en extracción como uso de agua.

El diagrama del proceso a controlar (a lazo abierto), que corresponde a un conjunto de cultivos y sistemas hidrogeológicos, se encuentra en la figura 4.1.

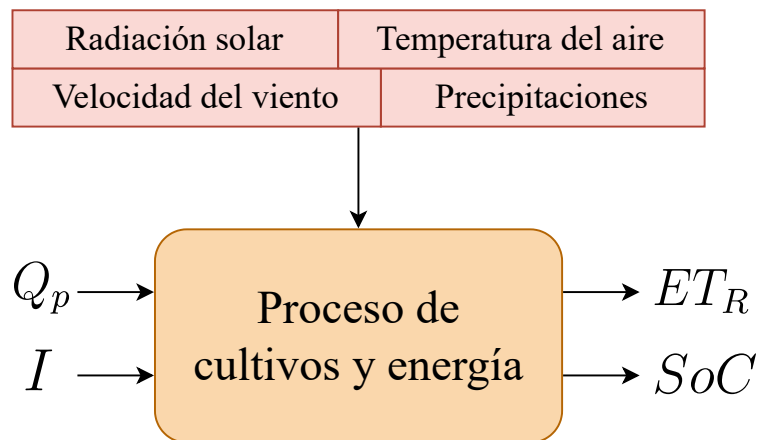


Figura 4.1: Diagrama del proceso a lazo abierto

De la figura 4.1 se observa que las variables que regulan el proceso son el uso de las bombas de extracción Q_p , que extraen agua de pozos ubicados cerca de cada cultivo y llenan los tanques de almacenamiento de agua. El riego de cada cultivo I también regula el proceso, al modificar su evapotranspiración real ET_R , según cuanta agua necesiten para desarrollarse. Por esto, la ET_R se define como una de las salidas del proceso, ya que permite monitorear

el crecimiento de los cultivos. Además, se define el estado de carga de los bancos de baterías SoC como la segunda salida, porque permite conocer la energía disponible dentro de la micro-red en estudio.

Como se observa en la figura 4.1, el cálculo del comportamiento de este proceso es afectado también por las condiciones meteorológicas de la zona, como la radiación solar y temperatura ambiente, las cuales permiten calcular la generación fotovoltaica, y las precipitaciones para el cálculo de la recarga de los acuíferos. Es por esto que la radiación solar, temperatura ambiente, velocidad del viento, humedad relativa y las precipitaciones se consideran perturbaciones dentro de este proceso.

A continuación, se detallan todos los procesos asociados al sistema hidrogeológico y eléctrico que influye en el sistema descrito.

4.2. Modelación del sistema hidrogeológico

Se define como sistema hidrogeológico al conjunto de un pozo, una bomba de extracción, un tanque de almacenamiento de agua y un grupo de cultivos, donde todos los sistemas compartirán el mismo acuífero, como se observa en la figura 4.2.




Figura 4.2: Conjunto de sistemas hidrogeológicos para un cultivo

El acuífero en cuestión se considera un acuífero libre donde se asume que su área será, por lo menos, la misma que el área que ocupan los cultivos, ubicándose justo debajo de estos.

Los principales objetivos de modelar la dinámica hídrica son conocer la cantidad de agua disponible destinada al riego, calculando la recarga proveniente de las precipitaciones diarias de la cuenca, conocer el comportamiento del nivel de agua de cada pozo al extraer agua con las bombas de extracción, y calcular la relación de la irrigación con el crecimiento de los cultivos, mediante el cálculo de su evapotranspiración real. Estos temas se detallan a continuación.

4.2.1. Estimación del agua disponible

Dado que la cantidad de agua dentro de un acuífero es limitada, se debe conocer la frecuencia y magnitud con la que esta se renueva, por lo que se debe aproximar cómo es su recarga. La recarga de un acuífero (R) se puede definir como el porcentaje de agua proveniente de las precipitaciones, que infiltra en la superficie y alcanza la zona saturada del acuífero, aumentando su nivel [39]. Para estimar el valor de la recarga del acuífero en estudio, se realiza

el balance hídrico en la cuenca donde se encuentra el sistema hidrogeológico en cuestión. Para esto, se consideran las precipitaciones de la zona (P), el riego de los cultivos (I), la evapotranspiración real de las plantas (ET_R), la escorrentía directa (E_s), la extracción de agua de cada pozo (Q_p) y la recarga (R). La ecuación (4.1) define su relación.

$$P + I = E_s + ET_R + Q_p + R \quad (4.1)$$

Para este caso, la figura 4.3 representa gráficamente la relación de las variables.




Figura 4.3: Balance hídrico para el sistema hidrogeológico propuesto

Inicialmente, toda el agua se acumula en la zona no saturada (color café claro), lo que aumentará directamente la humedad del suelo H_s , por lo que esta puede calcularse como la humedad en el instante anterior $H_s(k-1)$, más el volumen de agua que infiltra por las precipitaciones y riego ($P(k)$ y $I(k)$ respectivamente), y el volumen que se evapora y escurre ($ET_R(k)$ y $E_s(k)$ respectivamente), como se observa en la ecuación (4.2).

$$H_s(k) = H_s(k-1) + P(k) + I(k) - E_s(k) - ET_R(k) \quad (4.2)$$

Mientras continúe precipitando o se mantenga la irrigación, la humedad del suelo aumentará hasta que el suelo quede completamente saturado, alcanzando su humedad máxima $H_s^{máx}$. Luego, todo el excedente que siga infiltrando en la superficie se redistribuirá por diferentes rutas hasta alcanzar el acuífero. A esto se le llama “evento de recarga” [56]. Así, el evento de recarga se representa por la ecuación (4.3).

$$R(k) = \begin{cases} H_s(k) - H_s^{máx}(k) & \text{si } H_s(k) > H_s^{máx} \\ 0 & \text{si no} \end{cases} \quad (4.3)$$

La humedad máxima $H_s^{máx}$ dependerá del tipo de suelo que se considere, ya que el tamaño de los sedimentos determinará que tanta agua puede almacenar hasta que esta penetre en el acuífero. Según [57], la humedad máxima puede variar desde los 25 [mm/m] para un suelo arenoso hasta los 250 [mm/m] para un suelo arcilloso.

El valor de la recarga $R(k)$ que se obtiene de la ecuación (4.3) equivale a la recarga de la cuenca completa, por lo que para conocer la recarga localizada del acuífero en estudio R_{aq} , se debe ponderar este valor por su área A_{aq} , como se presenta en la ecuación (4.4).

$$R_{aq} = A_{aq}R \quad (4.4)$$

Así, R_{aq} es la cantidad de agua que se renueva en cada evento de recarga para el acuífero

en estudio.

El fin de modelar la recarga mediante las ecuaciones descritas (4.1 a 4.4), es poder utilizarlas como un simulador hidrogeológico, que permitirá generar datos de recarga subterránea a partir de datos históricos reales de precipitación, caudal y evapotranspiración de la cuenca. Estos datos se tratarán como mediciones reales, y así cubrir la falta de estos. En la figura 4.4 se muestra un diagrama de flujo del cálculo de la recarga.

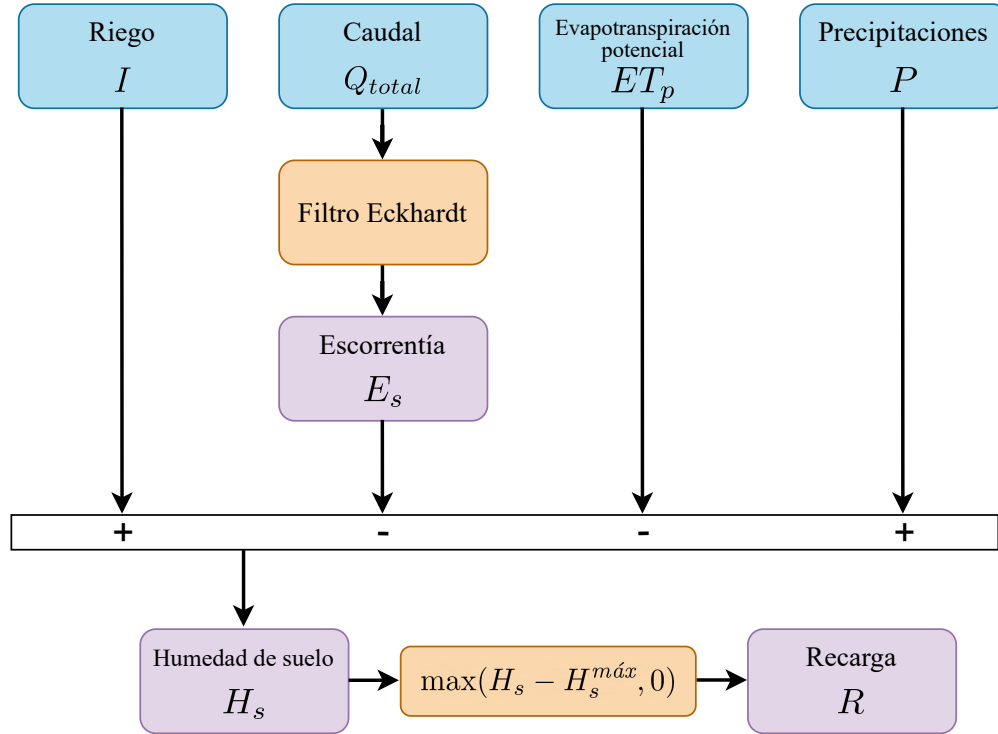


Figura 4.4: Diagrama del cálculo de la recarga

De la figura 4.4, el riego I , el caudal Q_{total} , la evapotranspiración potencial ET_p y las precipitaciones P , son mediciones obtenidas de estaciones meteorológicas. La escorrentía E_s se calcula a partir del caudal y el Filtro Eckhardt, siguiendo el procedimiento descrito en la sección 3.1.5. De estas mediciones se calcula la humedad de suelo H_s y, de la relación entre la humedad y la humedad máxima $H_s^{máx}$ (ecuación 4.3), se obtiene la recarga R .

A partir de la recarga del acuífero R_{aq} , se puede estimar el volumen de agua disponible para extraer (EAW por sus siglas en inglés), que corresponde a la recarga del acuífero en un instante k $R_{aq}(k)$, en conjunto al volumen de agua extraído, dado por el caudal de extracción $Q_p(k)$, y el agua que se encuentra actualmente en el acuífero. La relación anterior se observa en la ecuación (4.5).

$$EAW(k) = EAW(k - 1) + R_{aq}(k) - Q_p(k)\Delta t \quad (4.5)$$

De esta forma, se puede estimar la cantidad de agua disponible EAW que se puede extraer del acuífero, evitando su sobre-explotación. Por otro lado, la extracción misma impacta en el nivel de agua en cada pozo, y su influencia en el acuífero debe ser estudiado para asegurar un uso responsable. Así, a continuación se explica el modelo de las bombas de extracción y

los tanques de almacenamiento de agua.

4.2.2. Modelo del estanque y bomba de extracción

En la figura 4.2, cada tanque de almacenamiento de agua se considerará como un cilindro, además, el volumen de agua que tengan en un instante k ($V_T(k)$) estará dado por el volumen en el instante anterior y la diferencia entre el agua destinada a la irrigación (I) y el agua extraída por la bomba (Q_p). Esta relación se encuentra en la ecuación (4.6).

$$V_T(k) = V_T(k-1) + (Q_p(k) - I(k))\Delta t \quad (4.6)$$

Todos los estanques tendrán la misma capacidad máxima $V_T^{\text{máx}}$ asociada a sus dimensiones, por lo que se debe cumplir que:

$$0 \leq V_T \leq V_T^{\text{máx}} \quad (4.7)$$

Por otro lado, el caudal de extracción Q_p de los pozos es un caudal variable, pero que se mantendrá constante durante el tiempo de muestreo, así, cualquier cambio ocurrirá cada Δt intervalos de tiempo. Considerando esto y las ecuaciones (3.8) y (3.9) asociadas al descenso en múltiples pozos con caudal variable, el descenso en un pozo j en un instante k para N_p pozos, se puede obtener de la siguiente ecuación:

$$s_j(k) = \frac{1}{4\pi T} \sum_{l=1}^k \left[\Delta Q_{p,j}(l) W \left(\frac{R_j^2 S}{4T(k-l+1)\Delta t} \right) + \sum_{i=1 \neq j}^{N_p} \Delta Q_{p,i}(l) W \left(\frac{r_{i,j}^2 S}{4T(k-l+1)\Delta t} \right) \right] \quad (4.8)$$

Siendo $\Delta Q_{p,i}$ el cambio en el caudal de extracción del pozo i , l representa los cambios en el caudal hasta el instante k , R_j es el radio del pozo j , $r_{i,j}$ es la distancia desde el pozo i al pozo j , T es la transmisividad del acuífero y S su almacenamiento.

Al poder estimar el descenso en el nivel de agua de cada pozo, se puede definir un descenso máximo, que limite la influencia de la extracción en un pozo sobre los demás, acotando el cono de descenso. Por esto, el descenso s de todos los pozos debe cumplir que:

$$0 \leq s \leq s^{\text{máx}} \quad (4.9)$$

El uso de estas bombas de extracción y de los tanques de almacenamiento se ve influenciado directamente por la cantidad de agua que se debe destinar al riego, ya que para regar se utiliza el agua de los tanques, y si se agota, se encienden las bombas para extraer agua de los pozos. Por esta razón, es importante poder estimar la demanda de riego de cada cultivo diariamente. A continuación, se explica el procedimiento para calcular la demanda mencionada.

4.2.3. Cálculo de demanda de riego

Para conocer la cantidad de agua que necesita un cultivo para crecer de forma óptima, se puede analizar la relación entre su evapotranspiración potencial ET_p y real ET_R . Dado que la evapotranspiración de un cultivo representa cuanta agua ha perdido pasado un cierto tiempo, esta permite relacionar el riego directamente con el crecimiento y desarrollo de los mismos.

Como ahora se tiene conocimiento de los cultivos a los que se desea determinar una cuota hídrica, es posible utilizar ecuaciones más específicas para calcular tanto la ET_p como la ET_R , para esto se define la evapotranspiración de referencia (ET_0) que representa la tasa de evapotranspiración de un cultivo hipotético de referencia (pasto o similares) bajo abundante disponibilidad de agua y condiciones ideales de suelo [48]. Su valor depende solo de variables climáticas como la radiación solar, temperatura, velocidad del viento y presión, como se observa en la ecuación (4.10).

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T_a + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (4.10)$$

Donde R_n es la radiación neta en la superficie del cultivo (calculada a partir de la radiación solar R_s), G el flujo de calor del suelo, T_a la temperatura media del aire, u_2 la velocidad del viento a 2 metros de altura, $(e_s - e_a)$ el déficit de presión de vapor, Δ la pendiente de la curva de presión de vapor y γ la constante psicométrica.

A partir de la evapotranspiración de referencia se puede calcular la evapotranspiración potencial, según la siguiente ecuación:

$$ET_p = K_c ET_0 \quad (4.11)$$

Donde K_c es el coeficiente del cultivo, el cual busca incluir todos los parámetros del cultivo que no se consideran en el cultivo de referencia, como el tipo de cultivo, su altura, etapa de desarrollo, etc. Así, distintos cultivos tendrán distintos valores de K_c .

Luego, recordando que la evapotranspiración potencial ET_p es el valor máximo que puede alcanzar la evapotranspiración real ET_R (cuando se alcanzan condiciones ideales), se considera el factor estrés K_s el cual pondera a la ET_p para denotar un rendimiento menor en el desarrollo del cultivo, en este caso por un déficit en el agua disponible, así la evapotranspiración real se puede calcular como:

$$ET_R = K_s ET_p \quad (4.12)$$

Considerando que:

$$K_s = \begin{cases} \frac{TAW - D_r}{TAW - RAW} & \text{si } RAW < D_r \\ 1 & \text{si } RAW \geq D_r \end{cases} \quad (4.13)$$

$$TAW = 1000(\theta_{FC} - \theta_{WP})Z_r$$

$$RAW = p \cdot TAW$$

Donde TAW es el agua disponible total para los cultivos en la zona radicular (zona de la raíz), RAW es el agua fácilmente aprovechable, que representa la cantidad de agua que los cultivos pueden absorber sin producir estrés, p es la razón entre TAW y RAW , D_r es el agotamiento de humedad en la zona radicular, que representa la cantidad de agua faltante en la zona respecto a su capacidad de campo, θ_{FC} es el contenido de humedad a capacidad de campo, θ_{WP} el contenido en el punto de marchitez permanente y Z_r la profundidad de las raíces.

La ecuación (4.13) representa que, mientras que el agua faltante en la zona D_r sea menor al agua que los cultivos puedan aprovechar, la evapotranspiración real de estos será la óptima ($K_s = 1$), en cambio, luego de que los cultivos utilicen el agua disponible y el valor de D_r empiece a aumentar, cuando este sea mayor al agua aprovechable, las plantas entrarán en estrés hídrico, limitando su evapotranspiración real y por consiguiente, su desarrollo.

Para calcular D_r se realiza un balance hídrico en la zona de la raíz, considerando variables que antes no afectaban en el balance de la cuenca completa (ecuación 4.1), como el ascenso capilar o el mismo agotamiento de humedad. A partir de este balance, D_r queda definido por:

$$D_r(k) = D_r(k-1) - (P(k) - E_s(k)) - I(k) - CR(k) + ET_p(k) + DP(k) \quad (4.14)$$

Siendo P las precipitaciones, E_s la escorrentía, I el riego de los cultivos, CR el aumento del agua en la zona de la raíz por ascenso capilar, ET_p la evapotranspiración potencial y DP la pérdida de agua por percolación profunda (que pasará a ser recarga cuando alcance el nivel del acuífero).

A partir de las ecuaciones (4.12), (4.13) y (4.14), se encuentra la relación entre el riego de los cultivos I y su rendimiento, a través del cálculo del estrés hídrico K_s , así, al buscar maximizar la evapotranspiración real de cada cultivo, se puede encontrar el riego óptimo I^* . Con este, el volumen de riego óptimo (V_r^*) queda definido por:

$$V_r^* = p_t \frac{I^* \cdot A}{1000 \cdot \eta_r} \quad (4.15)$$

Donde I^* es el riego óptimo, A es el área total del cultivo, p_t es la porosidad del suelo, N_c es el número de cultivos y η_r la eficiencia de riego.

Además del volumen de agua destinado al riego, es necesario definir la relación entre el volumen de riego óptimo diario y el volumen de riego actual, para así verificar que se cumple con la demanda hídrica, esta relación se observa a continuación.

4.2.4. Relación entre riego y demanda hídrica

Para cumplir con la demanda de agua V_r^* se manipula la hora y cantidad del flujo de riego durante el día. El riego I se considera como un flujo de agua variable, desde los tanques de almacenamiento hasta los cultivos. Para controlar la hora del riego se considera una variable binaria b_r , que valdrá 1 en las horas que se desee regar y 0 en las que no.

Así, el volumen de agua utilizado en la irrigación en un instante k puede calcularse como:

$$V_r(k) = V_r(k-1) + b_r(k)I(k)\Delta t \quad (4.16)$$

De esta forma, se puede manipular el riego tanto en frecuencia como en magnitud, para que el volumen de agua regado $V_r(k)$ alcance al volumen de referencia V_r^* al final de cada día.

El modelo del sistema hidrogeológico descrito anteriormente permite estimar el volumen de agua disponible para usar, conocer la dinámica de los pozos al activarse las bombas de extracción, calcular la demanda hídrica necesaria para los cultivos y definir un método para administrar el riego durante el día. Sin embargo, el riego de los cultivos conlleva a un consumo eléctrico que debe ser considerado para utilizar correctamente la energía disponible en la micro-red. Por consiguiente, el modelo del sistema eléctrico se presenta a continuación.

4.3. Modelación del sistema eléctrico

En este caso, el sistema eléctrico hace referencia a cualquier componente que consuma o genere energía dentro de la micro-red. Así, se consideran 5 elementos principales: Paneles fotovoltaicos, bancos de baterías, un inversor, bombas de extracción y consumo eléctrico residencial. En la figura 4.5 se muestra un diagrama de la micro-red. En esta figura se observa que la energía proveniente de la generación solar se transforma en el convertidor DC/DC que hace de regulador MPPT, esta energía se transfiere a las baterías y, mediante un convertidor DC/AC, se conecta a la barra que alimenta tanto la bomba de extracción como el consumo eléctrico residencial, y permite comprar y vender energía a la red eléctrica

Al caracterizar cada componente, se desea conocer cuánta será la energía disponible dentro de la micro-red, como y cuánta energía inyecta el banco de baterías, y cuál será el consumo total a cubrir, entre la demanda residencial y el uso de las bombas de extracción. A continuación, se detalla el comportamiento de cada uno de estos componentes.

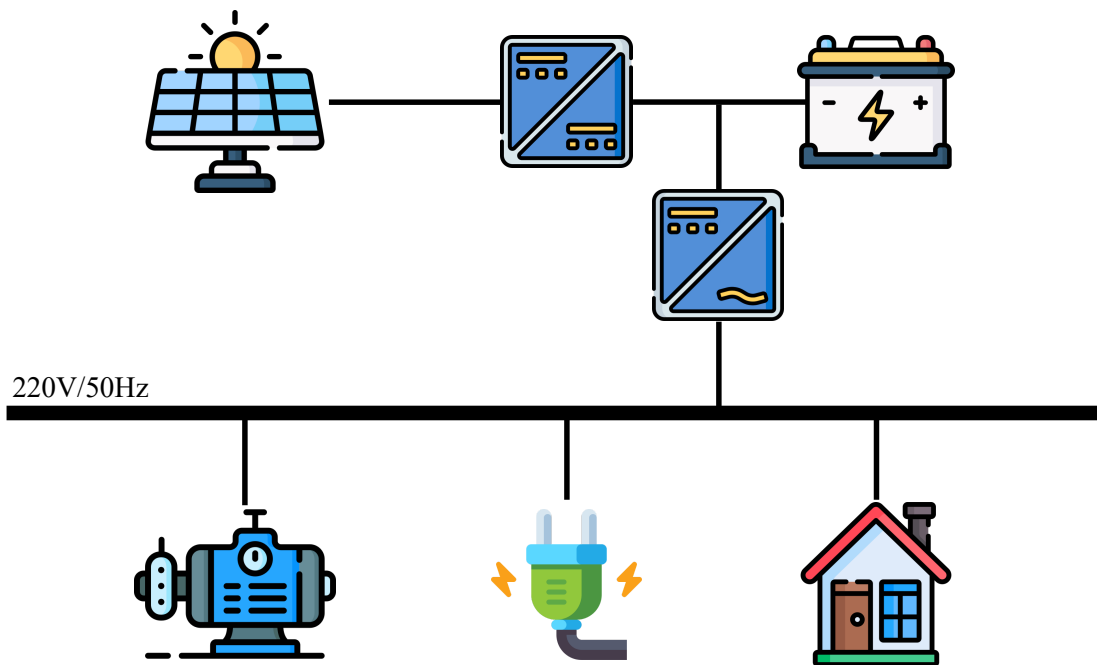


Figura 4.5: Diagrama de la micro-red

4.3.1. Generación fotovoltaica

Una parte fundamental de la energía disponible por la micro-red proviene de los paneles solares, los cuales aprovechan el efecto fotoeléctrico para generar electricidad utilizando la

radiación solar. Como se explica en [58] la generación depende tanto de la irradiancia de la zona como de la temperatura ambiental, donde en [59] se muestra una ecuación lineal que considera estos factores para calcular la potencia que entrega un arreglo de paneles, siendo esta la siguiente:

$$P_{fv} = \eta_{ref} \cdot [1 - \beta_{ref} \cdot (T_{fv} - T_{STC})] \cdot R_s \cdot A \quad (4.17)$$

Donde η_{ref} es la eficiencia del panel, β_{ref} el coeficiente de temperatura del panel, T_{fv} la temperatura de la celda, T_{STC} la temperatura en condiciones estándar (25 °C), R_s la radiación solar y A el área de la celda.

Además, en [60] se define T_{fv} como:

$$T_{fv} = T_a + \frac{T_{NOCT} - 20}{0.8} \quad (4.18)$$

Con T_a la temperatura ambiente y T_{NOCT} la temperatura de operación nominal de la celda (25 °C).

Dado que la generación fotovoltaica solo entrega energía en presencia de radiación solar, se considera el uso de bancos de baterías, que se utilizarán para almacenar la energía sobrante que provenga de los paneles solares y para inyectar energía cuando se requiera.

4.3.2. Bancos de baterías

Para modelar correctamente el comportamiento del banco de baterías, se considera como indicador el *State of Energy* (*SoE*), el cual muestra la cantidad de energía disponible dentro del banco. El *SoE* es un estado no medible, por lo que es necesario estimarlo, según la ecuación (4.19).

$$SoE(k+1) = SoE(k) - P_{bat}(k)\Delta t \quad (4.19)$$

Donde P_{bat} será la potencia que recibe o entrega el banco de baterías. Luego, se consideran dos variables de decisión $b_{bat,d}$ y $b_{bat,c}$ que definen si se cargarán o descargarán las baterías respectivamente, así, P_{bat} queda definido por:

$$P_{bat} = \begin{cases} \eta_c P_c(k) & \text{si } b_{bat,c} = 1 \\ \frac{P_d(k)}{\eta_d} & \text{si } b_{bat,d} = 1 \\ 0 & \sim \end{cases} \quad (4.20)$$

$$b_{bat,d} + b_{bat,c} \leq 1$$

Con P_c , P_d las potencias de carga y descarga del banco de baterías; y η_c , η_d la eficiencia de carga y descarga, respectivamente. La ecuación (4.20) representa que la potencia P_{bat} de las baterías dependerá de si esta se está cargando o descargando, aplicando el factor de eficiente correspondiente. Además, se restringen las variables binarias $b_{bat,d}$ y $b_{bat,c}$ para que solo una este activa a la vez.

Para alargar la vida útil de los bancos de baterías, se puede limitar su estado de energía bajo un mínimo y máximo [61], por lo que se debe cumplir que:

$$SoE_{mín} \leq SoE \leq SoE_{máx} \quad (4.21)$$

Tanto la generación solar como los bancos de baterías entregan energía en corriente continua, por lo que, para poder usar esta energía para satisfacer el consumo residencial o encender las bombas de extracción, se requiere de un inversor CC/AC.

4.3.3. Inversor

El inversor se considera como el elemento que permite la transformación de corriente continua (CC) a corriente alterna (AC), esto con el fin de adecuar las fuentes de generación en corriente continua para usarse en consumos de corriente alterna. Se asume una eficiencia η_{inv} para la transformación CC/AC, que se observa en la siguiente ecuación:

$$P_{AC} = \eta_{inv} P_{CC} \quad (4.22)$$

Con P_{CC} la potencia en corriente continua y P_{AC} su equivalente en corriente alterna.

4.3.4. Bombas de extracción

Las bombas de extracción cuentan como una carga controlable dentro del sistema, ya que, como se mencionó anteriormente, funcionan con un caudal Q_p variable en el tiempo, definido por el usuario en cada instante. Así, su potencia queda definida como [62]:

$$P_p(k) = \frac{BQ_p(k)h_p(k)}{\eta_p} \quad (4.23)$$

Donde B es una constante asociada a las propiedades del fluido, Q_p es el caudal de extracción, h_p es la altura desde donde se mueve el agua y η_p el rendimiento de la bomba.

Para calcular la altura h_p que se moverá el agua mediante la bomba, se debe considerar la altura del estanque de almacenamiento y el nivel de agua del pozo donde se extrae el agua. La primera corresponde a una constante que depende del estanque utilizado, y la segunda se puede calcular según la ecuación (4.8) asociada al descenso en el pozo a causa de la extracción. Entonces, la altura h_p se calcula como:

$$h_p(k) = h_T + s(k) \quad (4.24)$$

Donde h_T es la altura del estanque de almacenamiento y $s(k)$ el nivel de agua del pozo donde se está bombeando.

4.3.5. Consumo eléctrico residencial

El consumo eléctrico residencial P_{RL} se considera como una carga no controlable, donde la micro-red deberá tener siempre la energía suficiente para satisfacer esta demanda. Para esto, se impone que toda la generación de la micro-red deberá ser igual a todo el consumo, como se observa en la ecuación (4.25).

$$P_{fv} + P_{bat,d} + P_{buy} = P_p + P_{bat,c} + P_{RL} + P_{sell} \quad (4.25)$$

Donde P_{fv} es la potencia solar, $P_{bat,c}$ y $P_{bat,d}$ la potencia de carga o descarga del banco de baterías, P_p la potencia consumida por las bombas de extracción, P_{RL} el consumo eléctrico

residencial, y P_{buy} y P_{sell} la compra y venta de energía a la red.

Para caracterizar la demanda energética P_{RL} se utilizarán perfiles de demanda de la zona, según el trabajo realizado en [63].

Las ecuaciones descritas, tanto del sistema hidrogeológico como eléctrico, se considerarán al implementar el sistema de gestión de agua y energía, el cual utilizará la dinámica de todos los componentes del proceso descrito anteriormente para administrar eficientemente los recursos disponibles. El sistema de gestión se describe a continuación.

4.4. Sistema de gestión de agua y energía

De la figura 4.1, se observa que las variables que pueden influenciar el proceso de cultivos y energía son el riego I y el bombeo de agua subterránea Q_p . Por lo que, si se desea optimizar los recursos hídricos y energéticos, al mismo tiempo que se maximiza el rendimiento de los cultivos, se deben encontrar un par I^* , Q_p^* óptimo, que logre este objetivo.

Para decidir las acciones de riego I y extracción Q_p , se propone en esta tesis el Sistema de Gestión de Agua y Energía basado en control robusto (R-EWMS, por sus siglas en inglés), el cual es un sistema de control predictivo robusto que administra el agua y energía disponible con el fin de optimizar el crecimiento de los cultivos presentes en la zona al mismo tiempo que se minimizan costos de operación. El R-EWMS se divide en dos subsistemas de control: el sistema de gestión de energía (EMS) encargado de administrar la parte eléctrica del sistema y el sistema de gestión de agua (WMS) encargado de la parte hidrogeológica. El lazo de control descrito se encuentra en la figura 4.6.

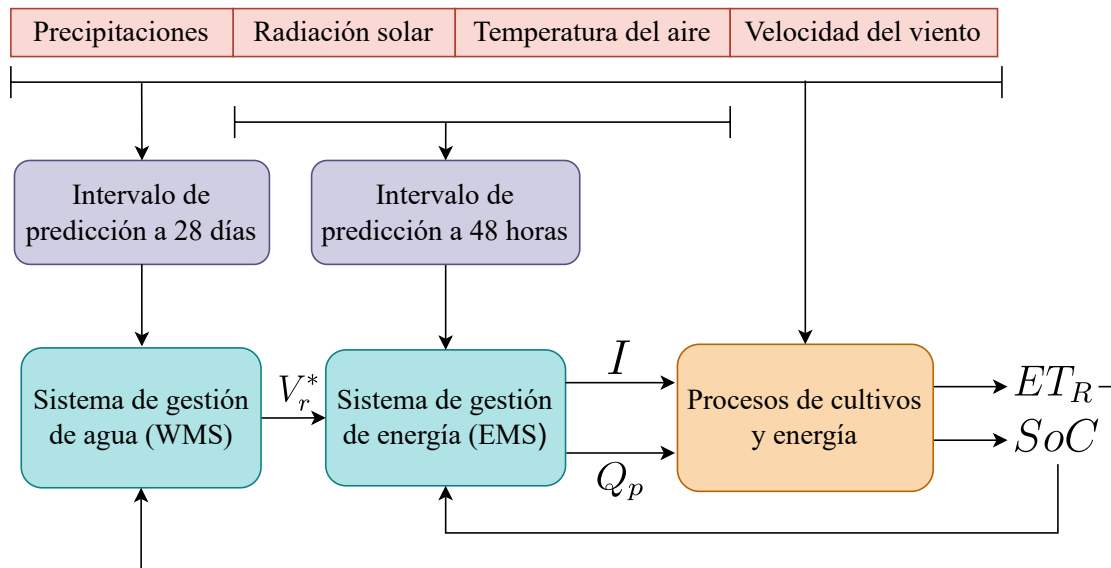


Figura 4.6: Esquema de control del sistema de gestión de agua y energía

De la figura anterior, se observa que el WMS utiliza el valor de la evapotranspiración de los cultivos en conjunto a las perturbaciones dadas por las condiciones climáticas para generar una demanda de riego (V_r^*), luego, el EMS utiliza esta demanda para definir el horario e

intensidad del riego I en conjunto a cuanta agua extraer de los pozos para cada tiempo de muestreo Q_p con el fin de suministrar el agua necesaria para alcanzar el óptimo desarrollo en cada cultivo, alcanzando su máxima evapotranspiración.

El EMS considera un tiempo de muestreo de $T_s = 10$ [min] y el WMS un tiempo de $T_s = 1$ [día]. Estos muestreos se definen según las escalas de tiempo que cada sistema debe tener en cuenta, por ejemplo, la capacidad de los bancos de baterías cambia notoriamente con una carga o descarga constante en ventanas de 10 minutos. En cambio, el sistema de cultivos, y en particular la evapotranspiración, es un proceso que presenta cambios paulatinos, no distinguibles en ventanas de minutos. En [48] las unidades comunes para la evapotranspiración son [mm/día], por lo que un tiempo de muestreo diario será el mínimo a considerar en el WMS.

Se utiliza un horizonte de predicción $N = 2$ [días] para el EMS, lo que permite decidir su uso tomando en cuenta un ciclo de carga o descarga completo. Además, al utilizar más de un día de la demanda de riego proveniente del WMS, se pueden llenar los estanques de almacenamiento tomando en cuenta una demanda futura distinta de la que se está cumpliendo actualmente.

Por otro lado, el horizonte de predicción para el WMS es de $N = 28$ [días], para que el cálculo de la demanda de riego considere más de una etapa en el crecimiento de cada cultivo, y así tomar en cuenta los cambios en su sensibilidad frente a la falta de agua.

De la figura 4.6, se observa que tanto el WMS como el EMS utilizan intervalos de predicción para estimar las condiciones climáticas de la zona, precipitaciones, radiación solar, temperatura del aire y velocidad del viento diarias para el WMS, y solo radiación solar y temperatura del aire cada 10 minutos para el EMS. La construcción de estos intervalos se muestra a continuación.

4.4.1. Modelación de variables climáticas

Para poder implementar un control robusto, es necesario cuantizar las perturbaciones del sistema, con el fin de incluirlas en el diseño del controlador. Para esto, se utilizan intervalos de predicción, los que permiten modelar las incertezas de, en este caso, las variables climáticas que influyen en el sistema, como lo son la radiación solar, temperatura ambiente, precipitaciones y velocidad del viento.

Se utilizan modelos Takagi-Sugeno para estimar el valor esperado de estas variables y números difusos para construir los intervalos de predicción, como se describe en las secciones 3.2 y 3.3 respectivamente. Estos modelos se entrenan a partir de datos históricos obtenidos de estaciones meteorológicas dentro del área en estudio, considerando predicciones hasta 48 horas para el EMS y hasta 28 días para el WMS. La figura 4.7 describe el uso de los intervalos en cada sistema de gestión.

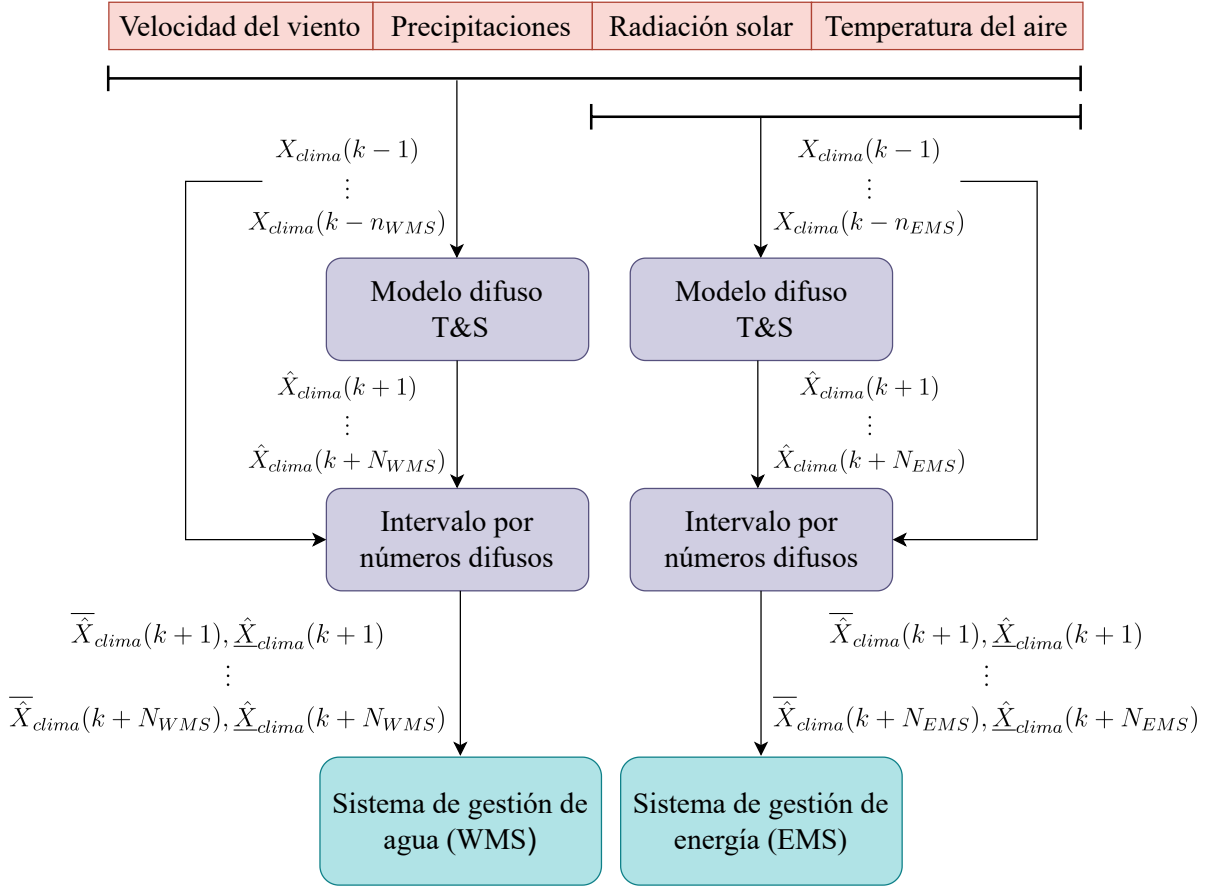


Figura 4.7: Diagrama de bloques de la construcción de los intervalos de predicción

De la figura anterior, se obtienen datos medidos de alguna variable meteorológica X_{clima} , considerando hasta n_{WMS} y n_{EMS} regresores para el WMS y EMS respectivamente. Estos datos se utilizan para entrenar modelos difusos T&S y así obtener las predicciones del valor esperado \hat{X}_{clima} de la variable climática utilizada, a N_{WMS} y N_{EMS} pasos a futuro para el WMS y EMS respectivamente. Luego, a partir de estas predicciones y los regresores de los datos medidos, se utiliza el método de números difusos para obtener los intervalos de predicción $\bar{\hat{X}}_{clima}$, $\hat{\underline{X}}_{clima}$ a los mismos pasos de predicción descritos anteriormente, los que son utilizados en el WMS y EMS para considerar las incertezas dentro de la gestión y así aplicar un control robusto.

Luego de definir los intervalos de predicción a utilizar, se describe en detalle el WMS, su función de optimización y restricciones.

4.4.2. Sistema de gestión de agua

El sistema de gestión de agua (WMS) es un controlador predictivo que define cuál será la demanda de agua que requiere cada uno de los N_c cultivos de cada sistema hidrogeológico, para un total de N_{hs} sistemas, obteniendo una demanda hídrica diaria $V_{ri,c}^*$ para un cultivo c en el sistema i , en una ventana de $N = 28$ días. Para medir el desempeño de los cultivos, se calcula su rendimiento relativo Y_r , que describe el crecimiento de un cultivo según la razón entre su evapotranspiración real ET_R y potencial ET_p , como se observa en la ecuación (4.26)

[64].

$$Y_r(k + N) = \prod_{j=1}^N \left[1 - K_y(k + j) \left(1 - \frac{ET_R(k + j)}{ET_p(k + j)} \right) \right]^{\frac{1}{M}} \quad (4.26)$$

Donde $Y_r(k + N)$ es el rendimiento relativo al final de N días, K_y el coeficiente de respuesta por falta de agua del cultivo, y M la duración de la etapa de crecimiento en la que se encuentra el cultivo. El rendimiento relativo máximo ($Y_r = 1$) se alcanza cuando $ET_R = ET_p$, lo que ocurre al no haber estrés hídrico en el cultivo ($K_s = 1$), cuyo valor se encuentra a través de la ecuación (4.13).

De la figura 4.6 se observa que todas las variables meteorológicas consideradas en esta tesis pueden perturbar al WMS. La radiación solar R_s , temperatura del aire T_a y velocidad del viento u_2 afectan al cálculo de la evapotranspiración de referencia ET_0 , como se observa en la ecuación (4.10), por otro lado, las precipitaciones P disminuyen el estrés hídrico K_s de los cultivos, como se observa en las ecuaciones (4.13) y (4.14). De esta forma, el peor caso de cada variable climática será la banda superior del intervalo de predicción para la radiación solar, temperatura del aire y velocidad del viento (\widehat{R}_s , \widehat{T}_a y \widehat{u}_2 respectivamente) y la banda inferior para el intervalo de predicción de las precipitaciones \widehat{P} . Por otro lado, la recarga del acuífero R_{aq} afecta directamente en el agua estimada disponible EAW WMS, según la ecuación (4.5), así, el peor caso de esta variable corresponde a la banda inferior del intervalo de predicción \widehat{R}_{aq} .

Considerando lo anterior, el WMS resuelve el siguiente problema de optimización.

$$\begin{aligned} \underset{V_{ri,c}^*}{\text{máx}} \quad & \sum_{i=1}^{N_{hs}} \sum_{c=1}^{N_c} \prod_{j=1}^N \left[1 - K_{yi,c}(k + j) \left(1 - \frac{ET_{Ri,c}(k + j)}{ET_{pi,c}(k + j)} \right) \right]^{\frac{1}{M_{i,c}}} \\ & - \lambda_V \sum_{i=1}^{N_{hs}} \sum_{c=1}^{N_c} \sum_{j=1}^N V_{ri,c}^*(k + j) \\ \text{s.a} \quad & \sum_{j=1}^N \sum_{i=1}^{N_{hs}} \sum_{c=1}^{N_c} V_{ri,c}^*(k + j) \leq EAW(k) + \sum_{j=1}^N \widehat{R}_{aq}(k + j) \\ & K_{si,c}(k + j) = f(\widehat{P}(k + j)) \\ & ET_{0i,c}(k + j) = g(\widehat{R}_s(k + j), \widehat{T}_a(k + j), \widehat{u}_2(k + j)) \end{aligned} \quad (4.27)$$

Donde N_{hs} es la cantidad de sistemas hidrogeológicos, N_c el número de cultivos dentro de cada sistema hidrogeológico, $M_{i,c}$ la duración de la etapa de crecimiento actual del cultivo c del sistema i , $V_{ri,c}^*$ la demanda de agua óptima para el cultivo c del sistema i , $K_{yi,c}$ el coeficiente de respuesta por falta de agua del cultivo c del sistema i , $ET_{Ri,c}$, $ET_{pi,c}$ la evapotranspiración real y potencial del cultivo c dentro del sistema i , respectivamente, $K_{si,c}$ el factor de estrés hídrico del cultivo c en el sistema i , EAW el agua estimada disponible para extraer sin recurrir a una sobre-explotación del acuífero y $ET_{0i,c}$ la evapotranspiración de referencia del cultivo c del sistema i .

El primer término de la ecuación (4.27) corresponde al rendimiento relativo Y_r después de N días para cada cultivo, lo que, al resolver el problema de optimización, permite encontrar la trayectoria óptima de V_r^* que maximice el rendimiento de los cultivos. El segundo término de la función penaliza el uso de agua al incluir la demanda hídrica en el costo, de esta forma, al resolver el problema de optimización, no solo se maximiza el rendimiento, sino que se utiliza la menor cantidad de agua posible para lograrlo. En esta caso, el parámetro λ_V permite ponderar el costo asociado a la cantidad de agua de la demanda hídrica, para definir que tan importante será disminuir el agua utilizada.

Con respecto a las restricciones de la ecuación (4.27), el primer término corresponde a limitar el uso del agua al definir la demanda hídrica, para que el total utilizado cada 28 días, no pueda superar al agua estimada disponible EAW actual y el peor caso la recarga futura \hat{R}_{aq} , así se asegura que el WMS no requiera más agua de la que se renueva naturalmente, y no se sobreexplota el acuífero.

La segunda, tercera y cuarta restricción están asociadas a incluir las incertezas en el diseño del sistema de control, como al calcular el estrés hídrico K_s considerando el peor caso de las precipitaciones (\hat{P}) y calculando la evapotranspiración de referencia ET_0 aplicando el peor caso de la radiación solar, temperatura ambiente y velocidad del viento (\hat{R}_s , \hat{T}_a y \hat{u}_2 respectivamente). En estas ecuaciones, $f(\cdot)$ corresponde a la ecuación (4.13), y $g(\cdot)$ a la ecuación (4.10).

Dado que, tanto la función de costos como las restricciones son de carácter no lineal, se utiliza el algoritmo *particle swarm optimization* (PSO) [65] para resolver el problema de optimización. Este algoritmo es un método de optimización evolutivo irrestricto, por lo que para poder aplicarlo, se reescribe el problema de optimización para incluir las restricciones dentro de la función de costos, como se observa en la siguiente ecuación:

$$\begin{aligned}
J = & \sum_{i=1}^{N_{hs}} \sum_{c=1}^{N_c} \prod_{j=1}^N \left[1 - K_{yi,c}(k+j) \left(1 - \frac{ET_{Ri,c}(k+j)}{ET_{pi,c}(k+j)} \right) \right]^{\frac{1}{M_{i,c}}} - \\
& \lambda_V \sum_{i=1}^{N_{hs}} \sum_{c=1}^{N_c} \sum_{j=1}^N V_{ri,c}^*(k+j) - \\
& \lambda_{cons} \max \left(0, \sum_{j=1}^N \sum_{i=1}^{N_{hs}} \sum_{c=1}^{N_c} V_{ri,c}^*(k+j) - \sum_{j=1}^N EAW(k+j) \right)
\end{aligned} \tag{4.28}$$

Donde λ_{cons} es una constante órdenes de magnitud mayor a los demás términos en la ecuación, lo que al maximizar este costo, permite que se cumpla con la restricción del uso de agua del problema de optimización planteado en la ecuación (4.27).

Luego de obtener el valor óptimo de la demanda hídrica en la ventana de 28 días, se utilizan los primeros dos valores como entrada al EMS (ver figura 4.6). Considerando esto, el diseño del EMS se describe a continuación.

4.4.3. Sistema de gestión de energía

El Sistema de gestión de energía (EMS) es un controlador predictivo que recibe la demanda de agua diaria ($V_{ri,c}^*$) para un cultivo c del sistema hidrogeológico i del WMS, la cual se debe suplir durante el día para alcanzar el rendimiento máximo de los cultivos considerados. Para alcanzar esta cuota, el EMS puede controlar tanto el cambio en el caudal de riego ($\Delta I_{i,c}$) para mover el agua desde el tanque de almacenamiento i hacia el cultivo c , como el cambio en el caudal de la bomba de extracción ($\Delta Q_{p,i}$) para llenar el estanques i con agua extraída de su pozo respectivo.

Por otro lado, el EMS también se encarga del uso del banco de baterías, al manipular las variables $b_{bat,d}$ y $b_{bat,c}$ de la ecuación (4.20), lo que permite definir cuando y por cuanto tiempo cargar o descargar los bancos de baterías para consumir o inyectar energía de la micro-red respectivamente. Además, el EMS puede decidir comprar o vender energía, al definir los valores de E_{buy} y E_{sell} , en casos donde falte energía para cumplir la demanda residencial o el consumo de las baterías, o casos donde sobre energía generada por los paneles solares y ya se hayan cubierto todos los consumos, siempre minimizando los costos de operación.

Con respecto a las perturbaciones, de la figura 4.6 se observa que las variables climáticas que afectan al EMS son la radiación solar R_s y la temperatura del aire T_a , las que modifican directamente a la generación solar. Así, para incluir estas incertezas en el controlador, se considera la banda inferior del intervalo para la radiación solar $\underline{\hat{R}}_s$ y la banda superior del intervalo para la temperatura ambiente $\overline{\hat{T}}_a$, ya que estos representan el peor caso, donde la generación solar se ve más reducida.

Es importante notar que, para el WMS se considera como peor caso la banda superior del intervalo para la radiación solar, en cambio, el EMS utiliza la banda inferior. Para que ambos intervalos puedan usarse simultáneamente, se considera que los primeros dos días de predicción (correspondientes al EMS) serán modelados por el intervalo inferior y los siguientes 26 días (correspondientes al WMS) serán modelados por el intervalo superior.

Luego, tomando en consideración el comportamiento de cada una de las variables del sistema eléctrico y los objetivos de este controlador, se plantea el siguiente problema de optimización:

$$\begin{aligned}
& \min_{\substack{E_{buy}, E_{sell}, b_{bat,d}, d_{bat,c} \\ \Delta I_{i,c}, \Delta Q_{p,i}}} \sum_{j=1}^N \sum_{i=1}^{N_{hs}} \sum_{c=1}^{N_c} \left[C_{ex} w_{ex}^{i,c}(k+j) + C_{ns} w_{ns}^{i,c}(k+j) \right] + \\
& \sum_{j=1}^N [C_{buy} E_{buy}(k+j) - C_{sell} E_{sell}(k+j)] + \\
& \sum_{j=1}^N \sum_{i=1}^{N_{hs}} \Delta Q_{p,i}^2(k+j-1) + \sum_{c=1}^{N_c} \Delta I_{i,c}^2(k+j-1) \tag{4.29} \\
\text{s.a} \quad & E_{buy}(k+j) + E_{fv}(k+j) + E_{bat,d}(k+j) = \\
& E_{sell}(k+j) + E_p(k+j) + E_{bat,c}(k+j) + E_{RL}(k+j) \\
& E_{fv}(k+j) = f\left(\widehat{R}_s(k+j), \widehat{T}_a(k+j)\right)
\end{aligned}$$

Donde N es el horizonte de predicción, N_{hs} es el número de sistemas hidrogeológicos y N_c el número de cultivos por sistema hidrogeológico.

La función de costos de la ecuación (4.29) busca cumplir con la demanda hídrica que entrega el WMS a través de las variables $w_{ns}^{i,c}$ y $w_{ex}^{i,c}$, que penalizan la falta o exceso de riego del cultivo c del sistema i frente a su demanda $V_{ri,c}^*$, durante el día de operación. Además, se incluyen las constantes C_{ex} y C_{ns} , asociadas a los costos de estar sobre o debajo de la demanda hídrica respectivamente.

Además de lo anterior, se minimizan los costos de operación de la micro-red, al minimizar la compra de energía E_{buy} y maximizar la venta E_{sell} dentro de lo posible. En este caso también se consideran constantes asociadas al costo de comprar o vender C_{buy} y C_{sell} respectivamente dentro de la función.

También, al penalizar las variables ΔQ_p y ΔI se obtiene una acción de control más suave, lo que permite alargar la vida útil de los actuadores, siendo en este caso las bombas de extracción y las válvulas de riego.

Con respecto a las restricciones de la ecuación (4.29), se impone que el problema de optimización debe mantener el balance de energía definido en la ecuación (4.25), considerando la compra de energía E_{buy} , la venta E_{sell} , la generación solar E_{fv} , la carga $E_{bat,c}$ o descarga $E_{bat,d}$ de los bancos de baterías, el consumo de las bombas E_p y la demanda residencial E_{RL} , con el fin de aprovechar toda la energía de la micro-red, ya sea cubriendo todos los consumos o vendiendo el sobrante a la red eléctrica.

La segunda restricción de la ecuación (4.29) incluye las incertezas de las variables climáticas al considerar el peor caso de la radiación solar \widehat{R}_s y temperatura ambiente \widehat{T}_a , y usarlas en el cálculo de la energía solar E_{fv} . En este caso, la función $f(\cdot)$ corresponde a la función de la ecuación (4.17) que calcula la potencia solar a partir de estas variables.

Además de las restricciones anteriores, se deben considerar los límites físicos de todos los procesos involucrados en el sistema, tanto de las variables de optimización (Q_p , I , E_{buy} , E_{sell}

y b_{bat}), como de los estados intermedios, que son el volumen de los estanques V_T descritos en la ecuación (4.6), el estado de carga de las baterías SoE presentado en la ecuación (4.19) y el descenso del nivel de agua s de cada pozo, expuesto en la ecuación (4.8). Estas restricciones se observan a continuación:

$$0 \leq I_{i,c}(k+j) \leq I^{m\acute{a}x} \quad (4.30)$$

$$0 \leq Q_{p,i}(k+j) \leq Q_p^{m\acute{a}x} \quad (4.31)$$

$$0 \leq V_T(k+j) \leq V_T^{m\acute{a}x} \quad (4.32)$$

$$SoE_{m\acute{i}n} \leq SoE(k+j) \leq SoE_{m\acute{a}x} \quad (4.33)$$

$$0 \leq s(k+j) \leq s_{m\acute{a}x} \quad (4.34)$$

A traves de esta formulacion, se obtiene un problema de optimizacion entero mixto (MILP por sus siglas en ingles), el cual se resuelve utilizando el *toolbox* YALMIP [66], en conjunto al *solver* GUROBI [67], que aplica un algoritmo de optimizacion basado en *Branch-and-bound* [68], simplificaciones del problema y heursticas.

De esta forma, el WMS define el volumen de riego necesario para optimizar el crecimiento de todos los cultivos, mientras que el EMS se encarga de cumplir esta demanda mientras se minimizan los costos operacionales.

4.5. Discusion

En este captulo se presenta la modelacion hidrogeologica y eletrica para el sistema de cultivos, en conjunto al diseo del sistema de gestion de agua y energa. Con respecto al primero, se muestra como se puede calcular la recarga difusa a partir de variables meteorologicas medibles, como las precipitaciones o el caudal, permitiendo crear el simulador hidrogeologico que se utilizar como generador de datos entrada/salida para identificar un modelo de prediccion sobre esta recarga. Por otro lado, se define el comportamiento que presentan la bomba de extraccion y los estanques de almacenamiento, especificando cual ser el descenso en cada pozo, segn cuanto es el caudal de extraccion, y definiendo los lmites fsicos de los estanques. Ademas, se relaciona la evapotranspiracion real de cada cultivo con la cantidad necesaria de agua para asegurar que estos se desarrollen ptimamente, para esto se requiere conocer el tipo de cultivo, sus etapas de crecimiento, la dinmica de distintas variables climticas como la radiacion solar o la velocidad del viento, y el agua capaz de almacenarse en el suelo. Finalmente, se define una forma de controlar las horas en las que se desea regar, con el fin de evitar periodos de mucho calor o con alta radiacion solar.

Con respecto al modelo del sistema eletrico requerido para activar las bombas, se detalla la dinmica de los paneles solares, para aproximar cuanta energa generarn al conocer la radiacion solar de la zona. Ademas, se muestran las ecuaciones necesarias para conocer la energa almacenada dentro de los bancos de bateras y como esta influye en la generacion o consumo de la micro-red. Tambien, se muestra como calcular la potencia consumida por las bombas de extraccion, la que depende de propiedades del lquido extrado como tambien de la altura a la cual este se encuentra. Finalmente, se explica como se modela la demanda eletrica residencial, considera un consumo que siempre se debe satisfacer.

Sobre el sistema de gestión de agua y energía, se explica su incorporación en el proceso de cultivos a controlar, describiendo su separación entre sistema de gestión de agua WMS y sistema de gestión de energía EMS, cada uno con su propio tiempo de muestreo. Además, se describe el proceso para construir los intervalos de predicción para las variables climáticas que afectan al proceso (radiación solar, temperatura ambiente, velocidad del viento y precipitaciones) las que serán usadas dentro del controlador para incluir estas incertezas en la optimización. De la misma forma, se describe el problema de optimización que cada sistema de gestión debe resolver para encontrar la acción de control que maximice el rendimiento de los cultivos, mientras se minimiza el uso de los recursos y costos operacionales. Finalmente, se describe los algoritmos de optimización utilizados para resolver los problemas descritos anteriormente, siendo no lineal para el WMS y lineal para el EMS.

Luego de diseñar el sistema de gestión de agua y energía, en la siguiente sección se exponen los resultados obtenidos, tanto por los modelos de predicción, como del sistema de gestión.

5. Resultados

En este capítulo se exponen las simulaciones y los resultados obtenidos del caso de estudio. Para el caso, se muestran las dimensiones de los equipos utilizados, los parámetros de los cultivos, el tipo de suelo y el valor de los costos de energía y agua para el EMS y WMS respetivamente.

Sobre los resultados, se muestran los valores obtenidos para la Transmisividad T y Almacenamiento S del acuífero estudiado, destacando el desempeño de los modelos entrenados para predecir las variables climáticas, a corto y mediano plazo, los experimentos propuestos para probar el desempeño del controlador y la respuesta de este en cada escenario.

5.1. Caso de estudio

5.1.1. Dimensionamiento de los componentes

El dimensionamiento de los equipos se realizó en base al estudio sobre la comunidad José Paineicura Hueñalihuen, comuna de Carahue, Chile, expuesto en [63], el cual consideró 44 viviendas y 2 espacios públicos. Luego, los paneles solares, bancos de baterías, bombas de extracción y tanques de almacenamiento presentan las siguientes características:

- Paneles solares de 90 $[kW]$.
- Bancos de baterías de 50 $[kWh]$ en total.
- Bombas de extracción centrífuga de caudal variable, con un máximo de 36 $[m^3/h]$ y una altura máxima de bombeo de 15 $[m]$.
- Tanques de almacenamiento de 2 $[m^2]$ de capacidad.

5.1.2. Características de los cultivos

Los cultivos utilizados en las simulaciones son tomates, papas, cebollas y maíz, cuyas características se observan en la tabla 5.1.

Tabla 5.1: Parámetros de los cultivos

Parámetros	Tomate	Papa	Cebolla	Maíz
Duración de etapas [días]	30, 40, 40, 25	25, 30, 30, 30	15, 25, 70, 40	20, 25, 25, 10
Coefficientes de cultivo	0.6, 1.15, 0.8	0.5, 1.15, 0.75	0.7, 1.05, 0.75	0.3, 1.15, 1.05
Coefficientes de rendimiento	1, 1, 1, 1	1, 1, 1, 1	1, 1, 1, 1	1, 1, 1, 1
Fracción de agotamiento	0.4	0.35	0.3	0.5
Profundidad radicular máxima [m]	1.1	0.5	0.45	1
Altura máxima [m]	0.6	0.6	0.4	1.5
Rendimiento máximo [kg/ha]	86910	3176	80000	15000
Precio [$$/kg$]	220	280	170	135

5.1.3. Parámetros de los sistemas hidrogeológicos

Las características del suelo en donde se encuentran los cultivos se definieron según el estudio de suelo realizado en la comunidad José Paineicura Hueñalihuen el 14 de enero del 2022 (Anexo A.1), y de la litología entregada por el Servicio Nacional de Geología y Minería [69]. De este análisis se define que el terreno es del tipo franco-arenoso, cuya humedad máxima se considera de 100 [mm/m], según [57].

Los pozos de extracción se consideran de un radio de 12 [cm], separados entre sí a una distancia de 150 [m].

Para definir la Transmisividad y Almacenamiento del acuífero en estudio, se utilizan datos de ensayos de bombeo registrados por la Dirección General de Aguas (DGA) en un estudio sobre la región de la Araucanía [70]. A partir de este informe, se utiliza el ensayo de bombeo más cercano a la comunidad (Pozo o-451, en las coordenadas 38.7300° S, 73.2697° O), realizado en noviembre del 2002. A partir del estudio realizado por la DGA para este pozo, se concluye que el acuífero del cual se extrajo agua corresponde a un acuífero confinado, y dado que no se cuentan con datos más cercanos a la Comunidad Jose Paineicura Hueñalihuen, se utilizan estos datos para representar el acuífero de la comunidad, utilizando las ecuaciones para la dinámica de acuíferos confinados expuesta en la sección 3.1.3.

Con respecto al agua disponible dentro del acuífero en estudio, se considera que este presenta un volumen de agua estimado disponible inicial $EAW(0)$ de 1000 [m^3], correspondientes a la recarga de todo un año previo al periodo de estudio.

5.1.4. Datos meteorológicos y consumo de la comunidad

Para desarrollar las simulaciones e implementar el controlador, se consideraron dos tipos de datos: De corto plazo, cuyo tiempo de muestreo es de 10 minutos, y de mediano plazo, cuyo tiempo de muestreo es de un día. Las fuentes de datos utilizadas se obtienen a partir del estudio realizado en [71]. Así, las variables a corto plazo consideradas son:

- Radiación solar y temperatura ambiente: Obtenida a partir de la estación meteorológica de la comunidad (38.6908° S, 73.3533° O), desde junio 2019 a enero 2020.
- Consumo eléctrico: Generado a partir del estudio realizado en [63].

Con respecto a las variables de mediano plazo, se consideran:

- Radiación solar y temperatura ambiente: Obtenida del “Explorador Solar” del Ministerio de energía, en las coordenadas de la comunidad. Desde el 2004 al 2016 [72].
- Velocidad del viento: Obtenida del “Explorador Eólico” del Ministerio de energía, en las coordenadas de la comunidad. Desde el 2004 al 2016 [73].
- Precipitaciones: Obtenidas del “Explorador Climático” del Centro de Ciencia del Clima y Resiliencia (CR)2, en la estación meteorológica de Puerto Saavedra (38.7886° S, 73.3936° O) [74].
- Caudal y Evapotranspiración potencial: Obtenida del “Explorador de cuencas” de la base de datos CAMELS-CL (Catchment Attributes and Meteorology for Large Sample Studies, Chile Dataset), para la cuenca “Río Lleu-Lleu En Desagüe Lago Lleu-Lleu” (38.12° S, 73.4° O) [75].

Con los datos y parámetros descritos anteriormente, a continuación se realizan distintas simulaciones para probar el desempeño de los modelos de predicción, intervalos y el sistema de gestión agua-energía.

5.2. Resultados experimentales

5.2.1. Cálculo de parámetros del acuífero

Para encontrar los valores de la Transmisividad T y Almacenamiento S , se utiliza el método de Cooper-Jacob, descrito en la sección 3.1.3, sobre los datos de descenso del pozo o-451 mencionado en la sección 5.1.3. La figura 5.1 muestra el ajuste lineal obtenido sobre estos datos. En esta figura se muestran los datos de descenso graficados en escala semilogarítmica, en conjunto al ajuste lineal obtenido, que permite aproximar los parámetros T y S del acuífero.

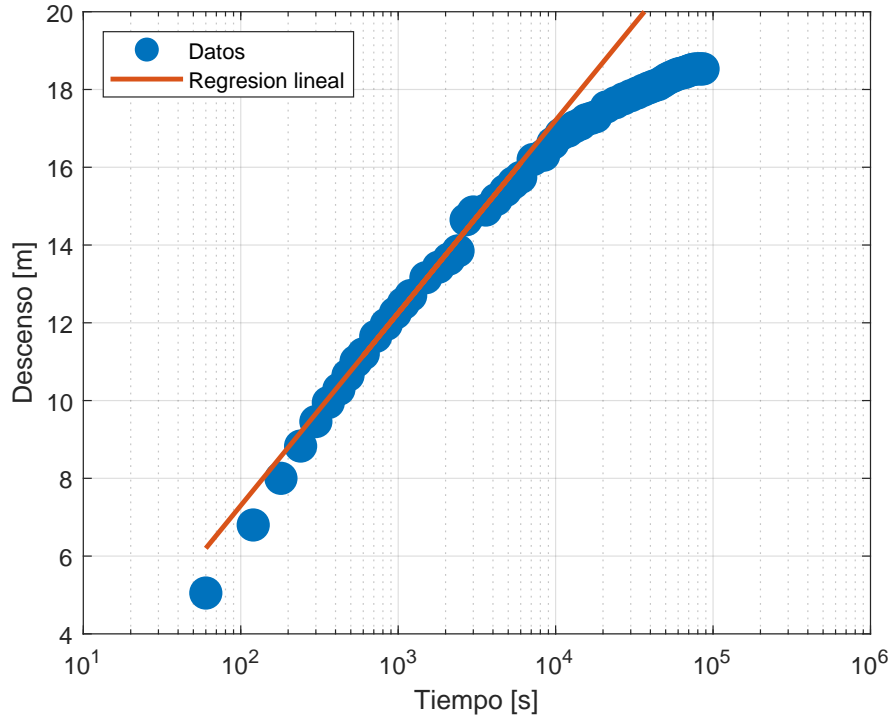


Figura 5.1: Prueba de gasto constante en el pozo o-451 y ajuste lineal.

De este ajuste, se obtiene el tiempo t_0 donde la regresión alcanza el valor $s = 0$, y el valor Δs , siendo el cambio en el descenso entre un ciclo logarítmico completo. Conociendo t_0 y Δs , y aplicando las ecuaciones (3.5) y (3.6), se pueden encontrar los valores de T y S respectivamente. La tabla 5.2 muestra los resultados obtenidos de este procedimiento.

Tabla 5.2: Parámetros obtenidos al aplicar el método Cooper-Jacob.

Parámetro	Valor
t_0 [s]	3.363
Δs [m]	4.954
T [$m^2/día$]	35.106
S	0.191

5.2.2. Cálculo de la recarga

Según la figura 4.3, para estimar la recarga se debe conocer el valor del riego I , las precipitaciones P , evapotranspiración potencial ET_p y la escurrentía E_s , donde esta última se debe calcular a partir del caudal total Q_{total} , aplicando el filtro de Eckhardt, como se muestra en la sección 3.1.5. Los parámetros necesarios para aplicar este filtro se calculan en el Anexo C, luego, la aplicación de este método se observa en la figura 5.2.

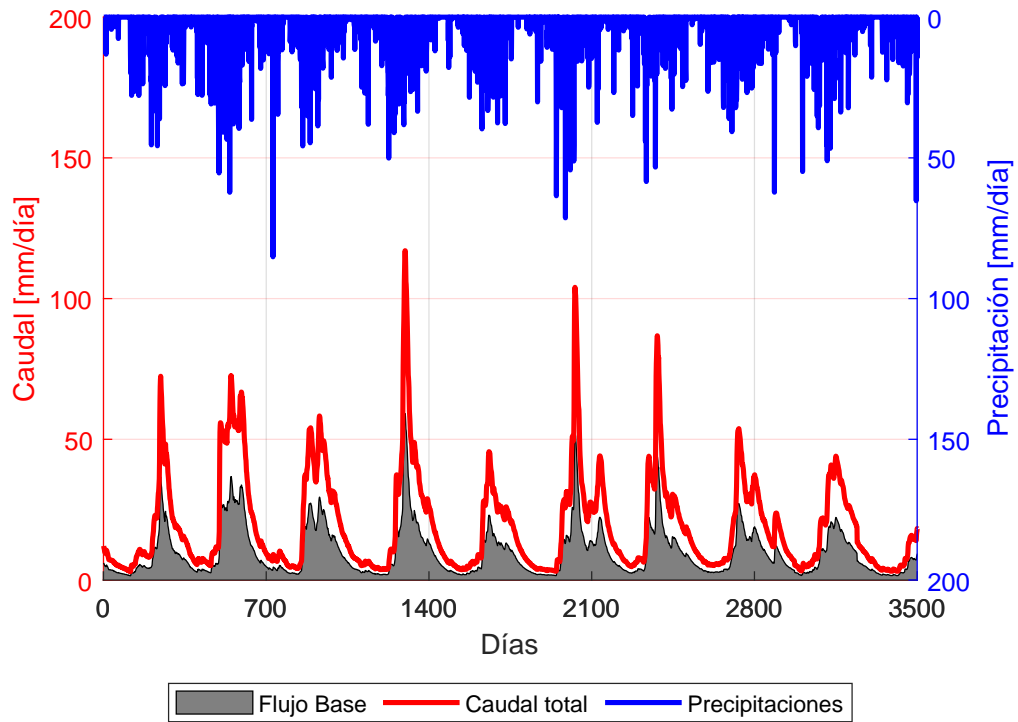


Figura 5.2: Separación del flujo base y escorrentía E_s al aplicar el filtro de Eckhardt sobre el caudal total Q_{total} . La escorrentía corresponde a la diferencia del área gris y la línea roja.

De la figura 5.2 se observa la separación del flujo base Q_b del caudal total Q_{total} , cuya diferencia aumenta en periodos de altas precipitaciones, ya que estas aumentan el caudal de los ríos. Así, la escorrentía E_s se obtiene de esta diferencia entre Q_b y Q_{total} .

Finalmente, al obtener el valor de la escorrentía en la cuenca, se calcula la recarga según la ecuación (4.3). La figura 5.3 muestra la recarga resultante y las precipitaciones en el mismo periodo.

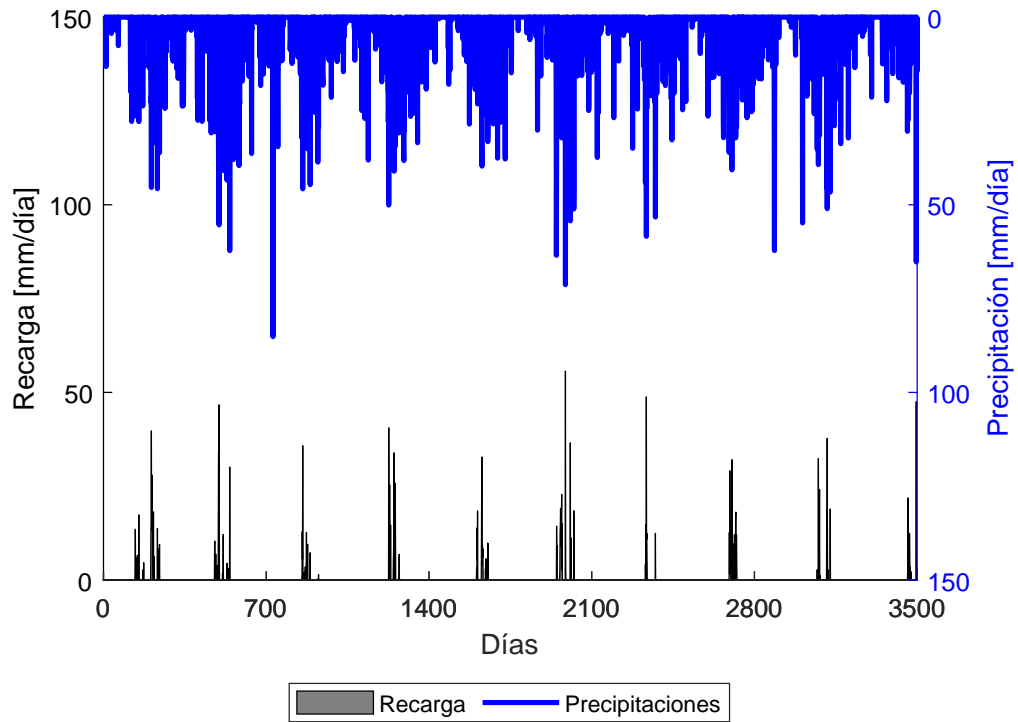


Figura 5.3: Recarga en la cuenca R y precipitaciones P .

De esta forma, se obtienen datos de las variables climáticas faltantes que perturban el sistema (P , E_s y R). Luego, usando estos datos se construyen los modelos e intervalos de predicción para caracterizar su dinámica futura.

5.2.3. Modelación de variables de corto plazo

Para modelar la radiación solar R_s se utilizó un modelo difuso Takagi-Sugeno, considerando un 60 % para el entrenamiento de parámetros, 20 % para optimizar la estructura y el último 20 % para validar el desempeño del modelo obtenido. La optimización de la estructura del modelo se realizó según el algoritmo descrito en el Anexo B. Se utilizó un máximo de 144 regresores y 4 reglas al inicio de la optimización.

Para construir el intervalo se utilizó el método de números difusos descrito en la sección 3.3, definiendo la cobertura deseada (PICP) en 90 %. El comportamiento del modelo y el intervalo para 1, 144 y 288 pasos (10 minutos, 24 horas y 48 horas) se observa en la figura 5.4.

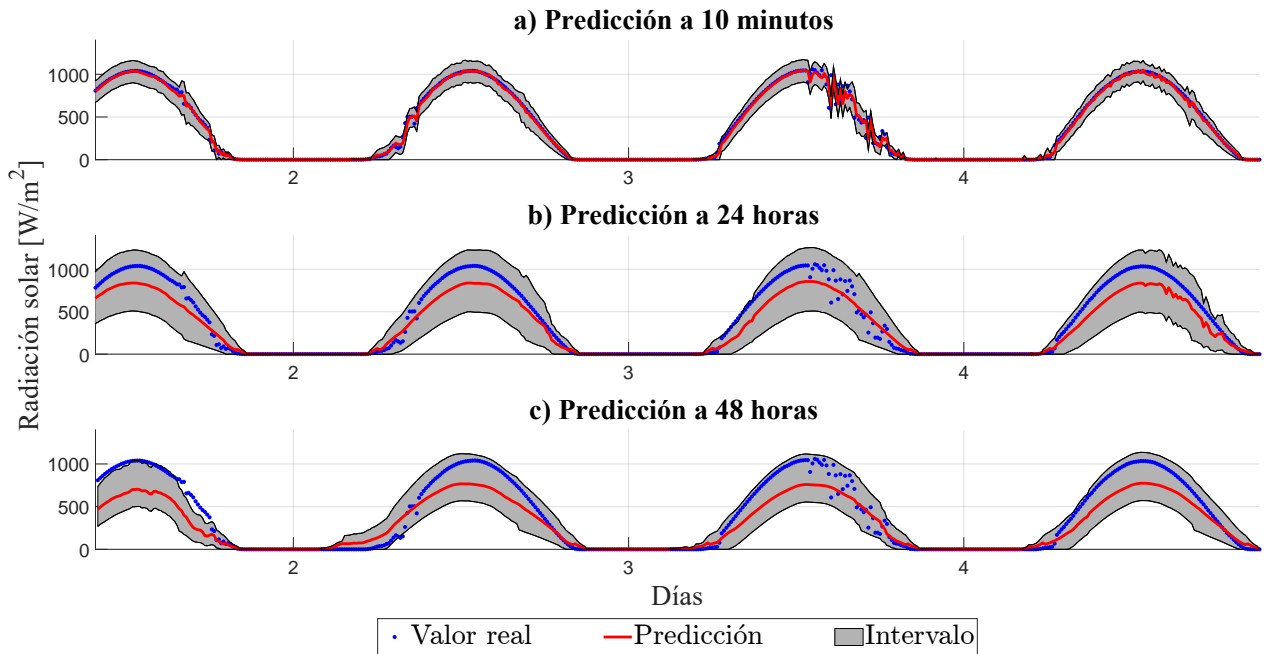


Figura 5.4: Predicción e intervalo de radiación solar R_s para distintos pasos de predicción.

De la figura 5.4, se puede notar que para la radiación solar R_s , el valor esperado obtenido es capaz de seguir la dinámica de la señal original, manteniéndose en cero para las horas de noche y aumentando mientras se entra en el día. No obstante, la predicción a 48 horas se comporta más como un promedio atenuado de la señal, donde las distintas perturbaciones no se captan solo con este valor esperado.

Con respecto a la temperatura ambiente T_a , esta se modela a través de un modelo difuso Takagi-Sugeno, con un 60 % de los datos usados en entrenamiento, 20 % para optimizar la estructura del modelo y 20 % para calcular las métricas de su desempeño. Se realiza el mismo algoritmo de optimización estructural del Anexo B, con un máximo de 144 regresores y 8 reglas.

De la misma forma, el intervalo se construyó con el método de números difusos, definiendo el PICP deseado en un 90 %. La figura 5.5 muestra el comportamiento del modelo para la temperatura ambiente y su intervalo.

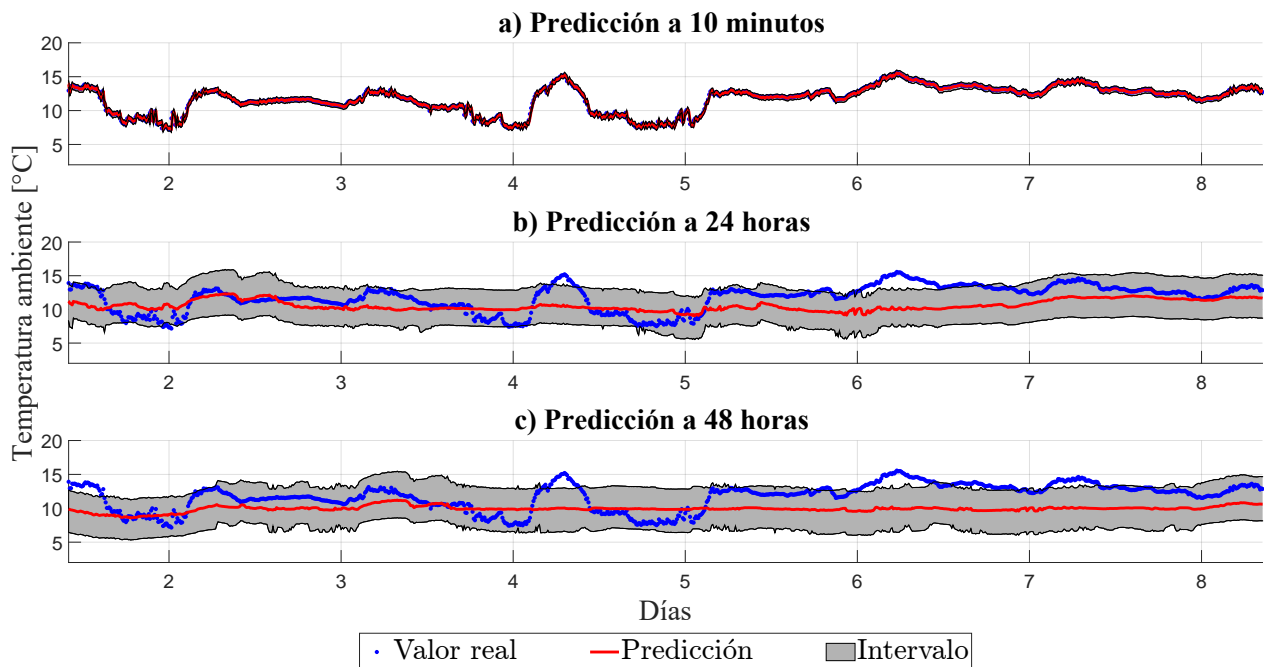


Figura 5.5: Predicción e intervalo de temperatura ambiente T_a para distintos pasos de predicción.

En la figura 5.5, la predicción de temperatura ambiente a 10 minutos sigue correctamente a los valores reales, con un intervalo muy acotado. Esto se debe a que la temperatura ambiente T_a no presenta perturbaciones considerables, por lo que la incerteza a un paso es pequeña. Sin embargo, se observa que el valor esperado de la temperatura ambiente a 48 horas no sigue tan precisamente la forma de la señal, esto se debe a que la temperatura no presenta una dinámica tan recurrente como la radiación solar, por lo que es más difícil de predecir a más pasos.

La tabla 5.3 muestra las métricas obtenidas de los modelos de radiación solar y temperatura ambiente. Para analizar el desempeño de las predicciones se utiliza el RMSE (ecuación (3.23)) y para el intervalo el PICP (ecuación (3.31)) y PINAW (ecuación (3.30)).

Tabla 5.3: Rendimiento de los modelos a corto plazo en distintos pasos de predicción.

Modelo	Métricas	Horizonte de predicción		
		10 min	24 hrs	48 hrs
Radiación Solar	RMSE [W/m^2]	50.15	141.51	153.92
	PICP [%]	89	91	91
	PINAW [%]	10	28	26
Temperatura ambiente	RMSE [$^{\circ}C$]	0.25	2.37	2.42
	PICP [%]	89	77	78
	PINAW [%]	5	43	54

De la tabla 5.3, se observa que el intervalo de predicción de la radiación solar R_s alcanza

un porcentaje de cobertura del 91 % a 48 horas, mostrando que este intervalo logra captar las incertezas presentes en el tiempo. Por otro lado, el intervalo resultante de la temperatura ambiente obtiene un porcentaje de cobertura del 78 % a 48 horas y un ancho promedio del 54 %, siendo notablemente menor que el obtenido para la radiación solar. Esto se debe al desempeño obtenido del valor esperado, el cual a 48 horas se acerca más al promedio de la señal, en vez de seguir su dinámica, lo que empeora la construcción de los intervalos. Aun así, se considera que una cobertura del 78 % es suficiente para modelar las incertezas de la temperatura ambiente.

Luego de analizado el desempeño de los modelos e intervalos de predicción para las variables climáticas a corto plazo, se realiza el mismo procedimiento para las mismas variables con un muestreo diario (mediano plazo).

5.2.4. Modelación de variables de mediano plazo

La radiación solar R_s , temperatura ambiente T_a y velocidad del viento diaria u_2 se modelan mediante modelos difusos Takagi-Sugeno, utilizando la misma partición de datos que los modelos anteriores (60 %, 20 % y 20 %). Para la optimización estructural, se utilizan 60 regresores máximo y hasta 10 reglas para elegir la configuración óptima según el Anexo B. El intervalo se construye con el método de números difusos definiendo el PICP objetivo en 90 %.

El comportamiento del modelo de predicción e intervalo para la radiación solar R_s se observa en la figura 5.6.

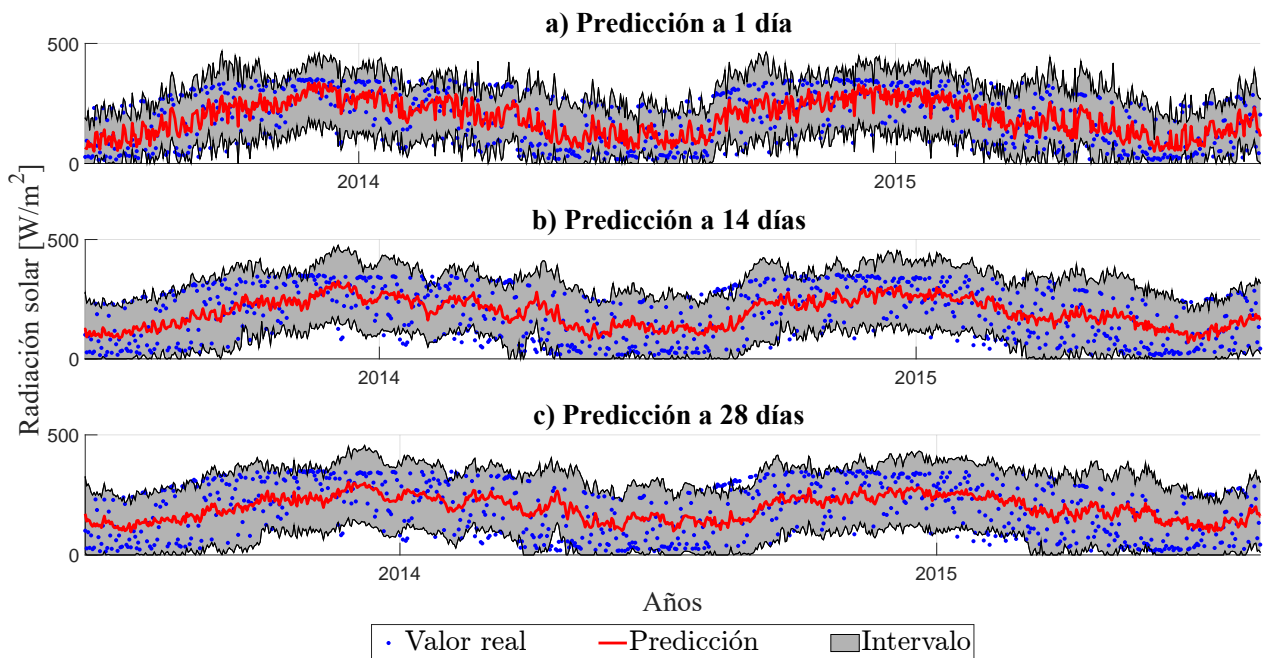


Figura 5.6: Predicción e intervalo de radiación solar R_s para distintos pasos de predicción.

De la figura 5.6 se observa que la radiación solar R_s presenta una clara estacionalidad al medirse diariamente, siendo más alta en fechas de verano y baja en fechas de invierno. Este

comportamiento se logra captar por el modelo de predicción al disminuir o aumentar su valor esperado según la época del año que se esté prediciendo. Aun así, al predecir a 28 días, se observa que el valor esperado tiende al promedio de los datos en vez de seguir la dinámica punto a punto. No obstante, el intervalo de predicción obtenido logra cubrir la mayoría de los datos para todos los pasos de predicción expuestos en la figura.

Con respecto a la temperatura ambiente T_a , su modelo de predicción junto a su intervalo se observan en la figura 5.7

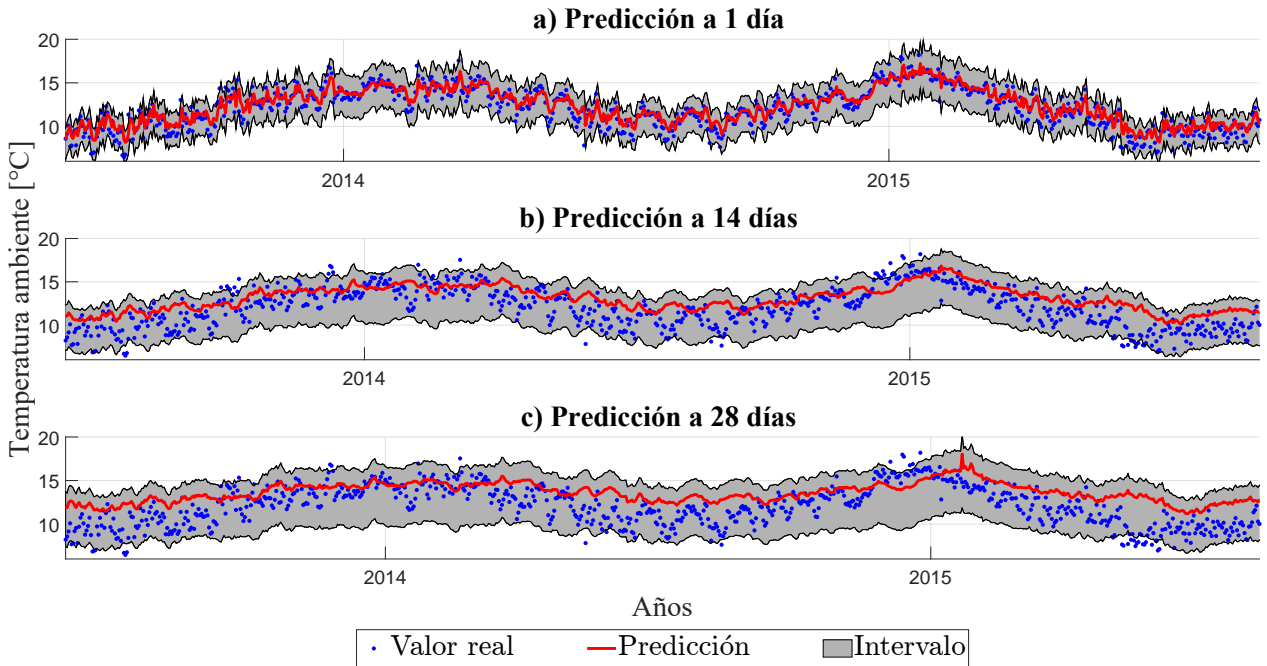


Figura 5.7: Predicción e intervalo de temperatura ambiente T_a para distintos pasos de predicción.

De la figura anterior, se observa que la temperatura ambiente T_a presenta la misma estacionalidad que la radiación solar, diferenciándose en que la primera muestra menos variaciones diarias, dado que la temperatura ambiente no se ve directamente perturbada como la radiación solar. Por lo mismo, el valor esperado obtenido en la predicción a un día logra seguir correctamente la dinámica de esta variable. No obstante, al predecir 28 días a futuro, el valor esperado sigue más la tendencia de los datos que sus valores día a día, dado que la propagación del error de predicción no permite estimar con la misma precisión que al predecir a un solo día. Con respecto a los intervalos obtenidos, se observa el mismo comportamiento que el obtenido en la radiación solar, donde el intervalo cubre la mayoría de los datos, manteniendo la estacionalidad presente en el valor esperado.

Analizando la velocidad del viento u_2 , las predicciones e intervalos se muestran en la figura 5.8




Figura 5.8: Predicción e intervalo de la velocidad del viento u_2 para distintos pasos de predicción.

De la figura 5.8 se observa que los datos de la velocidad del viento u_2 no siguen un comportamiento definido y no presentan la misma estacionalidad que la radiación solar o temperatura ambiente. Por esto, las predicciones del valor esperado siguen más el promedio de estos datos en vez de captar una dinámica, lo que se observa mejor entre más aumentan los pasos de predicción. Similar a las variables anteriores, el intervalo de predicción de la velocidad del viento u_2 cubre la mayoría de los datos reales, pero en este caso, al no seguir una tendencia o dinámica, este intervalo no resulta tan informativo como los de radiación solar o temperatura ambiente.

En el caso del modelo para las precipitaciones diarias P , se comparan modelos Takagi-Sugeno con modelos AR. Los modelos difusos se entrenan de la misma forma que para las variables anteriores y los modelos AR consideran solamente 60 regresores en total.

El desempeño de cada modelo para las precipitaciones se puede observar en la figura 5.9.




Figura 5.9: Comparación de las predicciones P a 28 días de la precipitación utilizando modelos Takagi-Sugeno y AR.

Además, la tabla 5.4 muestra el RMSE de cada modelo para las precipitaciones a 1, 14 y 28 días de predicción.

Tabla 5.4: Comparación de modelo Takagi-Sugeno y AR para las precipitaciones P a distintos horizontes de predicción

Horizonte de predicción	Métricas	Modelos	
		T&S	AR
1 día	RMSE [$mm/día$]	6.795	6.815
14 días	RMSE [$mm/día$]	7.129	7.107
28 días	RMSE [$mm/día$]	7.048	7

De la tabla 5.4 se nota que el modelo AR presenta un menor RMSE a 14 y 28 días de predicción, además, de la figura 5.9.a se observa que la predicción del modelo difuso es en su mayoría mayor a cero, aun cuando el valor real es nulo, a diferencia del modelo AR, cuya predicción se acerca más al cero en los periodos donde no hay grandes precipitaciones. Este fenómeno se observa más claramente al graficar las curvas doble música para cada modelo, como se muestra en la figura 5.10

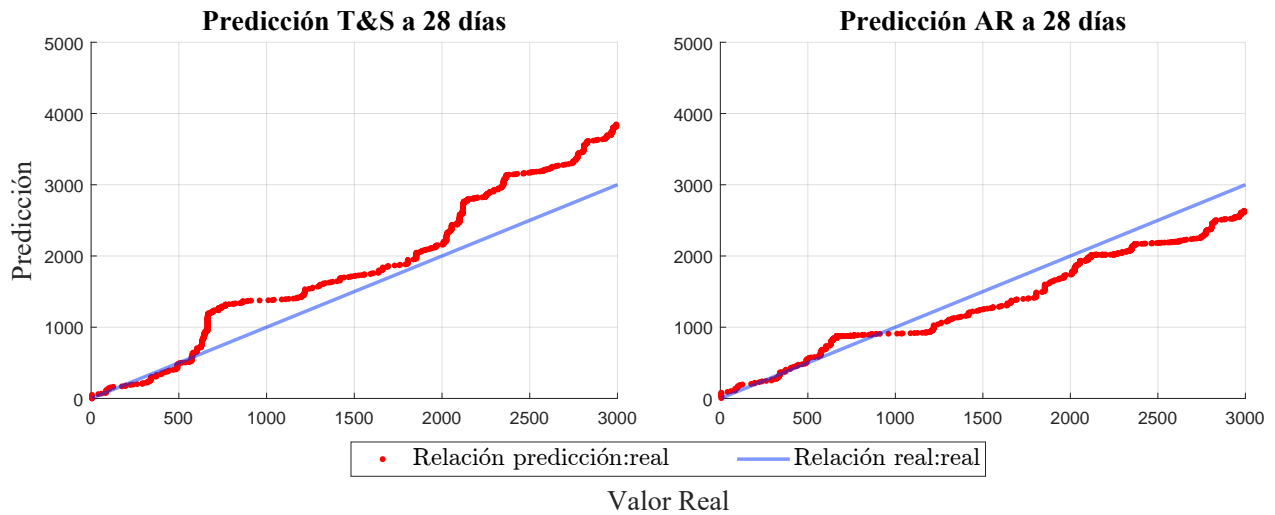


Figura 5.10: Curva doble másica para los modelos Takagi-Sugeno y AR de las precipitaciones a 28 días.

De la figura 5.10 se observa que el modelo difuso entrega una predicción acumulada mayor a la real en todo el tiempo simulado, en cambio, el modelo AR se presenta una precipitación acumulada menor, que además se acerca más a la línea 1:1, siendo más cercana al valor real de la lluvia acumulada. Las diferencias entre el modelo T&S y el modelo AR se encuentran en la cantidad de datos disponibles para entrenar (3000 aproximadamente), los que resultan insuficientes para captar la dinámica de las precipitaciones y entrenar todos los parámetros de un modelo T&S, en cambio, el modelo AR presenta un mejor desempeño al tener un número de parámetros considerablemente menor. Por lo anterior, se elige el modelo AR para predecir el comportamiento de las precipitaciones.

Luego, la figura 5.11 muestra las predicciones del modelo AR para las precipitaciones en conjunto con su intervalo de predicción lineal construido mediante el método de números difusos.

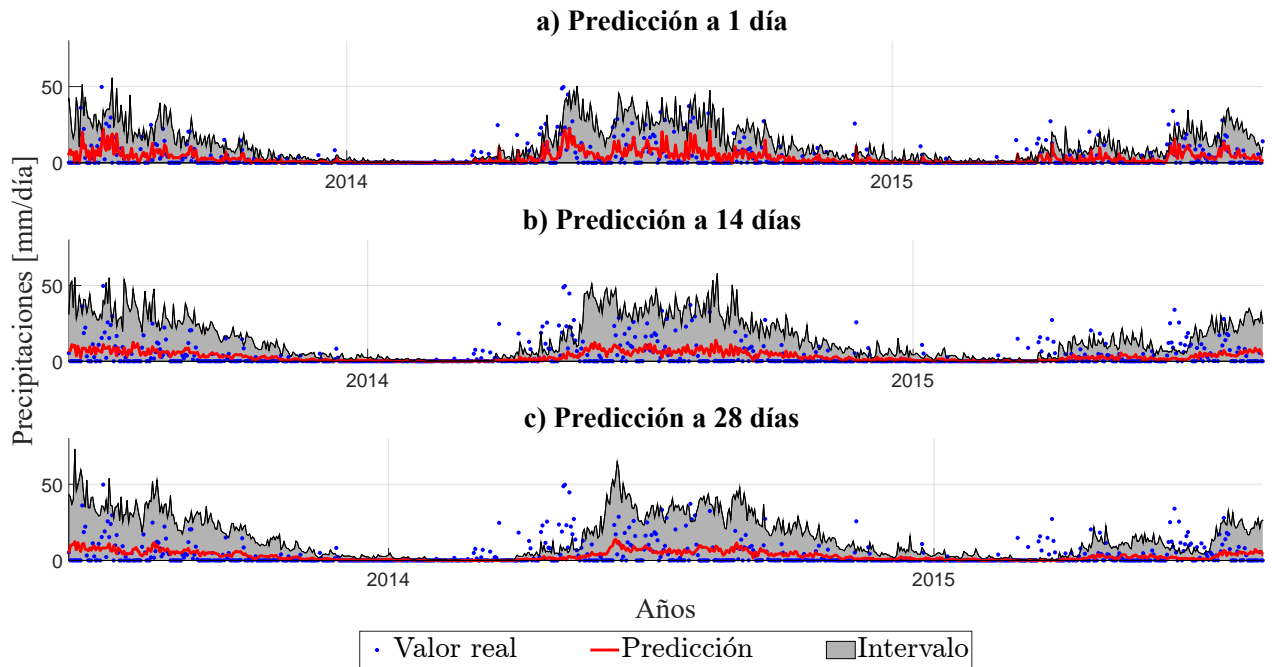


Figura 5.11: Predicción e intervalo de las precipitaciones a distintos pasos de predicción

De la figura 5.11 se observa que el valor esperado a 1 día de predicción logra seguir adecuadamente la forma de las precipitaciones, siendo alta en periodos de invierno y cercana a cero en verano. No obstante, para 14 y 28 días de predicción, el valor esperado se ve atenuado con respecto a los valores reales de precipitaciones, debido a que el error que se propaga al predecir iterativamente no permite estimar correctamente el valor real. Sobre el intervalo de predicción obtenido, se puede notar que la banda inferior se encuentre siempre en cero, dada la gran cantidad de datos reales que presentan valores cercanos a este número. Debido a esto, el intervalo obtenido para las precipitaciones y en particular la banda inferior, que corresponde al peor caso de precipitaciones \hat{P} dentro del WMS (ver sección 4.4.2), no resulta muy informativo con respecto a la incerteza de esta variable, al ser siempre nulo incluso en periodos de invierno. Por esta razón se utilizan también tres casos extras, considerados análogos a la banda inferior, correspondiendo al valor esperado de las precipitaciones, escaladas en un 75 %, 50 % y 25 %, como se observa en la figura 5.12.




Figura 5.12: Predicciones de precipitaciones a 28 días para cada experimento

De la figura 5.12, se pueden notar 5 escenarios para las precipitaciones: El valor esperado del modelo AR, tres valores escalados y la banda inferior, los que se aplican en el sistema de gestión de agua, como se muestra en la ecuación (4.27).

Dado que las predicciones obtenidas para las precipitaciones no siguen correctamente la dinámica de los datos reales a varios pasos de predicción, como se observa en la figura 5.11, se opta por no utilizar este modelo como variable exógena al entrenar los modelos que estimen la recarga, para no propagar el error del modelo de precipitación a este. Conforme a esto, para estimar la recarga de la cuenca se utilizan modelos Takagi-Sugeno, AR y una media móvil (MM), esta última con una ventana de 7 días para calcular la predicción. Se utiliza una ventana de 7 días, ya que se considera que las condiciones climáticas diarias no mantendrán una tendencia pasada una semana, por lo que una ventana mayor no permitiría seguir correctamente la dinámica de estas variables. Luego, la figura 5.13 muestra el comportamiento de cada modelo y la tabla 5.5 expone las métricas obtenidas en cada predicción, para cada modelo estudiado de la recarga.




Figura 5.13: Comparación de las predicciones a 28 días de la recarga utilizando modelos Takagi-Sugeno, AR y Media Móvil.

Tabla 5.5: Comparación de modelo Takagi-Sugeno, AR y Media Móvil para la recarga obtenida en 5.3 a distintos horizontes de predicción

Horizonte de predicción	Métricas	Modelos		
		T&S	AR	MM
1 día	RMSE [$mm/día$]	4.183	4.249	4.563
14 días	RMSE [$mm/día$]	5.364	4.729	5.358
28 días	RMSE [$mm/día$]	5.318	4.773	5.381

De la tabla 5.13, se puede notar que el modelo AR alcanza un RMSE menor a un horizonte de predicción mayor, en comparación a los modelos T&S y MM, no obstante, de la figura 5.13, se observa que la predicción obtenida por este modelo AR resulta la más baja en magnitud. Por esto, se analiza también el valor acumulado de la recarga a través de la curva doble másica, como se muestra en la figura 5.14.




Figura 5.14: Curva doble mágica para los modelos Takagi-Sugeno, AR y Media Móvil para la recarga a 28 días.

La figura 5.14 muestra que las predicciones realizadas con una media móvil (MM) alcanza una recarga acumulada más cercana a la real, en comparación al modelo AR o T&S, a pesar de presentar un RMSE mayor. Esto se debe a que las predicciones por media móvil presentan un desfase constante en sus predicciones con respecto a los datos reales al promediar los valores pasados, y por la misma razón, su predicción acumulada se acerca más a la real. A partir de lo anterior, y considerando que la recarga no afecta directamente el riego de los cultivos, se prioriza un modelo con más precisión sobre la recarga total que la predicción diaria. Por esto, se eligen las predicciones mediante media móvil como las más adecuadas para utilizar en conjunto al controlador.

Utilizando el modelo de media móvil (MM) para realizar las predicciones, la figura 5.15 muestra el desempeño de estas, en conjunto al intervalo de predicción construido mediante números difusos.

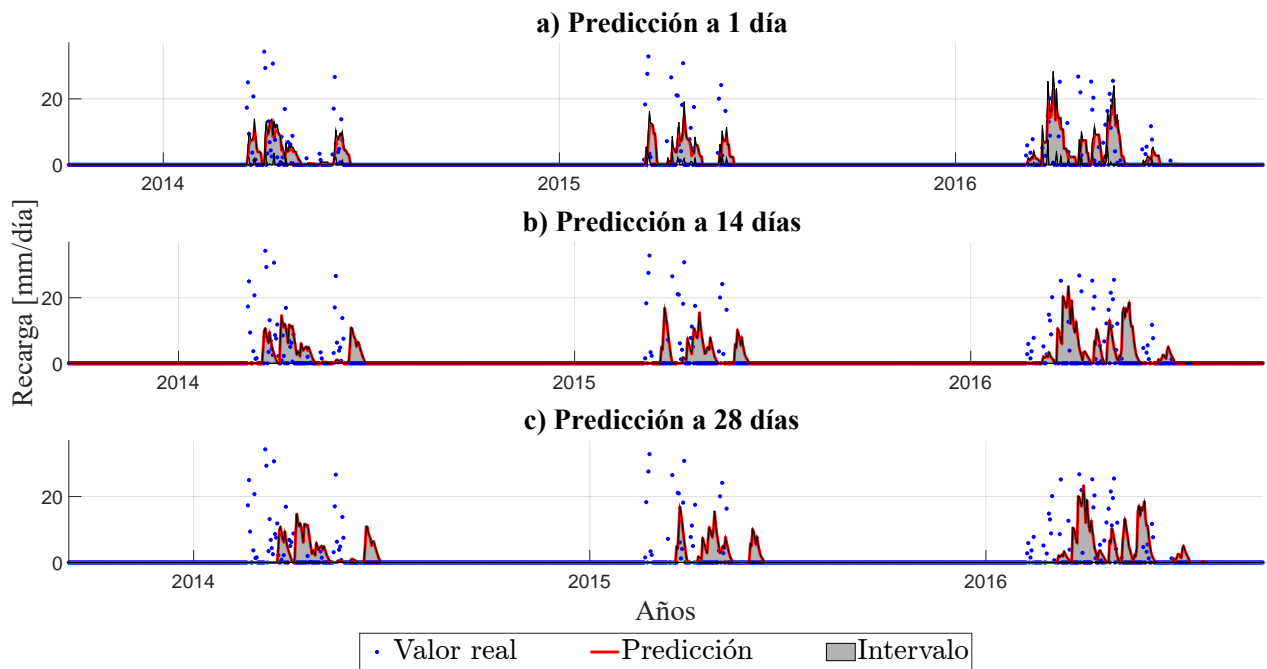


Figura 5.15: Predicción e intervalo de la recarga a distintos pasos de predicción

De la figura 5.15 se observa que la predicción del valor esperado a 1 día es capaz de seguir la dinámica de la recarga, siendo mayor a cero solo en ciertos periodos del año, no obstante, mientras aumentan los pasos de predicción, se nota un retardo con respecto a los valores reales, debido a que el modelo en base a una media móvil promedia los nuevos datos con 7 muestras pasadas, lo que retrasa el cambio en la dinámica al empezar y terminar los eventos de recarga. Sobre el intervalo obtenido para la recarga, de la figura 5.15, se observa que la banda superior se encuentra muy cercana al valor esperado, esto se debe a que, como la mayoría de los valores reales son cero, para alcanzar un PICP de 90 %, basta con cubrir estos valores. Por esta razón, la banda inferior se encuentra siempre en cero, similar al intervalo obtenido para las precipitaciones, por lo que el peor caso de la recarga \hat{R}_{aq} tampoco resulta informativo con respecto a las incertezas de esta variable. Debido a lo anterior, también se consideran tres casos extras para caracterizar la incerteza de la recarga \hat{R}_{aq} , correspondiendo a escalar su valor esperado hasta un 75 %, 50 % y 25 %, al igual que con las precipitaciones.

La tabla 5.6 muestra las métricas obtenidas de los modelos de radiación solar, temperatura ambiente, velocidad del viento, precipitaciones y recarga. Para analizar el desempeño de las predicciones se utiliza el RMSE y para el intervalo el PICP y PINAW.

Tabla 5.6: Rendimiento de los modelos a mediano plazo en distintos pasos de predicción

Modelo	Métricas	Horizonte de predicción		
		1 día	14 días	28 días
Radiación Solar	RMSE [W/m^2]	87.52	91.73	91.6
	PICP [%]	84	84	84
	PINAW [%]	72	73	73
Temperatura ambiente	RMSE [$^{\circ}C$]	1.61	1.84	1.95
	PICP [%]	89	86	86
	PINAW [%]	21	25	26
Velocidad del viento	RMSE [m^2/s]	1.84	1.98	2
	PICP [%]	91	92	92
	PINAW [%]	58	59	61
Precipitaciones	RMSE [$mm/día$]	6.82	7.12	7
	PICP [%]	90	89	89
	PINAW [%]	24	28	31
Recarga	RMSE [$mm/día$]	4.563	5.358	5.381
	PICP [%]	91	92	91
	PINAW [%]	2	2	2

De la tabla 5.6 se observa que el RMSE de la radiación solar R_s , temperatura ambiente T_a , velocidad del viento u_2 , precipitaciones P y recarga R , no presentan un aumento considerable al incrementar los pasos de predicción, presentando un incremento máximo del 20 % del RMSE, correspondiente a la temperatura ambiente. Esto se debe a que, a mediano plazo, los valores reales corresponden a un promedio diario, por lo que el efecto de las perturbaciones de corta duración que afectan a estas variables se ve atenuado, en comparación al corto plazo, donde las mismas perturbaciones pueden afectar a más de una muestra y, por lo tanto, impactar más notablemente el desempeño de las predicciones.

Con respecto a los intervalos de predicción obtenidos, de la tabla 5.6 se observa que el ancho del intervalo para la radiación solar R_s es 1.8 veces más grande al obtenido en el corto plazo (ver tabla 5.3). Esto se debe a que, como a mediano plazo se considera más de un año en los datos de entrenamiento, para alcanzar el 90 % de cobertura, el intervalo debe contener tanto datos de periodos de invierno como de verano, los que presentan dinámicas distintas, según la figura 5.6, donde el valor esperado tiende al promedio de los datos y, por lo tanto, el PINAW aumenta para cubrir esta alta variabilidad. Este fenómeno también se observa para la temperatura ambiente T_a , pero en este caso el intervalo presenta un ancho más acotado, según la tabla 5.6), ya que las variaciones de datos en periodos de invierno y verano es menor comparado a la radiación solar (desviación de un 20 % del promedio de los datos para T_a y de un 54 % para R_s).

Sobre los intervalos de predicción para la velocidad del viento u_2 , de la tabla 5.6 se observa que, a pesar de que se alcanza el 90 % de cobertura deseado, presenta un PINAW promedio

de 59%, siendo más del doble respecto a la temperatura ambiente T_a o a las precipitaciones P (24% y 28% respectivamente), esto se debe a la alta variabilidad que presenta esta señal, cuya desviación con respecto a su media es del 45%, y al comportamiento del valor esperado, que como se mencionó anteriormente, tiende al promedio de los datos (ver figura 5.8).

En el caso de las precipitaciones, de la tabla 5.6, se observa que se alcanza el porcentaje de cobertura deseado (90%), en conjunto a un PINAW menor al obtenido para R_s o u_2 , a pesar de que el valor esperado no logra seguir correctamente la dinámica, como se mencionó al analizar la figura 5.11. Lo anterior se debe al comportamiento esporádico de la lluvia, donde en periodos de verano el promedio de esta se encuentra cerca del cero y en periodos de invierno el promedio aumenta considerablemente, como se observa de la figura 5.11. Este comportamiento estacional permite que el ancho del intervalo obtenido sea más angosto en ciertos periodos, reduciendo el valor del PINAW en general.

Similar al anterior, el intervalo de recarga también presenta un ancho bajo en relación con el resto de variables, como se observa de la tabla 5.6, alcanzando un PINAW de apenas el 2% para una cobertura superior al 90%. El motivo de esto es una estacionalidad similar a la presente en las precipitaciones, pero más notorio, como se observa de la figura 5.15, donde los eventos de recarga solo ocurren una vez a mediados de año. Por esto, el ancho del intervalo se encuentra cercano a cero en la mayoría de las muestras, lo que reduce considerablemente el PINAW obtenido para todo el conjunto de validación.

En base a los modelos de predicción e intervalos descritos anteriormente, se explican los experimentos a realizar para probar el desempeño del sistema de gestión de agua y energía.

5.2.5. Experimentos propuestos

Para probar el desempeño del controlador se proponen seis experimentos basados en los modelos seleccionados en la sección anterior.

1. **EWMS con predicciones reales (EWMS-PR)**: Este experimento considera utilizar los valores futuros reales dentro del controlador para obtener una acción de control que no se vea afectada por las incertezas de las condiciones climáticas. Para esto, se asume que es posible predecir con perfecta precisión la radiación solar R_s , temperatura ambiente T_a , velocidad del viento u_2 , precipitaciones P y recarga R_{aq} . Este escenario se utiliza como *benchmark* para comparar el desempeño de los demás experimentos propuestos y analizar el impacto en la calidad de la predicción sobre el controlador.
2. **EWMS Convencional (EWMS)**: Este experimento corresponde a utilizar el valor esperado de los modelos de predicción, descritos en la sección anterior, dentro del controlador. Esto es, el valor esperado de \hat{R}_s y \hat{T}_a a corto y mediano plazo, y \hat{u}_2 , \hat{P} y \hat{R}_{aq} a mediano plazo.
3. **EWMS Robusto (R-EWMS-PZ)**: Este experimento corresponde a aplicar el peor caso de las variables climáticas en el EWMS, para incluir sus incertezas en las decisiones que toma el controlador para realizar la gestión de agua y energía. Según lo explicado en la sección 4.4.1, para aplicar el control robusto se utilizan el intervalo inferior $\underline{\hat{R}}_s$ y el intervalo superior $\overline{\hat{T}}_a$ para la radiación solar y temperatura ambiente a corto plazo,

respectivamente, y el intervalo superior $\overline{\hat{R}_s}$, $\overline{\hat{T}_a}$ y $\overline{\hat{u}_2}$ para la radiación solar, temperatura ambiente y velocidad del viento a mediano plazo respectivamente; y el intervalo inferior $\underline{\hat{P}}$ y $\underline{\hat{R}_{aq}}$ para las precipitaciones y recarga a mediano plazo, respectivamente.

4. **EWMS Robusto con precipitaciones al 75 % (R-EWMS-P75)**: Este experimento corresponde a utilizar los intervalos de los modelos para definir el peor caso de las variables climáticas mencionadas en el escenario R-EWMS-PZ, a excepción de las precipitaciones P y recarga del acuífero R_{aq} , que se calculan como el 75 % del valor esperado obtenido a partir de sus modelos de predicción.
5. **EWMS Robusto con precipitaciones al 50 % (R-EWMS-P50)**: Este experimento considera los mismos intervalos que el R-EWMS-PZ, ahora utilizando el 50 % del valor esperado de las precipitaciones y recarga.
6. **EWMS Robusto con precipitaciones al 25 % (R-EWMS-P25)**: Similar al anterior, este experimento considera los mismos intervalos que el R-EWMS-PZ, pero utilizando el 25 % del valor esperado para las precipitaciones y recarga.

5.2.6. Resultados del sistema de gestión de agua

A continuación, se muestran los resultados obtenidos el sistema de gestión de agua (WMS) para cada experimento propuesto.

El rendimiento relativo de todos los cultivos en conjunto al volumen de riego de referencia para cada experimento se observa en la figura 5.16. Además, considerando estos volúmenes de referencia, el agua utilizada por cada experimento, en conjunto a la recarga del acuífero para ese periodo, se encuentran en la figura 5.17. Finalmente, la tabla 5.7 resume los resultados obtenidos por cada experimento dentro del sistema de gestión de agua WMS. En esta tabla se observa el rendimiento relativo más bajo obtenido en cada experimento, las ganancias obtenidas al vender los cultivos luego de cosechar, y el volumen de agua total utilizado durante toda la operación.

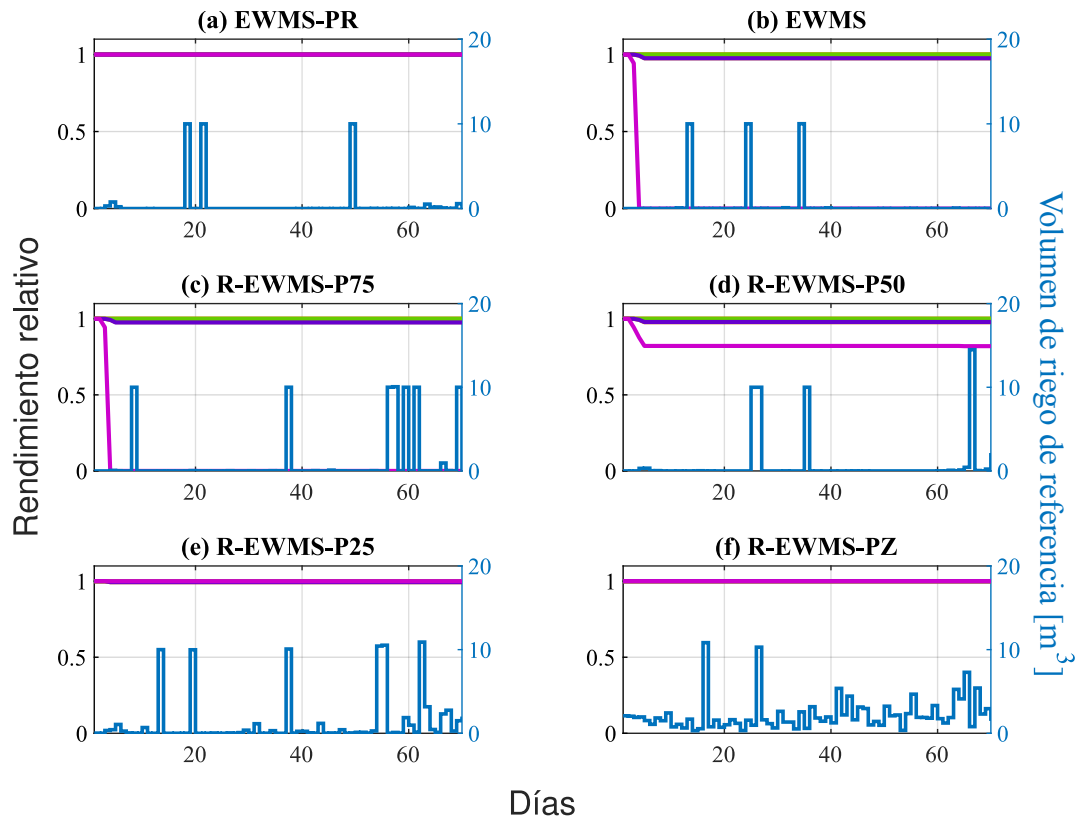


Figura 5.16: Rendimiento relativo de los cultivos y volumen de riego de referencia para 70 días de simulación de cada experimento




Figura 5.17: Agua estimada disponible en el acuífero para cada experimento (en diferentes colores) y recarga estimada.

Tabla 5.7: Resultados del WMS para los distintos experimentos propuestos

Experimento	Rendimiento relativo mínimo	Ganancia de los cultivos [USD]	Agua total utilizada [m^3]
EWMS-PR	1	2409	33.124
EWMS	0	1557	30.533
R-EWMS-P75	0	1558	71.478
R-EWMS-P50	0.8202	2274	48.314
R-EWMS-P25	0.9940	2409	98.495
R-EWMS-PZ	1	2409	215.545

Se puede notar de la figura 5.16.a, que al considerar predicciones con datos reales, el EWMS-PR logra un rendimiento máximo para todos los cultivos, utilizando menos agua en comparación a los otros escenarios. Esto se debe a que al conocer precisamente los días en que precipitará, el controlador es capaz de compensar adecuadamente solo cuando no ocurre lluvia. Por otro lado, se observa que el EWMS a pesar de definir un volumen de riego de referencia similar en magnitud al EWMS-PR (ver tabla 5.7) no logra mantener a todos los cultivos en su máximo rendimiento, en particular, el cultivo asociado a la cebolla (línea fucsia) se marchitó luego de 5 días. Esto ocurre porque el valor esperado del modelo de precipitaciones no logra definir con precisión que días lloverá y que días no, por lo que el controlador no logra coordinar la frecuencia del riego con las precipitaciones, obteniendo un riego nulo en días donde no llueve.

Sobre los escenarios donde se utilizan los intervalos de predicción, de la figura 5.16 se observa que el R-EWMS-P75 obtiene un volumen de riego de referencia mayor al EWMS, dado que sus predicciones de precipitaciones son menores, pero aun así no mantiene los cultivos en un rendimiento máximo, dado que esta reducción en la lluvia no es suficientemente grande como para compensar la falta de precisión en las predicciones. Por otro lado, el R-EWMS-P50 si logra evitar que los cultivos se marchiten (manteniendo sus rendimientos mayores a cero) al considerar predicciones de lluvia aún menores, permitiendo compensar mejor la falta de precisión, sin embargo, en la tabla 5.7 se muestra que el cultivo con menor rendimiento del R-EWMS-P50 sigue siendo menor al EWMS-PR, por lo que el volumen de referencia que se encontró para este escenario no es el óptimo.

Refiriéndose a los últimos dos escenarios, en la figura 5.16 se observa que, tanto el R-EWMS-P25 como el R-EWMS-PZ, logran mantener el rendimiento de los cultivos muy cerca o en su máximo (0.99 y 1 para el cultivo con peor rendimiento respectivamente) mostrando que reducir las predicciones de precipitaciones a un 25% o cero si permite compensar la imprecisión de las predicciones, no obstante, esta reducción aumenta el uso de agua considerablemente en comparación al EWMS-PR, que representa el mejor control posible. Esto se observa mejor en la figura 5.17 y la tabla 5.7, donde que el R-EWMS-P25 obtiene un volumen de referencia total 3 veces mayor al EMWS-PR y el R-EWMS-PZ un volumen 7 veces mayor.

A pesar de lo anterior, de la figura 5.17, se observa que el volumen de agua disponible al final de los 70 días de simulación se encuentra sobre el valor inicial de 1000 [m^3] para todos los escenarios, mostrando que el controlador implementado, en cada uno de los experimentos,

presenta un uso de agua sustentable en comparación a los eventos de recarga que ocurrieron. De esta forma, tanto el R-EWMS-P25 como el R-EWMS-PZ corresponden a soluciones aceptables en términos de rendimiento relativo alcanzado y uso de agua utilizado (ver tabla 5.7), donde el R-EWMS-P25 representa el punto en la disminución de las precipitaciones donde el rendimiento de los cultivos es menos del 5% menor al valor máximo, con un volumen de agua total menor que el peor caso.

Por otro lado, de la figura 5.16 y 5.17 se observa que los cambios más notorios en el volumen de agua utilizada y el rendimiento de los cultivos ocurren al modificar la predicción tanto de las precipitaciones P como la recarga R_{aq} , dado que estas variables modifican directamente el volumen de riego necesario para el crecimiento óptimo de los cultivos. De la misma forma, la radiación solar R_s , temperatura ambiente T_a y velocidad del viento u_2 a mediano plazo, consideradas en el sistema de gestión agua-energía, también generan un impacto en el volumen de riego. Lo anterior se observa de la ecuación 4.10, ya que al considerar los peores casos \widehat{R}_s , \widehat{T}_a y \widehat{u}_2 , se aumenta la evapotranspiración de referencia para cada cultivo, incrementando su demanda hídrica, como se observa al comparar el volumen de referencia definido por el controlador para el EWMS-PR y R-EWMS-P75 (ver tabla 5.7), ya que estos escenarios presentan precipitaciones acumuladas de similar magnitud, pero el R-EWMS-P75 requiere de más agua al considerar condiciones climáticas más extremas, por utilizar el peor caso de las variables mencionadas anteriormente.

Luego de analizar el desempeño del sistema de gestión de agua, se analizan los resultados obtenidos para el sistema de gestión de energía EMS.

5.2.7. Resultados del sistema de gestión de energía considerando la demanda hídrica del WMS

Para mostrar el desempeño del sistema de gestión de energía, se eligen solo cuatro escenarios, correspondientes al EWMS-PR y EWMS para contar con casos de comparación al utilizar predicciones precisas en el primero y utilizar el valor esperado en el segundo, y los casos robustos R-EWMS-P25 y R-EMWS-PZ, al presentar el mejor desempeño de los escenarios robustos analizados en la sección 5.2.6.

A partir de los cuatro escenarios mencionados anteriormente, la figura 5.18 muestra el estado de carga de los bancos de baterías, según la operación del EMS para los 70 días de simulación en cada experimento. Además, la figura 5.19 presenta la energía comprada y vendida por la micro-red, según la operación del EMS y las perturbaciones asociadas al sistema, siendo el consumo eléctrico residencial y la generación solar, para un periodo arbitrario de 3 días de simulación. El uso de las bombas se puede apreciar en la figura 5.20 y 5.21, donde en la primera se muestra la suma de la potencia utilizada por las bombas de cada sistema hidrogeológico, en cada escenario, y la segunda muestra un acercamiento de esta señal para analizar mejor su forma. Finalmente, en la tabla 5.8 se expone un resumen de los resultados obtenidos en cada experimento, donde se considera la energía total comprada por la micro-red durante todo el periodo de operación, la energía total vendida por la micro-red en este periodo y la energía total consumida por las bombas de extracción en los 70 días de simulación.




Figura 5.18: Estado de carga de los bancos de baterías para cada experimento (en distintos colores).

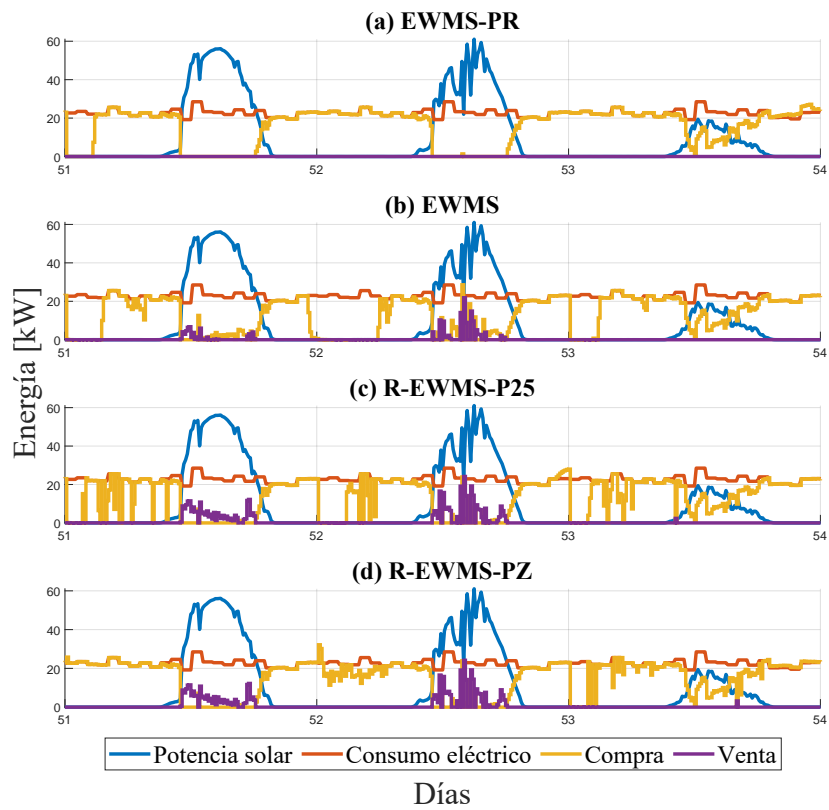


Figura 5.19: Energía en la micro-red para cada experimento propuesto.

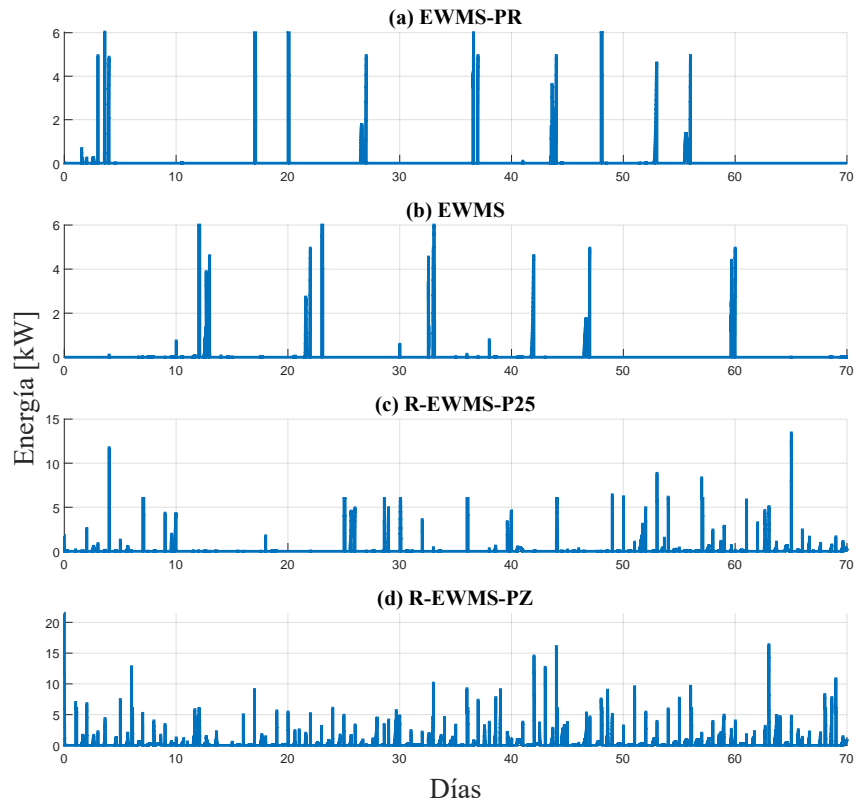


Figura 5.20: Uso de la bomba de extracción según su potencia.




Figura 5.21: Uso de la bomba de extracción según su potencia (acercamiento en distintos periodos de la figura 5.20).

Tabla 5.8: Resultados del EMS para los distintos experimentos propuestos

Experimento	Energía comprada [kW]	Energía vendida [kW]	Energía total de las bombas [kW]
EWMS-PR	154,891	296	727
EWMS	156,543	4,857	684
R-EWMS-P25	159,163	7,279	1,303
R-EWMS-PZ	160,660	7,397	3,018

De la figura 5.18, se observa que para todos los escenarios, las baterías se cargan y descargan constantemente durante los 70 días de simulación, por lo que en ningún caso se alcanzan los límites superiores e inferiores impuestos. Además, se nota que el EWMS es el que alcanza un estado de carga menor en todos los casos debido a que, como las predicciones de la radiación solar en algunos casos es mayor al valor real (ver figura 5.4), se sobrestima la capacidad de cargar la batería. Por otro lado, el R-EWMS-P25 y el R-EWMS-PZ muestran un estado de carga mayor durante toda la simulación, debido a que, como ambos escenarios sub-dimensionan la potencia solar diaria, mantienen un estado de carga más alejado de los límites, compensando las incertezas que se presentan en la señal real. Esta subestimación se observa mejor en la figura 5.4, donde el intervalo inferior (correspondiente al peor caso \hat{R}_s) se mantienen siempre por debajo de los valores reales de la radiación solar, obteniendo una potencia solar menor a la efectiva cada 10 minutos. De la misma forma, el EWMS-PR obtiene el estado de carga mayor y como mayor variabilidad, ya que en este caso, se puede conocer precisamente la radiación solar futura \hat{R}_s , permitiendo utilizar los bancos de batería con más libertad.

De la figura 5.19, se observa que el EWMS-PR decide comprar energía solo por las noches, cuando no hay generación solar, y busca compensar el consumo eléctrico residencial. Además, al poder coordinar correctamente el uso de baterías, en la mayoría de la simulación no necesita vender energía sobrante, como se observa en la tabla 5.8. Por otro lado, el resto de los experimentos venden energía constantemente y en periodos donde si existe generación solar. Esto se debe a que, como en estos escenarios las predicciones no son exactamente los valores reales, al final de cada optimización la micro red presenta energía sobrante o faltante, la que se debe vender cuando se subestima la generación o comprar cuando se sobrestima. En particular, de la tabla 5.8, se observa que tanto la energía comprada como la vendida aumentan al considerarse escenarios con un consumo de agua mayor, como lo son el R-EWMS-P25 y el R-EWMS-PZ, debido a que, como aumenta el consumo al necesitar extraer más agua con las bombas, se opta por comprar la energía inmediatamente y cumplir con la demanda de riego, para luego vender la energía que no se utilizó.

Similar a lo anterior, en la figura 5.20 se observa que la bomba se utiliza más a medida que se requiere más agua para el riego, como es para el R-EWMS-P25 y R-EWMS-PZ, utilizando hasta 4 veces más energía, como se observa de la tabla 5.8. Sin embargo, al comparar el uso del agua y energía utilizada por las bombas, entre el EWMS-PR y el R-EWMS-PZ, se puede notar que al necesitar 7 veces más agua para regar los cultivos, se necesita solo 3 veces más energía, según se muestra en las tablas 5.7 y 5.8 respectivamente, por lo que al considerar

más cultivos, el uso de energía no debiese aumentar linealmente.

Por otro lado, de la figura 5.21 se observa que el uso de las bombas de extracción en cada escenario presenta un comportamiento más suave que una acción de encendido-apagado, mostrando que considerar una bomba capaz de entregar un caudal variable en el tiempo obtendrá una vida útil más larga que una bomba convencional.

5.3. Discusión

En este capítulo se muestra tanto el caso de estudio considerado, junto a las constantes definidas y parámetros de cada sistema, como los resultados obtenidos por los modelos de predicción y por el controlador en distintos escenarios.

Para realizar el análisis, se exponen los resultados obtenidos en cada etapa del estudio: El cálculo de los parámetros del acuífero, cálculo de la recarga, modelos e intervalos de predicción para las variables climáticas y el sistema de gestión de agua y energía. En primer lugar, se utiliza el ensayo de bombeo descrito para estimar la transmisividad y almacenamiento a través del método de Cooper-Jacob para acuíferos confinados, parámetros que se utilizan en el cálculo del descenso en el nivel de agua de cada pozo. Con respecto a la recarga, primero se aplica el filtro de Eckhardt para estimar la escorrentía histórica E_s de la cuenca en estudio, la que se utiliza en conjunto a las precipitaciones P , evapotranspiración potencial ET_p y riego I , para estimar la recarga de la cuenca y así conocer el volumen de agua disponible para la operación del sistema de gestión.

A continuación se muestra el desempeño obtenido por los modelos difusos e intervalos de predicción para las variables climáticas a corto y mediano plazo. Con respecto al corto plazo, se muestra que los modelos obtenidos para la radiación solar R_s y temperatura ambiente T_a obtienen un buen desempeño en términos de RMSE, donde este valor aumenta a medida que se predice más a futuro. Además, se detalla que los intervalos de predicción obtenidos para estas variables permiten caracterizar correctamente las incertezas presentes, al obtener porcentajes de cobertura al 90 % definido durante su entrenamiento. Con respecto a las variables de mediano plazo, los modelos obtenidos para la radiación solar R_s , temperatura ambiente T_a y velocidad del viento u_2 presentan un desempeño aceptable al evaluar su valor esperado a 28 días a futuro. En particular, los modelos de R_s y T_a logran captar la estacionalidad que presenta cada señal, al predecir correctamente los cambios en la dinámica a lo largo de varios años. Sobre los intervalos obtenidos para estas variables, en todos los casos se obtiene un porcentaje de cobertura cercano a 90 %, con anchos acorde a la desviación estándar de cada variable, por lo que se considera que estos intervalos son aceptables para caracterizar las incertezas presentes en estas señales. En el caso de las precipitaciones P y recarga R_{aq} , se prueban modelos basados en Takagi y Sugeno y modelos autorregresivos (AR) para predecir su valor esperado, buscando el equilibrio entre obtener un bajo RMSE y un valor acumulado lo más cercano posible al valor real. En base a lo anterior se utiliza un modelo AR para las precipitaciones y uno basado en una media móvil para la recarga. Los intervalos de predicción obtenidos para estas variables alcanzan un 90 % de cobertura, al igual que para la radiación solar, temperatura ambiente y velocidad del viento, con la excepción que la banda inferior de su intervalo se encuentra siempre en cero, por esta razón se opta por considerar casos inter-

medios para representar el peor caso, correspondientes al 75 %, 50 % y 25 % del valor esperado.

Utilizando los modelos e intervalos descritos anteriormente, se prueba el sistema de gestión de agua y energía bajo seis escenarios, que varían según las predicciones utilizadas. Los escenarios corresponden a utilizar datos reales como predicción (EWMS-PR), el valor esperado de los modelos obtenidos (EWMS), los peores casos correspondientes a las bandas de los intervalos de predicción (R-EWMS-PZ) y los peores casos para la radiación solar, temperatura ambiente y velocidad del viento, en conjunto a los tres casos intermedios para las precipitaciones y recarga (R-EWMS-P75, R-EWMS-P50 y R-EWMS-P25). A partir de los resultados obtenidos en cada escenario, se concluye que incluir las incertezas de las variables climáticas dentro del sistema de gestión, permite encontrar acciones de control que aseguren un crecimiento óptimo de cada cultivo, al presentar un rendimiento relativo cercano al caso donde se utilizan predicciones a partir de datos reales, a costa de un consumo de agua mayor. Además, se nota que al considerar predicciones intermedias para las precipitaciones y recarga, permite encontrar una operación que asegura un crecimiento correcto de los cultivos, utilizando un volumen de agua menor en comparación al escenario del peor caso, ya que este último utiliza predicciones de precipitación y recarga poco probables. Por otro lado, los resultados obtenidos permiten concluir que la variable que más influye en la operación son las precipitaciones, ya que impactan directamente en el agua que debe destinarse al riego, no obstante, la radiación solar, temperatura ambiente y velocidad del viento también muestran un impacto en el volumen de agua necesario, ya que al considerar el peor caso, este volumen aumenta. Con respecto al volumen de agua utilizado en la simulación, se muestra que el sistema de gestión, en todos los escenarios, utiliza menos agua de la que se recarga en el periodo estudiado, demostrando que esta propuesta evita la sobreexplotación del acuífero.

En relación a los resultados obtenidos por el sistema de gestión de energía, que utiliza el resultado del WMS como entrada, se muestra que los escenarios robustos manejan la energía de manera más conservativa que al utilizar el valor esperado como predictor, ya que al considerar menos energía disponible durante el día, optan por comprar y vender más energía para que el estado de carga de los bancos de baterías no se acerque a los límites mínimos y máximos establecidos. Por esta razón, los escenarios robustos alcanzan un costo de operación mayor al escenario donde se cuenta con predicciones precisas. Por otro lado, al analizar la extracción de agua definida por el sistema de gestión, se observa que en todos los casos el uso de estas bombas es menos abrupto al compararlo con bombas de acción binaria, mostrando que el sistema de gestión de energía-agua es capaz de cumplir con la demanda hídrica definida, mientras se prolonga la vida útil de los actuadores.

6. Conclusiones

En esta tesis se diseñó e implementó por simulación un sistema de gestión de agua y energía basado en control robusto para cultivos a campo abierto.

En la primera parte del trabajo se caracteriza el sistema hidrogeológico que permite modelar las distintas dinámicas presentes en el uso del agua. Para esto se realizó un balance hídrico sobre la cuenca en estudio, considerando las precipitaciones de la zona, riego de cultivos, escorrentía, evapotranspiración potencial y recarga. Este balance permitió aislar las interacciones del agua en la cuenca y así poder estimar los eventos de recarga a lo largo del tiempo y conocer el agua disponible destinada al riego. Los parámetros del acuífero (Transmisividad y Almacenamiento) se aproximaron al estudiar los ensayos de bombeo realizados en la zona, para así obtener valores más afines al lugar donde se realiza el trabajo. De este desarrollo se mostró que es posible estimar la recarga de la cuenca a través de las ecuaciones fenomenológicas correspondientes al balance hídrico. Además, se generan datos entrada/salida para entrenar algún tipo de modelo de predicción, evidenciando la utilidad de este modelamiento, obteniéndose una buena aproximación del recurso hídrico, para definir restricciones adecuadas en el desarrollo del sistema de control. De la misma forma, al aproximar los parámetros del acuífero, se estima el descenso del nivel de agua en los pozos, permitiendo definir límites a la extracción, que aseguren que no se perturbará de gran manera el nivel de los pozos cercanos al área de estudio.

A partir del análisis del sistema hidrogeológico presentado, se estudió el crecimiento de los cultivos a través del cálculo de su evapotranspiración real, considerando las condiciones climáticas, como lo son la radiación solar, temperatura ambiente, velocidad del viento y precipitaciones; los parámetros intrínsecos de estos cultivos, como el coeficiente de cultivo y sensibilidad frente a un déficit de agua; y las propiedades del suelo donde se encuentran. Esto permitió estimar la demanda de riego necesaria por cada cultivo que asegure un crecimiento óptimo en un intervalo de tiempo definido. Se destaca la versatilidad de esta propuesta, ya que permite caracterizar cualquier cultivo, mientras se encuentren las constantes más afines a estos.

De la misma forma, se modeló el sistema eléctrico como una micro-red, que cuenta con generación fotovoltaica, bancos de baterías y una conexión a la red para la obtención de energía, y bombas de extracción en conjunto a una demanda eléctrica residencial que cuenta como consumo. Para conocer la magnitud de la generación solar y el comportamiento de los bancos de baterías y las bombas, se utilizaron ecuaciones fenomenológicas que describen la potencia generada en caso de los paneles solares, la energía consumida/entregada y el estado de carga en el caso de las baterías, y la potencia consumida por la bomba de extracción. Se

destaca la utilidad de las ecuaciones utilizadas, ya que permiten estimar la generación solar, estado de carga de las baterías y consumo de las bombas directamente de las acciones de control y modelos de predicción, requiriendo un bajo esfuerzo computacional.

Considerando el modelamiento realizado, se diseñó un sistema de gestión de agua y energía basado en control predictivo robusto. Dado que las constantes de tiempo del modelo hidrogeológico y eléctrico difieren considerablemente, el sistema de gestión se dividió en dos subsistemas. El primero corresponde al sistema de gestión de agua WMS, encargado de definir una demanda hídrica diaria para el riego de los cultivos, que maximice su crecimiento. Además, el WMS impone que la demanda hídrica total, en una ventana de 28 días, no debe superar a la recarga total dentro del mismo periodo, para lograr que el consumo de agua sea siempre menor a la tasa de renovación del agua subterránea. Por otro lado, el segundo subsistema corresponde al sistema de gestión de energía EMS, el cual administra, el uso de las bombas de extracción y define un horario de riego para seguir la demanda hídrica diaria entregada por el WMS. Estas acciones de control se obtienen al minimizar la función de costos del sistema de gestión de energía, los costos operacionales de la micro-red, y los cambios bruscos del uso de la bomba y las horas de riego. El EMS también limita el estado de carga de las baterías, para alargar su vida útil, define un caudal de extracción máximo para no aumentar el cono de descenso de los pozos considerablemente, y mantiene el balance de energía en la micro-red, igualando el consumo de energía a la generación. Al considerar este esquema de control es posible analizar tanto los fenómenos hídricos como eléctricos de manera simultánea, lo que permite optimizar ambos recursos, a pesar de que sus dinámicas se encuentren en escalas distintas.

Para modelar el comportamiento e incertezas de la radiación solar, temperatura ambiente y velocidad del viento, se utilizaron modelos difusos Takagi-Sugeno y modelos autorregresivos con intervalos de predicción basados en números difusos. Para el EMS se construyeron modelos e intervalos para la radiación solar y temperatura a 10 minutos, considerando predicciones hasta 48 horas, utilizando modelos difusos T&S. Para el WMS, se construyeron modelos de radiación solar, temperatura y velocidad del viento diaria, con predicciones máximas de 28 días, utilizando modelos T&S. Por otro lado, el modelo de las precipitaciones diarias fue realizado con un modelo AR y para la recarga con un modelo de media móvil. Al evaluar el desempeño de cada modelo, en conjunto con el intervalo de predicción construido, se mostró que es posible caracterizar la dinámica e incertezas de estas condiciones climáticas, al obtener errores de predicción aceptables y porcentajes de cobertura cercanos al 90%. Se puede notar, a partir del buen desempeño obtenido, que los modelos T&S y los intervalos a partir de números difusos permiten modelar la dinámica no lineal e incertezas de las variables consideradas, posibilitando su uso dentro de sistemas de control más complejos, volviéndolos robustos a las incertezas.

Luego de obtener los modelos e intervalos de predicción de cada variable climática, se probaron dos configuraciones para el sistema de gestión agua-energía. El primero corresponde al uso del valor esperado de cada modelo en el controlador, sin tomar en cuenta las incertezas de estas predicciones, llamado *Energy-Water Management System* (EWMS). En el segundo se incluyen las incertezas en el sistema de gestión al considerar el uso del peor caso de cada variable, llamado *Robust Energy-Water Management System* (R-EWMS). Para los modelos relacionados con el EMS, se consideró el peor caso como la banda inferior y superior del

intervalo de la radiación y temperatura respectivamente. Para las variables del WMS, se utilizó la banda superior para la radiación y temperatura, y la banda inferior para la velocidad del viento, precipitaciones y recarga. Dado que el peor caso de las precipitaciones y recarga corresponden a valores nulos, el R-EWMS se probó bajo nuevos escenarios, que consideran una reducción del 75 %, 50 % y 25 % del valor esperado de estas dos variables, llamando a estos controladores R-EWMS-P75, R-EWMS-P50 y R-EWMS-P25, respectivamente. Por último, se consideró un controlador que tuviera acceso al valor futuro real de las condiciones climáticas para utilizarlo como *benchmark*, llamado EWMS-PR.

Con respecto a los resultados obtenidos en la gestión de agua, el EWMS-PR logró mantener los cultivos en un rendimiento máximo, obteniendo una demanda hídrica no nula solo cuando las precipitaciones disminuyeran, utilizando poca agua en comparación a los demás controladores. Por otro lado, el EWMS al utilizar el valor esperado de las precipitaciones para calcular la demanda de riego, no logra coordinar correctamente cuando compensar la falta de lluvia, ya que las predicciones varían notablemente de los valores reales futuros, por esto, a pesar de que el uso de agua es similar al EWMS-PR, el rendimiento de los cultivos disminuye considerablemente. Para los controladores robustos, se observa que entre más se atenúan las predicciones de las precipitaciones, se alcanza un rendimiento más alto para los cultivos, donde con el R-EWMS-P25 y el R-EWMS-PZ, se alcanza el rendimiento máximo. No obstante, a medida que se atenúan las predicciones, el uso de agua aumenta proporcionalmente, ya que el sistema de gestión compensa en mayor medida la falta de precipitaciones. De estos resultados se puede destacar la efectividad del control robusto en la gestión de agua, ya que al considerar las incertezas de las variables climáticas al tomar las decisiones, se pudo alcanzar un rendimiento igual al EWMS-PR, mientras se asegura que el agua utilizada siempre sea menor a la que el acuífero renueva naturalmente, evitando la sobre-explotación del mismo.

En el caso de la gestión de energía, que utiliza el resultado diario del sistema de gestión de agua, se obtienen resultados similares a los descritos anteriormente, donde el EWMS-PR, al contar con predicciones perfectas, logró utilizar correctamente los bancos de baterías, manteniendo su estado de carga alejado de los límites máximos y mínimos. De la misma forma, el R-EWMS-P25 y R-EWMS-PZ mantienen el estado de carga de las baterías más alejado de los límites que el EWMS, ya que al considerar la variabilidad de la radiación solar y temperatura, pueden utilizar los bancos de baterías de forma más conservativa al compararse al EWMS. En este caso, el control robusto permite asegurar que cada componente de la micro-red se mantenga dentro de los límites operacionales impuestos.

En conclusión, del trabajo realizado se observa que considerar el nexo agua-energía-alimento, al diseñar el sistema de gestión de agua y energía EWMS, permite tomar en cuenta las interacciones entre el proceso de cultivos, dinámica del uso del agua y uso de energía como un conjunto, abordando correctamente sus distintos tiempos de respuesta y logrando una operación óptima de los recursos disponibles, la que no hubiera sido posible si se considerara cada fenómeno de forma independiente. Además, se muestra que al considerar las incertezas en el sistema de gestión, se logra alcanzar un desempeño similar a cuando se utilizan predicciones precisas, manteniendo cada variable dentro de los límites definidos, sin la necesidad de conocer perfectamente el comportamiento de las condiciones climáticas de la zona en estudio. A su vez, se logra una implementación a tiempo real del sistema de gestión de agua y energía propuesto.

En el marco de esta tesis, se tomaron ciertos supuestos y se realizaron algunos compromisos en la modelación y diseño del sistema completo, por lo que, a continuación, se detallan algunos puntos importantes a mejorar en un próximo trabajo.

6.1. Trabajo futuro

En el desarrollo de esta tesis, se trabajó bajo distintas simplificaciones que permitieron el desarrollo de los modelos y sistemas utilizados. Estas suposiciones no necesariamente representa la dinámica real de todos los procesos en estudio, por lo que se propone como trabajo futuro los siguientes puntos.

- Considerar instalar sensores que midan las precipitaciones de la zona, para contar con datos más acordes a la cuenca en estudio.
- Realizar ensayos de bombeo en el acuífero donde se plantarán los cultivos, para conocer con mayor precisión la dinámica del nivel de agua de los pozos.
- Realizar un estudio sobre las extracciones de agua subterránea en lugares cercanos a la zona de trabajo y así considerar un posible descenso en los pozos por un bombeo irresponsable.
- Medir la evapotranspiración real de los cultivos y poder estimar parámetros más precisos con respecto a su crecimiento y respuesta al estrés hídrico.
- Extender los modelos hidrogeológicos y de evapotranspiración para incluir dinámicas no consideradas como movimiento de agua desde y hacia cuencas aledañas o disminución del crecimiento por falta de nutrientes, acidez del suelo, calidad del agua, entre otros.
- Caracterizar los cambios en la dinámica del sistema debido a eventos climáticos extremos a través de modelos en evolución.

Por otro lado, los modelos obtenidos para predecir las precipitaciones no alcanzaron resultados tan precisos como los de radiación solar, temperatura y velocidad de viento, por esto, se propone que se consideren otros métodos para predecir las precipitaciones, como redes neuronales profundas y/o modelos mesoescalares, que permiten obtener un valor esperado más cercano a los valores reales futuros y así construir intervalos de predicción con un ancho menor.

Bibliografía

- [1] Siebert, S., Burke, J., Faures, J. M., Frenken, K., Hoogeveen, J., Döll, P., y Portmann, F. T., “Groundwater use for irrigation – a global inventory,” *Hydrology and Earth System Sciences*, vol. 14, no. 10, pp. 1863–1880, 2010, [doi:10.5194/hess-14-1863-2010](https://doi.org/10.5194/hess-14-1863-2010).
- [2] Alexandratos, N. y Bruinsma, J., “World agriculture towards 2030/2050: the 2012 revision,” Working Paper 12-03, Food and Agriculture Organization of the United Nations, 2012.
- [3] Food and Agriculture Organization, *The future of food and agriculture: Trends and challenges*. Rome, Italy: Food & Agriculture Organization of the United Nations (FAO), 2017.
- [4] Wada, Y., van Beek, L. P. H., van Kempen, C. M., Reckman, J. W. T. M., Vasak, S., y Bierkens, M. F. P., “Global depletion of groundwater resources,” *Geophysical Research Letters*, vol. 37, no. 20, 2010, [doi:https://doi.org/10.1029/2010GL044571](https://doi.org/10.1029/2010GL044571).
- [5] R. G. Taylor *et al.*, “Ground water and climate change,” *Nature Climate Change*, vol. 3, pp. 322–329, 2012, [doi:10.1038/nclimate1744](https://doi.org/10.1038/nclimate1744).
- [6] R. Garreaud *et al.*, “Informe a la nación: La megasequía 2010-2015, una lección para el futuro.” Centro de Ciencia del Clima y la Resiliencia (CR)2, 2015 [Online], <https://www.cr2.cl/informe-a-la-nacion-la-megasequia-2010-2015-una-leccion-para-el-futuro/>.
- [7] Smajgl, A., Ward, J., y Pluschke, L., “The water–food–energy nexus – realising a new paradigm,” *Journal of Hydrology*, vol. 533, pp. 533–540, 2016, [doi:https://doi.org/10.1016/j.jhydrol.2015.12.033](https://doi.org/10.1016/j.jhydrol.2015.12.033).
- [8] Zhang, C., Chen, X., Li, Y., Ding, W., y Fu, G., “Water-energy-food nexus: Concepts, questions and methodologies,” *Journal of Cleaner Production*, vol. 195, pp. 625–639, 2018, [doi:https://doi.org/10.1016/j.jclepro.2018.05.194](https://doi.org/10.1016/j.jclepro.2018.05.194).
- [9] Kurian, M., “The water-energy-food nexus: Trade-offs, thresholds and transdisciplinary approaches to sustainable development,” *Environmental Science & Policy*, vol. 68, pp. 97–106, 2017, [doi:https://doi.org/10.1016/j.envsci.2016.11.006](https://doi.org/10.1016/j.envsci.2016.11.006).
- [10] Garcia, D. J. y You, F., “The water-energy-food nexus and process systems engineering: A new focus,” *Computers & Chemical Engineering*, vol. 91, pp. 49–67, 2016, [doi:https://doi.org/10.1016/j.compchemeng.2016.03.003](https://doi.org/10.1016/j.compchemeng.2016.03.003). 12th International Symposium on Process Systems Engineering & 25th European Symposium of Computer Aided Process Engineering (PSE-2015/ESCAPE-25), 31 May - 4 June 2015, Copenhagen, Denmark.
- [11] Katz, S. L., Padowski, J. C., Goldsby, M., Brady, M. P., y Hampton, S. E., “Defining the nature of the nexus: Specialization, connectedness, scarcity, and scale in food–energy–

- water management,” *Water*, vol. 12, no. 4, 2020, doi:[10.3390/w12040972](https://doi.org/10.3390/w12040972).
- [12] Raya-Armenta, J. M., Bazmohammadi, N., Avina-Cervantes, J. G., Sáez, D., Vasquez, J. C., y Guerrero, J. M., “Energy management system optimization in islanded microgrids: An overview and future trends,” *Renewable and Sustainable Energy Reviews*, vol. 149, p. 111327, 2021, doi:<https://doi.org/10.1016/j.rser.2021.111327>.
- [13] Zahraoui, Y., Alhamrouni, I., Mekhilef, S., Basir Khan, M. R., Seyedmahmoudian, M., Stojcevski, A., y Horan, B., “Energy management system in microgrids: A comprehensive review,” *Sustainability*, vol. 13, no. 19, 2021, doi:[10.3390/su131910492](https://doi.org/10.3390/su131910492).
- [14] Khalkhali, M., Westphal, K. S., y Mo, W., “The water-energy nexus at water supply and its implications on the integrated water and energy management.,” *The Science of the total environment*, vol. 636, pp. 1257–1267, 2018.
- [15] Qiu, W., Yang, Y., Guo, Q., y Nojavan, S., “Simultaneous management of water and energy nexus: Economic and environmental assessment using stochastic p-robust optimization approach,” *Sustainable Energy Technologies and Assessments*, vol. 52, p. 102004, 2022, doi:<https://doi.org/10.1016/j.seta.2022.102004>.
- [16] Abrishambaf, O., Faria, P., Gomes, L., y Vale, Z., “Agricultural irrigation scheduling for a crop management system considering water and energy use optimization,” *Energy Reports*, vol. 6, pp. 133–139, 2020, doi:<https://doi.org/10.1016/j.egy.2019.08.031>. The 6th International Conference on Energy and Environment Research - Energy and environment: challenges towards circular economy.
- [17] Yahyaoui, I., Tadeo, F., y Segatto, M. V., “Energy and water management for drip-irrigation of tomatoes in a semi- arid district,” *Agricultural Water Management*, vol. 183, pp. 4–15, 2017, doi:<https://doi.org/10.1016/j.agwat.2016.08.003>. Special Issue: Advances on ICTs for Water Management in Agriculture.
- [18] Mousavi, N., Kothapalli, G., Habibi, D., Das, C. K., y Baniasadi, A., “A novel photovoltaic-pumped hydro storage microgrid applicable to rural areas,” *Applied Energy*, vol. 262, p. 114284, 2020, doi:<https://doi.org/10.1016/j.apenergy.2019.114284>.
- [19] Roje, T., Sáez, D., Muñoz, C., y Daniele, L., “Energy–water management system based on predictive control applied to the water–food–energy nexus in rural communities,” *Applied Sciences*, vol. 10, no. 21, 2020, doi:[10.3390/app10217723](https://doi.org/10.3390/app10217723).
- [20] Endo, A., Parra, S., Cartagena, O., Sáez, D., Muñoz, C., y Huircan, J. I., “Energy–water management system based on mpc for a greenhouse in a mapuche indigenous community,” *Applied Sciences*, vol. 13, no. 8, 2023, doi:[10.3390/app13084734](https://doi.org/10.3390/app13084734).
- [21] Wang, L.-X., “Fuzzy systems are universal approximators,” en [1992 Proceedings] *IEEE International Conference on Fuzzy Systems*, pp. 1163–1170, 1992, doi:[10.1109/FUZZY.1992.258721](https://doi.org/10.1109/FUZZY.1992.258721).
- [22] Schäfer, A. M. y Zimmermann, H. G., “Recurrent neural networks are universal approximators,” en *Artificial Neural Networks – ICANN 2006* (Kollias, S. D., Stafylopatis, A., Duch, W., y Oja, E., eds.), (Berlin, Heidelberg), pp. 632–640, Springer Berlin Heidelberg, 2006.
- [23] Cartagena, O., Parra, S., Muñoz-Carpintero, D., Marín, L. G., y Sáez, D., “Review on fuzzy and neural prediction interval modelling for nonlinear dynamical systems,” *IEEE Access*, vol. 9, pp. 23357–23384, 2021, doi:[10.1109/ACCESS.2021.3056003](https://doi.org/10.1109/ACCESS.2021.3056003).

- [24] Khosravi, A., Nahavandi, S., Creighton, D., y Atiya, A. F., “Comprehensive review of neural network-based prediction intervals and new advances,” *IEEE Transactions on Neural Networks*, vol. 22, pp. 1341–1356, 2011, [doi:10.1109/TNN.2011.2162110](https://doi.org/10.1109/TNN.2011.2162110).
- [25] Rodríguez, F., Insausti, X., Etxezarreta, G., Galarza, A., y Guerrero, J. M., “Very short-term parametric ambient temperature confidence interval forecasting to compute key control parameters for photovoltaic generators,” *Sustainable Energy Technologies and Assessments*, vol. 51, p. 101931, 2022, [doi:https://doi.org/10.1016/j.seta.2021.101931](https://doi.org/10.1016/j.seta.2021.101931).
- [26] Nourani, V., Sadikoglu, F., Paknezhad, N. J., y Sharghi, E., “Estimation of prediction intervals for artificial neural network-based rainfall-runoff modeling,” en *Advances in Intelligent Systems and Computing*, pp. 601–609, Springer International Publishing, 2021, [doi:10.1007/978-3-030-64058-3_74](https://doi.org/10.1007/978-3-030-64058-3_74).
- [27] Veltman, F., Marin, L. G., Sáez, D., Guitierrez, L., y Núñez, A., “Prediction interval modeling tuned by an improved teaching learning algorithm applied to load forecasting in microgrids,” en *2015 IEEE Symposium Series on Computational Intelligence*, pp. 651–658, 2015, [doi:10.1109/SSCI.2015.100](https://doi.org/10.1109/SSCI.2015.100).
- [28] Serale, G., Fiorentini, M., Capozzoli, A., Bernardini, D., y Bemporad, A., “Model predictive control (mpc) for enhancing building and hvac system energy efficiency: Problem formulation, applications and opportunities,” *Energies*, vol. 11, p. 631, 2018, [doi:10.3390/en11030631](https://doi.org/10.3390/en11030631).
- [29] Limon, D., Alvarado, I., Alamo, T., y Camacho, E., “Mpc for tracking piecewise constant references for constrained linear systems,” *Automatica*, vol. 44, pp. 2382–2387, 2008, [doi:10.1016/j.automatica.2008.01.023](https://doi.org/10.1016/j.automatica.2008.01.023).
- [30] Hovgaard, T. G., Edlund, K., y Jorgensen, J. B., “The potential of economic mpc for power management,” en *49th IEEE Conference on Decision and Control (CDC)*, pp. 7533–7538, IEEE, 2010, [doi:10.1109/CDC.2010.5718175](https://doi.org/10.1109/CDC.2010.5718175).
- [31] Manzano, J., Salvador, J., Romaine, J., y Alvarado-Barrios, L., “Economic predictive control for isolated microgrids based on real world demand/renewable energy data and forecast errors,” *Renewable Energy*, vol. 194, pp. 647–658, 2022, [doi:10.1016/j.renene.2022.05.103](https://doi.org/10.1016/j.renene.2022.05.103).
- [32] Lin, Y., Zhang, J., y Li, L., “A model predictive control approach to a water pumping system in an australian cotton farm microgrid,” *Cleaner Energy Systems*, vol. 3, p. 100026, 2022, [doi:https://doi.org/10.1016/j.cles.2022.100026](https://doi.org/10.1016/j.cles.2022.100026).
- [33] Bemporad, A. y Morari, M., “Robust model predictive control: A survey,” en *Robustness in identification and control*, pp. 207–226, Springer London, 2007, [doi:10.1007/bfb0109870](https://doi.org/10.1007/bfb0109870).
- [34] Zhang, Y., Fu, L., Zhu, W., Bao, X., y Liu, C., “Robust model predictive control for optimal energy management of island microgrids with uncertainties,” *Energy*, vol. 164, pp. 1229–1241, 2018, [doi:10.1016/j.energy.2018.08.200](https://doi.org/10.1016/j.energy.2018.08.200).
- [35] Marín, L. G., Sumner, M., Muñoz-Carpintero, D., Köbrich, D., Pholboon, S., Sáez, D., y Núñez, A., “Hierarchical energy management system for microgrid operation based on robust model predictive control,” *Energies*, vol. 12, no. 23, 2019, [doi:10.3390/en12234453](https://doi.org/10.3390/en12234453).
- [36] Organización Meteorológica Mundial, *International Glossary of Hydrology*. WMO,

UNESCO, 2012.

- [37] Ge, S. y Gorelick, S., *HYDROLOGY, FLOODS AND DROUGHTS | Groundwater and Surface Water*, pp. 209–216. Elsevier, 2015, [doi:10.1016/B978-0-12-382225-3.00171-7](https://doi.org/10.1016/B978-0-12-382225-3.00171-7).
- [38] Zhang, H., *Fundamentals of Groundwater*. J. Wiley, 2003.
- [39] Fitts, C. R., *Groundwater Science*. Elsevier, 2 ed., 2013, [doi:10.1016/C2009-0-62950-0](https://doi.org/10.1016/C2009-0-62950-0).
- [40] Theis, C. V., “The relation between the lowering of the piezometric surface and the rate and duration of discharge of a well using ground-water storage,” *Transactions, American Geophysical Union*, vol. 16, p. 519, 1935, [doi:10.1029/TR016i002p00519](https://doi.org/10.1029/TR016i002p00519).
- [41] Cooper, H. H. y Jacob, C. E., “A generalized graphical method for evaluating formation constants and summarizing well-field history,” *Transactions, American Geophysical Union*, vol. 27, p. 526, 1946, [doi:10.1029/TR027i004p00526](https://doi.org/10.1029/TR027i004p00526).
- [42] Boulton, N. S., “Analysis of data from pumping tests in unconfined anisotropic aquifers,” *Journal of Hydrology*, vol. 10, no. 4, pp. 369–378, 1970, [doi:https://doi.org/10.1016/0022-1694\(70\)90223-4](https://doi.org/10.1016/0022-1694(70)90223-4).
- [43] Neuman, S. P., “Analysis of pumping test data from anisotropic unconfined aquifers considering delayed gravity response,” *Water Resources Research*, vol. 11, no. 2, pp. 329–342, 1975, [doi:https://doi.org/10.1029/WR011i002p00329](https://doi.org/10.1029/WR011i002p00329).
- [44] Theis, C. V., “The significance and nature of the cone of depression in ground-water bodies,” *Economic Geology*, vol. 33, pp. 889–902, 1938, [doi:10.2113/gsecongeo.33.8.889](https://doi.org/10.2113/gsecongeo.33.8.889).
- [45] Birsoy, Y. K. y Summers, W. K., “Determination of aquifer parameters from step tests and intermittent pumping data,” *Groundwater*, vol. 18, pp. 137–146, 1980, [doi:10.1111/J.1745-6584.1980.TB03382.X](https://doi.org/10.1111/J.1745-6584.1980.TB03382.X).
- [46] Kuo, M. C., Wang, W. L., Lin, D. S., Lin, C. C., y Chiang, C. J., “An image-well method for predicting drawdown distribution in aquifers with irregularly shaped boundaries,” *Groundwater*, vol. 32, pp. 794–804, 1994, [doi:10.1111/J.1745-6584.1994.TB00921.X](https://doi.org/10.1111/J.1745-6584.1994.TB00921.X).
- [47] Waterman, B. R., Alcantar, G., Thomas, S. G., y Kirk, M. F., “Spatiotemporal variation in runoff and baseflow in watersheds located across a regional precipitation gradient,” *Journal of Hydrology: Regional Studies*, vol. 41, p. 101071, 2022, [doi:10.1016/j.ejrh.2022.101071](https://doi.org/10.1016/j.ejrh.2022.101071).
- [48] Allan, R., Pereira, L., y Smith, M., *Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56*, vol. 56. Food & Agriculture Organization of the United Nations (FAO), 2006.
- [49] Eckhardt, K., “How to construct recursive digital filters for baseflow separation,” *Hydrological Processes*, vol. 19, pp. 507–515, 2005, [doi:10.1002/hyp.5675](https://doi.org/10.1002/hyp.5675).
- [50] Collischonn, W. y Fan, F. M., “Defining parameters for eckhardt’s digital baseflow filter,” *Hydrological Processes*, vol. 27, no. 18, pp. 2614–2622, 2013, [doi:https://doi.org/10.1002/hyp.9391](https://doi.org/10.1002/hyp.9391).
- [51] Smakhtin, V., “Low flow hydrology: a review,” *Journal of Hydrology*, vol. 240, no. 3, pp. 147–186, 2001, [doi:https://doi.org/10.1016/S0022-1694\(00\)00340-1](https://doi.org/10.1016/S0022-1694(00)00340-1).
- [52] Takagi, T. y Sugeno, M., “Fuzzy identification of systems and its applications to modeling and control,” *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-15, pp. 116–132, 1985, [doi:10.1109/TSMC.1985.6313399](https://doi.org/10.1109/TSMC.1985.6313399).

- [53] Bezdek, J. C., *Pattern Recognition with Fuzzy Objective Function Algorithms*. Springer US, 1981, [doi:10.1007/978-1-4757-0450-1](https://doi.org/10.1007/978-1-4757-0450-1).
- [54] Everitt, B. S. y Howell, D., eds., *Encyclopedia of statistics in behavioral science*. John Wiley & Sons, 1 ed., 2005.
- [55] Marín, L. G., Cruz, N., Sáez, D., Sumner, M., y Núñez, A., “Prediction interval methodology based on fuzzy numbers and its extension to fuzzy systems and neural networks,” *Expert Systems with Applications*, vol. 119, pp. 128–141, 2019, [doi:10.1016/j.eswa.2018.10.043](https://doi.org/10.1016/j.eswa.2018.10.043).
- [56] Andrade, F., “Cambios hidroclimáticos y procesos de recarga en los acuíferos fracturados de la cordillera de la costa (macrozona central sur): cuenca de puangue (31.1°s), nilahue (34.5°s) y purapel (35.5°s),” b.s. thesis, Universidad de Chile, Santiago, Chile, 2022.
- [57] Doneen, L. D., *Irrigation practice and water management*. Food and Agriculture Organization of the United Nations, 1971, <https://www.fao.org/3/r4082e/r4082e00.htm>.
- [58] Dubey, S., Sarvaiya, J. N., y Seshadri, B., “Temperature dependent photovoltaic (pv) efficiency and its effect on pv production in the world – a review,” *Energy Procedia*, vol. 33, pp. 311–321, 2013, [doi:https://doi.org/10.1016/j.egypro.2013.05.072](https://doi.org/10.1016/j.egypro.2013.05.072). PV Asia Pacific Conference 2012.
- [59] Gholami, A., Ameri, M., Zandi, M., y Gavagsaz Ghoachani, R., “Electrical, thermal and optical modeling of photovoltaic systems: Step-by-step guide and comparative review study,” *Sustainable Energy Technologies and Assessments*, vol. 49, p. 101711, 2022, [doi:https://doi.org/10.1016/j.seta.2021.101711](https://doi.org/10.1016/j.seta.2021.101711).
- [60] Santiago, I., Trillo-Montero, D., Moreno-Garcia, I., Pallarés-López, V., y Luna-Rodríguez, J., “Modeling of photovoltaic cell temperature losses: A review and a practice case in south spain,” *Renewable and Sustainable Energy Reviews*, vol. 90, pp. 70–89, 2018, [doi:10.1016/j.rser.2018.03.054](https://doi.org/10.1016/j.rser.2018.03.054).
- [61] Keeli, A. y Sharma, R. K., “Optimal use of second life battery for peak load management and improving the life of the battery,” en *2012 IEEE International Electric Vehicle Conference*, pp. 1–6, 2012, [doi:10.1109/IEVC.2012.6183276](https://doi.org/10.1109/IEVC.2012.6183276).
- [62] Moazeni, F., Khazaei, J., y Asrari, A., “Step towards energy-water smart microgrids; buildings thermal energy and water demand management embedded in economic dispatch,” *IEEE Transactions on Smart Grid*, vol. 12, pp. 3680–3691, 2021, [doi:10.1109/TSG.2021.3068053](https://doi.org/10.1109/TSG.2021.3068053).
- [63] Morales, R., “Planificación de micro-redes para comunidades rurales con caracterización de incertidumbre de los recursos renovables y demanda eléctrica,” m.s. thesis, Universidad de Chile, Santiago, Chile, 2017.
- [64] Raes, D., Geerts, S., Kipkorir, E., Wellens, J., y Sahli, A., “Simulation of yield decline as a result of water stress with a robust soil water balance model,” *Agricultural Water Management*, vol. 81, no. 3, pp. 335–357, 2006, [doi:https://doi.org/10.1016/j.agwat.2005.04.006](https://doi.org/10.1016/j.agwat.2005.04.006).
- [65] Kennedy, J. y Eberhart, R., “Particle swarm optimization,” en *Proceedings of ICNN’95 - International Conference on Neural Networks*, vol. 4, pp. 1942–1948 vol.4, 1995, [doi:10.1109/ICNN.1995.488968](https://doi.org/10.1109/ICNN.1995.488968).
- [66] Lofberg, J., “Yalmip : a toolbox for modeling and optimization in matlab,” en *2004 IEEE*

- International Conference on Robotics and Automation (IEEE Cat. No.04CH37508), pp. 284–289, 2004, [doi:10.1109/CACSD.2004.1393890](https://doi.org/10.1109/CACSD.2004.1393890).
- [67] Gurobi Optimization, LLC, “Gurobi Optimizer Reference Manual,” 2023, <https://www.gurobi.com>.
- [68] Lawler, E. L. y Wood, D. E., “Branch-and-bound methods: A survey,” *Operations Research*, vol. 14, no. 4, pp. 699–719, 1966, [doi:10.1287/opre.14.4.699](https://doi.org/10.1287/opre.14.4.699).
- [69] Servicio Nacional de Geología y Minería, “Portal Geomin.” Accessed Apr. 21, 2023 [Online], <https://portalgeomin.sernageomin.cl/>.
- [70] Dirección General de Aguas. División de estudios y Planificación, “Estudio hidrogeológico, región de la araucanía, informe final,” rep. tec., Ministerio de Obras Públicas, 2016.
- [71] Rojas, L., “Diseño e implementación de modelos de intervalos neuronales para sistema de gestión de agua-energía de cultivos,” b.s. thesis, Universidad de Chile, Santiago, Chile, 2023.
- [72] Ministerio de Energía, “Explorador Solar.” Accessed Jan. 25, 2023 [Online], <https://solar.minenergia.cl/inicio>.
- [73] Ministerio de Energía, “Explorador Eólico.” Accessed Jan. 25, 2023 [Online], <https://eolico.minenergia.cl/inicio>.
- [74] Center of Climate and Resilience Research (CR2), “Explorador Climático.” Accessed Jan. 25, 2023 [Online], <https://explorador.cr2.cl/>.
- [75] Alvarez-Garreton, C., Mendoza, P. A., Boisier, J. P., Addor, N., Galleguillos, M., Zambrano-Bigiarini, M., Lara, A., Puelma, C., Cortes, G., Garreaud, R., McPhee, J., y Ayala, A., “The CAMELS-CL dataset: catchment attributes and meteorology for large sample studies – chile dataset,” *Hydrology and Earth System Sciences*, vol. 22, pp. 5817–5846, 2018, [doi:10.5194/hess-22-5817-2018](https://doi.org/10.5194/hess-22-5817-2018).
- [76] Nelles, O. y Isermann, R., “Identification of nonlinear dynamic systems classical methods versus radial basis function networks,” en *Proceedings of 1995 American Control Conference - ACC’95*, vol. 5, pp. 3786–3790 vol.5, 1995, [doi:10.1109/ACC.1995.533847](https://doi.org/10.1109/ACC.1995.533847).

A. Estudio de suelo en la comunidad

A continuación se muestra el estudio de suelo realizado en la comunidad José Painecura Hueñalihuen, el 14 de enero de 2022.



LABORATORIO DE QUÍMICA DE SUELOS Y AGUAS
 INFORME DE RESULTADOS DE ANÁLISIS



Informe N° : 17
 Nombre cliente : Martina Casanova
 Comuna - Región : Carahue - Araucanía
 Tipo de muestra : Suelo
 Fecha : 14 de enero de 2022

Identificación de la Muestra

N° Lab	N° Campo	Fecha muestreo	Manejo	Fertilizante / Enmienda química	Incorporación enmienda orgánica	Riego	Pastoreo animales	Coordenadas (Latitud)	Coordenadas (Longitud)
327	Campo 2	5/19/2021	Cultivo	Si	Si	No	Si	73°30'41.4"	38°31'41.4"
328	Campo 8	5/19/2021	Cultivo	Si	Si	No	Si	73°30'22.2"	38°31'36.7"

Resultados Análisis Químicos Elementales

N° Lab	N disponible (mg/kg)	P (mg/kg)	S (mg/kg)	Ca (cmol+/kg)	Mg (cmol+/kg)	Na (cmol+/kg)	K (cmol+/kg)
327	10.35	18.14	9.100	4.058	1.361	1.378	0.328
328	9.45	16.80	6.026	4.760	1.713	1.859	0.663

Resultados Análisis Químicos no Elementales

N° Lab	pH	MOS (%)
327	5.23	12.45
328	5.33	11.63

Resultados Análisis Físicos

N° Lab	% arena	%Limo	%Arcilla	Clase Textural
327	38.77	36.83	24.40	Franco
328	39.81	27.15	33.04	Franco Arcilloso


Informe N° : 17
Nombre cliente : Martina Casanova
Comuna - Región : Carahue - Araucanía
Tipo de muestra : Suelo
Fecha : 14 de enero de 2022

RECOMENDACIONES PARA EL MANEJO DE SUELOS

Interpretación: Suelos de pH fuertemente ácido; materia orgánica en valores altos; nitrógeno disponible muy bajo; fósforo disponible varía entre medio y alto; potasio intercambiable varía entre medio a adecuado; calcio intercambiable varía de bajo a medio; magnesio intercambiable adecuado; y sodio intercambiable muy alto. Suelo de clase textural que varía de franca a franco arcillosa.

Recomendación agricultura convencional: Se recomienda mantener una fertilización fosforada para llegar al menos a un nivel de 20 mg P ha⁻¹ (nivel adecuado para la mayoría de las plantas), aplicar 60 kg P₂O₅/ha, lo que es equivalente a unos 130 kg Superfosfato triple/ha por año. La dosis de nitrógeno dependerá de la demanda del cultivo/hortaliza a establecer. Se recomienda mantener una fertilización potásica para llegar al menos a un nivel superior a 0,5 cmol₍₊₎ kg⁻¹ (nivel adecuado para la mayoría de las plantas). Para el potasio aplicar unos 50 kg K₂O/ha, lo que es equivalente a 80 kg cloruro de potasio/ha. El pH es fuertemente ácido y se recomienda aplicar 2 ton cal/ha cada 2 años.

Recomendación principios agroecológicos: Favorecer los procesos de reciclaje de residuos y la fabricación de bioprocesados que aporten N-P-K considerando los materiales disponibles en la comunidad: residuos orgánicos domiciliarios, algas marinas, restos de cosecha, guano animal, etc. En particular, evaluar la incorporación de leguminosas dentro de la rotación de cultivos para favorecer el proceso de fijación simbiótica de N.



Osvaldo Salazar Guerrero
Ingeniero Agrónomo M.S., Ph.D
Facultad de Ciencias Agronómicas
Universidad de Chile - Campus Antumapu
Santa Rosa 11315 - La Pintana - Santiago - Chile
Tel +56 2 29785752 | osalazar@uchile.cl

Figura A.1: Estudio de suelo realizado en la comunidad.

B. Optimización estructural de modelos Takagi-Sugeno

Para definir todos los parámetros del modelo, y encontrar un número de entradas y reglas adecuadas, se sigue el siguiente algoritmo:

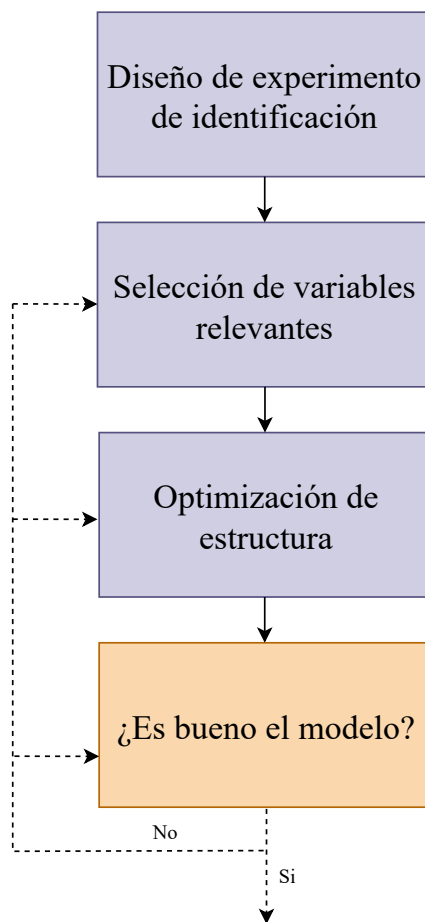


Figura B.1: Algoritmo de identificación de parámetros y estructura

Cada paso se describe a continuación:

- i. **Diseñar el experimento de identificación:** Se utilizan datos históricos para caracterizar la dinámica de la señal a identificar, o en caso de no contar con estos datos, se debe

generar una señal APRBS [76] para usar como entrada al modelo y así obtener datos para realizar el entrenamiento, test y validación. Es importante que esta señal excite, de ser posible, todos los modos de operación de la planta, por lo que se deben elegir valores adecuados para la amplitud máxima y frecuencia de esta. Luego, se deben separar los datos disponibles en Entrenamiento, Test o Prueba y Validación. El tamaño de cada uno puede variar, pero valores similares a 60 %, 20 % y 20 % suelen ser los utilizados.

ii. Selección de variables relevantes: Se selecciona el número de regresores a utilizar en el modelo, para esto se analiza la sensibilidad de cada uno:

- Se propone una gran cantidad de regresores para $y(k)$ y $u(k)$ (de ser necesario) la que hará de cota superior para el modelo.
- Se entrenará un modelo con este número de regresores y un número fijo de reglas, utilizando datos del conjunto de entrenamiento.
- Se calcula la sensibilidad de cada regresor con respecto a la salida $\xi_i(k) = \frac{d\hat{y}(k)}{dz_i(k)}$ de cada regresor z_i utilizando datos del conjunto de entrenamiento.
- Se calcula el indicador $I_i = \mu^2(\bar{\xi}_i) + \sigma^2(\bar{\xi}_i)$, donde $\bar{\xi}_i$ es el parámetro ξ_i para todos los datos.
- Se elige una cota para eliminar todos los regresores con un indicador de sensibilidad I_i más baja a esta o se elimina el menor de todos.
- Se repiten los pasos anteriores hasta alcanzar el mínimo error de salida
$$e = \frac{1}{N} \sqrt{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}.$$

iii. Optimización de estructura: Para elegir el número adecuado de reglas se utiliza el siguiente procedimiento:

- Se propone un límite superior e inferior de reglas para el modelo
- Se entrena el modelo con el mínimo número de reglas definido y se selecciona el número de regresores aplicando el algoritmo descrito en ii).
- Se calcula el error del modelo con respecto a la salida $e = \frac{1}{N} \sqrt{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}$ utilizando datos del conjunto de prueba.
- Se aumenta en uno el número de reglas y se repite el procedimiento.
- Se continúa iterando hasta alcanzar el número máximo de reglas definido al inicio.
- Se elige el número de reglas que minimice el error definido anteriormente.

iv. Validar el modelo: Luego de definir todos los parámetros del modelo se analiza su desempeño a través de distintas métricas (RMSE, MAE, MAPE, etc.) en el conjunto de validación. Si se considera que el desempeño obtenido no es bueno, se puede repetir cualquiera de los pasos anteriores para obtener un modelo con distintos parámetros que podría dar mejores resultados.

C. Estimación de parámetros del filtro de Eckhardt

Para poder aplicar el filtro de Eckhardt descrito en la sección 3.1.5, se deben calcular el índice máximo de flujo base $BFI_{m\acute{a}x}$ y la constante de recesión α . Para obtener el primero se calcula la curva de duración de caudales (CDC), correspondiente a una curva de frecuencia acumulada, que muestra la probabilidad con que un caudal sea igualado o superado [51]. A partir de esta curva es posible calcular el índice Q_{90}/Q_{50} , el cual se puede utilizar para estimar el índice máximo de flujo base, según la ecuación (C.1) [50].

$$BFI_{m\acute{a}x} = 0.8344 \frac{Q_{90}}{Q_{50}} + 0.2146 \quad (C.1)$$

La figura C.1 muestra la curva de duración de caudales para la cuenca en estudio.




Figura C.1: Curva de duración de caudales en escala semilogarítmica.

Por otro lado, la constante de recesión α se puede estimar al construir la curva de recesión maestra (CRM) a partir de las curvas de recesión del caudal de la cuenca. Estas curvas de recesión permiten observar la disminución del caudal de los ríos luego de periodos de lluvia,

por lo que la curva de recesión maestra se utiliza para calcular la constante de recesión α necesaria para aplicar el filtro de Eckhardt [51]. La CRM se construye aplicando un ajuste exponencial que mejor se ajuste a las curvas de recesión. La figura C.2 muestra la construcción de la curva de recesión maestra.

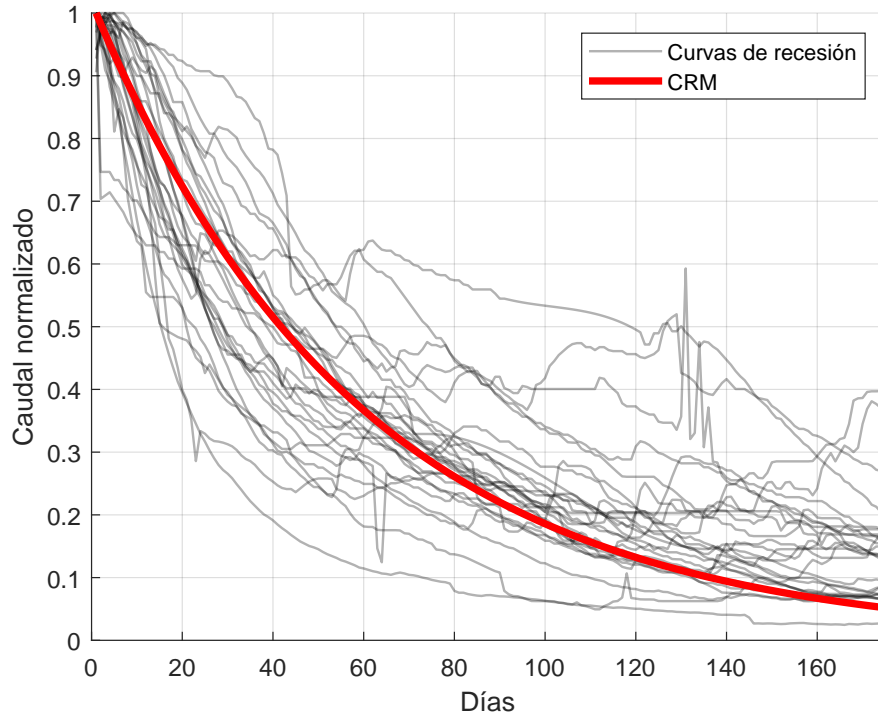


Figura C.2: Curvas de recesión del caudal de la cuenca en estudio, junto a la curva de recesión maestra construida.

Considerando un ajuste exponencial de la forma $b \cdot e^{-\alpha}$.

Luego, la tabla C.1 muestra los parámetros obtenidos al aplicar los métodos descritos anteriormente.

Tabla C.1: Parámetros obtenidos al estudiar el caudal de la cuenca.

Parámetros	Valor
Q_{90} [mm/día]	3.8
Q_{50} [mm/día]	10.9
$BFI_{máx}$	0.506
α	0.017

Al obtener los valores de $BFI_{máx}$ y α , es posible aplicar el filtro de Eckhardt para separar la escorrentía E_s del caudal total Q_{total} .