



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

**SISTEMA DE GESTIÓN DE AGUA Y ENERGÍA PARA INVERNADEROS DE
COMUNIDADES RURALES INDÍGENAS**

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

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO

ALVARO CRISTOBAL ENDO LAVADO

PROFESORA GUÍA:

Doris Sáez Hueichapan

PROFESOR CO-GUÍA:

Carlos Muñoz Poblete

MIEMBROS DE LA COMISIÓN:

Alfredo Nuñez Vicencio

Constanza Ahumada Sanhueza

SANTIAGO DE CHILE

2022

RESUMEN DE LA TESIS PARA OPTAR
AL GRADO DE MAGÍSTER EN
CIENCIAS DE LA INGENIERÍA,
MENCION ELÉCTRICA
MEMORIA PARA OPTAR AL TÍTULO
DE INGENIERO CIVIL ELÉCTRICO
POR: **ALVARO CRISTOBAL ENDO LAVADO**
FECHA: 2022
PROF. GUÍA: Doris Sáez Hueichapan

SISTEMA DE GESTIÓN DE AGUA Y ENERGÍA PARA INVERNADEROS DE COMUNIDADES RURALES INDÍGENAS

1. Resumen

En esta tesis, se propone un sistema de gestión de agua y energía para invernaderos en comunidades rurales indígenas, que tiene como objetivo principal maximizar el desarrollo de los cultivos a la vez que minimiza el uso de agua. Para lograr esto el sistema utiliza dos bloques de control predictivo incluyendo optimización difusa. Uno a mediano plazo el cual decide volúmenes diarios de riego de forma de cumplir el objetivo principal y uno a corto plazo el cual administra el riego diario a la vez que regula el micro clima del invernadero.

Se probaron los dos bloques de control predictivo del sistema obteniendo resultados para cada bloque. El bloque de corto plazo logró mantener la temperatura del invernadero en un rango deseado un 90 % del tiempo y la humedad relativa un 94 % en el mejor caso. En cuanto al riego se tuvo un error de seguimiento de $2[L]$. Finalmente el sistema de gestión de agua y energía se probó en dos escenarios. En ambos casos se logró un rendimiento relativo cercano a 0.99 usando entre $130[L]$ y $135[L]$ de agua diarios en promedio.

Agradecimientos

Quiero agradecer a mi madre Eugenia Lavado Valdés y mi padre Alvaro Endo Arriagada quienes me han apoyado durante toda mi vida académica. Desde siempre apoyándome y aconsejándome en mis tiempos de crisis, así como también nunca perdiendo la fe en mí. También quiero agradecer al resto de mi familia por todo el apoyo que me han dado toda mi vida.

Quiero agradecer a mi profesora guía Doris Sáez Hueichapan quien me introdujo a este proyecto y me guió durante todo este proceso. También a mi profesor co-guía Carlos Muñoz Poblete quien también me ha aconsejado durante el desarrollo de esta tesis.

Quiero agradecer a mis amigos del colegio, de la universidad y de los caminos de la vida quienes me han brindado apoyo moral en momentos de estrés. También quiero agradecer a todos los colaboradores de los proyectos relacionados a este trabajo. Agradecer a mi ex-compañero de universidad Sebastian Parra por ayudarme con el desarrollo de las redes neuronales y escritura de papers. A Daniela Lasso por encontrar errores y ayudar a corregir el modelo del invernadero. A Javier Ocaranza por la colaboración en la escritura de uno de los papers relacionados al proyecto. Y a Oscar Cartagena por ayudarme mas de una vez en la escritura de varios papers.

También quiero agradecer a la comunidad Jose Painecura Hueñalihuen por colaborar con nosotros en varios proyectos. En especial a Ermes García y su esposa quienes nos ayudaron y permitieron armar el invernadero sobre el cual se trata este proyecto.

Se agradece el apoyo de los siguientes proyectos para el desarrollo de la tesis: Instituto Sistemas Complejos de Ingeniería (ISCI) ANID PIA/BASAL AFB180003 , Solar Energy Research Center SERC-Chile ANID/FONDAP/15110019, ANID/CONICYT/FONDECYT 1220507 “Distributed Predictive Control Strategies based on Evolving Prediction Intervals for Energy-Water Microgrids” y Project VID UChile ENL08/21 “Design of Prediction Intervals based on Computational Intelligence and Evolving Systems for Modeling and Control of a Water and Energy Management System”. Además, se agradece el apoyo y financiamiento del Programa de Pueblos Indígenas, Dirección de Diversidad y Género, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile.

Tabla de Contenido

1. Resumen	i
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	2
1.4. Metodología	3
1.5. Alcances	4
1.6. Estructura de la Tesis	4
1.7. Publicaciones generadas	5
2. Estado del arte	6
2.1. Sistemas de gestión de agua y energía	6
2.2. Sistemas de gestión de agua y energía en invernaderos	9
2.3. Discusión	11
3. Modelación del invernadero	12
3.1. Arquitectura del invernadero	12
3.2. Micro-clima del invernadero	13
3.2.1. Efecto de la radiación solar	15
3.2.2. Efecto de la conducción y convección	16
3.2.3. Efecto del intercambio de calor con el suelo	16
3.2.4. Efecto de la renovación del aire	17
3.2.5. Efecto de la evapotranspiración	18
3.2.6. Efecto de la condensación	19
3.3. Demanda de riego	20
3.4. Discusión	22
4. Sistema propuesto de gestión de agua y energía para invernaderos	23
4.1. Planteamiento del problema	23
4.2. Sistema de gestión agua y energía propuesto	24
4.3. Predicción climática	25
4.3.1. Predicción climática a corto plazo de variables externas	25
4.3.2. Predicción climática a corto plazo de variables internas	26
4.3.3. Predicción climática a mediano plazo	27
4.4. Sistema de gestión a corto plazo	28
4.4.1. Control de ventanas	29

4.4.2. Sistema de gestión de agua-energía	32
4.5. Sistema de gestión a mediano plazo	34
4.6. Discusión	34
5. Resultados	36
5.1. Resultados de la predicción climática a corto plazo	36
5.1.1. Predicción climática a corto plazo de variables externas	36
5.1.2. Predicción climática a corto plazo de variables internas	41
5.2. Resultados de control a corto plazo	44
5.2.1. Resultados del controlador de ventanas	44
5.2.2. Resultados del sistema de gestión a corto plazo	48
5.3. Resultados de la predicción climática a mediano plazo	50
5.4. Resultados de control a mediano plazo	59
5.5. Discusión	61
6. Conclusión	64
6.1. Trabajo futuro	66
Bibliografía	68
Anexo A.	71
A.1. Parámetros	71
A.1.1. Arquitectura del invernadero	71
A.1.2. Modelo fenomenológico	71
A.1.2.1. Efecto de la radiación solar	72
A.1.2.2. Efecto de la conducción y convección	72
A.1.2.3. Efecto del intercambio de calor con el suelo	72
A.1.2.4. Efecto del intercambio de calor con el suelo	72
A.1.2.5. Efecto de la evapotranspiración	73
A.1.3. Demanda de riego	73
A.1.4. Parámetros controladores	73
A.1.4.1. Sistema de gestión de agua-energía a corto plazo	73
A.1.4.2. Sistema de gestión a mediano plazo	74
A.2. Controladores de ventanas por reglas	74
A.3. Redes neuronales	74
A.4. Estrategia de análisis de sensibilidad	75

Índice de Tablas

4.1.	Límites climáticos del invernadero.	29
5.1.	Número de regresores en los modelos con los mejores resultados en validación.	37
5.2.	Errores de las predicciones hechas por los mejores modelos de temperatura externa (T_{ext}) en $^{\circ}C$ en el conjunto de validación.	37
5.3.	Errores de las predicciones hechas por los mejores modelos de temperatura externa (T_{ext}) en $^{\circ}C$ en el conjunto de prueba.	37
5.4.	Errores de la predicción de humedad relativa externa (HR_{ext}) en % en el conjunto de validación.	38
5.5.	Errores de la predicción de humedad relativa externa (HR_{ext}) en % en el conjunto de prueba.	38
5.6.	Errores de la predicción de irradiancia (Ir) en $[\frac{W}{m^2}]$ en el conjunto de validación.	39
5.7.	Errores de la predicción de irradiancia (Ir) en $[\frac{W}{m^2}]$ en el conjunto de prueba.	39
5.8.	Errores de la predicción de la velocidad del viento (u^{ext}) en $[\frac{m}{s}]$ en el conjunto de validación.	40
5.9.	Errores de la predicción de la velocidad del viento (u^{ext}) en $[\frac{m}{s}]$ en el conjunto de prueba.	40
5.10.	Error máximo absoluto (MxAE) de cada simulación con respecto a la simulación donde $\Delta t_i = 0.1$	42
5.11.	Resultados del control de ventanas MPC.	44
5.12.	Resultados del control de ventanas MPCF.	45
5.13.	Resultados del control de ventanas MPCF.	45
5.14.	Resultados del control de ventanas con restricción dura.	45
5.15.	Resultados del segundo experimento.	46
5.16.	Rendimiento del riego a corto plazo en la simulación.	48
5.17.	Resultados usando datos de invierno	51
5.18.	Resultados usando datos de verano	51
5.19.	Uso de agua	59
5.20.	Rendimiento relativo total	60

Índice de Ilustraciones

1.1.	Estructura de la metodología de trabajo	3
3.1.	Diagrama de la arquitectura del invernadero.	12
3.2.	Diagrama de bloques del modelo del invernadero.	14
3.3.	Representación gráfica de los flujos del invernadero.	15
3.4.	Diagrama completo de la modelación del invernadero y sus interacciones. . . .	22
4.1.	Dibujo del invernadero, se pueden observar sensores para el estanque, el suelo del invernadero y el aire del invernadero.	24
4.2.	Representación gráfica de las relaciones entre las funciones del administrador.	25
4.3.	Representación gráfica de los instantes que representan cada predicción auxiliar, con $\Delta t_i = 60[s]$	26
4.4.	Diagrama de bloques del controlador a corto plazo.	29
4.5.	Relación de las temperaturas límites con la radiación.	30
4.6.	Funciones de pertenencia.	31
5.1.	Predicciones de temperatura externa (T_{ext}) obtenidas a través de una red neuronal en el conjunto de prueba	38
5.2.	Predicciones de humedad relativa externa (HR_{ext}) obtenidas con una red neuronal en el conjunto de prueba	39
5.3.	Predicciones de irradiancia (Ir) obtenidas con una red neuronal en el conjunto de prueba	40
5.4.	Predicciones de la velocidad del viento (u^{ext}) obtenidos con un modelo de media móvil en el conjunto de prueba	41
5.5.	Temperatura del invernadero (T_{inv}) obtenida con el modelo fenomenológico usando $\Delta t_i = 0.1[s]$ y $\Delta t_i = 25[s]$	42
5.6.	Humedad relativa del invernadero HR_{inv} obtenida con el modelo fenomenológico usando $\Delta t_i = 0.1[s]$ y $\Delta t_i = 25[s]$	43
5.7.	Temperatura del subsuelo del invernadero T_{ss} obtenida con el modelo fenomenológico usando $\Delta t_i = 0.1[s]$ y $\Delta t_i = 25[s]$	43
5.8.	Temperatura del invernadero, su zona de operación normal y su zona de seguridad.	47
5.9.	Humedad relativa del invernadero, su zona de operación normal y su zona de seguridad.	47
5.10.	Decisión de ventanas.	48
5.11.	Riego diario en la simulación.	49
5.12.	Energía en la batería durante la simulación.	50
5.13.	Volumen de agua en el estanque durante la simulación..	50
5.14.	Resultados de la temperatura mínima.	52
5.15.	Resultados de la temperatura máxima.	53
5.16.	Resultados de la humedad relativa mínima.	54

5.17.	Resultados de la humedad relativa máxima.	55
5.18.	Resultados de la velocidad del viento.	56
5.19.	Resultados de la radiación neta.	57
5.20.	Resultados de la evapotranspiración.	58
5.21.	Riego entregado en la simulación de riego exclusivo.	59
5.22.	Riego entregado en simulación de riego compartido.	60
5.23.	Evapotranspiración real y potencial en la simulación sin riego paralelo.	61
5.24.	Evapotranspiración real y potencial en la simulación con riego paralelo.	61
A.1.	Representación de un perceptrón multicapa	75

Capítulo 1

Introducción

1.1. Motivación

El agua, la energía y el alimento son recursos esenciales para la humanidad. Sin embargo, debido a fenómenos como el cambio climático y el crecimiento poblacional, cada vez se dificulta más la obtención de estos recursos, al mismo tiempo que crece su demanda [1]. Un ejemplo de fenómenos naturales que han afectado la vida humana recientemente, son las sequías que se han presentado en Chile en los últimos tiempos [2]. Por lo general, las sequías tienen un impacto negativo en la agricultura, lo que afecta gravemente a las comunidades rurales.

Una forma de enfrentar estos problemas es buscar soluciones basadas en el nexo agua-energía-alimento [3]. El nexo agua-energía-alimento consiste en la relación entre estos tres tipos de recursos y el como el uso de uno de estos afecta en la obtención de otro. En consecuencia, este planteamiento permite utilizarlos de forma más eficiente en las distintas estrategias y sistemas de control.

Este trabajo busca diseñar un administrador de agua y energía para un invernadero en la comunidad lafquenche José Painecura Hueñalihuen. Esta es una comunidad costera rural, cuyas actividades principales son la agricultura y la recolección costera. La comunidad ha cooperado anteriormente en proyectos con la Universidad de Chile y la Universidad de la Frontera. Entre estos proyectos, se encuentra una estación meteorológica que provee datos atmosféricos de la zona, así como la construcción de un invernadero, que en esta tesis se desea automatizar a través de un controlador.

El sistema a diseñar se basa en la estructura de un *Model Predictive Controller* (MPC). Se elijé este esquema debido a que permite hacer una toma de decisiones que considera disponibilidad de recursos a futuro y como cambiaría el sistema dadas unas decisiones. Entre los factores afectados se encuentran el agua en el estanque y la energía en la batería, el como afectan al día siguiente el riego de un día y cuales serían las mejores horas para regar. También se debe considerar que el control del clima del invernadero también debe ser de carácter predictivo, pues las condiciones climáticas internas de este puede afectar al riego.

El invernadero a controlar tiene un área de $60[m^2]$ y una cubierta de policarbonato. Si bien no corresponde con los patrones de cultivos de la zona, para motivos del experimento, se supone un monocultivo de tomates. La estructura del invernadero es similar a uno que

hubo anteriormente en el mismo espacio. El invernadero anterior para regular el micro-clima abría las ventanas de día y las cerraba de noche. El agua para este invernadero se obtiene de un estanque que se rellena desde una vertiente y se rellena con una bomba.

1.2. Hipótesis

Para la realización de este trabajo, se usan las siguientes hipótesis:

- Es posible diseñar un sistema de gestión de agua y energía para comunidades rurales indígenas, que maximice el rendimiento de los cultivos usando la menor cantidad de agua posible.
- El invernadero puede ser controlado por un sistema jerárquico, donde un sistema determine las necesidades diarias, mientras que otro administre el funcionamiento durante el día. También es posible desacoplar la administración de las necesidades diarias en un sistema de control de ventanas y un sistema de control de riego.
- Es posible controlar el micro-clima de un invernadero con resultados satisfactorios a través de la apertura y el cierre de las ventanas.
- Es posible determinar la cantidad de riego que requiere un cultivo para desarrollarse sin estrés hídrico por medio de la estimación de su evapotranspiración y la zona de agotamiento de raíz.

1.3. Objetivos

1.3.1. Objetivo general

En esta tesis, el objetivo principal es diseñar un sistema de gestión de agua y energía para invernaderos de comunidades rurales indígenas. Este sistema maximizará el rendimiento de los cultivos usando la menor cantidad de agua necesaria y respetando la disponibilidad de energía.

1.3.2. Objetivos específicos

Del objetivo principal, se desprenden los siguientes objetivos específicos:

- Derivar un modelo fenomenológico de invernadero que permita modelar el microclima, dadas la temperatura ambiental y la humedad relativa.
- Generar modelos de predicción climática para la radiación solar, humedad relativa, temperatura ambiental y velocidad del viento a corto plazo, para predecir el clima del invernadero por medio del modelo fenomenológico y datos experimentales.
- Diseñar un controlador predictivo a corto plazo que administre el riego y la apertura de las ventanas del invernadero. Estas acciones deben considerar el uso y la disponibilidad de energía.

- Generar modelos de predicción climática a mediano plazo para radiación solar, velocidad del viento, humedad relativa del invernadero y temperatura del invernadero. A su vez, estas predicciones se usarán para predecir la evapotranspiración por medio de un modelo fenomenológico y datos medidos.
- Diseñar un controlador predictivo a mediano plazo que determine la mínima cantidad de agua que se debe regar por día para asegurar el desarrollo de los cultivos. Este sistema debe estar integrado con el de corto plazo.

1.4. Metodología

Como se observa en la figura 1.1, para desarrollar el sistema, se realizó una investigación de modelos climáticos de invernadero, se obtuvo datos meteorológicos y se hizo entrevistas sobre los cultivos y el uso del agua. Se investigaron modelos que tuvieran posibilidades de adaptarse o combinarse para ser utilizados en el diseño de un control predictivo para el microclima del invernadero; dicho control tiene como único actuador las ventanas del invernadero. Por su parte, los datos meteorológicos que se obtuvieron corresponden a datos de corto plazo (cada diez minutos), con los cuales se pueden calcular datos de mediano plazo (cada día). Finalmente, las entrevistas se realizaron con el agricultor que maneja el invernadero. Estas entrevistas buscaban determinar qué cultivos se plantarían en el invernadero y también cuáles eran los gastos hídricos del invernadero anterior.

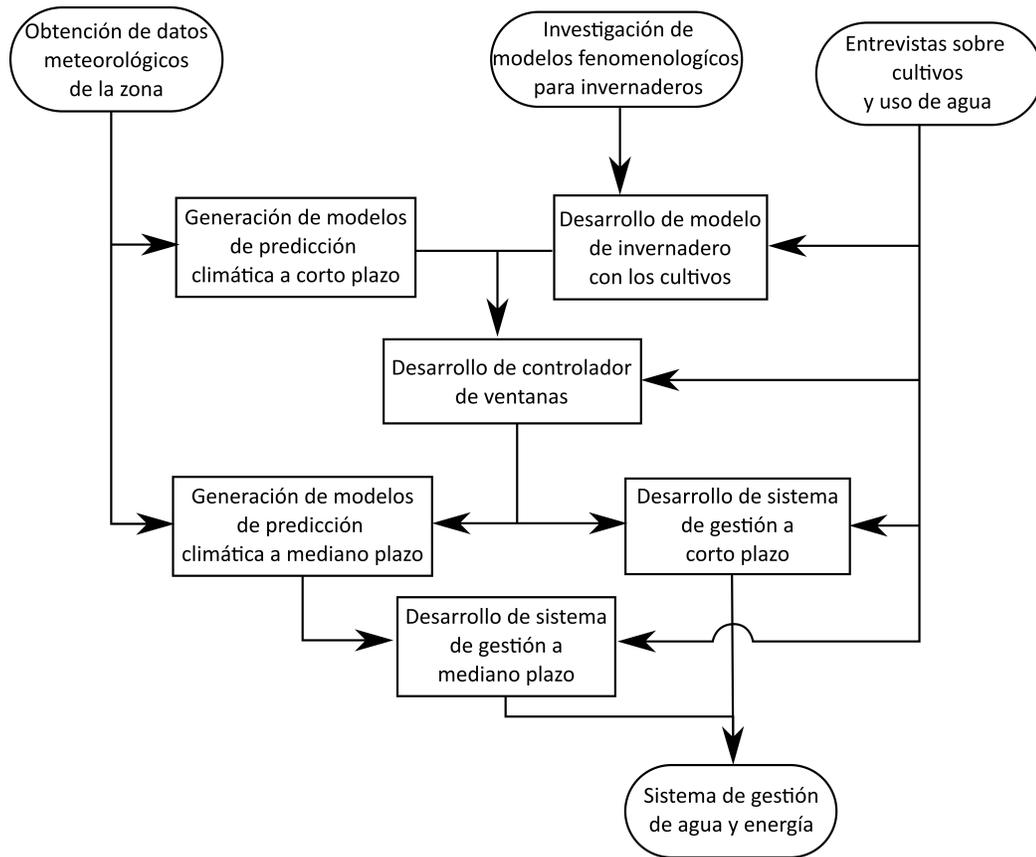


Figura 1.1: Estructura de la metodología de trabajo

Con esta información, se procede a ejecutar los dos primeros pasos indicados en la figura 1.1: el modelo fenomenológico del invernadero con los cultivos y los modelos de predicción climática a corto plazo. El modelo del invernadero se desarrolla con base en la información del invernadero actual; sin embargo, los parámetros de este se deben ajustar con base en los datos reales que se obtendrán del invernadero que se construirá en el futuro. En cuanto a los modelos de predicción, se entrenan con modelos auto-regresivos lineales y modelos neuronales, y se debe elegir aquellos que obtengan el mejor resultado para cada variable.

Una vez que se tiene un modelo fenomenológico del invernadero y modelos de predicción climática, se desarrolla un controlador predictivo para el micro-clima que determina el tiempo de apertura de las ventanas del invernaderos. Este controlador predictivo debe mantener el micro-clima en condiciones ideales para los cultivos. Para esto, se consideran múltiples funciones objetivo que consideran la cantidad de tiempo que la humedad y temperatura del invernadero se encuentran en valores deseados y los cambios de estado de ventanas realizados.

El controlador de ventanas se incorpora en los modelos de predicción climática a mediano plazo y a corto plazo en el sistema de gestión. Para los modelos de predicción climática a mediano plazo también se considera la humedad y la temperatura del invernadero, las cuales se rigen por el comportamiento del control de ventanas y afectan la evapotranspiración. El sistema de gestión a corto plazo permite el riego de los cultivos de modo que se cumpla con el objetivo de riego diario, mientras se consideran las decisiones de la apertura de ventana.

Con las predicciones a mediano plazo, se puede desarrollar el sistema de gestión a mediano plazo, el cual consiste en un controlador predictivo que determina el volumen de riego diario con base en la evapotranspiración. Luego, el sistema a corto plazo y el sistema a mediano plazo se pueden integrar. Así se obtendría el sistema de gestión de agua y energía final.

1.5. Alcances

Este trabajo diseña un sistema de gestión de agua y energía para un invernadero donde hay un solo tipo de cultivo. Además, la estructura del sistema está basada en el sistema de gestión de agua y energía para cultivos en campo abierto propuesto por Roje *et al.* [4]. Esto significa que el sistema se puede dividir en un sistema de gestión a corto plazo que controle el riego y el clima del invernadero y uno a mediano plazo que determine el riego óptimo por día. En esta implementación, el sistema solo puede regular el micro-clima del invernadero por medio de la apertura de ventanas, por lo que se prioriza que el clima sea apto más que óptimo para los cultivos.

1.6. Estructura de la Tesis

Esta tesis se conforma de 6 capítulos mas un anexo los cuales serán descritos en los siguientes párrafos.

El primer capítulo consiste en una introducción en donde se muestra la motivación de la tesis y también sus hipótesis y objetivos. Además, esta sección incluye la metodología que se usa para lograr los objetivos de la tesis así como también se presentan los alcances de esta.

El segundo capítulo corresponde al estado del arte en donde se presentan distintos trabajos relacionados a la gestión de agua y energía. En el capítulo se realiza un análisis de estos trabajos pre-existentes y se comparan con los objetivos y características de este trabajo.

El tercer capítulo es la modelación del invernadero, en donde se muestra modelos dinámicos para la arquitectura del invernadero, el micro-clima del invernadero y la demanda de riego.

El cuarto capítulo presenta el sistema propuesto de gestión de agua y energía para invernaderos. En este capítulo se plantea el diseño de los dos niveles de control que utiliza el sistema de gestión de agua y energía. Esto incluyen las estrategias de predicción y las de control de cada nivel.

Los resultados se presentan en el quinto capítulo. Aquí se muestran los resultados de los experimentos realizados en los distintos componentes de ambos niveles de control. En base a los resultados de cada experimento se calibra la configuración de cada componente. Cada vez que se configura una parte del sistema esta es utilizada para los experimentos siguientes.

Finalmente el ultimo capítulo corresponde a la conclusión en donde se analizan los resultados obtenidos y el nivel de completitud de los objetivos. También se presentan posibles trabajos a futuro por donde se pueda expandir o mejorar el trabajo presentado.

1.7. Publicaciones generadas

Durante el desarrollo de este trabajo se realizaron las siguientes publicaciones:

- Publicadas:

- 1 A. Endo, O. Cartagena, D. Sáez, D. Muñoz-Carpintero, “Predictive Control based on Fuzzy Optimization for Multi-Room HVAC Systems”, *IEEE International Conference on Fuzzy Systems, WCCI 2020*,, Glasgow, UK, 19-24 July 2020.

- 2 A. Endo, J. Ocaranza, O. Cartagena, C. Muñoz, D. Sáez. “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.

- En preparación:

- 3 A. Endo, S. Parra, O. Cartagena, D. Sáez, C. Muñoz, J. Huiran, “Energy-Water Management System based on MPC For a Greenhouse at Mapuche Indigenous Community”, En preparación para ser enviada a la revista Applied Sciences.

Capítulo 2

Estado del arte

En esta sección, se aborda el estado del arte en cuanto a estrategias de gestión de agua y energía para enfrentar problemas relacionados al nexo agua-energía-alimento. Posteriormente, se describen estrategias para la administración de agua y energía en invernaderos.

2.1. Sistemas de gestión de agua y energía

El nexo agua-energía-alimento consiste en la relación de estos recursos. Dicho de otro modo, por lo general, la obtención de uno de estos recursos involucra el uso de los otros dos. Esto causa grandes complicaciones cuando hay escasez de cualquiera de ellos, como se pronostica que ocurra por efectos del cambio climático. Una forma de enfrentar esta situación es la aplicación de sistemas de gestión de agua y energía, que requieren la optimización del uso de los recursos y la optimización de la infraestructura en la que se producen o se obtienen. Para analizar esta situación diferentes estudios se han llevado a cabo.

En Suárez *et al.* 2014 [5], se desarrolla un modelo de administración de agua para disminuir el estrés en la cuenca del río Copiapó. El modelo considera la existencia de fuentes subterráneas y superficiales de agua, así como la demanda y uso de esta. El sistema evalúa distintos escenarios de distribución de agua y demanda; cada uno de estos escenarios incluye un costo energético debido al proceso de desalinización necesario para compensar la falta de agua. Una conclusión de este artículo es que todos los escenarios analizados son mejores económicamente que la inacción.

Una planeación a gran escala de una micro-red se observa en Zhang *et al.* 2020 [6]. Aquí se propone una integración de tecnologías para la micro-red de una comunidad. El estudio considera fuentes de energías renovables (eólica, solar y mareomotriz), sistemas de almacenamiento de energía (baterías e hidrógeno) y tratamiento de agua. Para determinar el dimensionamiento de estos, se aplica una optimización multiobjetivo con tres funciones objetivo: minimización de costo de capital, mantención y operación; minimización de emisión de gases de invernadero y minimización del uso de agua en los sistemas de energía. Este proceso posee la restricción de que la micro-red debe ser capaz de cumplir con la demanda de energía de la comunidad. Para ponderar los múltiples objetivos, se usa la distancia de Minkowski y se prueban distintas distribuciones de pesos. Finalmente, se obtiene que la integración de las tecnologías disminuye la emisión de gases de invernadero y el uso de agua, aún cuando solo se minimiza el costo.

En Naval *et al.* 2020 [7], se propone la integración de gestión de agua y energía para una planta de energía virtual (VPP), lo cual optimiza el costo energético y la carga máxima. Esta implementación busca optimizar un sistema de extracción de agua para riego. La red tiene como carga 27 estaciones de bombeo de agua. De esas, 10 se pueden regular y las otras 17 deben cumplir una demanda fija. En cuanto a la fuente de energía, se tiene que la red eléctrica consta de una planta eólica y 6 hidroeléctricas; además, junto a cada bomba, hay una planta fotovoltaica para uso propio. Para gestionar el sistema, se toman decisiones de importación o exportación de energía a la red, importación o exportación de energía de cada estación de bombeo y exceso de energía para cada día a un año a futuro. El modelo también determina relaciones a escala de una hora: la generación de las fuentes renovables, la energía que se importa o exporta del sistema o subsistemas y la demanda eléctrica de cada bomba. Para tomar estas decisiones, se optimiza una función objetivo enfocada en minimizar el costo o maximizar la ganancia usando una formulación de programación no lineal mixta (MINLP). El modelo se evalúa con datos reales del año 2017 y se obtiene que la VPP logra cubrir el 99.64 % de su demanda energética, por lo que es más conveniente usar la electricidad que el sistema general. Esto también tiene como consecuencia que el comportamiento de la bombas se adapte al de la generación de energía.

En Moazeni *et al.* 2021 [8], se propone una formulación del tipo programación lineal intermixta (MILP) para enfrentar el problema del despacho económico para redes de agua-energía. Se busca gestionar la energía de varios edificios controlando la temperatura de estos con base en sus horarios de uso. Otro elemento que se gestiona es el funcionamiento de las bombas de agua para satisfacer la demanda de los edificios, considerando el costo relacionado. La micro-red se energiza con tres generadores distribuidos, una planta solar, una planta eólica, un sistema de baterías y conexión con la red. Las cargas del sistema corresponden a casas, edificios de oficinas y departamentos residenciales. Para el sistema de agua, se tiene una reserva, un estanque y una bomba. El sistema se gestiona optimizando una función objetivo con una formulación MILP, la cual cumple las demandas hídricas y energéticas y minimiza el costo.

Todos los ejemplos mencionados muestran múltiples maneras de abordar el nexo agua-energía desde una perspectiva a gran escala. Si bien esto puede llevar a resultados más eficientes (debido a la economía de escala), su implementación también puede presentar más complicaciones. Dichas complicaciones pueden ser de coordinación, financiamiento o baja prioridad para las instituciones que podrían ejecutarlos. En cambio, los de pequeña escala son menos susceptibles a estos inconvenientes, por lo que su implementación es más probable. Los siguientes tres ejemplos corresponden a estrategias susceptibles de ser replicadas por una entidad mediana o pequeña.

En Karan *et al.* 2018 [9], se aborda el problema de diseñar viviendas sustentables. Este artículo propone un sistema de alimento-energía-agua a pequeña escala, que puede satisfacer las necesidades de una familia de 4 personas. Para evaluar el diseño del sistema, se utiliza un modelo cuantitativo estocástico, con lo cual se calcula su costo. Esto se hace por medio de los índices de sustentabilidad, tanto para el agua y la energía como el alimento. Estos indicadores representan la probabilidad de que el sistema sea capaz de suplir la demanda de cada recurso. Con esta métrica, se procede a elegir estrategias de uso/obtención/reuso de recursos a fin

de cumplir con las demandas y a la vez minimizar el costo total del sistema por medio del dimensionamiento de este. La adopción masiva de esta estrategia sería probablemente una de las soluciones más efectivas para la gestión del nexo agua-energía-alimento; sin embargo, también requiere adoptar un estilo de vida compatible con el sistema, lo que complica su implementación.

Una estrategia que utiliza el agua tanto para riego como para almacenamiento de energía se presenta en Mousavi *et al.* 2019 [10]. La estrategia consiste principalmente en que una micro-red almacene energía en forma de energía potencial gravitatoria; esto se hace en forma de agua en un estanque, la cual se puede devolver al pozo. Este tipo de almacenamiento de energía se conoce como *Pumped Hydro Storage* (PHS). Se sube el agua al estanque por medio de bombas y después se utiliza para riego o se regresa al acuífero para generación de energía. La micro-red se controla a través de un *Energy Management System* (EMS), que debe satisfacer la demanda de energía y controlar las bombas de riego. La energía de esta micro-red proviene de la red eléctrica y de paneles fotovoltaicos y es almacenada en el PHS. Ahora bien, el EMS se compone de dos niveles: administración de agua y riego y administración de bombas y turbina. El primero de estos niveles se activa a las 23:00 horas y decide la zona de operación del PHS para las próximas 72 horas, así como el día y la hora en que se riega. El objetivo de riego se basa en planes de riego predeterminados y la separación entre los días de riego. Esto se hace con base en un controlador predictivo que optimiza con algoritmos genéticos y busca minimizar el costo de operación. El segundo nivel se activa cada hora y utiliza los requisitos de riego determinados anteriormente, el agua en la reserva y las predicciones de demanda para determinar la zona de operación de la bomba o la turbina hasta el final del día. Este nivel también usa un control predictivo con optimización con algoritmos genéticos.

Se realizan pruebas experimentales que muestran que el sistema es capaz de controlar la bomba y la turbina de forma eficiente ante diferentes tarifas de costo y generación de energía minimizando el costo total. También se encuentra que gestionar el riego y el volumen de agua en el reservorio ayuda a usar la energía de forma más eficiente. Finalmente, hay una disminución general del costo de la electricidad.

En el caso de Roje *et al.* 2020 [4], se tiene un administrador de agua y energía para riego en campo abierto. El sistema se compone de dos partes: un administrador de agua (WMS) y uno de energía (EMS). Para el WMS, se utiliza evapotranspiración para determinar las necesidades diarias de agua de cultivos en campo abierto y agua de pozo para rellenar el estanque. A fin de saber cuántos litros de agua destinar al riego diario, se maximiza la ganancia con el menor consumo de agua posible en un horizonte de 28 días. Para ello, se optimiza una función objetivo por medio de un algoritmo genético. El EMS después determina los mejores momentos para regar con base en el objetivo de riego diario, buscando minimizar el costo de la operación y considerando los costos y disponibilidad de energía. Esta parte actúa cada 10 minutos con un horizonte de 48 horas. La función objetivo se resuelve con un método de programación lineal que utiliza el algoritmo “*Branch-and-Bound*”.

Tanto [10] como [4] usan sistemas de dos capas para administrar los recursos y decidir el riego de los cultivos. Esto les permite manejar factores que se encuentran a distintas escalas de tiempo. Ambos casos consideran un riego en campo abierto, por lo que no podrían implementarse de forma directa a cultivos en invernaderos, pues la gestión de un invernadero

involucra la mantención tanto de un clima artificial como el riego de cultivos.

2.2. Sistemas de gestión de agua y energía en invernaderos

Un invernadero consiste en un micro-clima controlado que permite el cultivo de plantas fuera de su estación o clima ideal. Debido a que su objetivo es la mantención de condiciones necesarias para un cultivo, se necesita administrar su funcionamiento. Esto involucra tanto regular el clima del invernadero como los cultivos. Como es de esperarse, se requiere generalmente de recursos hídricos y energéticos, ya sea para gestionar el micro-clima o regar los cultivos. En consecuencia, se necesita desarrollar estrategias que permitan hacer uso adecuado de estos recursos.

En Jooste *et al.* 2017 [11], se plantea un sistema de bajo costo energético para seguir condiciones del invernadero. El sistema desarrollado posee sensores con conexión inalámbrica que miden la luz, el CO_2 , la temperatura ambiente y la humedad tanto ambiental como del suelo. A partir de estas mediciones, el sistema determina cuándo regar, ya sea con base en reglas o en decisiones del productor. El sistema también incluye una interfaz gráfica, que muestra información actual, histórica y de fácil acceso para los productores. Los datos recolectados se almacenan en una base de datos, que puede consultarse para futuros estudios y análisis. Cabe señalar que este sistema no posee características predictivas y por lo tanto no usa el agua de la forma más eficiente posible. Sin embargo, la implementación y la recolección de datos de este sistema permitirá desarrollar controladores más eficientes en el futuro.

En Hidayat *et al.* 2017 [12] se propone un método de identificación de parámetros distribuidos discreto. El método construye un modelo por identificación en base a mediciones realizadas en una grilla de puntos en el sistema a modelar. Después el modelo se simplifica con el método de Lasso para reducir mediciones y regresores. Uno de los sistemas evaluados corresponde a la temperatura de un invernadero pequeño al cual se le realiza un experimento sin cultivos y usando calefactores. El modelo obtenido logra obtener predicciones con bajo error aun a 20 pasos de predicción. Este sistema de identificación requiere de mediciones reales por lo que no se podría aplicar a invernaderos sobre los cuales no hay mediciones. Aparte aun queda la incógnita de predecir la humedad del invernadero ya que esta podría al ser afectada por el desarrollo de las plantas podría requerir de muchos mas datos o considerar mas factores (como el nivel de desarrollo de los cultivos).

En Reza *et al.* 2018 [13], se propone una estrategia de riego para invernadero basada en la evapotranspiración. El sistema busca maximizar la ganancia al determinar la cantidad de agua necesaria para el buen desarrollo de los cultivos con base en la evapotranspiración. Asimismo, como el riego se realiza con agua desalinizada, se considera el efecto que la salinidad tendría sobre los cultivos. De esa manera, las concentraciones de esta mezcla dependen del efecto de la salinidad en el cultivo y cómo contribuye a maximizar la ganancia. El problema de optimización se resuelve con un modelo de gradiente reducido generalizado. Entre los costos considerados por el sistema, se encuentran el costo de energía de bombeo, el costo de las aguas desalinizadas, el costo de mano de obra y el costo capital. La estrategia se ve afectada por la tolerancia a la salinidad de los cultivos, esto significa que mientras menos tolerante sea

el cultivo a la salinidad, se requiere mayor proporción de agua desalinizada. También se tiene que, para implementar este controlador con pocos ajustes, se precisa de acceso a un servicio de agua desalinizada, lo cual no es económicamente factible para algunas zonas rurales.

En Hassabou *et al.* 2019 [14], se diseña un invernadero que busca disminuir el uso de agua y energía. El estudio ocurre en Qatar, que es un desierto subtropical caliente. El diseño se basa en integrar paneles fotovoltaicos al techo de los invernaderos de forma que no bloqueen la luz necesaria para los cultivos. El invernadero utiliza un diseño del tipo Pasivhaus que mejora significativamente la aislación y permite controlar el micro-clima más fácilmente. Los actuadores del invernadero tienen la función de controlar la ventilación, la temperatura y la luz del invernadero. Estos se alimentan con los paneles solares y buscan mantener a las plantas en condiciones ideales. En las simulaciones realizadas, se muestra que este diseño es capaz de mantener el micro-clima usando solo la energía provista por el panel solar. En este caso, se tiene un diseño que, debido al clima de Qatar, aísla casi completamente el clima del invernadero del exterior. Si bien se logran buenos resultados en este país, es posible que en otros climas se pueda gestionar el clima del invernadero con menos aislación y menos actuadores lo que llevaría a un menor costo.

En Achour *et al.* 2020[15], se propone un sistema de control para un invernadero que busca mantener las condiciones ideales para los cultivos. El diseño propuesto posee generación de energía fotovoltaica y eólica; conexión con la red; una unidad de almacenamiento de energía; una reserva de agua; actuadores para gestionar la humedad, la temperatura, la luz y el CO_2 del invernadero (sistema de nebulización, des-humificadores, inyector de CO_2 , luces, bombas y el sistema de calefacción y enfriamiento); un sistema de gestión de energía y sensores que registran variables ambientales. El EMS utiliza una función objetivo para minimizar la compra de energía, a la vez que busca cumplir las condiciones ideales del invernadero (incluido el riego). El sistema opera para horizontes de 24 y 96 horas (dependiendo del caso) con una tasa de muestreo de 15 minutos.

El sistema anteriormente descrito presenta similitudes conceptuales con el sistema que se presenta en esta tesis, a pesar de ello difieren principalmente en la gestión del clima del invernadero. En [15] el uso de múltiples actuadores climáticos permite asegurar condiciones óptimas, pero aumenta la probabilidad de que algún actuador falle. En cambio, el sistema de esta tesis busca gestionar el clima del invernadero usando solo la apertura de ventanas, estrategia que los agricultores de la zona han usado anteriormente. Si bien esto no asegura condiciones óptimas, se tiene la ventaja de que hay menos puntos de falla y un costo energético de activación menor.

En Ouammi *et al.* 2020[16], se desarrolla un sistema que gestiona una red de invernaderos, los cuales producen su propia agua por medio de desalinización. La micro-red a la que se conectan los invernaderos posee acceso a energías renovables, almacenamiento de energía, bombas de agua, fuentes de aguas salobres e infraestructura para medición. Cada invernadero de la red tiene un sistema para la desalinización de agua y el control del micro-clima del invernadero. El sistema se plantea con control predictivo con seguimiento de referencia, el cual busca mantener el clima del invernadero en las condiciones óptimas para los cultivos a la vez que se minimiza el uso de agua y energía. La función objetivo del sistema se compone de tres términos: minimizar el error de seguimiento del clima del invernadero, maximizar el

estado de energía de los sistemas de almacenamiento y minimizar los intercambios con la red. En las simulaciones realizadas para el experimento, el sistema logra entregar el agua necesaria y el 84 % de la energía utilizada proviene de una fuente renovable. Los resultados obtenidos en este sistema alcanzan buenos resultados en el uso de agua y energía; sin embargo, esta implementación requiere de infraestructura para la desalinización que podría no estar disponible o no ser asequible para algunas comunidades rurales.

2.3. Discusión

El nexo agua-energía-alimento es ampliamente investigado debido a la importancia de estos recursos. Estas investigaciones generalmente usan métricas económicas y buscan mejorar la obtención de los recursos o la eficiencia de su uso. Existen sistemas a gran escala que requieren optimizaciones con modelos más generales, y de pequeña escala que optimizan a nivel de detalle. Un caso específico es el de la agricultura, la cual puede ser de pequeña o gran escala. En el caso de la agricultura, se pueden identificar cultivos de campo abierto y cultivos en invernadero.

Los sistemas de agua y energía en invernadero, al igual que otros casos [5][6][7][8][9][10][4], buscan optimizar el uso de agua y energía de este. Los puntos que generalmente consideran estos sistemas son: demanda de agua de riego, uso energético en la obtención de agua y mantención del clima del invernadero, y obtención de energía. La demanda de riego se elige generalmente de tres formas: por medio de la demanda fija, la humedad de la tierra o la evapotranspiración. Este último método permitiría lograr un buen desarrollo con la menor cantidad de agua posible.

En cuanto al clima del invernadero, se tiene que algunos sistemas usan múltiples actuadores para mantener condiciones óptimas para el cultivo [15], mientras que otros usan menos actuadores y energía, pero se diseñan para el clima en donde se usan [14]. Finalmente para la obtención de energía generalmente se presentan fuentes de energía renovables incorporadas al diseño del invernadero que en algunos casos logran proveer toda la energía necesaria.

Este trabajo se desarrolla en una comunidad rural indígena, ubicada en un país que enfrenta una fuerte sequía. Para abordar este planteamiento, el riego diario se determina a partir de la evapotranspiración. El clima del invernadero se controla únicamente con la apertura de ventanas, pues, además de ser un método simple y menos costoso que la calefacción, existe el antecedente de un invernadero anterior que usaba esta estrategia. Finalmente, el invernadero tiene una red energética aislada para no depender de la red.

Capítulo 3

Modelación del invernadero

En este capítulo, se explicarán los modelos fenomenológicos utilizados para describir la arquitectura del invernadero, la dinámica del micro-clima y la demanda de riego.

3.1. Arquitectura del invernadero

El invernadero utiliza dos recursos principalmente para su funcionamiento, estos son energía y agua. En el caso del agua, esta se obtiene de un estanque , que se recarga con agua de vertiente. Esta agua es almacenada en un estanque para su uso en el invernadero por medio de la activación de electroválvulas. El agua se mueve de un estanque a otro usando una bomba eléctrica , que es alimentada por una batería. Esta batería tiene la función de proveer energía al sistema y es alimentada por un panel fotovoltaico. Los tres elementos eléctricos se conectan mediante un inversor. Estas relaciones se pueden observar en la figura 3.1.

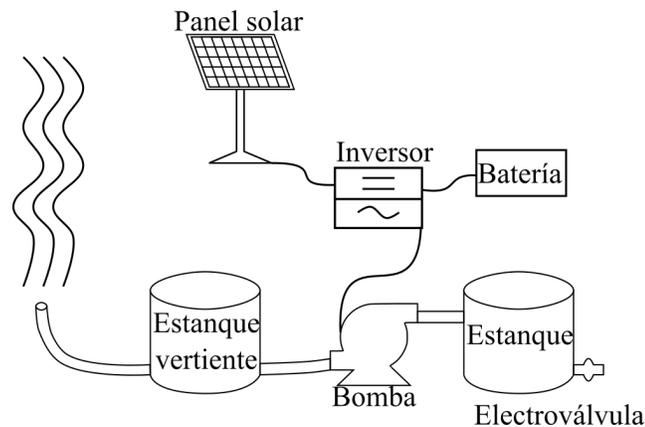


Figura 3.1: Diagrama de la arquitectura del invernadero.

El volumen del estanque $V_{estanque}$ en $[m^3]$ se puede computar de forma discreta con base en las decisiones de regar y activar la bomba, como se describe en la ecuación (3.1).

$$V_{estanque}(k+1) = V_{estanque}(k) + Rec_{bomba}(k) \cdot \Delta t \cdot \rho_{rec} - I(k) \cdot \Delta t \cdot \rho_r \quad (3.1)$$

En donde, $Rec_{bomba}(k)$ y $I(k)$ son variables relacionadas respectivamente a la decisión de

utilizar la bomba y el tiempo de riego en el instante k , donde $Rec_{bomba}(k)$ una variable binaria y $I(k)$ una variable continua entre 0 y 1. ρ_{rec} y ρ_r son respectivamente el flujo de agua del proceso de recarga del estanque y el flujo de riego, ambos medidos en $[\frac{m^3}{s}]$.

En el caso de la batería, se considera el estado de energía (SoE) en $[kJ]$, que está dado por la ecuación (3.2). Este corresponde a una versión discreta de la integral de corriente.

$$SoE(k+j+1) = SoE(k+j) - \frac{\Delta t \cdot P_{bat}(k+j)}{1000}$$

$$P_{bat}(k) = \begin{cases} \eta_{char} P_{dem}(k) & P_{dem}(k) < 0 \\ \frac{P_{dem}(k)}{\eta_{dis}} & P_{dem}(k) \geq 0 \end{cases} \quad (3.2)$$

$$P_{dem}(k) = \frac{P_{bomba} Rec_{bomba}(k)}{\eta_{inv}} - P_{Solar}(k),$$

Aquí $P_{bat}(k)$ es la potencia que entrega o recibe la batería en $[W]$. P_{bomba} y P_{Solar} son las potencias que usa la bomba y la que genera el panel solar en $[W]$ respectivamente. η_{char} y η_{dis} son las eficiencias de carga y descarga de la batería. Mientras que η_{inv} es la eficiencia del inversor. $P_{dem}(k)$ corresponde a la potencia que entregan o requieren los aparatos conectados a la batería; su valor es positivo cuando la batería entrega energía y negativo cuando la recibe. También se asume que si la batería está completamente cargada, el sistema no la intentara cargar.

Para este seguimiento, solo se considera el consumo y generación de energía de la bomba y el panel solar, que son por mucho superiores a los de otros elementos del invernadero, por lo que el consumo y generación de estos últimos es despreciable. Para el cálculo de la potencia solar $P_{Solar}(k)$, se utiliza la ecuación (3.3). Si bien esta ecuación es una aproximación simple a la potencia generada que se usó en [4], es suficiente para los alcances de este trabajo.

$$P_{Solar}(k) = P_{fv,n} \frac{Ir(k)}{I_{STC}(k)} [1 + \frac{\alpha_{fv}}{100} (T(k) - T_{STC})] \quad (3.3)$$

$$T(k) = T_{ext}(k) + \frac{Ir(k)}{800} (T_n - 20)$$

En donde, $P_{fv,n}$ es la potencia nominal del panel. $Ir(k)$ y $I_{STC}(k)$ son la irradiancia incidente en el panel y la irradiancia media en condiciones estándar respectivamente, ambas medidas en $[\frac{W}{m^2}]$. α_{fv} es el coeficiente de temperatura del panel, expresado en $[\frac{\%}{^\circ C}]$. T_{STC} , T y T_n son la temperatura ambiente estándar, la temperatura de operación de la celda y la temperatura nominal de operación, medidas en $[^\circ C]$.

3.2. Micro-clima del invernadero

El modelo de micro-clima propuesto se basa en el modelo de [17] con respecto al seguimiento que hace de la temperatura y en el modelo de [18] en cuanto al seguimiento de la humedad del invernadero. Estos modelos monitorean las distintas fuentes de ganancia y pérdida de calor y humedad en el invernadero de forma discreta. A estos modelos se les agrega una dinámica de la temperatura del subsuelo para que puedan usarse de forma predictiva.

En el diagrama de bloques de la figura 3.2, se observan las principales entradas y salidas. La entrada corresponde al estado de apertura de la ventana V_s . Las salidas son la temperatura del invernadero T_{inv} , la humedad relativa del invernadero HR_{inv} y la temperatura del subsuelo T_{ss} . También se incluyen las perturbaciones externas, las cuales corresponden a la temperatura ambiental externa T_{ext} , la humedad relativa externa HR_{ext} , la irradiancia solar Ir y la velocidad del viento externo u^{ext} .

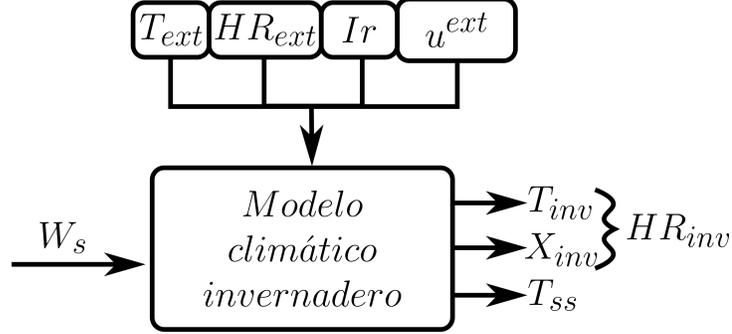


Figura 3.2: Diagrama de bloques del modelo del invernadero.

Las dinámicas de la temperatura ambiental $T_{inv}[^{\circ}C]$, el subsuelo $T_{ss}[^{\circ}C]$ y la humedad absoluta del invernadero $X_{inv} \left[\frac{g}{m^3} \right]$ se representan con las ecuaciones (3.4). Estas ecuaciones calculan el intercambio total de calor Q_t y el intercambio total de humedad dado por su variación ΔX_t .

$$\begin{aligned}
 T_{inv}(k+1) &= T_{inv}(k) + \Delta t \cdot \frac{Q_t(k)}{\left(\rho_{air} \cdot c_{pa} + \frac{X_{inv}(k) \cdot c_{pv}}{1000} \right) V_{inv}} \\
 T_{ss}(k+1) &= T_{ss}(k) + \Delta t \cdot \frac{Q_g(k)}{A_g L_{ss} c_{pg} \rho_g} \\
 X_{inv}(k+1) &= X_{inv}(k) + \Delta t \cdot \Delta X_t(k)
 \end{aligned} \tag{3.4}$$

Donde:

$$\begin{aligned}
 Q_t(k) &= Q_{rad}(k) - Q_{cc}(k) - Q_{ren}(k) - Q_g(k) - Q_{evap}(k) \\
 \Delta X_t(k) &= -\Delta X_{ren}(k) + \Delta X_{evap}(k) - \Delta X_c(k)
 \end{aligned} \tag{3.5}$$

Δt es el periodo de tiempo utilizado para la muestra discreta. ρ_{air} es la densidad del aire en $\left[\frac{kg}{m^3} \right]$ y V_{inv} es el volumen de la masa de aire del invernadero en $[m^3]$. c_{pa} , c_{pv} y c_{pg} son los calores específicos del aire seco, del vapor de agua y de la tierra del invernadero, expresados en $\left[\frac{J}{kgK} \right]$. A_g es el área de la superficie del suelo del invernadero en $[m^2]$. L_{ss} es la profundidad a la que se mide la temperatura del subsuelo en $[m]$. Finalmente, ρ_g es la densidad de la tierra del invernadero.

En la figura 3.3, se representan los distintos factores que se consideran para determinar el cambio de la temperatura interna del invernadero $Q_t(k)$ y variación de su humedad ambiental ($\Delta X_t(k)$). Estos son el efecto de la radiación solar (Q_{rad}), el efecto conductivo y convectivo del viento (Q_{cc}), el efecto del intercambio de calor con el suelo (Q_g), el efecto de la renovación

del aire (Q_{ren} y ΔX_{ren}), el efecto de la evapotranspiración (Q_{evap} y ΔX_{evap}) y el efecto de la condensación (ΔX_c). Debido a que no se tienen mediciones reales del invernadero, que permitieran ajustar los parámetros, en la simulación la humedad relativa se satura cuando llega al 100%.

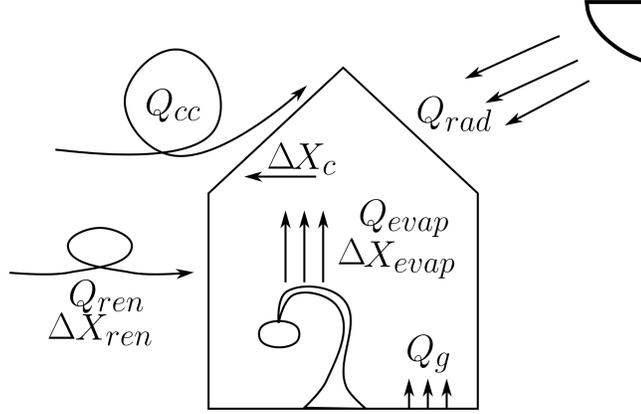


Figura 3.3: Representación gráfica de los flujos del invernadero.

A continuación, se explorarán los diferentes efectos que afectan tanto a Q_t como a ΔX_t .

3.2.1. Efecto de la radiación solar

El intercambio de calor causado por la radiación Q_{rad} se puede calcular con las ecuaciones (3.6) y (3.7), obtenidas de [17]. Se separan las fuentes de calor por radiación: la radiación solar que logra entrar al invernadero R_{sol} y la radiación térmica de la estructura del invernadero R_{ter} .

$$Q_{rad}(k) = R_{sol}(k) + R_{ter}(k) \quad (3.6)$$

Donde:

$$R_{sol}(k) = A_g \cdot [Ir(k) \cdot (\alpha_{inv} + \tau_{inv} \cdot (\alpha_c f_c + \alpha_g(1 - f_c)))]$$

$$R_{ter}(k) = A_{cu} \cdot \sigma \cdot \tau_{inv} \cdot (\varepsilon_{atm}(k)(T_{atm}(k))^4 - \varepsilon_{inv}(T_{cu}(k) + 273.15)^4)$$

$$T_{cu}(k) = \frac{T_{inv}(k) + T_{ext}(k)}{2}$$

$$T_{atm}(k) = f_n T_{ext}(k) + 0.0552(1 - f_n)(T_{ext}(k) + 273.15)^{1.5} \quad (3.7)$$

$$\varepsilon_{atm}(k) = 1 - e^{-\frac{10e_a^{ext}(k)}{T_{ext}(k)}}$$

$$e_a^{ext}(k) = e^{o_{ext}(k)} \cdot \frac{HR_{ext}(k)}{100}$$

$$e^{o_{ext}(k)} = 6.108 \cdot \exp\left(\frac{17.27T_{ext}(k)}{T_{ext}(k) + 237.3}\right)$$

Aquí A_g y A_{cu} son el área del suelo del invernadero y de la superficie de cobertura del mismo. Ir es la irradiancia solar en $\left[\frac{W}{m^2}\right]$. Mientras, α_{inv} , τ_{inv} y ε_{inv} son coeficientes de

absorción, transmisividad y emisividad de la estructura del invernadero. ε_{inv} es el coeficiente de emisividad de la atmósfera. α_c y α_g son coeficientes de absorción de los cultivos y del suelo respectivamente. f_c es la proporción del suelo que tiene cultivos. f_n es la nubosidad, siendo 1 despejado y 0 completamente nublado; para esta implementación, no se busca estimar este valor por lo que se asumirá fijo. σ es la constante de Stefan-Boltzmann $\left[\frac{W}{m^2K^4}\right]$. HR_{ext} es la humedad relativa exterior en $\%$. e^{oext} es la presión de vapor de saturación fuera del invernadero y e_a^{ext} es la presión de vapor real fuera del invernadero, que se miden en $[hPa]$. T_{ext} y T_{inv} son las temperaturas ambientales fuera y dentro del invernadero, expresadas en $[^\circ C]$; mientras que T_{cu} es una estimación de la temperatura de la cubierta, en $[^\circ C]$. Por último, T_{atm} es la temperatura de emisión de energía de la atmósfera, medida en $[^\circ K]$.

3.2.2. Efecto de la conducción y convección

El intercambio de calor por convección y conducción Q_{cc} se puede calcular con las ecuaciones (3.8) y (3.9). En ellas, se calcula la ganancia y pérdida de calor por la interacción de la superficie del invernadero con la atmósfera.

$$Q_{cc}(k) = A_{cu} \cdot U_{cc}(k) \cdot (T_{inv}(k) - T_{ext}(k)) \quad (3.8)$$

Donde:

$$U_{cc}(k) = \begin{cases} \left(\frac{1}{h_i(k)} + \frac{e_c}{\lambda_c} + \frac{1}{h_e(k)}\right)^{-1}, & h_i(k) > 0 \\ \left(\frac{e_c}{\lambda_c} + \frac{1}{h_e(k)}\right)^{-1}, & h_i(k) \leq 0 \end{cases}$$

$$h_i(k) = \begin{cases} 7.2, & T_{cu}(k) - T_{inv}(k) > 11.1 \\ 1.5 \cdot |T_{cu}(k) - T_{inv}(k)|^{0.3}, & T_{cu}(k) - T_{inv}(k) \leq 11.1 \end{cases} \quad (3.9)$$

$$h_e(k) = 7.2 + 3.84 \cdot u^{ext}(k)$$

$$T_{cu}(k) = \frac{T_{inv}(k) + T_{ext}(k)}{2}$$

U_{cc} es el coeficiente convectivo del invernadero, expresado en $\left[\frac{W}{K \cdot m^2}\right]$. h_i y h_e son los coeficientes convectivos al interior y exterior del invernadero, también en $\left[\frac{W}{K \cdot m^2}\right]$. A_{cu} es la superficie de la cubierta del invernadero en $[m^2]$. e_c es el espesor del material de la cubierta en $[m]$. λ_c es la conductibilidad térmica del material de la cubierta, medida en $\left[\frac{W}{m^3K}\right]$. Finalmente, u^{ext} es la velocidad del viento externo en $\left[\frac{m}{s}\right]$.

3.2.3. Efecto del intercambio de calor con el suelo

Este efecto (Q_g) corresponde al calor ganado o perdido por la interacción térmica con el suelo. Esto significa que depende únicamente de la temperatura del suelo T_{ss} y la temperatura del aire en el invernadero T_{inv} . En consecuencia, se necesita monitorear la dinámica de la temperatura del subsuelo. Esto se realiza con la ecuación (3.10), la cual proviene de [17].

$$Q_g(k) = K_g \cdot A_g \cdot \frac{(T_{inv}(k) - T_{ss}(k))}{L_{ss}} \quad (3.10)$$

K_g es la conductividad térmica del suelo en $\left[\frac{W}{m \cdot K}\right]$. L_{ss} es la profundidad a la que se mide la temperatura del subsuelo, expresada en $[m]$.

3.2.4. Efecto de la renovación del aire

La renovación del aire afecta tanto la temperatura del invernadero como la humedad (Q_{ren} y ΔX_{ren}). Por ello, se tiene que determinar una tasa de renovación del aire $Ren(k)$, que se presenta en la ecuación (3.11) con unidades de $\left[\frac{1}{hr}\right]$. Esta ecuación es semejante a la que aparece en [17], pero se diferencia en cómo se calcula el efecto del viento cuando la ventana está abierta. Para simplificarlo, el efecto del viento se entiende como una proporción entre la velocidad del viento a la altura de la ventana u_{vent}^{ext} en $\left[\frac{m}{s}\right]$ y el volumen del invernadero V_{inv} en $[m^3]$. Este cambio con respecto a [17] se debe a que el sistema no tendrá control de la ventana cenital, por lo que el efecto de esta última se considera una perturbación. Si la ventana está cerrada, se utiliza una tasa de infiltración R_{Inf} , que depende del material. Esta tasa representa la tasa de recambio de aire ocasionada por infiltración, medida en $\left[\frac{1}{hr}\right]$.

$$Ren(k) = \begin{cases} \frac{u_{vent}^{ext}(k) \cdot A_{vent} \cdot 3600}{V_{inv}}, & W_s(k) = 1 \\ R_{Inf}, & W_s(k) = 0 \end{cases} \quad (3.11)$$

$$u_{vent}^{ext}(k) = \frac{u_2^{ext}(k) \ln(67,8z_v - 5,42)}{4,87}$$

$$u_2^{ext}(k) = u^{ext}(k) \frac{4,87}{\ln(67,8z - 5,42)}$$

A_{vent} es el área de las ventanas a cada lado del invernadero en $[m^2]$ y W_s es el estado de la ventana. Si esta variable es 1, las ventanas están abiertas y si es 0, están cerradas. Esto permite controlar el efecto del viento para la regulación del invernadero. u_2^{ext} es la velocidad del viento a 2 $[m]$ y u^{ext} es la velocidad del viento medida en la estación meteorológica. z y z_v corresponden a la altura de medición del viento en $[m]$ y a la altura de la mitad de la ventana en $[m]$ respectivamente.

Para calcular el intercambio de calor por renovación, se utilizan las ecuaciones (3.12) y (3.13), que se extraen de [17], pero presentan modificaciones a fin de expresar la humedad absoluta en $\left[\frac{g}{m^3}\right]$. Esta ecuación separa los flujos de calor en tres tipos. El primer tipo es el flujo de calor por intercambio de aire a distintas temperaturas. El segundo tipo es el flujo de calor relacionado a la energía utilizada en la evaporación de distintas masas de vapor. Finalmente, el tercero corresponde al flujo de calor debido al intercambio de masas de calor a distintas temperaturas.

$$Q_{ren}(k) = \frac{V_{inv} Ren(k)}{3600} [\rho_{air} c_{pa} (T_{inv}(k) - T_{ext}(k)) + \lambda_o(k) \frac{(X_{inv}(k) - X_{ext}(k))}{1000} + \frac{c_{pv}(k) (X_{inv}(k) T_{inv}(k) - X_{ext}(k) T_{ext}(k))}{1000}] \quad (3.12)$$

Donde:

$$\lambda_o(k) = 2502535.259 - 2385.76424 T_{inv}(k) \quad (3.13)$$

c_{pa} y c_{pv} son el calor específico del aire seco en $\left[\frac{J}{kgK}\right]$ y del vapor de agua en $\left[\frac{J}{kgK}\right]$; para esta implementación, se supone que sus valores serán cercanos a los valores que adquieren

cuando la temperatura es $0[^\circ C]$. λ_o es el calor latente del agua en $[\frac{J}{kg}]$, como se calcula en [17].

El efecto de la renovación del aire en la humedad se obtiene con la ecuación (3.14), que proviene de [18]. En este caso, se requiere hacer seguimiento solo del intercambio de la masa de vapor, lo cual se hace calculando la diferencia entre las humedades absolutas del invernadero X_{inv} y de la atmósfera X_{ext} en $[\frac{g}{m^3}]$.

$$\Delta X_{ren}(k) = \frac{V_{inv}Ren(k)}{3600}(X_{inv}(k) - X_{ext}(k)) \quad (3.14)$$

3.2.5. Efecto de la evapotranspiración

La evapotranspiración es la suma de la pérdida de agua de un área por evaporación del suelo y por transpiración de las plantas (representadas como Q_{evap} y ΔX_{evap}). Para conocer el efecto de la evapotranspiración, primero se debe calcular la evapotranspiración de referencia (ET_o). Esto requiere la ecuación Penman-Monteith que la *Food and Agriculture Organization of the United Nations* (FAO) define en [19] para calcular evapotranspiración por hora. Debido a que el diseño del sistema a corto plazo solo tiene acceso a una medición de humedad y temperatura cada 10 minutos, no es posible usar la fórmula proporcionada por el organismo mencionado, la cual es más precisa y utiliza valores mínimos y máximos. Así que la evapotranspiración se calculará a partir de la presión de saturación de vapor e° en $[kPa]$, en vez de su promedio. Además, se tiene la fórmula de presión de vapor real e_a en $[kPa]$, por lo que se deberá adaptar para que solo utilice una medición de temperatura y humedad. Esto hace que la evapotranspiración de referencia ET_o en $[\frac{mm}{hr}]$ esté dada por las ecuaciones (3.15) y (3.16).

$$ET_o = \frac{0,408\Delta(k)(R_n(k)-G)+\gamma(k)\cdot\frac{C_n}{T_{inv}(k)+237}u_2^c(k)\cdot(e^\circ-e_a)}{\Delta(k)+\gamma(k)(1+C_d u_2(k))} \quad (3.15)$$

Donde:

$$e^\circ(T_{inv}) = 0.6108 \cdot \exp\left(\frac{17.27T_{inv}}{T_{inv}+237.3}\right)$$

$$e_a = e^\circ(T_{inv}) \cdot \frac{HR_{inv}}{100}$$

$$R_n(k) = Q_{rad}(k) \cdot \frac{0.0036}{A_g} \quad (3.16)$$

$$u_2(k) = \max\left(u^{ext}W_s \frac{4,87}{\ln(67,8z-5,42)}, 0.5\right)$$

$$\Delta = \frac{4098e^\circ(T_{inv})}{(T_m+237,3)^2}$$

R_n es la radiación neta en $[\frac{MJ}{hr \cdot m^2}]$, una forma de calcularla es por medio del calor ganado por radiación, como se muestra en la fórmula de arriba. G es el flujo de calor de la tierra en $[\frac{MJ}{hr \cdot m^2}]$; según la escala de tiempo que se utilice, es posible simplificar este término. Si es 1 hora, se puede simplificar como $0.1R_n$ cuando es de día y $0.5R_n$ cuando es de noche. γ es la constante psicrométrica y Δ es la pendiente de la presión de saturación de vapor en función de la temperatura. A_g es el área del suelo del invernadero en $[m^2]$. u_2^c es la proyección a 2 metros de altura de la velocidad del viento que perciben los cultivos y que se expresa en $[\frac{m}{s}]$. Si las ventanas están abiertas, se considera que esta variable depende del viento

externo medido; si no están abiertas, se utiliza la velocidad mínima que recomienda la FAO en [19]. z es la altura a la que se mide la velocidad del viento. C_n y C_d son constantes que dependen de la escala y hora del día, estas constantes se pueden encontrar en [20]. Para esta implementación, se considera que un instante ocurre en el día si $Ir \geq 100[\frac{W}{m^2}]$ y si no, se interpreta que sucede de noche. HR_{inv} es la medición de humedad relativa en %. Tanto T_{inv} como HR_{inv} se miden con sensores en el invernadero.

Finalmente, para calcular la variación de temperatura (Q_{evap}) y la variación de humedad (ΔX_{evap}) que se deben a la evapotranspiración, se utiliza la evapotranspiración potencial ET_p en $[\frac{mm}{hr}]$, obtenida a partir de ET_o , tal y como se observa en la ecuación (3.17). La fórmula del efecto de la evapotranspiración por el calor se obtuvo de [17] y la fórmula del efecto en la humedad se extrajo de [18]. Si bien es posible obtener un valor más certero utilizando la evapotranspiración real, esta no se utiliza debido a que no es posible obtenerla cada 10 minutos, pues se necesitaría actualizar el dato de la zona de agotamiento de raíz a esa misma velocidad y el modelo utilizado para ello es a escala diaria.

$$Q_{evap}(k) = \frac{\sum_{c=1}^{Cultivos} \lambda_o ET_{pc}(k) A_c}{3600}$$

$$\Delta X_{evap}(k) = \frac{\sum_{c=1}^{Cultivos} 1000 ET_{pc}(k) A_c}{V_{inv} 3600} \quad (3.17)$$

$$ET_{pc}(k) = K_c ET_o(k) \quad (3.18)$$

A_c es el área designada para el cultivo c y K_c es una constante que depende del cultivo.

3.2.6. Efecto de la condensación

Este efecto (ΔX_c) corresponde al flujo de agua entre el aire del invernadero y la condensación en la cubierta del invernadero. Para calcular este efecto, se utiliza la ecuación (3.19), que es una variación de la usada en [18]. La original calcula la condensación en forma de gramos por cada metro cuadrado de suelo, mientras que (3.19) calcula en gramos por metro cúbico de aire.

$$\Delta X_c(k) = \frac{A_g}{V_{inv}} g_c \{0.2522 e^{0.0485 \cdot T_{int}(k)} (T_{inv}(k) - T_{ext}(k)) - (X_{inv}^{sat}(k) - X_{inv}(k))\} \quad (3.19)$$

Donde:

$$g_c = \max(0, P_{gc} (T_{inv}(k) - T_{cu}(k))^{\frac{1}{3}}) \quad (3.20)$$

g_c es la conductancia de condensación en $[\frac{m}{s}]$. T_{inv} , T_{ext} y T_{cu} son las temperaturas del invernadero en el exterior y en la cubierta, expresadas en $[^\circ C]$. X_{inv}^{sat} y X_{inv} son la humedad de saturación del invernadero y la humedad absoluta del invernadero en $[\frac{g}{m^3}]$. La constante P_{gc} , calculada en $[\frac{m}{s^\circ C^{\frac{1}{3}}}]$, depende del invernadero y su valor se determina con la ecuación (3.21), la cual proviene de [21].

$$P_{gc} = \frac{A_{cu}}{A_g} 1.64 \cdot 10^{-3} \quad (3.21)$$

A_{cu} y A_g son las áreas en $[m^2]$ de la cubierta y del suelo del invernadero.

Para mantener un invernadero, no solo es necesario gestionar el micro-clima de este, sino que también se requiere regar los cultivos que alberga en su interior. Por ello, se necesita modelar la demanda de riego.

3.3. Demanda de riego

Una forma de establecer el volumen de agua de riego que se requiere por día es determinar cuánta agua le falta a un cultivo para desarrollarse lo mejor posible. Esto puede saberse por medio de la relación entre la evapotranspiración real ET_a y la potencial ET_p : cuando la evapotranspiración real alcanza a la evapotranspiración potencial, la planta no sufre estrés hídrico y se desarrolla de la mejor forma posible dadas las condiciones en la que se encuentra. Para calcular ambas evapotranspiraciones en escala de días, se utilizan las fórmulas propuestas por la FAO en [19], que se presentan en la ecuación (3.22). Esta ecuación se diferencia de la descrita en (3.15) en que dispone de más datos, pues calcula la evapotranspiración diariamente. Esto permite utilizar la presión de vapor de saturación promedio e_s en $[kPa]$ y calcular de forma más precisa la presión de vapor real e_a en $[kPa]$. Asimismo, la ecuación del presente trabajo se diferencia en que calcula la pendiente de presión de saturación Δ a través del promedio de la temperatura máxima y mínima diaria.

$$ET_o = \frac{0,408\Delta(k)(R_n(k)-G)+\gamma(k)\cdot\frac{C_n}{T_{inv}(k)+237}u_2^p(k)\cdot(e_s-e_a)}{\Delta(k)+\gamma(k)(1+C_d u_2(k))}$$

$$e^\circ(T) = 0,6108 \exp \left[\frac{17,27T}{T+237,3} \right]$$

$$e_s = \frac{e^\circ(T_{max})+e^\circ(T_{min})}{2}$$

$$e_a = \frac{e^\circ(T_{min})\frac{HR_{max}}{100}+e^\circ(T_{max})\frac{HR_{min}}{100}}{2} \quad (3.22)$$

$$T_m = \frac{T_{max}+T_{min}}{2}$$

$$\Delta = \frac{4098e^\circ(T_m)}{(T_m+237,3)^2}$$

$$ET_p(k) = K_c \cdot ET_o(k)$$

$$ET_a(k) = K_s(k) \cdot K_c \cdot ET_o(k)$$

ET_o , ET_p y ET_a son la evapotranspiración de referencia, la potencial y la real, medidas en $[\frac{mm}{day}]$. G es el flujo de calor de la tierra, que se puede igualar a 0 en la escala de día. $R_n(k)$ es la radiación neta percibida por el invernadero en $[\frac{MJ}{m^2 \text{ día}}]$. u_2^p es la velocidad promedio del viento a 2 $[m]$, percibida por los cultivos y expresada en $[\frac{m}{s}]$. $e_s(k)$ y $e_a(k)$ son la saturación de vapor promedio y la saturación de vapor real en $[kPa]$; en este caso, se cuenta con más

datos para calcularlas, a diferencia de cuando se estimaron para conocer el efecto de la evapotranspiración en el micro-clima. K_c es una contante que depende del cultivo. K_s es una variable que representa el estrés por falta de agua y se puede calcular a partir de la zona de agotamiento de raíz D_r y el agua fácilmente disponible RAW , como se observa en la ecuación (3.23).

$$K_s(k) = \begin{cases} \frac{TAW - D_r(k)}{TAW - RAW(k)} & \text{si } RAW(k) < D_r(k) \\ 1 & RAW(k) \geq D_r(k) \end{cases} \quad (3.23)$$

$$RAW(k) = p(k) \cdot TAW$$

$$p(k) = p_c + 0.04 \cdot (5 - ET_p(k)),$$

Ahí p_c es un coeficiente adimensional, que depende del cultivo. $D_r(k)$ es la zona de agotamiento de raíz en $[mm]$. TAW y $RAW(k)$ son *Total Available Water* y *Readily Available Water*, medidas en $[mm]$, es decir, el agua total disponible y el agua fácilmente disponible. $p(k)$ es una fracción de TAW que el cultivo puede extraer sin estrés. La relación entre TAW , D_r y el riego se observa en la ecuación (3.24).

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

$$D_r(k) = D_r(k-1) - I_d(k) - CR(k) + DP(k) + ET_p(k)$$

$$D_r(0) = 1000 \cdot (\theta_{FC} - \theta_0) \cdot Z_r \quad (3.24)$$

$$I_d(k) = \bar{V}(k) \frac{1000\eta_r}{p_t A}$$

$$0 \leq D_r(k) \leq TAW$$

θ_{FC} y θ_{WP} son la capacidad de campo y el punto de marchitamiento respectivamente y se expresan en $[\frac{m^3}{m^3}]$. θ_0 es la cantidad de agua que en promedio tendría la tierra y cuya unidad de medida es $[\frac{m^3}{m^3}]$; en un caso inicial donde la tierra esté bien regada, esta variable se puede ignorar y, en consecuencia, fijar D_r inicial como 0. Z_r es la profundidad de las raíces en $[m]$, la cual es posible determinar por medio de una función lineal que depende del cultivo [22].

Asimismo, $I_d(k)$ es el riego total. $DP(k)$ es la percolación profunda, que se refiere al agua que se vuelve inaccesible debido a que se ha filtrado en la tierra a causa de la gravedad. $CR(k)$ es el alza capilar, es decir, el agua que sube desde acuíferos subterráneos debido a la capilaridad. Estas tres variables se miden en el día k en $[mm]$. $I_d(k)$ se calcula usando el volumen de riego $\bar{V}(k)$ en $[m^3]$, el área de plantado A en $[m^2]$, la eficiencia de riego η_r y la porosidad de la tierra p_t .

Ahora bien, esta ecuación normalmente incluiría el efecto de la lluvia y el escurrimiento, pero se espera que estos fenómenos no afecten este experimento.

3.4. Discusión

En este capítulo, se describieron las tres dinámicas que caracterizan las necesidades y limitaciones del invernadero. Estas son la arquitectura del invernadero, el micro-clima del invernadero y la demanda de riego. La modelación de la arquitectura permite dar seguimiento a los recursos disponibles en el invernadero y de esa forma poder administrarlos.

Además de la administración de los recursos, es necesario modelar el microclima del invernadero. Esto se realiza combinando un modelo de temperatura de invernadero con uno de humedad de invernadero y agregar una dinámica de la temperatura del subsuelo, de tal manera que el modelo se pueda usar de forma predictiva. Una vez modelado el micro-clima, se puede conocer las condiciones ambientales dentro del invernadero y predecirlas.

Luego, es posible gestionar dichas condiciones para garantizar que los cultivos tengan un crecimiento adecuado, así como estimar la evapotranspiración de estos. Por último, gracias al cálculo de la demanda de riego, se puede saber cuánta agua usan los cultivos y cuánta necesitan para tener un desarrollo óptimo.

Las relaciones entre estos tres modelos se pueden ver en la figura 3.4.

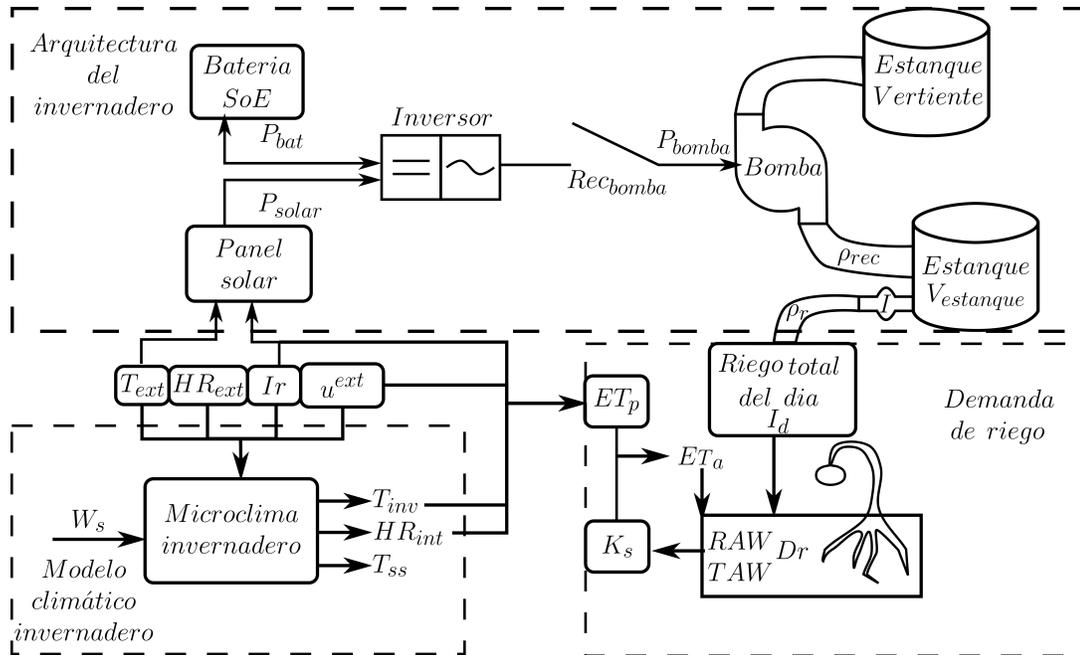


Figura 3.4: Diagrama completo de la modelación del invernadero y sus interacciones.

Estos modelos contribuyen al diseño de controladores que permiten el control del invernadero para procurar el desarrollo adecuado de los cultivos con el menor gasto de agua. Estos controladores se presentan en el siguiente capítulo.

Capítulo 4

Sistema propuesto de gestión de agua y energía para invernaderos

4.1. Planteamiento del problema

El sistema a controlar es un invernadero en la comunidad lafkenche José Paineicura Hueñalihuen de la comuna de Carahue. En este estudio, se considera que el cultivo de este invernadero es únicamente de tomates. También se considera que el sistema debe regar solo la mitad de estos cultivos, mientras que la otra mitad se riega a mano. El agua para riego se almacena en un estanque elevado y se bombea desde otro estanque, el cual se rellena con una vertiente. El riego del invernadero es de tipo goteo y se realiza con una válvula *on/off*. La energía del sistema proviene de una red eléctrica, exclusiva del invernadero y que consta de baterías y un panel solar. Para la regulación del micro-clima del invernadero, se controla la apertura de las ventanas con un sistema que implementa sensores que miden la temperatura T_{inv} y la humedad relativa HR_{inv} del invernadero, la temperatura del subsuelo del invernadero T_{ss} y el nivel del agua del estanque $V_{estanque}$. Para mediciones climáticas externas se utilizan los datos obtenidos por una estación meteorológica, los cuales son: temperatura externa T_{ext} , humedad relativa externa T_{ext} , velocidad del viento u^{ext} y radiación solar Ir . Todos estos elementos están representados en la figura 4.1, en donde S_a es el sensor de temperatura y humedad del invernadero, S_s es el sensor de temperatura del subsuelo y S_e es el sensor de nivel del estanque.

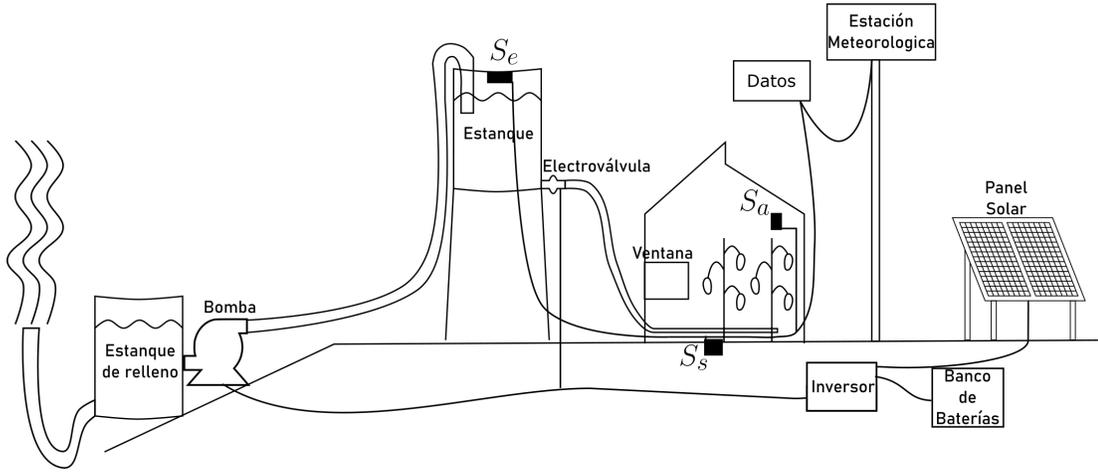


Figura 4.1: Dibujo del invernadero, se pueden observar sensores para el estanque, el suelo del invernadero y el aire del invernadero.

4.2. Sistema de gestión agua y energía propuesto

La principal diferencia entre el controlador propuesto y los mencionados en 2.2 es que este se diseña para un invernadero independiente de la red eléctrica, que solo utiliza la apertura de ventanas para la regulación de su microclima y así disminuir los actuadores necesarios. El sistema de gestión de agua-energía funciona con dos niveles de gestión: mediano y corto plazo, como se observa en la figura 4.2.

El nivel de gestión a mediano plazo establece un objetivo de riego diario \bar{V} ; por su parte, el nivel a corto plazo si bien intenta alcanzar dicho objetivo, reporta la cantidad de agua que se regó realmente durante el día (V_{irr}). El controlador a mediano plazo asegura que los cultivos estén óptimamente regados, mediante la evaluación de la evapotranspiración; luego, designa volúmenes de riego diarios para 28 días a futuro. En cambio, el controlador a corto plazo se asegura de regar el volumen adecuado de agua, para lo cual decide cada 10 minutos cuánto regar y cuándo rellenar el estanque.

Además, con el objetivo de tomar decisiones óptimas, el controlador contempla el funcionamiento del invernadero en las siguientes 48 horas futuras y tiene en cuenta los recursos disponibles (carga de la batería SoE y volumen en el estanque $V_{estanque}$). Igualmente, el controlador elige cuándo abrir o cerrar las ventanas, con el objetivo de mantener el micro-clima del invernadero en condiciones idóneas para los cultivos.

Todos los controladores dependen de predicciones climáticas, las cuales se hacen en base a datos meteorológicos y el estado de la ventana W_s . Los datos meteorológicos se separan entre datos externos e internos. Por un lado, los externos son: temperatura externa T_{ext} , humedad relativa externa HR_{ext} , irradiancia solar Ir y velocidad del viento u^{ext} . Por otro lado, los internos son: la temperatura del ambiente del invernadero T_{inv} , la humedad relativa del invernadero HR_{inv} y la temperatura del subsuelo del invernadero T_{ss} .

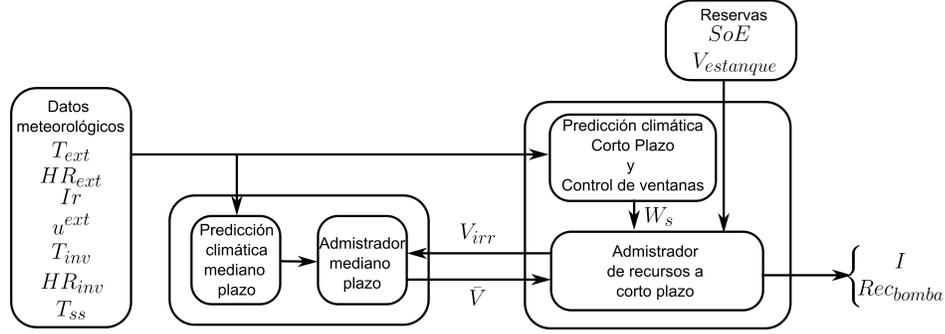


Figura 4.2: Representación gráfica de las relaciones entre las funciones del administrador.

4.3. Predicción climática

Para poder utilizar un controlador predictivo, es necesario realizar predicciones de las perturbaciones medidas y de las variables de estado. Debido a la naturaleza del controlador, se requiere una predicción a corto plazo y otra a mediano plazo.

4.3.1. Predicción climática a corto plazo de variables externas

La predicción a corto plazo tiene un periodo de muestreo de 10 minutos y predice las próximas 48 horas o 288 pasos a futuro. Se reconocen dos tipos de variables climáticas: externas (temperatura atmosférica, humedad relativa atmosférica, velocidad del viento e irradiancia solar) e internas (humedad del invernadero, temperatura del invernadero y temperatura del subsuelo). Cada categoría de variables requiere una estrategia distinta. En el caso de las externas, se pretende abordar con redes neuronales, modelos lineales y promedios móviles. En cuanto a las variables internas, se utiliza el modelo fenomenológico del micro-clima del invernadero que se describió en la sección 3.2.

Para predecir las variables externas a corto plazo, se entrenan distintos modelos autorregresivos y se elige el que funcione mejor para cada variable. Las variables a predecir son: temperatura externa, humedad relativa externa, irradiancia y velocidad del viento. Los modelos a utilizar son redes neuronales, modelos lineales autorregresivos y media móvil, los cuales se describen de forma general en la ecuaciones (4.1), (4.2) y (4.3) respectivamente.

En primer lugar, se utilizan los 144 datos que corresponden a la información de las últimas 24 horas como regresores iniciales. En el caso de la media móvil y del modelo lineal, los regresores se eligen con el objetivo de disminuir el error en validación. En cambio, las redes neuronales se optimizan mediante un análisis de sensibilidad, que consiste en descartar los regresores menos influyentes hasta que el error en validación ya no disminuya [23]. Debido a la alta cantidad de iteraciones necesarias se utiliza un algoritmo diferente que se presenta en el anexo A.4.

$$T_{inv}(k) = NN(T_{inv}(k-1), \dots, T_{inv}(k-144)) \quad (4.1)$$

$$T_{inv}(k) = \sum_{i=1}^{144} A_i T_{inv}(k-i) \quad (4.2)$$

$$T_{inv}(k) = \sum_{i=1}^{N_m} \frac{T_{inv}(k-i)}{N_m} \quad (4.3)$$

En (4.2), A_i son los parámetros del modelo y, en (4.3), N_m es la cantidad de regresores para la media móvil.

4.3.2. Predicción climática a corto plazo de variables internas

Para la predicción de las variables internas (T_{inv} , X_{inv} y T_{ss}), se utiliza una versión modificada del modelo fenomenológico que describe la dinámica de estas y que se presentó en la sección 3.2. En esta versión, se usan predicciones auxiliares que corresponden a una interpolación entre los pasos. El objetivo de esto es disminuir el error de predicción causado por el tiempo de muestreo y la falta de resolución de los datos. Para este proceso, se define un tiempo de interpolación Δt_i , que representa el paso de tiempo para la interpolación. Este valor debe elegirse de forma que $\frac{\Delta t}{\Delta t_i} = J$ sea entero, donde Δt es el tiempo de muestreo del sistema. Cabe mencionar que mientras mas pequeño sea Δt_i , mayor será la precisión, pero el cálculo demorará más. En la figura 4.3, se observa una representación de la relación entre los pasos interpolados y el tiempo real.

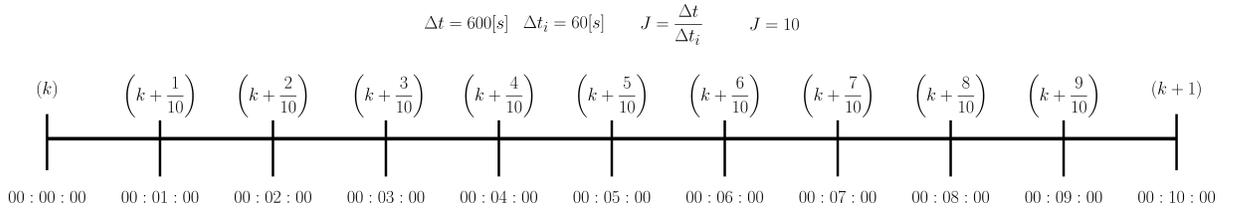


Figura 4.3: Representación gráfica de los instantes que representan cada predicción auxiliar, con $\Delta t_i = 60[s]$.

En las ecuaciones (4.4), (4.5) y (4.6), todos los términos de calor Q y variación de humedad ΔX en el instante $k + \frac{j}{J}$ se calculan con la interpolación lineal de las variables climáticas externas para el instante $k + \frac{j-1}{J}$ y las variables climáticas internas predichas para el instante $k + \frac{j-1}{J}$.

$$T_{inv}^{aux} \left(k + \frac{j}{J} \right) = T_{inv}^{aux} \left(k + \frac{j-1}{J} \right) + \Delta t_i \cdot \frac{Q_t \left(k + \frac{j-1}{J} \right)}{\left(\rho_{air} \cdot c_{pa} + \frac{X_{inv} \left(k + \frac{j-1}{J} \right) \cdot c_{pv}}{1000} \right) V_{inv}}, j \in [1, \dots, J]$$

$$T_{inv}^{aux}(k) = T_{inv}(k) \quad (4.4)$$

$$Q_t \left(k + \frac{j-1}{J} \right) = Q_{rad} \left(k + \frac{j-1}{J} \right) - Q_{cc} \left(k + \frac{j-1}{J} \right) - Q_{ren} \left(k + \frac{j-1}{J} \right) \dots \\ - Q_g \left(k + \frac{j-1}{J} \right) - Q_{evap} \left(k + \frac{j-1}{J} \right), j \in [1, \dots, J]$$

$$T_{ss}^{aux} \left(k + \frac{j}{J} \right) = T_{ss}^{aux} \left(k + \frac{j-1}{J} \right) + \Delta t_i \cdot \frac{Q_g \left(k + \frac{j-1}{J} \right)}{A_g L_{ss} c_{pg} \rho_g}, j \in [1, \dots, J] \quad (4.5)$$

$$T_{ss}^{aux}(k) = T_{ss}(k)$$

$$X_{inv}^{aux} \left(k + \frac{j}{J} \right) = X_{inv}^{aux} \left(k + \frac{j-1}{J} \right) + \Delta t_i \cdot \Delta X \left(k + \frac{j-1}{J} \right), j \in [1, \dots, J]$$

$$\Delta X \left(k + \frac{j-1}{J} \right) = -\Delta X_{ren} \left(k + \frac{j-1}{J} \right) + \Delta X_{evap} \left(k + \frac{j-1}{J} \right) - \Delta X_c \left(k + \frac{j-1}{J} \right), j \in [1, \dots, J] \quad (4.6)$$

4.3.3. Predicción climática a mediano plazo

En el caso de la predicción climática a mediano plazo, se requiere predecir las variables de las que depende la evapotranspiración de referencia; esas predicciones deben ser para cada uno de los siguientes 28 días futuros. Luego, se puede calcular la evapotranspiración de referencia para ese mismo periodo. Las variables a predecir son la radiación neta (R_n); la velocidad promedio del viento a 2 [m], percibida por los cultivos (u_2^p); la temperatura mínima y la temperatura máxima del invernadero (T_{min} , T_{max}) y las humedades relativas mínimas y máximas (HR_{min} , HR_{max}).

Las predicciones para los dos primeros días se calculan como si fueran predicciones a corto plazo. Sin embargo, para los días posteriores (del 3 al 28), se puede recurrir a otra estrategia que involucra menos precisión. Esto se hace debido a que no se tienen los datos necesarios para realizar modelos mas complejos (5 años de datos mínimo) y por la alta estocasticidad de las variables climáticas. En el caso de la radiación neta R_n , se calcula por medio de una modificación la manera de calcular el calor por radiación, la cual se presenta en la ecuación (4.7). Ahí se ignora el efecto de la temperatura del invernadero y solo se considera la radiación solar, donde Ir_d representa la irradiancia promedio en un día, medida en $\left[\frac{W}{m^2} \right]$ y predicha con un modelo de media móvil que usa 7 días de información.

$$R_n(k) = \frac{R_{solmean}(k)}{A_g} \cdot \frac{86,400}{1,000,000} \quad (4.7)$$

$$R_{solmean} = A_g \cdot [Ir_d(k) \cdot (\alpha_{inv} + \tau_{inv} \cdot \alpha_{inv})]$$

El segundo término de la primera ecuación es un factor de transformación que cambia la unidad de medida de $[\frac{W}{m^2}]$ a $[\frac{MJ}{m^2 Day}]$. Así esta última se expresa en las mismas unidades que se utilizan en la ecuación de la evapotranspiración de referencia en la escala de días (3.22).

Para conocer la velocidad del viento a dos metros u_2^p , se usa la ecuación (4.8), donde W_{perf} es el porcentaje promedio de tiempo que la ventana está abierta durante el día y u_{perf}^{ext} es la velocidad promedio del viento. Estos términos se fijan debido a la dificultad de estimar la apertura de las ventanas y las velocidades del viento en los siguientes 28 días.

$$u_2(k) = \max \left(W_{perf} u_{perf}^{ext} \frac{4,87}{\ln(67,8z - 5,42)}, 0,5 \right) \quad (4.8)$$

Siendo z la altura en $[m]$ a la que se mide la velocidad del viento.

Finalmente, las predicciones que se hacen durante los días del 3 al 28 para las variables de temperatura (T_{min} y T_{max}) y humedad (HR_{min} y HR_{max}) se obtienen con los promedios de los primeros dos días de predicción, ante el supuesto de que el sistema de control de clima mantendrá un comportamiento similar. La fórmula se presenta en la ecuación (4.9). Esto se justifica porque el sistema de control climático debería mantener tales variables en valores similares para todos los días. Además, el error tendrá un menor efecto en el sistema de control mientras más lejana sea la predicción.

$$\begin{aligned} T_{max}(j) &= \frac{T_{max}(1)+T_{max}(2)}{2} & j \in [3, \dots, 28] \\ T_{min}(j) &= \frac{T_{min}(1)+T_{min}(2)}{2} & j \in [3, \dots, 28] \\ HR_{max}(j) &= \frac{HR_{max}(1)+HR_{max}(2)}{2} & j \in [3, \dots, 28] \\ HR_{min}(j) &= \frac{HR_{min}(1)+HR_{min}(2)}{2} & j \in [3, \dots, 28] \end{aligned} \quad (4.9)$$

4.4. Sistema de gestión a corto plazo

La gestión del invernadero a corto plazo se puede separar en dos actividades: la gestión del micro-clima y la gestión de recursos hídricos y energéticos. En ambos casos, se usan controladores predictivos debido a que las condiciones del micro-clima pueden limitar la decisión de riego.

El primer paso es predecir a corto plazo las variables climáticas externas (T_{ext} , HR_{ext} , Ir y u^{ext}). Después, se decide la apertura de las ventanas con el controlador de las mismas. Con base en esta decisión, se predicen las variables climáticas internas (T_{inv} , HR_{inv} y T_{ss}). Luego, se realiza la gestión de recursos, la cual es ejecutada por un controlador que administra el uso de agua y energía con base en decisiones sobre el uso de la bomba y los actuadores de riego. Los controladores tienen horizonte de predicción y control $N_y = N_u = 2H$, donde H es igual a la cantidad de pasos necesarios para completar un día. Usando un tiempo de muestreo de 10 minutos, se tiene que $2H = 288$.

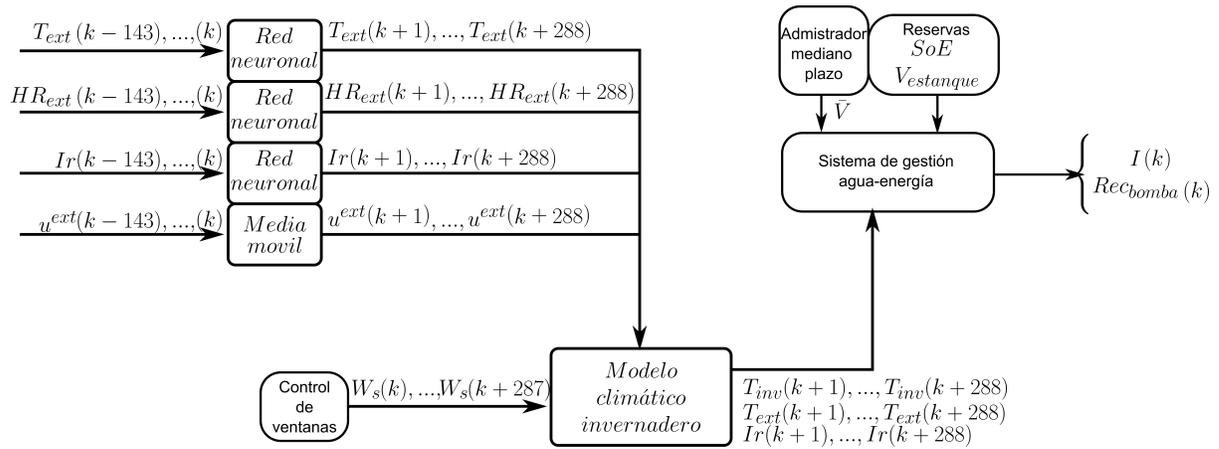


Figura 4.4: Diagrama de bloques del controlador a corto plazo.

4.4.1. Control de ventanas

El control de ventanas busca mantener el micro-clima del invernadero por medio de la minimización de una función objetivo, la cual aumenta de valor cuando las variables climáticas están fuera de los márgenes deseados. Asimismo, debe evitarse que la ventana cambie frecuentemente de estado, de forma de disminuir el desgaste de su mecanismo. Para este fin, se consideran tres tipos de funciones objetivo: seguimiento de referencia, que se presenta en (4.10); estrategia de penalización, que corresponde a (4.11), y optimización difusa, la cual se describe en (4.12). Los parámetros de estas tres funciones se diseñan a partir de las recomendaciones climáticas expuestas en [17] y [24] (ver tabla 4.1). Estas funciones deben considerar si un instante evaluado corresponde a un instante de noche o de día; para esta implementación, se considera que el instante k es de día si $Ir(k) \geq 100 \left[\frac{W}{m^2} \right]$, como se ve en la figura 4.5.

Tabla 4.1: Límites climáticos del invernadero.

	Mín. seguridad	Mín. normal	Máx. normal	Máx. seguridad
T_{inv} de día [$^{\circ}C$]	10	22	26	30
T_{inv} de noche [$^{\circ}C$]	10	13	16	30
HR_{inv} %	30	55	75	90

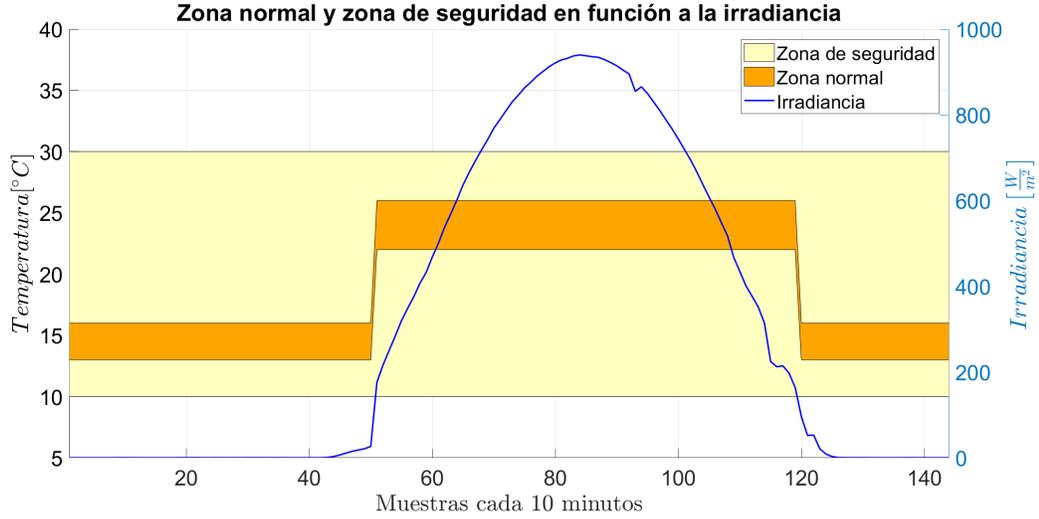


Figura 4.5: Relación de las temperaturas límites con la radiación.

La primera función objetivo, descrita en (4.10), es un seguimiento de referencia. Esta función busca trasladar la temperatura y la humedad del invernadero a referencias que dependan de la hora, a la vez que busca minimizar los cambios de estado de la ventana. Estas referencias se determinan por medio de las características de los cultivos que crecen en el invernadero.

$$\min_{W_s(k) \dots W_s(k+N_u-1)} \sum_{j=1}^{2H} \lambda_T (T_{inv}(k+j) - T_{ref}(k+j))^2 + \quad (4.10)$$

$$\lambda_{HR} (HR_{inv}(k+j) - HR_{ref}(k+j))^2 + \sum_{j=1}^{N_u} \lambda_{W_s} \Delta W_s(k+j-1)^2$$

λ_T , λ_{HR} y λ_{W_s} son parámetros de diseño, que se usan para ajustar respectivamente la penalización de la temperatura, de la humedad y del cambio de estado de la ventana. $T_{ref}(k)$ y $HR_{ref}(k)$ son la temperatura y la humedad de referencia. Se supone que los cultivos del invernadero compartirán condiciones ideales similares.

La segunda función objetivo es una estrategia de penalización y se describe en (4.11). Esta función aumenta de valor cuantas veces T_{inv} o HR_{inv} se salen de los límites normales. A su vez, podemos saber cuándo la temperatura T_{inv} o la humedad HR_{inv} sobrepasan dichos límites, gracias a las funciones indicatrices O_T y O_{HR} .

$$\min_{W_s(k) \dots W_s(k+N_u-1)} \sum_{j=1}^{2H} O_T(k+j) + O_{HR}(k+j) + \sum_{j=1}^{N_u} \lambda_{W_s} \Delta W_s(k+j-1)^2$$

$$O_T(k+j) = \begin{cases} 0, & T_{minC}(k+j) \leq T_{inv}(k+j) \leq T_{maxC}(k+j) \\ 1, & \sim \end{cases} \quad (4.11)$$

$$O_{HR}(k+j) = \begin{cases} 0, & HR_{minC}(k+j) \leq HR_{inv}(k+j) \leq HR_{maxC}(k+j) \\ 1, & \sim \end{cases}$$

Por un lado, $T_{minC}(k)$ y $HR_{minC}(k)$ son la temperatura y humedad relativa mínimas nor-

males respectivamente. En contraposición, $T_{maxC}(k)$ y $HR_{maxC}(k)$ son la temperatura y la humedad máximas normales. Se supone que no hay conflictos entre los valores mínimos y máximos de los cultivos, ya que los cultivos de un invernadero deberían tener necesidades atmosféricas compatibles.

La última de las funciones objetivo se enfoca en una optimización difusa, como se aprecia en (4.12). Una descripción de este tipo de optimización se puede encontrar en [25]. La forma de esta función es similar a la de [26]. Es decir, se evalúan los complementos de las funciones de pertenencias, los cuales toman un valor de 0 ante comportamientos deseados, 1 para comportamientos que se buscan evitar y valores entre 0 y 1 en casos intermedios. Este tipo de optimización se considera pues permite introducir restricciones flexibles al sistema.

$$\begin{aligned} \min_{W_s(k) \dots W_s(k+N_u-1)} & \sum_{j=1}^{2H} \bar{\mu}_T^{k+j} (T_{inv}(k+j) - T_{ref}(k+j))^2 + \bar{\mu}_{HR} (HR_{inv}(k+j) - HR_{ref}(k+j))^2 \\ & + \lambda_{W_s} \bar{\mu}_{W_s} \left(\sum_{j=1}^{N_u} \Delta W_s(k+j-1) \right)^2 \end{aligned} \quad (4.12)$$

$\bar{\mu}_T^k$, $\bar{\mu}_{HR}$ y $\bar{\mu}_{W_s}$ son complementos respectivamente de las funciones de pertenencia para el error de la temperatura, la humedad interna y la variación de la apertura de la ventana. En el caso de la función de pertenencia de la temperatura, esta depende de si el instante que evalúa es de día o noche. Estas funciones se grafican en 4.6.

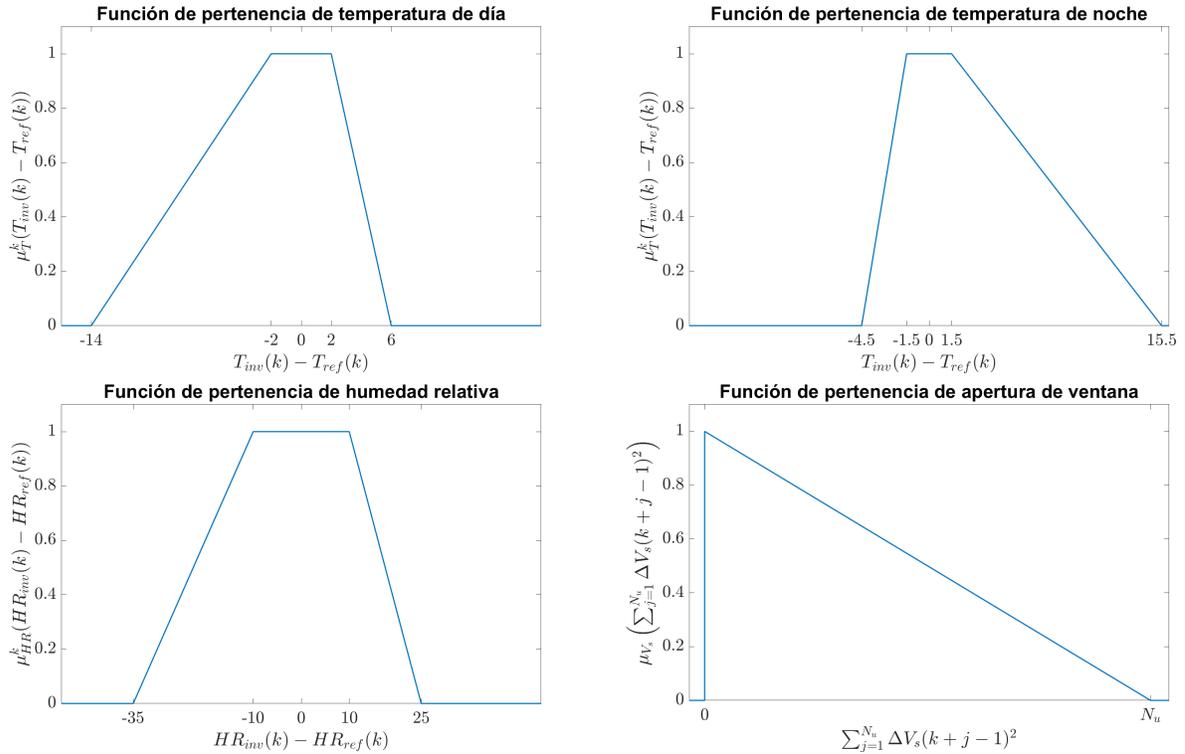


Figura 4.6: Funciones de pertenencia.

Para las tres funciones, se prueban optimizaciones con y sin restricciones duras. La versión

con restricción dura es evaluada con los λ_{W_s} óptimos, que se obtienen de resolver la versión sin restricciones duras. El controlador es optimizado con el método de enjambre de partículas (PSO, por sus siglas en inglés) en su forma clásica. En esta implementación, las partículas representan decisiones de ventana que se aplican en el modelo fenomenológico del invernadero, con lo que se generan valores de temperatura y humedad. Para evaluar a las partículas en el modelo, se limitan los valores de estas entre 0 y 1, y se redondean durante la implementación y evaluación. Las partículas utilizadas se componen de 288 características y poseen la siguiente forma:

$$x = \{W_s(1) \ \cdots \ W_s(288)\} \quad (4.13)$$

Para inicializar la optimización, hay una población de 30 partículas, de las cuales 24 son aleatorias, pero 6 están predeterminadas: ventanas siempre cerradas, ventanas siempre abiertas, acatar la predicción de la mejor partícula del instante anterior pero desfasándola un paso (es decir, la segunda decisión se vuelve la primera) y tres decisiones generadas con controladores por reglas.

Las decisiones con controladores por reglas se generan al implementar cada uno de los controladores en una simulación del invernadero en el horizonte de predicción. Los controladores utilizados corresponden a las ecuaciones (A.1), (A.2) y (A.3). El primero busca mantener la temperatura en el rango normal; el segundo, la humedad en el rango normal y el último abre y cierra la ventana dependiendo de si es de día o no.

Ahora que se tiene una metodología para gestionar el micro-clima del invernadero y así mantener los cultivos en condiciones adecuadas, se requiere diseñar una estrategia para el riego de estos con base en el sistema de agua y energía.

4.4.2. Sistema de gestión de agua-energía

La administración del agua y la energía se realiza también con un controlador predictivo. Este controlador decide el tiempo de la acción de riego I y la activación de la bomba Rec_{pump} para las próximas 48 horas por medio de la optimización de la función objetivo (4.14), respetando la dinámica del invernadero anteriormente descrita.

La función objetivo se compone de tres términos. El primero penaliza tanto la falta como el exceso de riego usando las variables de tipo δ_d , donde d es el día. Esta variable representa la diferencia entre el riego que se aplica y el objetivo de riego para el día $\bar{V}(d)$. Debido a que cada día tiene un objetivo de riego distinto e interactúa con el horizonte de control de forma diferente, se tienen tres términos δ distintos para cada día. El segundo término busca minimizar los instantes en que se riega; esto busca evitar que haya múltiples instancias de riego que sean demasiado cortas. Finalmente, el tercer término es una penalización de uso de energía de la batería, esto es para incentivar al sistema a recargar el estanque con energía del panel.

$$\min_{u(k), \dots, u(k+N_u-1)} \sum_{i=1}^3 C_i \delta_i(k) + \lambda_I \sum_{i=1}^{N_u} \text{sign}(I(k+i-1)) + \lambda_P \sum_{i=1}^{N_u} \max(P_{dem}(k+i-1), 0) \quad (4.14)$$

Donde:

$$u(k) = [I(k), Rec_{pump}(k)]$$

$$C_i = \begin{cases} C_{ex} & \text{si } \delta_i(k) \geq 0 \\ -C_{lack} & \text{si } \delta_i(k) < 0 \end{cases}$$

$$\delta_1(k) = [V_{irr}(k) + \sum_{j=1}^{N(k)} \Delta t \rho_r I(k+j-1)] - \bar{V}(1) \quad (4.15)$$

$$\delta_2(k) = \sum_{j=1+N(k)}^{N(k)+H} \Delta t \rho_r I(k+j-1) - \bar{V}(2)$$

$$\delta_3(k) = \begin{cases} \frac{N(k)-H}{H} \left[\sum_{j=H+N(k)+1}^{2H} \Delta t \rho_r I(k+j-1) - \bar{V}(3) \right] & \text{si } N(k) < H \\ 0 & \sim \end{cases}$$

$N(k)$ es el número de pasos restantes que quedan en el instante k para finalizar el primer día. Es decir, la muestra $N(k) + k$ siempre será la primera muestra del segundo día. Con un paso de 10 minutos, $N(k) = 144$ a las 00:00 y $N(k) = 1$ a las 23:50. C_{ex} es el costo de regar excesivamente y C_{lack} , de la falta de riego. Para δ_1 del primer día, solo se observan los próximos $N(k)$ pasos y también se considera el riego $V_{irr}(k)$ ya aplicado anteriormente en ese mismo día. En el caso de δ_2 del segundo día, se puede observar el intervalo completo, por lo que solo depende de las decisiones desde $1 + N(k)$ a $N(k) + H$. Finalmente, para el tercer día δ_3 , se debe considerar que, debido a que el horizonte de predicción es de 48 horas, solo es posible observar una porción del tercer día, lo cual provoca que las decisiones tengan un error implícito. Esto se compensa con un factor lineal, que reduce el efecto de esta diferencia en función de cuanto porcentaje del día se puede observar. Además, se fija el valor de δ_3 en cero para los casos en que no se puede observar el día. Por otra parte, el sistema debe respetar la siguientes restricciones:

$$sign(I(k+j)) \leq Rest_{riego}(k+j), \forall j \in [0, \dots, N_u - 1]$$

$$V_{estanque_{min}} \leq V_{estanque}(k+j) \leq V_{estanque_{max}}, \forall j \in [1, \dots, N_y] \quad (4.16)$$

$$SoE_{min} \leq SoE(k+j) \leq SoE_{max}, \forall j \in [1, \dots, N_y]$$

$Rest_{riego}$ es una variable binaria que determina, dado un factor externo, como una temperatura demasiado alta o incluso la hora del día, si es posible regar o no. Esta variable toma el valor de 0 si se detecta una condición adversa para el riego.

Los límites superiores e inferiores del estanque y la batería no son necesariamente sus límites físicos, también pueden ser límites de mantención o de seguridad. En el caso del estanque, se puede elegir su límite inferior de modo que se garantice el agua en casos de emergencia. En cuanto a la batería, se pueden definir SoE_{min} y SoE_{max} tales que alarguen su vida útil.

Las restricciones de este sistema se implementan de dos formas, mediante la penalización y la corrección. La primera consiste en penalizar fuertemente a la función objetivo cuando no

se cumplen dichas restricciones; esta implementación se usa para el estanque y la batería. La segunda forma, que se usa únicamente para el riego, modifica la acción de control de modo que $I(k)$ cumpla la restricción. En este caso, cuando $Rest_{riego}(k) = 0$, todos los $I(k)$ toman el valor de 0.

Para la optimización de la función (4.14), se utiliza una estrategia PSO en su forma clásica. Por una parte, las variables binarias son redondeadas. Por otra parte, las variables continuas cuyos valores son menores a 0.05 son tratadas como si ese valor fuera 0. Por último, como cada uno de los 288 pasos implica 2 decisiones, las partículas se componen de 576 características (4.17).

$$x = \{I(1) \ \cdots \ I(288) \ Rec_{pump}(1) \ \cdots \ Rec_{pump}(288)\} \quad (4.17)$$

4.5. Sistema de gestión a mediano plazo

La gestión a mediano plazo determina el volumen de agua de riego necesaria por día durante un plazo de 28 días. Para determinar el riego diario, se maximiza la función objetivo (4.18), la cual se compone de dos términos: rendimiento relativo Y_r y uso relativo del agua V_r . El rendimiento relativo se calcula en base a las ecuaciones mostradas en [19]. Este se maximiza cuando la evapotranspiración real ET_a se iguala a la potencial ET_p . La relación de estas variables con el riego se observa en la demanda de riego que se explicó en la sección 3.3. El segundo factor, V_r , se usa para penalizar el uso de agua y es el resultado de dividir el promedio de los volúmenes asignados para el riego diario $\bar{V}(k)$ entre el máximo volumen posible \bar{V}_{max} . Este volumen se puede determinar de diversas formas, por ejemplo, mediante la tasa de renovación de un pozo o los derechos de agua.

$$\max_{\bar{V}(1), \dots, \bar{V}(28)} Y_r - \gamma_w V_r = \prod_{j=1}^{28} \left[1 - K_y(k+j) \left(1 - \frac{ET_a(k+j)}{ET_p(k+j)} \right) \right]^{\frac{1}{28}} - \sum_{j=1}^{28} \gamma_w \frac{\bar{V}(k+j)}{28\bar{V}_{max}} \quad (4.18)$$

$K_y(k)$ es un factor de respuesta del rendimiento y depende del cultivo y de la etapa de desarrollo en que este se encuentra en el día k . Tanto Y_r como V_r tienen valores entre 0 y 1, y se usa γ_w para balancear el peso de ambos. Y_r es una media geométrica que penaliza los valores más bajos, mientras que V_r es una media aritmética que penaliza el total de agua utilizada.

Para la optimización de esta función, se utiliza (PSO) en su forma clásica, la cual se describe brevemente en [27]. En este tipo de optimización, las partículas se componen de 28 características que representan la decisión de riego de cada uno de los 28 días.

$$x^* = \{\bar{V}(1) \ \cdots \ \bar{V}(28)\} \quad (4.19)$$

4.6. Discusión

En este capítulo, se planteó a detalle el funcionamiento del administrador de agua y energía. Se describió cómo se hacen las predicciones climáticas a corto y mediano plazo; el sistema de gestión a corto plazo, que incluye el control de ventanas y la gestión del riego, y el sistema de gestión a mediano plazo, que determina el volumen de riego diario. Cada uno de estos

sistemas debe ser entrenado, calibrado o probado usando los datos disponibles.

Para las predicciones a corto plazo, se consideran predicciones externas e internas. En el caso de las variables externas, se buscan modelos auto-regresivos; en cambio, para las internas, se utiliza una modificación del modelo 3.2. En este modelo, se interpolan los datos entre los pasos, debido a que el sistema es más rápido que el tiempo de muestreo. En cuanto a las predicciones a mediano plazo, se propusieron distintas soluciones de predicción para cada variable, las cuales deben ser calibradas con base en los datos disponibles.

El sistema de gestión a corto plazo se diseñó para cumplir dos funciones: controlar el microclima y regular el riego. El microclima se controla por medio del controlador de ventanas, que utiliza MPC para maximizar el tiempo que los cultivos experimentan condiciones ideales. En cuanto al riego, este se gestiona con el sistema de gestión agua-energía, el cual utiliza un MPC que busca cumplir con los objetivos de riego de cada día, a la vez que minimiza las instancias de riego y el uso de la batería.

Por su parte, el sistema de gestión a mediano plazo recurre a un MPC, que pretende maximizar el rendimiento diario de los cultivos, al mismo tiempo que minimiza el uso total de agua.

Ahora bien, la calibración y prueba de estos sistemas se hace por medio de distintos experimentos, que se presentan en el próximo capítulo.

Capítulo 5

Resultados

Establecida una metodología para la implementación de cada elemento del administrador de agua y energía, se procede a probar y ajustar los 4 sistemas que componen al sistema de gestión de agua y energía: predicción climática a corto plazo (que se divide en variables internas y externas), control a corto plazo (que se divide en el controlador de ventanas y el sistema de gestión a corto plazo), predicción climática a mediano plazo y control a mediano plazo. Debido a que a la fecha no se poseen mediciones del invernadero, todas estas pruebas se realizan por simulación. Todos los parámetros usados durante la simulación provienen de la literatura y una aproximación a las características del invernadero, estas se presenta en el anexo A.1, . Los primeros resultados corresponden a los sistemas de corto plazo ya que estos pueden afectar el rendimiento de los sistemas de mediano plazo. Un ejemplo de esta relación es el efecto que tiene el control de ventanas sobre la predicción climática a mediano plazo.

5.1. Resultados de la predicción climática a corto plazo

5.1.1. Predicción climática a corto plazo de variables externas

Las primeras pruebas corresponden al entrenamiento de los distintos modelos de predicción climática externa a corto plazo. Las métricas son el rendimiento de los modelos de predicción del tipo neuronal (RN), del modelo autorregresivo lineal (ML) y de la media móvil (MM). Para cada variable y cada modelo se optimizaron los regresores en función al rendimiento en el conjunto de validación para la predicción a 144 pasos (1 día de predicción). Después con base en el rendimiento de estos en el conjunto de prueba, se elije el modelo con el que se predice cada variable. Las fechas de los conjuntos son del 2019-08-16 09:40:00 al 2019-08-31 23:50:00 y del 2019-10-24 00:00:00 al 2020-01-09 23:50:00 para entrenamiento, del 2019-07-16 04:50:00 al 2019-08-16 09:30:00 para validación y del 2019-06-15 00:00:00 al 2019-07-16 04:40:00 para prueba. Este conjunto de entrenamiento se eligió debido a que presenta mayor variabilidad. En la tabla 5.1, se presentan el número de regresores que poseen los modelos finales para temperatura externa (T_{ext}), la humedad relativa externa (HR_{ext}), la irradiancia (Ir) y la velocidad del viento externo (u^{ext}). Además, en las tablas 5.2 y 5.3, se muestran los errores de predicción a 144 pasos (144 p.) y 288 pasos (288 p.) de los mejores modelos de temperatura en validación. Para la humedad relativa, se pueden ver los resultados en 5.4 y 5.5. Los resultados de irradiancia se despliegan en las tablas 5.6 y 5.7. Finalmente, los resultados en cuanto a velocidad del viento aparecen en las tablas 5.8 y 5.9.

Tabla 5.1: Número de regresores en los modelos con los mejores resultados en validación.

	Regresores RN	Regresores ML	Regresores MM
T_{ext}	135	143	4
HR_{ext}	136	131	5
Ir	142	144	5
u^{ext}	132	128	144

Se observa en la tabla 5.1 que tanto los modelos neuronales como los auto-regresivo lineales utilizan gran parte de los regresores disponibles; se podría decir entonces que todos los modelos encuentran útil casi en su totalidad la información generada a lo largo del día anterior. En cambio, en el caso de la media móvil, se puede interpretar que, para la temperatura, la humedad relativa y la irradiancia, se tiene un comportamiento similar a la ultima hora. En el caso de la velocidad del viento, el hecho de que la media móvil requiera de los 144 regresores se puede interpretar como que la variable es mas estocástica y por ende más difícil de predecir.

Para la evaluación de cada modelo, se utilizaron las métricas de $RMSE$ (“*Root Mean Squared Error*”) y $MAPE$ (“*Mean Absolute Percentage Error*”), que se pueden definir como:

$$\begin{aligned}
 RMSE &= \sqrt{\sum_{k=1}^N \frac{(y(k) - \bar{y}(k))^2}{N}}, \\
 MAPE &= 100 \sum_{k=1}^N \left| \frac{y(k) - \bar{y}(k)}{y(k)N} \right|.
 \end{aligned}
 \tag{5.1}$$

N es el número de datos $y(k)$ es el dato real correspondiente a k , mientras que $\bar{y}(k)$ es su estimación.

Tabla 5.2: Errores de las predicciones hechas por los mejores modelos de temperatura externa (T_{ext}) en $^{\circ}C$ en el conjunto de validación.

	144 pasos		288 pasos	
	RMSE [$^{\circ}C$]	MAPE %	RMSE [$^{\circ}C$]	MAPE %
RN	1.8332	13.6794	2.1559	16.472
ML	1.8788	14.3731	2.2333	17.7232
MM	1.9409	14.5034	2.3162	17.8933

Tabla 5.3: Errores de las predicciones hechas por los mejores modelos de temperatura externa (T_{ext}) en $^{\circ}C$ en el conjunto de prueba.

	144 pasos		288 pasos	
	RMSE [$^{\circ}C$]	MAPE %	RMSE [$^{\circ}C$]	MAPE %
RN	2.4101	15.5795	2.7551	18.62
ML	2.6445	17.1723	2.9376	20.6376
MM	2.7193	17.3752	3.0666	20.6695

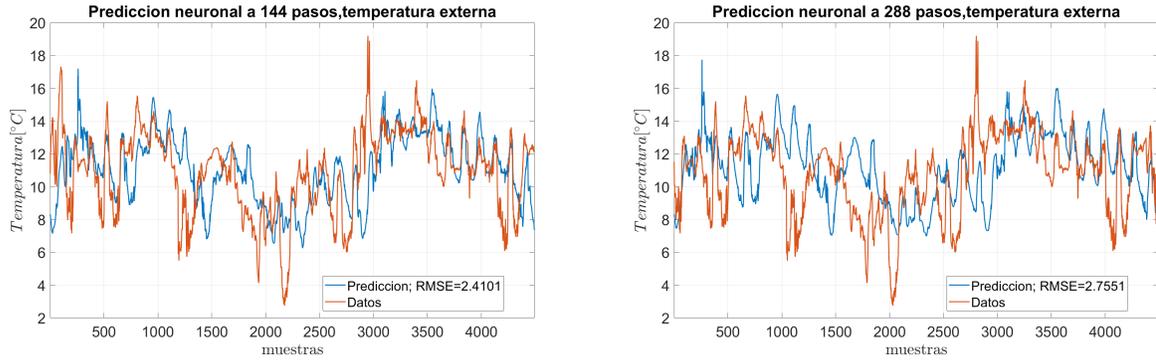


Figura 5.1: Predicciones de temperatura externa (T_{ext}) obtenidas a través de una red neuronal en el conjunto de prueba

En las tablas 5.2 y 5.3, se advierte claramente que la red neuronal obtiene los mejores resultados tanto en validación como en prueba. Con base en esto, se puede concluir que la red neuronal funciona mejor para la predicción de la temperatura externa (T_{ext}). En los gráficos de la figura 5.1, se observa que la red neuronal logra capturar la dinámica de la temperatura externa (T_{ext}) aun a 288 pasos.

Tabla 5.4: Errores de la predicción de humedad relativa externa (HR_{ext}) en % en el conjunto de validación.

	144 pasos		288 pasos	
	RMSE %	MAPE %	RMSE %	MAPE %
RN	11.5244	10.9241	11.6707	11.1524
ML	13.2375	12.4399	14.9086	13.7417
MM	13.7538	12.7917	16.0004	14.832

Tabla 5.5: Errores de la predicción de humedad relativa externa (HR_{ext}) en % en el conjunto de prueba.

	144 pasos		288 pasos	
	RMSE %	MAPE %	RMSE %	MAPE %
RN	13.1979	12.1016	11.7778	11.4252
ML	12.8459	11.7455	14.4062	13.0922
MM	13.1429	11.7351	15.4721	14.0391

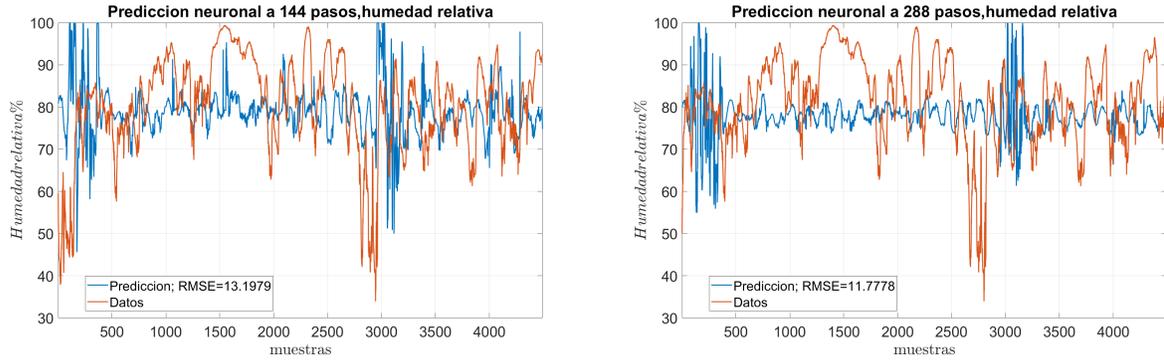


Figura 5.2: Predicciones de humedad relativa externa (HR_{ext}) obtenidas con una red neuronal en el conjunto de prueba

En la tabla 5.4 se aprecia nuevamente que la red neuronal logra una mejor optimización en el conjunto de validación. Sin embargo, como se observa en la tabla 5.5, la red neuronal solo obtiene mejores resultados a los 288 pasos, ya que su rendimiento es ligeramente peor que el rendimiento de la media móvil y del modelo lineal a 144 pasos. Dado que la red neuronal logra mejores resultados a lo largo del tiempo, se decide que este sea el modelo de predicción de humedad relativa externa (HR_{ext}). En los gráficos de la figura 5.2, se observa que la red neuronal tiene dificultades para capturar la dinámica de la humedad relativa externa (HR_{ext}), aunque, la mayor parte del tiempo, alcanza valores similares a los reales a 144 y 288 pasos.

Tabla 5.6: Errores de la predicción de irradiancia (Ir) en $[\frac{W}{m^2}]$ en el conjunto de validación.

	144 pasos		288 pasos	
	RMSE $[\frac{W}{m^2}]$	MAPE %	RMSE $[\frac{W}{m^2}]$	MAPE %
RN	90.311	34.8005	96.3086	37.207
ML	97.2918	41.1199	118.4498	56.1393
MM	100.3871	37.8429	126.6462	52.094

Tabla 5.7: Errores de la predicción de irradiancia (Ir) en $[\frac{W}{m^2}]$ en el conjunto de prueba.

	144 pasos		288 pasos	
	RMSE $[\frac{W}{m^2}]$	MAPE %	RMSE $[\frac{W}{m^2}]$	MAPE %
RN	70.0787	33.1625	76.6546	33.3896
ML	70.9202	38.2906	84.8151	48.4462
MM	74.4542	35.1445	88.8211	43.2404

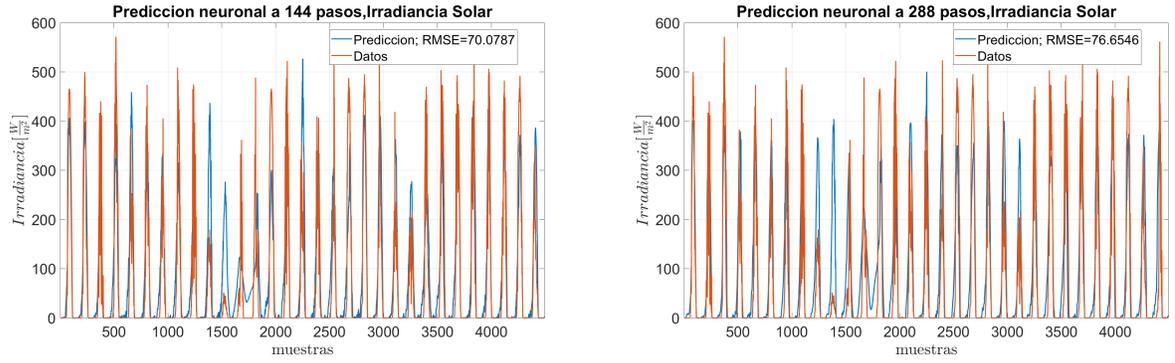


Figura 5.3: Predicciones de irradiancia (Ir) obtenidas con una red neuronal en el conjunto de prueba

Tanto en las tablas 5.6 y 5.7, es posible notar la misma tendencia que en las tablas 5.2 y 5.3: la red neuronal logra mejores predicciones a 144 y 288 pasos tanto en validación como en prueba. Cabe mencionar que el alto valor del MAPE, se puede atribuir a los datos obtenidos de noche pues la irradiancia (Ir) es 0. Debido a esto, se utiliza el modelo de red neuronal para predecir la irradiancia (Ir) solar. En la figura 5.3, se observa que las predicciones a 144 y 288 pasos de la red neuronal se asemejan a la dinámica de la irradiancia (Ir).

Tabla 5.8: Errores de la predicción de la velocidad del viento (u^{ext}) en $[\frac{m}{s}]$ en el conjunto de validación.

	144 pasos		288 pasos	
	RMSE $[\frac{m}{s}]$	MAPE %	RMSE $[\frac{m}{s}]$	MAPE %
RN	2.7512	50.8313	3.6149	57.8489
ML	2.9118	59.3876	2.9246	63.4228
MM	3.1566	55.7412	3.1058	54.5405

Tabla 5.9: Errores de la predicción de la velocidad del viento (u^{ext}) en $[\frac{m}{s}]$ en el conjunto de prueba.

	144 pasos		288 pasos	
	RMSE $[\frac{m}{s}]$	MAPE %	RMSE $[\frac{m}{s}]$	MAPE %
RN	2.9815	54.8457	3.803	62.8844
ML	2.7919	58.921	3.0344	68.7358
MM	2.8621	52.2798	3.0131	55.0215

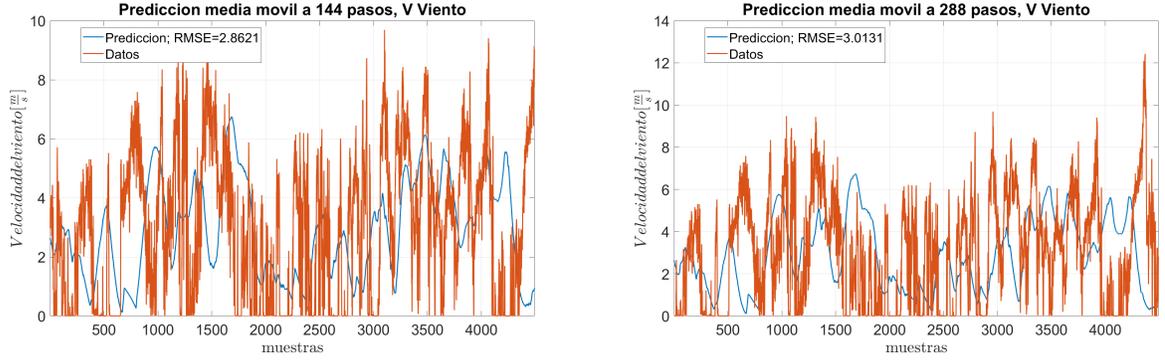


Figura 5.4: Predicciones de la velocidad del viento (u^{ext}) obtenidos con un modelo de media móvil en el conjunto de prueba

En la tabla 5.8, se observa que todos los modelos obtienen RMSE muy altos (cerca del 25 % del máximo, el cual es aproximadamente $12 \left[\frac{m}{s} \right]$). Esto también se advierte en la tabla 5.9, donde la media móvil tiene el mejor resultado a 288 pasos. Se puede deducir entonces que a todos los modelos se les dificulta captar la dinámica del viento con los datos disponibles. Por esta razón, se utiliza la media móvil pues es la estrategia de predicción más simple entre las consideradas. Como se ve en la figura 5.4, las predicciones de la media móvil forman una aproximación general de la dinámica del viento.

Con base en estos resultados, se implementan los modelos neuronales para predecir la temperatura, la irradiancia y la humedad relativa; a su vez, se aplica la media móvil para predecir el viento. Los modelos seleccionados logran buenos resultados en cuanto a la temperatura y a la irradiancia, y presentan resultados aceptables en cuanto a la humedad y a la velocidad del viento. De esta manera, se obtiene la predicción externa a corto plazo, la cual se puede utilizar para computar la predicción climática interna.

5.1.2. Predicción climática a corto plazo de variables internas

Como se mencionó en la sección 4.3.2, el modelo interno utiliza un tiempo Δt_i de interpolación para interpolar entre los pasos de predicción. Se supone que mientras más pequeño sea Δt_i , el modelo se asemeja más al caso real, pero su cálculo también demora más. Debido a esto, se busca encontrar el Δt_i más grande que realice una simulación satisfactoria y que cumpla $\frac{\Delta t}{\Delta t_i} = J$, siendo J un entero. Se toma como referencia una simulación con tiempo de interpolación $\Delta t_i = 0.1[s]$ y se usan como valores iniciales $T_{inv} = 22[^\circ C]$, $HR_{inv} = 50\%$ y $T_{ss} = 15[^\circ C]$. Se supone además que los cultivos cuentan con 14 días de edad al inicio de la simulación.

El experimento consiste en aplicar una señal de apertura de ventanas aleatoria, la cual puede cambiar de valor cada 6 muestras (1 hora); esta señal se aplica a todos los modelos. Los datos de la simulación van desde 2019-6-14 00:00:00 hasta 2019-9-2 00:00:00, con un tiempo de muestreo de 10 minutos, lo que corresponde a 11665 muestras en total.

Los resultados de estos experimentos se resumen en la tabla 5.10, donde se presenta el error absoluto máximo (MxAE) de cada simulación con respecto a la de $\Delta t_i = 0.1[s]$. Estos errores corresponden a los valores de la temperatura del invernadero T_{inv} , la humedad relativa

del invernadero HR_{inv} y la temperatura del subsuelo del invernadero T_{ss} . Se puede observar claramente que $\Delta t_i = 25[s]$ es el periodo más largo y factible en el que se logra el objetivo deseado, ya que obtiene errores máximos absolutos con respecto a $\Delta t_i = 0.1[s]$ menores que 1. También se observa que $\Delta t_i = 30[s]$ arroja errores significativamente más grandes.

Tabla 5.10: Error máximo absoluto (MxAE) de cada simulación con respecto a la simulación donde $\Delta t_i = 0.1$.

$\Delta t_i =$	5[s]	10[s]	15[s]	20[s]	25[s]	30[s]
MxAE $T_{inv} [^{\circ}C]$	0.0205	0.0414	0.0627	0.0855	0.1104	156.7267
MxAE $HR_{inv} \%$	0.1831	0.3733	0.5714	0.7699	0.9796	95.7658
MxAE $T_{ss} [^{\circ}C]$	0.0016	0.0037	0.0067	0.01011	0.01187	1.1076

En la figuras 5.5, 5.6 y 5.7, se aprecia que la diferencia entre las curvas generadas con la simulaciones donde $\Delta t_i = 0.1[s]$ y $\Delta t_i = 25[s]$ es insignificante, lo que confirma que $\Delta t_i = 25[s]$ cumple con las condiciones que se buscan.

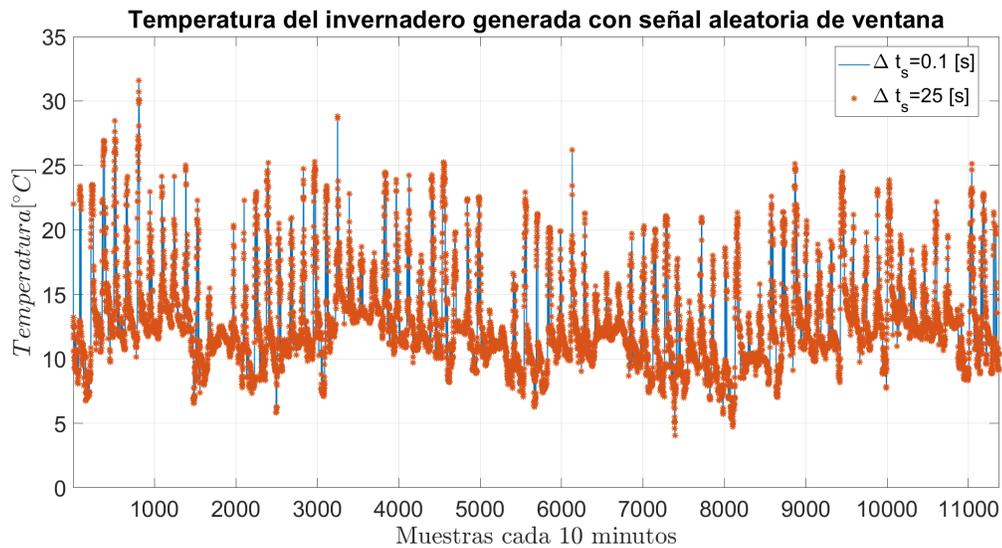


Figura 5.5: Temperatura del invernadero (T_{inv}) obtenida con el modelo fenomenológico usando $\Delta t_i = 0.1[s]$ y $\Delta t_i = 25[s]$.

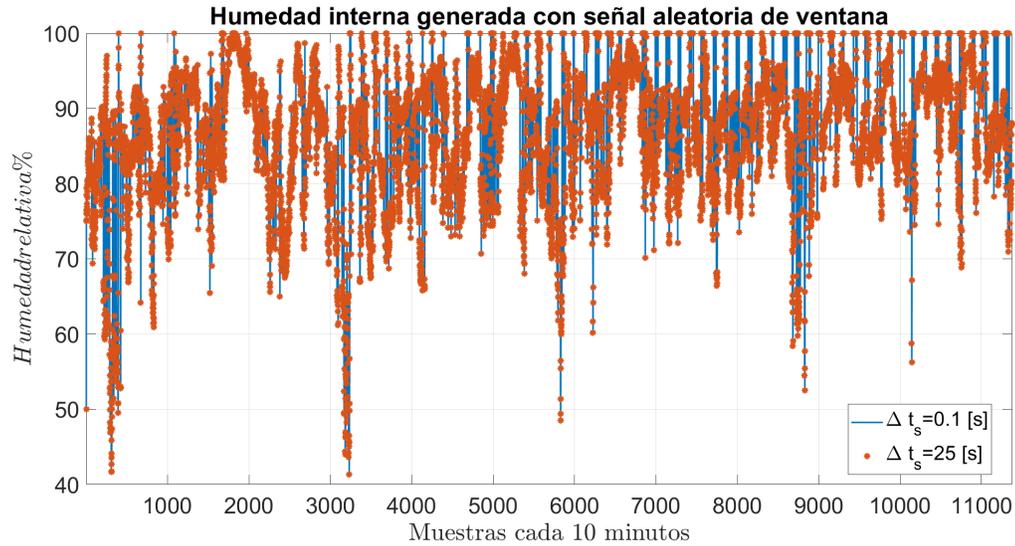


Figura 5.6: Humedad relativa del invernadero HR_{inv} obtenida con el modelo fenomenológico usando $\Delta t_i = 0.1[s]$ y $\Delta t_i = 25[s]$.

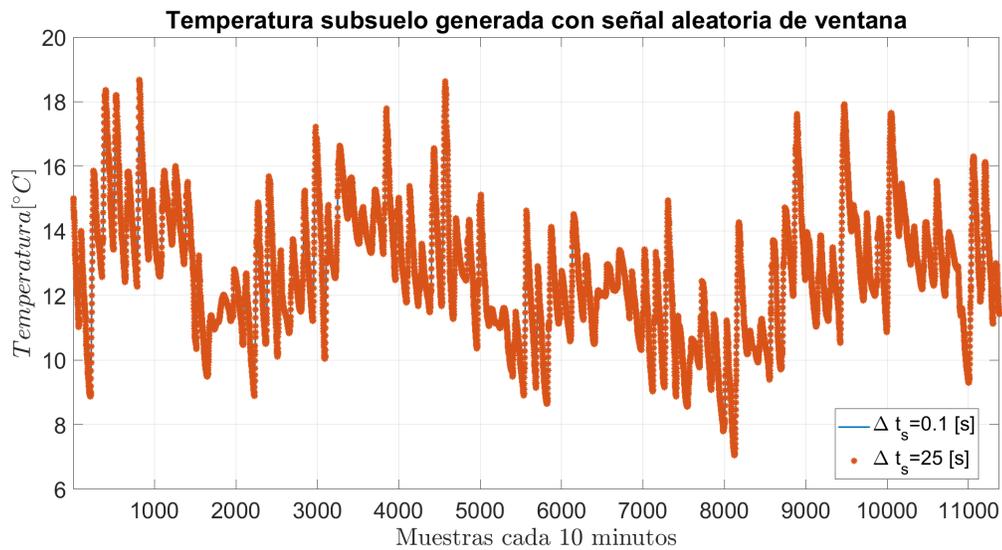


Figura 5.7: Temperatura del subsuelo del invernadero T_{ss} obtenida con el modelo fenomenológico usando $\Delta t_i = 0.1[s]$ y $\Delta t_i = 25[s]$.

Con base en estos resultados, se decide utilizar $\Delta t_i = 25[s]$ para predicciones de variables internas del invernadero y $\Delta t_i = 0.1[s]$ para la simulación del modelo que se controla. Esta diferencia tiene como objetivo que el invernadero simulado sea más preciso que las predicciones. Una vez que se tienen los sistemas de predicción y modelación a corto plazo, es posible calibrar y probar los sistemas de control a corto plazo.

5.2. Resultados de control a corto plazo

5.2.1. Resultados del controlador de ventanas

El primer sistema de control a corto plazo que se prueba es el control de ventanas. Para esto, se consideraron tres tipos de función objetivo: seguimiento de referencia (MPC), estrategia de penalización (MPCP) y optimización difusa (MPCF). Se consideran distintos pesos en las funciones, lo que afecta el comportamiento del controlador en el desarrollo de cada experimento. El rendimiento de cada una se evalúa con base en tres tipos de indicadores: porcentaje del tiempo en que está dentro de los límites mínimos y máximos para temperatura ($T_{seguridad}$) y humedad interna ($H_{seguridad}$), porcentaje del tiempo en que se tienen condiciones ideales de temperatura (T_{normal}) y humedad interna (H_{normal}) y cuántas veces cambia el estado de la ventana ($\#\Delta W_s$). Para discernir entre los controladores, se le da prioridad a aquellos que mantengan mayor tiempo en la zona de seguridad. Los experimentos se realizan con datos obtenidos desde 2019-06-14 00:00:00 hasta 2019-09-03 00:00:00, lo que da un total de 11,665 muestras. Además, se supone que los cultivos tienen 14 días de edad.

La primera función objetivo es la de seguimiento de referencia, descrita en (4.10). En esta implementación, se toma como referencia el promedio de los valores óptimos, los cuales se presentan en la ecuación (5.2):

$$T_{ref}(k) = \begin{cases} 24[^\circ C] & , Ir(k) \geq 100 \left[\frac{W}{m^2} \right] \\ 14.5[^\circ C] & , Ir(k) < 100 \left[\frac{W}{m^2} \right] \end{cases} \quad (5.2)$$

$$HR_{ref}(k) = 65 \%$$

Se fija que los pesos de temperatura y humedad sean $\lambda_T = \frac{1}{1.5^2}$ y $\lambda_H = \frac{1}{10^2}$ respectivamente para que, en ambos casos, el efecto del error de seguimiento en la función sea 1 cuando los valores lleguen al borde de la zona normal; en el caso de la temperatura, se usa la zona normal de noche pues es más estricta que la de día. Para el experimento, se consideraron tres posibles valores de $\lambda_{W_s} = \{0.1, 0.01, 0.001\}$, cuyos rendimientos se presentan en la tabla 5.11.

Tabla 5.11: Resultados del control de ventanas MPC.

λ_{W_s}	$T_{seguridad} \%$	$H_{seguridad} \%$	$T_{normal} \%$	$H_{normal} \%$	$\#\Delta W_s$
0.1	98.35	66.09	44.81	7.76	640
0.01	98.32	66.17	44.51	7.64	712
0.001	98.39	66.24	44.55	7.63	722

En la tabla 5.11, se observa que el porcentaje de tiempo en las zonas de seguridad y en la zona normal no se ve afectado significativamente por la variación de λ_{W_s} y muestran solo un aumento en la variación de la apertura de ventanas. Asimismo, se logran tiempos de seguridad cercanos al 100% para la temperatura, pero solo del 66% para la humedad. Esto podría entenderse como que el sistema tiene dificultades para gestionar la humedad en invierno, estación en la que se tomaron los datos.

La segunda función objetivo que se propone es la penalización (4.11). Para esta función también se considera $\lambda_{W_s} = \{0.1, 0.01, 0.001\}$. Los resultados del experimento para todos estos valores se presentan en la tabla 5.12.

Tabla 5.12: Resultados del control de ventanas MPCF.

λ_{W_s}	<i>Tseguridad</i> %	<i>Hseguridad</i> %	<i>Tnormal</i> %	<i>Hnormal</i> %	$\#\Delta W_s$
0.1	97.75	64.28	41.27	8.72	588
0.01	97.66	63.58	41.20	8.76	632
0.001	97.71	64.02	41.40	8.60	682

En la tabla 5.12, se observa nuevamente que el efecto de variar λ_{W_s} no es significativo para la permanencia en la zona normal y la zona de seguridad; solo se advierte un aumento en la variación de ventanas. Además, se obtienen resultados similares a los de la función de seguimiento por referencia, tanto en las fortalezas como en las debilidades.

La última función objetivo propuesta es la de optimización difusa, descrita en 4.12. Esta también se evalúa con $\lambda_{W_s} = \{0.1, 0.01, 0.001\}$. Los resultados obtenidos se exponen en la tabla 5.13.

Tabla 5.13: Resultados del control de ventanas MPCF.

λ_{W_s}	<i>Tseguridad</i> %	<i>Hseguridad</i> %	<i>Tnormal</i> %	<i>Hnormal</i> %	$\#\Delta W_s$
0.1	97.27	67.21	38.13	8.98	1216
0.01	97.20	67.25	37.91	9.09	1254
0.001	97.22	67.30	38.13	8.96	1216

Como se aprecia en la tabla 5.13, la optimización difusa obtiene resultados similares a las otras dos funciones propuestas, con la diferencia de que esta varía la apertura de ventanas más veces que las otras. Asimismo, la variación de ventanas cuando $\lambda_{W_s} = 0.1$ y $\lambda_{W_s} = 0.001$ es la misma; esto podría significar que λ_{W_s} afecta menos a esta función que a las otras.

Con base en estos resultados, se implementan las tres funciones usando $\lambda_{W_s} = 0.1$ y se añade una restricción dura para la optimización. Esta restricción tiene la forma de una penalización que se aplica cada vez que una variable se sale de los límites de seguridad. Cabe mencionar que debido a que cada función es diferente, el efecto de λ_{W_s} no es equivalente entre las tres. Los resultados se despliegan en la tabla 5.14.

Tabla 5.14: Resultados del control de ventanas con restricción dura.

Función	<i>Tseguridad</i> %	<i>Hseguridad</i> %	<i>Tnormal</i> %	<i>Hnormal</i> %	$\#\Delta W_s$
MPC	92.09	67.97	24.18	8.91	2630
MPCP	90.28	66.83	22.62	8.72	1830
MPCF	91.82	67.85	22.73	9.37	2558

En la tabla 5.14, se observa que todos los controladores disminuyen de forma similar su rendimiento en el control de la temperatura, pero sin mejorar la gestión de la humedad. Este peor rendimiento incluye una mayor cantidad de acciones de control. El hecho de que los sistemas tengan un peor funcionamiento cuando incluyen restricciones puede deberse a que el sistema de control usado (la apertura de ventanas) no tiene la capacidad de cumplir todas las restricciones, por lo que el sistema no podría resolver adecuadamente el problema de optimización.

En resumen, se tiene que las tres propuestas se comportan de forma similar con los datos de invierno pues presentan tres factores en común: una buena gestión de la temperatura, dificultad para la gestión de la humedad y una disminución en el rendimiento cuando se aplican restricciones duras. Estos factores se manifiestan casi en el mismo grado en las tres opciones, lo que dificulta la elección de una opción para el sistema. Para explorar mejor las diferencias entre estas opciones, se hace un segundo experimento, en el cual la edad inicial del cultivo es de 40 días y se usan los datos recolectados desde 2019-10-23 00:00:00 hasta 2019-11-12 00:00:00. Los resultados se exponen en la tabla 5.15.

Tabla 5.15: Resultados del segundo experimento.

Función	<i>Tseguridad</i> %	<i>Hseguridad</i> %	<i>Tnormal</i> %	<i>Hnormal</i> %	$\#\Delta W_s$
MPC	91.22	88.89	44.76	22.01	450
MPCP	85.49	91.04	24.72	53.02	332
MPCF	89.51	94.34	21.28	35.31	374

En la tabla 5.15, es posible notar que, en estas nuevas condiciones, las tres funciones obtuvieron distintos resultados. La estrategia que mejor controla la temperatura es el MPC tanto en seguridad como en intervalo normal. Por otra parte, la estrategia que mejor controla la humedad es el MPCP. Por su parte, el MPCF es la estrategia que permaneció más tiempo en la zona de seguridad, si se suman los porcentajes obtenidos tanto para la temperatura como para la humedad. Esto último puede deberse a que la función difusa opera como una restricción suave implícita lo que hace que tenga restricciones flexibles. Además, en los tres controladores, hay una mejoría en el control de humedad y un empeoramiento en el control de la temperatura, esto en comparación con el otro conjunto de datos que corresponden a una época más fría.

Con base en estos resultados, se decide que la función objetivo sea el MPCF con $\lambda_{W_s} = 0.1$ y sin restricciones duras. Un segmento de la segunda simulación, que corresponde a los días del 5 al 15, se presenta en las figuras 5.8, 5.9 y 5.10, en ellas se observa el comportamiento de la temperatura, de la humedad relativa y de las ventanas respectivamente.

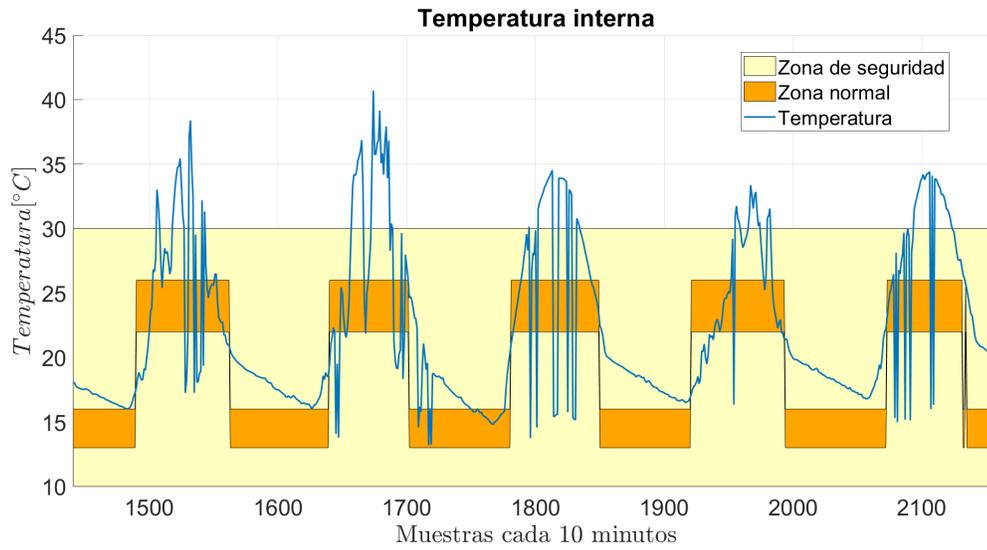


Figura 5.8: Temperatura del invernadero, su zona de operación normal y su zona de seguridad.

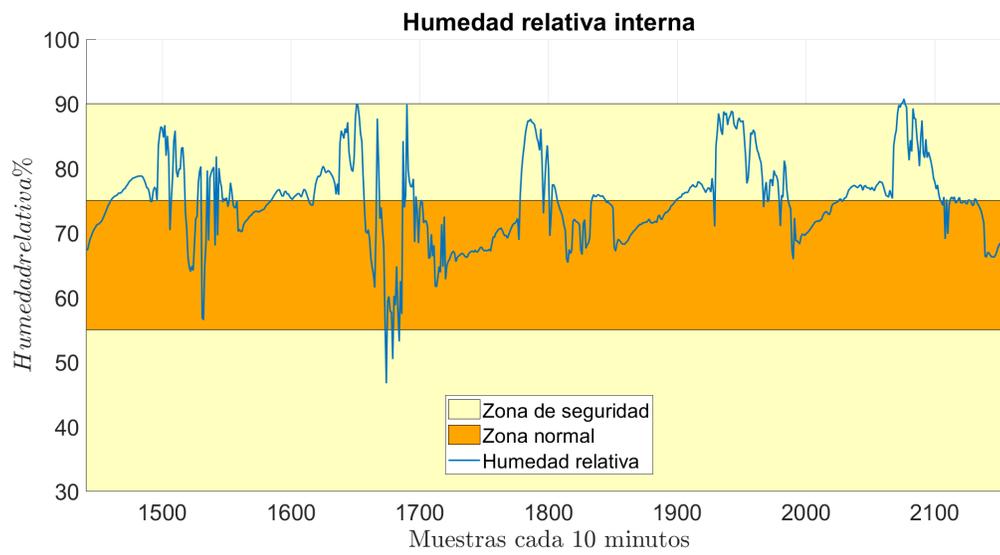


Figura 5.9: Humedad relativa del invernadero, su zona de operación normal y su zona de seguridad.

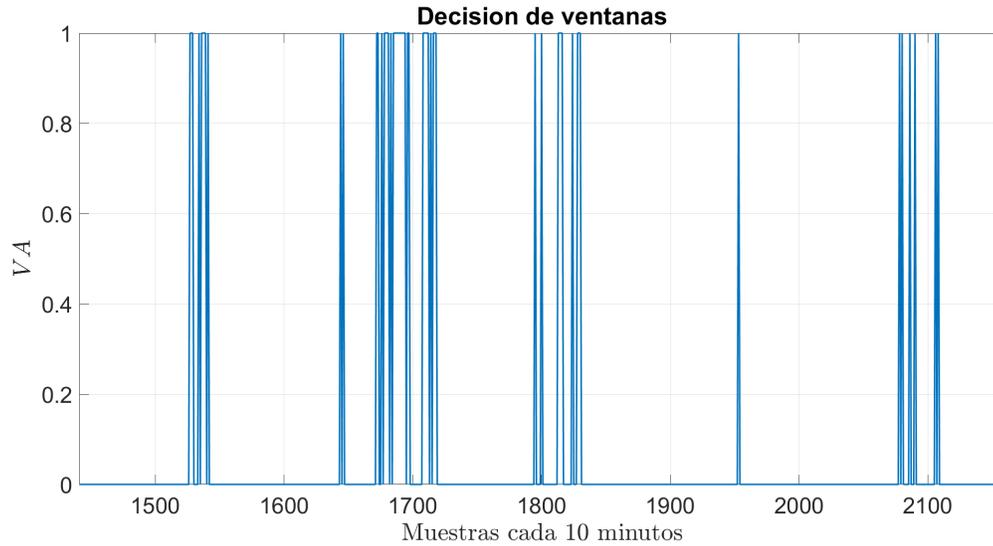


Figura 5.10: Decisión de ventanas.

Ahora que se tiene un sistema para el control de la ventanas, se procede a implementar el sistema de gestión a corto plazo.

5.2.2. Resultados del sistema de gestión a corto plazo

Para probar el sistema de gestión a corto plazo, se plantea la siguiente situación: el sistema debe entregar un riego diario de 250 [L] o 0.25 [m³] (la mitad del estanque) durante un periodo de 80 días. Esta cantidad es una cota superior del riego que se entregaba al invernadero anterior, que recargaba su estanque cada dos días, para regar todos los cultivos en un invernadero lleno. Para calcular su rendimiento, se evalúa el seguimiento de la referencia, el ciclo de la batería CB [28], el número de activaciones de la bomba $\#Rec$ y el promedio de veces que se riega en un día $avg\#I$. El cálculo del ciclo de batería se puede describir de esta manera:

$$CB = \frac{E_{total}[kJ]}{SoE_{max}[kJ]} \quad (5.3)$$

Siendo E_{total} la energía total usada por el sistema durante toda la simulación.

Los resultados se presentan en la tabla 5.16. Esta simulación incluye todos los sistemas de corto plazo anteriormente probados y utiliza los datos recolectados desde 2019-06-14 00:00:00 hasta 2019-09-03 00:00:00, lo que da un total de 11,665 muestras. Los cultivos inician con 14 días de edad. El riego de esta simulación se presenta en la figura 5.11

Tabla 5.16: Rendimiento del riego a corto plazo en la simulación.

$RMSE[L]$	CB	$\#Rec$	$avg\#I$
2.0306	19.2096	99	5

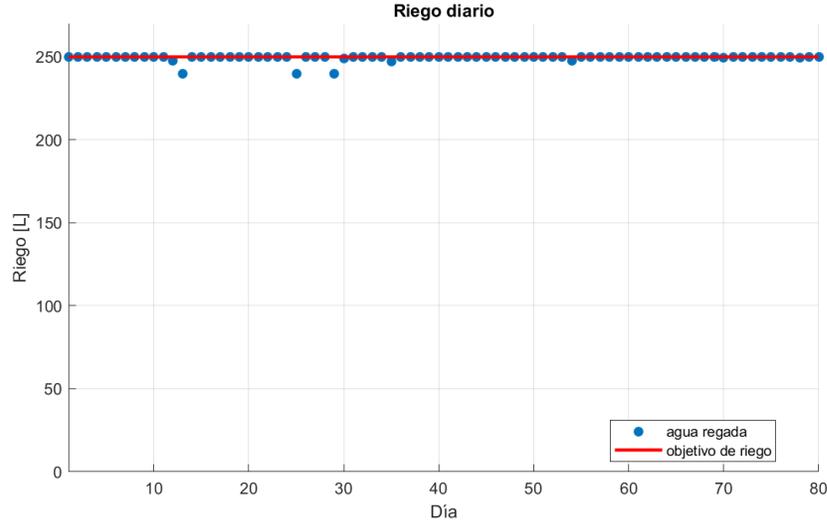


Figura 5.11: Riego diario en la simulación.

En la tabla 5.16 y en la figura 5.11, se observa que el sistema cumple con el objetivo de riego. En cuanto al ciclo de batería, se utiliza un equivalente a 19.2 veces la capacidad máxima para 99 recargas en todo el proceso. Si se compara con un caso en que el sistema no usa energía solar para la bomba (cálculo presentado en la ecuación (5.4)), se tiene que se ahorra cerca de 0.9 ciclos de batería. Finalmente, el sistema tuvo un promedio de 5 instancias de riego por día; si se considera que el sistema puede regar un máximo de 60[L] cada 10 minutos, el mínimo de instancias necesarias para lograr el objetivo también serían 5. A continuación, en la ecuación (5.4) se presenta el cálculo del ciclo de batería que se habría utilizado si se decidiera solo cargar de noche:

$$P_{bat}(k) = \frac{P_{bomba}}{\eta_{inv}\eta_{dis}} = \frac{745.699[W]}{0.9 \cdot 0.85} = 974.7699[W]$$

$$E_{total}[kJ] = \frac{99 \cdot P_{bat}[W] \cdot \Delta t[s]}{1000} = \frac{99 \cdot 974.7699[W] \cdot 600[s]}{1000} = 57901.3[kJ] \quad (5.4)$$

$$CB = \frac{E_{total}[J]}{SoE_{max}[kJ]} = \frac{57901.3}{2880} = 20.1046$$

Este cálculo utiliza la expresión de P_{bat} , descrita en la ecuación (3.2). En este caso, se deja la potencia del panel en 0 y de esa forma, se obtiene la potencia necesaria para recargar de noche. Esta potencia se multiplica por el número de recargas (99) y el tiempo que se usa esta potencia (600[s]) para obtener el uso energético total de la batería y así calcular su ciclo de batería.

Otro factor que cabe destacar es el cumplimiento de todas las restricciones. Como se puede ver en las figuras 5.12 y 5.13, el sistema nunca se sale de las restricciones impuestas.

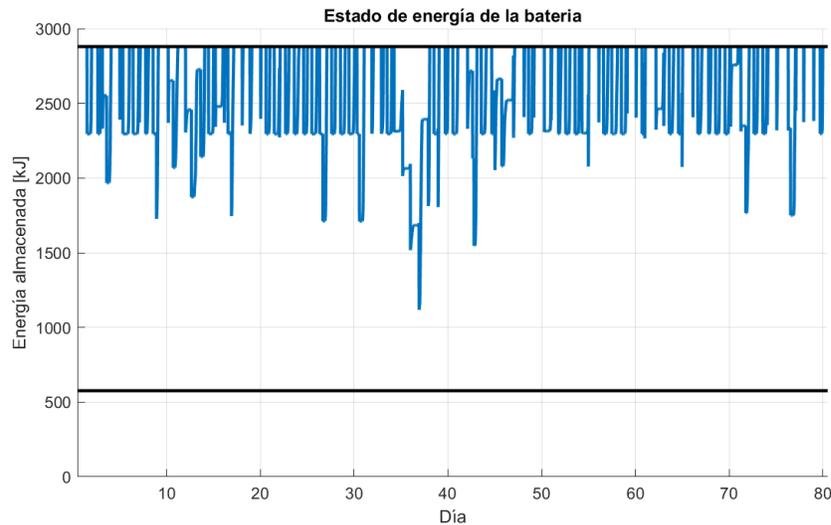


Figura 5.12: Energía en la batería durante la simulación.

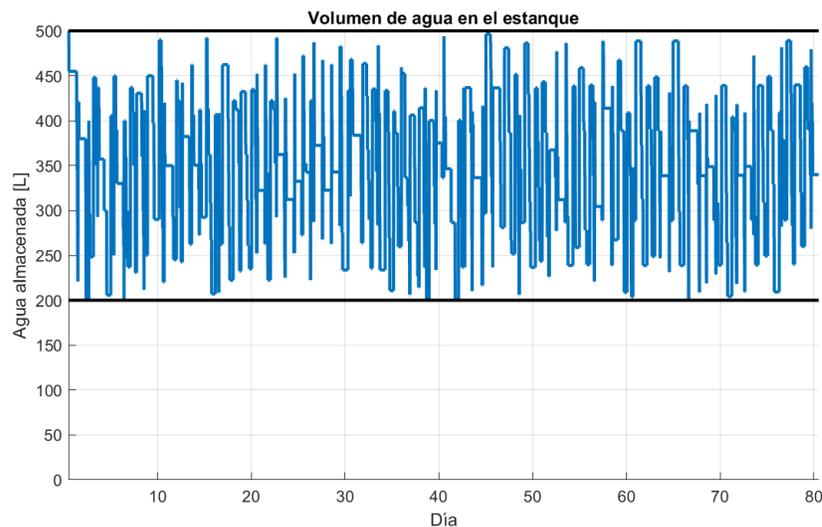


Figura 5.13: Volumen de agua en el estanque durante la simulación..

De esta forma, se concluyen los experimentos a corto plazo. Se tiene que los métodos MPC propuestos cumplen con los objetivos según las simulaciones ejecutadas, bajo el supuesto de que reciban un objetivo a mediano plazo. Ahora se puede proceder a evaluar el rendimiento de los sistemas a mediano plazo.

5.3. Resultados de la predicción climática a mediano plazo

El primer sistema a mediano plazo a evaluar es la estrategia de predicción propuesta en la sección 4.3.3. Esta propuesta tiene como fin predecir un valor aproximado de la evapotranspiración de referencia diaria durante un periodo de 28 días. Para evaluar su rendimiento, se realizaron dos simulaciones, cuyos resultados se presentan en las tablas 5.17 y 5.18. Las dos

simulaciones se diferencian por el conjunto de datos utilizados: uno que va desde 2019-06-14 00:00 a 2019-09-03 00:00, y otro que va desde 2019-10-23 00:00 hasta 2020-01-12 00:00. Ambos conjuntos poseen 11,665 datos (81 días). El primero se denomina datos de invierno y el segundo, datos de verano. Debido a que las predicciones son de 28 días y el sistema requiere información de 7 días al pasado, los resultados se limitan a 47 días por conjunto (considerando que el primer paso de predicción del día d es predecir el resto del día d). Durante los experimentos, las condiciones de los cultivos son las mismas que las que tenían en las pruebas del control a corto plazo.

Tabla 5.17: Resultados usando datos de invierno

Método	Variable	Promedio	RMSE		MAPE	
			14 días	28 días	14 días	28 días
Proyección días 1 y 2	$T_{min}[C^{\circ}]$	10.896	2.972	2.892	20.7	22.6
	$T_{max}[C^{\circ}]$	22.728	12.808	12.626	53.4	52.5
	$HR_{min}\%$	71.277	17.420	17.217	20.3	20.3
	$HR_{max}\%$	97.279	17.516	18.316	15.4	16.1
Constante	$u_2^p \left[\frac{m}{s} \right]$	0.750	0.758	0.419	56.4	54.6
Media móvil	$Rn \left[\frac{MJ}{m^2 Day} \right]$	5.585	2.897	3.184	77.1	68.1
Cálculo	$ET_o[mm]$	1.671	0.898	0.996	64.4	57.2

Tabla 5.18: Resultados usando datos de verano

Método	Variable	Promedio	RMSE		MAPE	
			14 días	28 días	14 días	28 días
Proyección días 1 y 2	$T_{min}[C^{\circ}]$	13.4191	2.880	2.408	15.9	13.1
	$T_{max}[C^{\circ}]$	31.848	20.062	18.026	60.2	56.9
	$HR_{min}\%$	65.007	18.231	13.569	24.0	16.4
	$HR_{max}\%$	93.789	14.989	17.244	13.4	15.7
Constante	$u_2^p \left[\frac{m}{s} \right]$	1.472	1.072	1.417	46.6	54.2
Media móvil	$Rn \left[\frac{MJ}{m^2 Day} \right]$	18.030	4.631	4.845	25.3	23.7
Cálculo	$ET_o[mm]$	5.395	1.937	1.799	30.8	28.2

Primeramente se puede observar que el sistema de predicción presenta en general errores de magnitud significativa, lo que era de esperarse debido al periodo de tiempo que se busca predecir. Otro detalle es que las variables T_{max} , HR_{min} , u_2 , Rn y ET_o muestran diferencias significativas entre las estaciones. Ambas observaciones indican que el sistema necesita de una mayor cantidad de datos para desarrollar modelos de predicción más precisos y capturar mejor la diferencia entre las estaciones. A continuación, cada variable se discutirá con más detalle, junto con su respectivas figuras. La figura 5.14 corresponde a la temperatura mínima; 5.15, a la temperatura máxima; 5.16, a la humedad relativa mínima; 5.17, a la humedad relativa máxima; 5.18, a la velocidad del viento; 5.19, a la radiación neta y la figura 5.20, a la evapotranspiración de referencia.

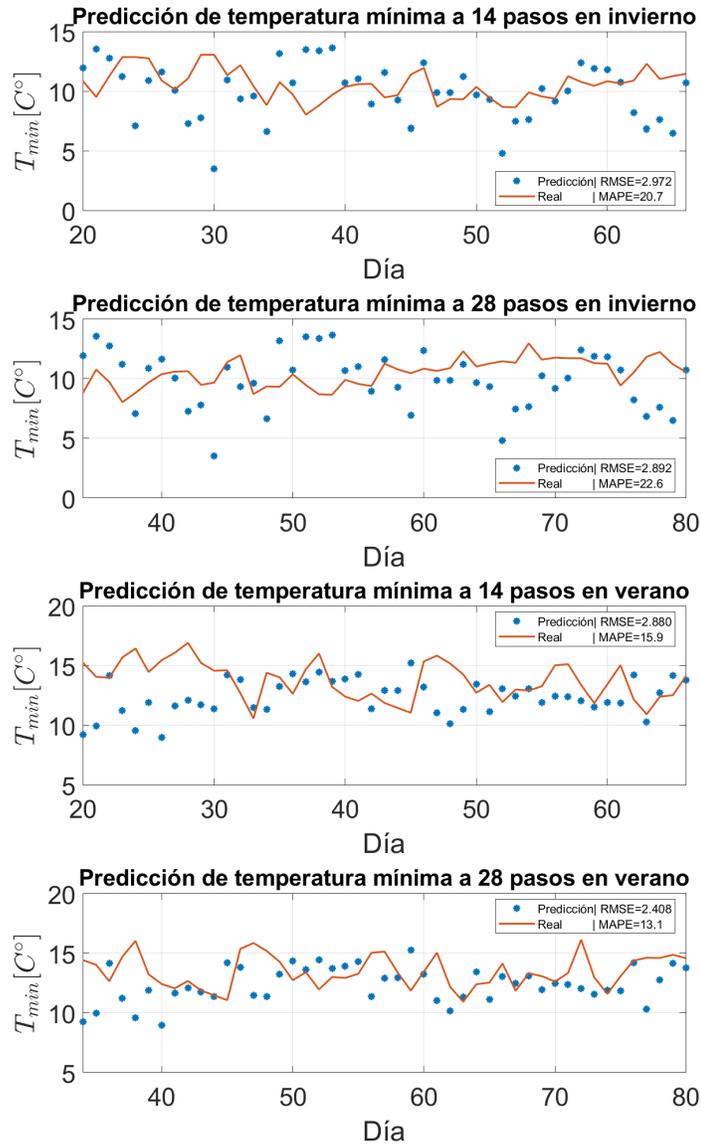


Figura 5.14: Resultados de la temperatura mínima.

El error de predicción de la temperatura mínima con este método es bajo en comparación con las otras variables. Debido al método que se utiliza (la proyección de los dos primeros días), se podría pensar que se cumpliría la hipótesis de que el invernadero mantendría un clima similar en el tiempo, al menos para esta variable. Sin embargo, los datos disponibles son muy pocos como para asegurarlo (ver figura 5.14).

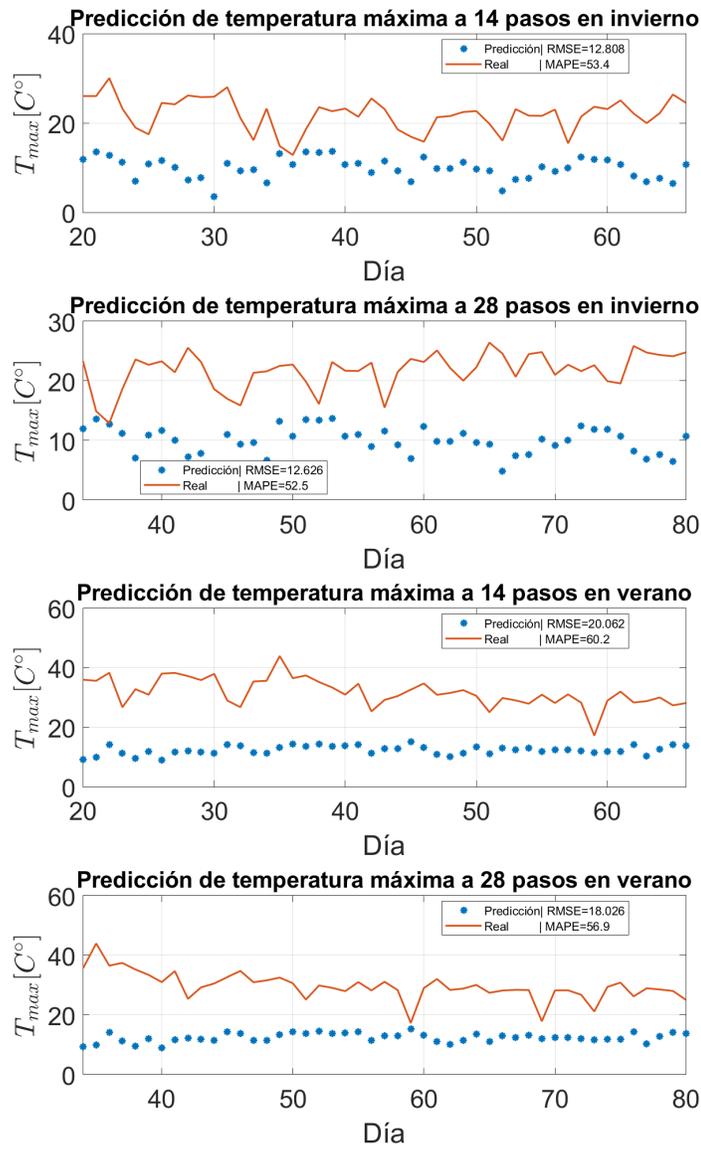


Figura 5.15: Resultados de la temperatura máxima.

La predicción de la temperatura máxima es una de las que presenta mayor error de predicción. Particularmente, se observa que la estimación subestima por un amplio margen el valor real (ver figura 5.15).

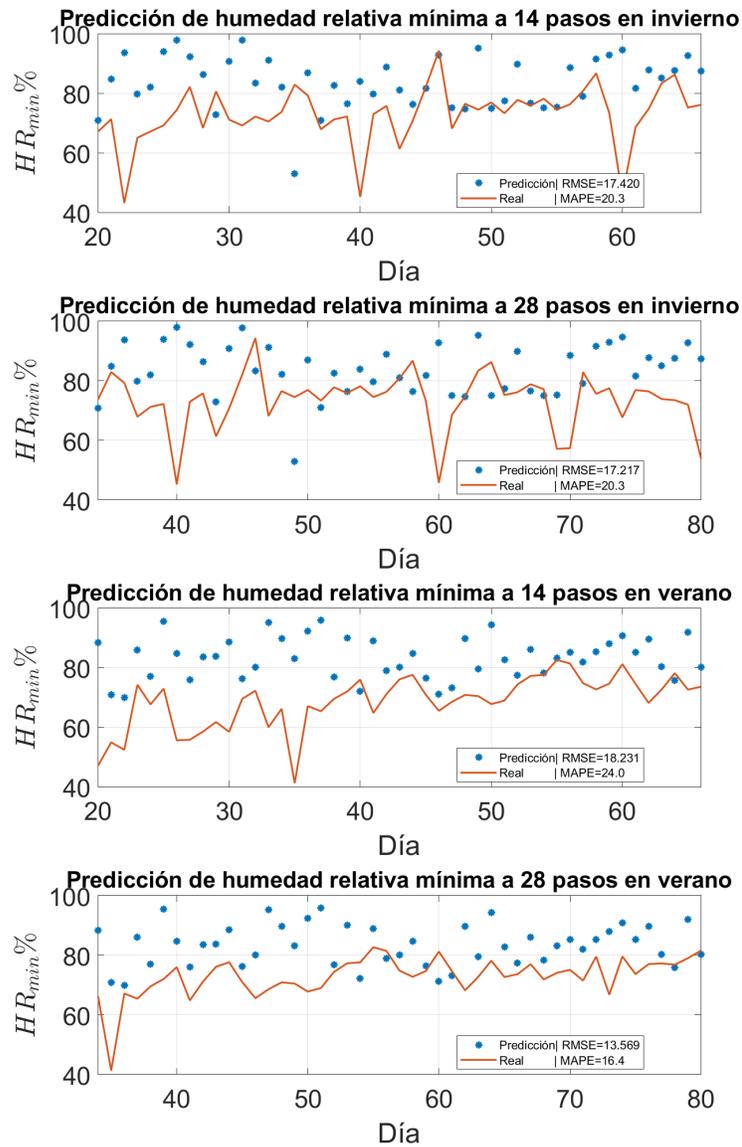


Figura 5.16: Resultados de la humedad relativa mínima.

De forma similar a la temperatura mínima, la humedad mínima muestra el mismo grado de error, por lo que se puede llegar a conclusiones similares. Sin embargo, también se observa que la estimación usualmente arroja valores mayores a los reales, es decir, la proyección está sobrestimando la humedad mínima (ver figura 5.16).

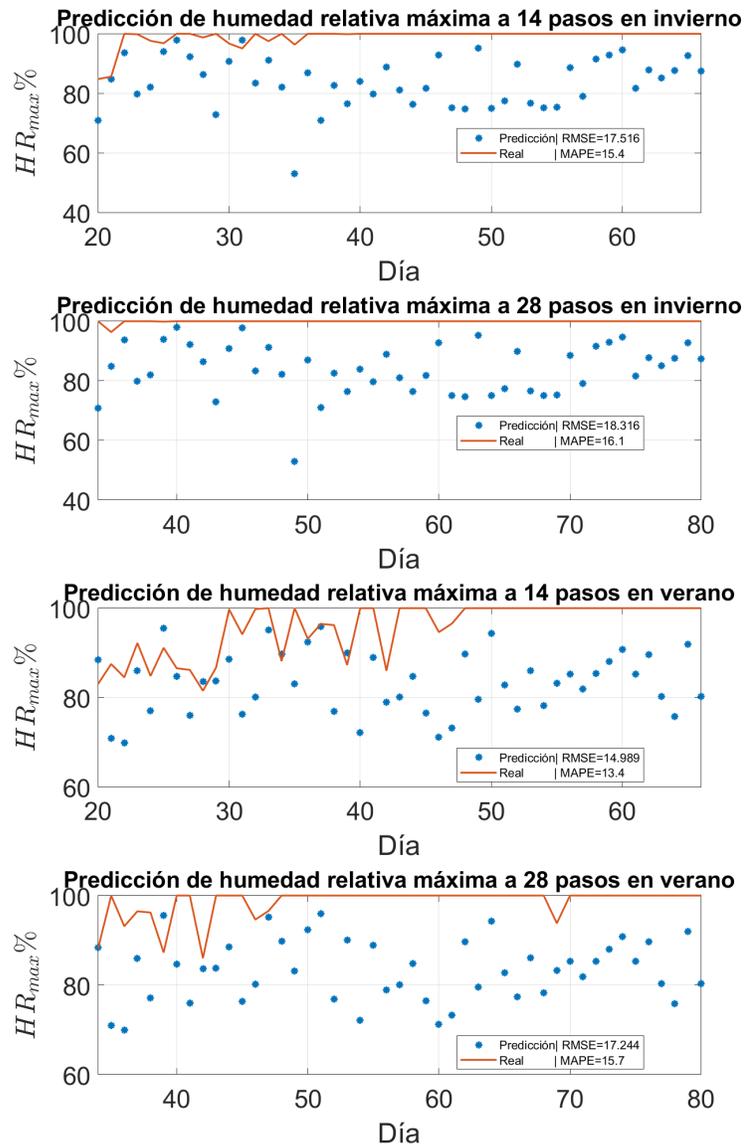


Figura 5.17: Resultados de la humedad relativa máxima.

En el caso de la humedad máxima, hay errores similares a los vistos en la temperatura y la humedad mínimas. No obstante, se tiene que esta se encuentra muchas veces en un valor de 100%. Este valor corresponde al punto de saturación del modelo, así que no se podría asegurar la validez del análisis de esta variable (ver figura 5.17).

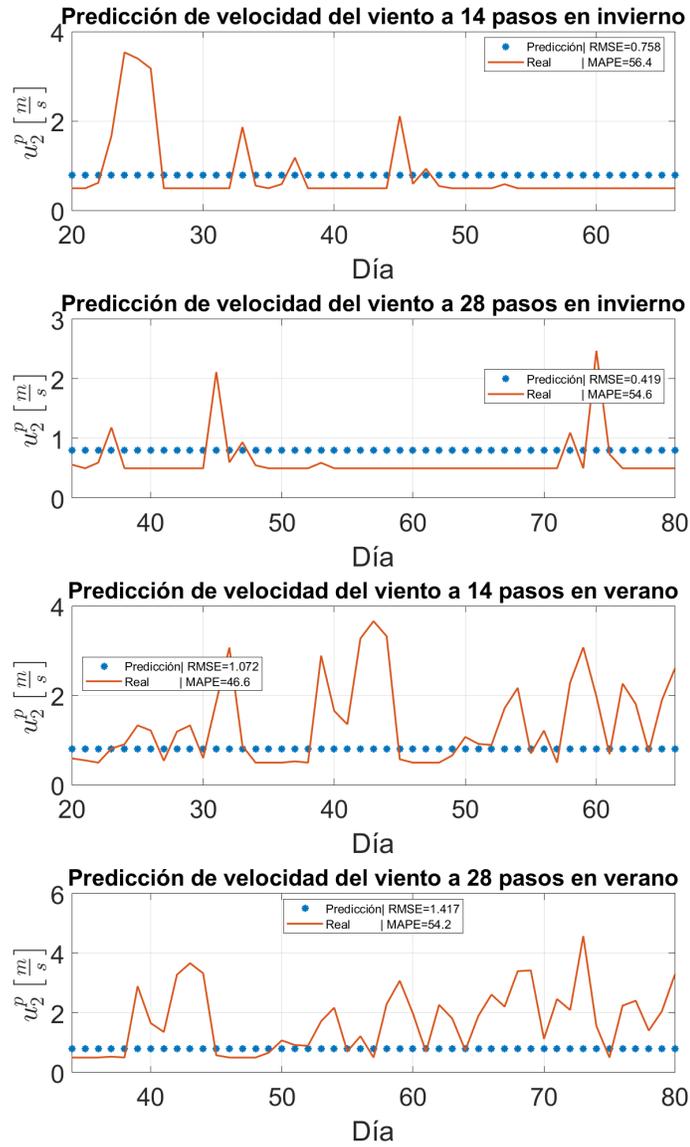


Figura 5.18: Resultados de la velocidad del viento.

La baja precisión de la predicción del viento era esperable, pues para estimarla se utiliza el valor constante de $u_2^p = 0.8003 \left[\frac{m}{s} \right]$. Sin embargo, se observa que en invierno la mayor parte del tiempo el valor real corresponde al mínimo recomendado por la FAO; esto probablemente se deba a que el sistema prefiere mantener las ventanas cerradas en esa época y no tanto a que las velocidades del viento sean menores en esa época (ver figura 5.18).

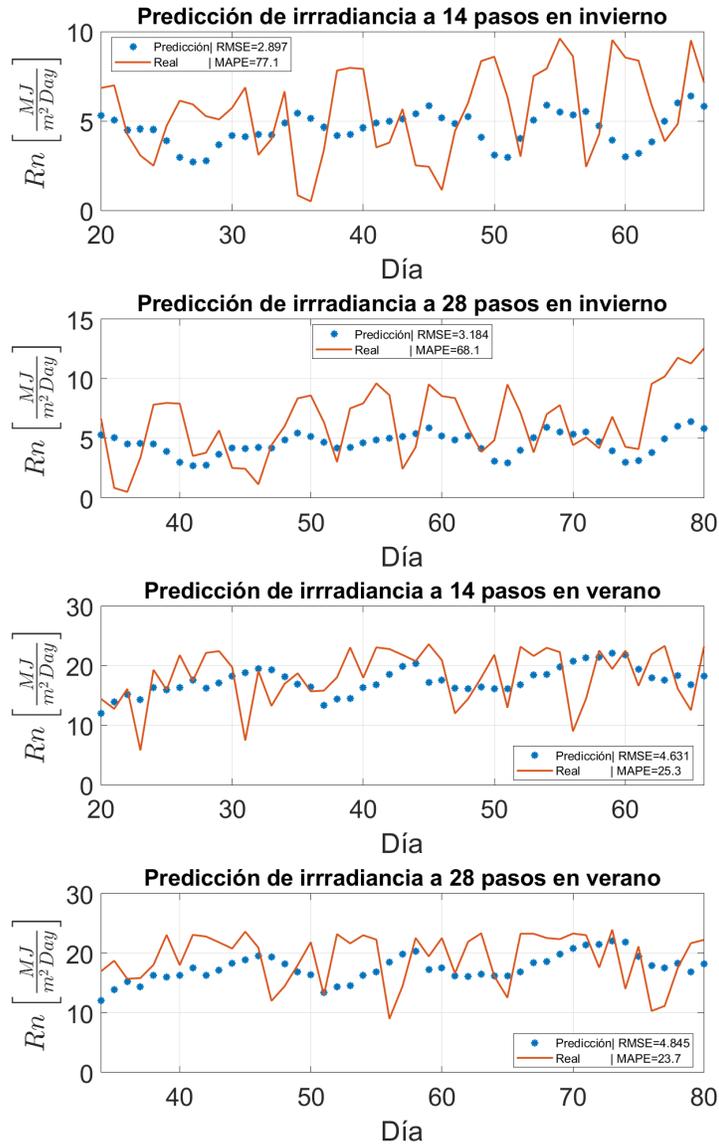


Figura 5.19: Resultados de la radiación neta.

En el caso de la radiación, se advierte que, a pesar de que en invierno se tiene un RMSE menor que en verano, la estación fría presenta un MAPE mucho mayor. Esto se explica por la diferencia en la amplitud de ambos. También se tiene que, como se usa la media móvil, la predicción pierde la variabilidad de la variable real, lo que causa la mayor parte del error que esta presenta (ver figura 5.19).

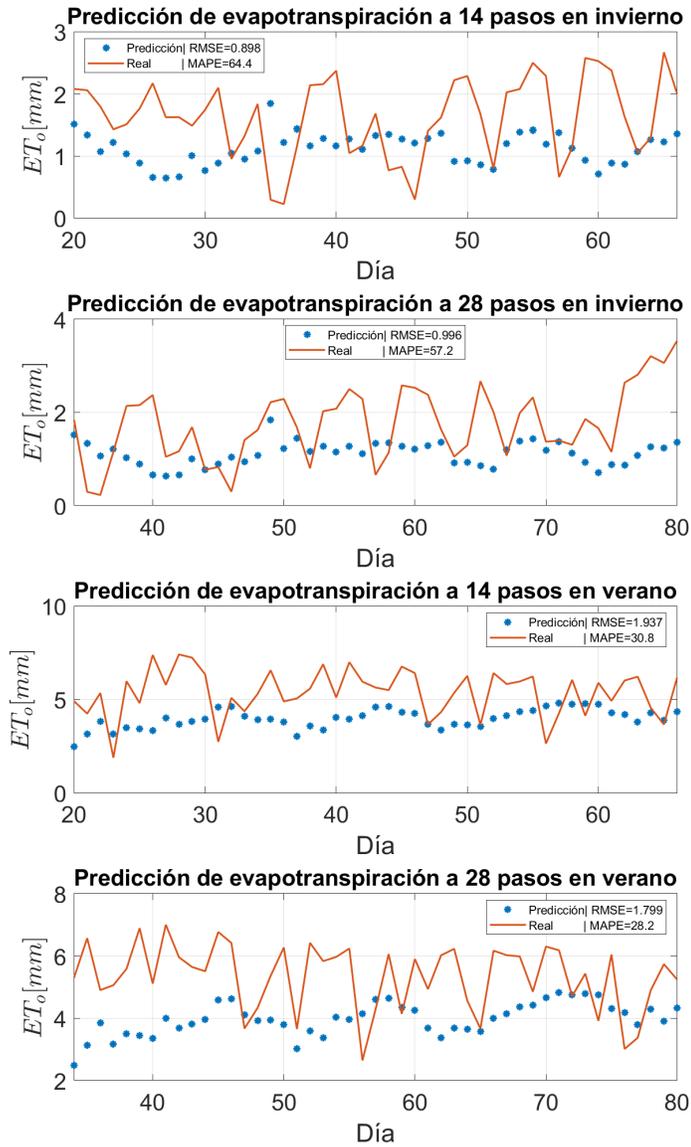


Figura 5.20: Resultados de la evapotranspiración.

En cuanto a la evapotranspiración, se observa que se comporta de manera similar a la radiación, pues tanto el MAPE como la forma de la curva son semejantes para los respectivos conjuntos de datos y pasos de predicción. Esto puede significar que la radiación es la variable más importante para el cálculo de la evapotranspiración y que si mejora la estimación de esta, se podría obtener también una mejor estimación de la evapotranspiración. Cabe señalar que estos resultados utilizan pocos datos, por lo que no se puede asegurar ninguna conclusión (ver figura 5.20).

Con estos resultados no es posible estimar si el error obtenido es aceptable para el sistema de gestión. Para poder evaluar su utilidad, es necesario probar todo el sistema en conjunto.

5.4. Resultados de control a mediano plazo

El último sistema a evaluar es el controlador a mediano plazo con todo los sistemas incluidos. La simulación busca examinar el uso de agua diario del sistema de gestión de agua y energía. Como punto de comparación, se utiliza la información obtenida en las entrevistas que apunta a que se riegan diariamente de 100 [L] a 200 [L] en caso de que solo esté cultivada la mitad del invernadero. Por simplicidad, se toma como caso base el riego de 150 [L] diarios. El experimento consta de dos simulaciones que usan los datos recolectados desde 2019-10-23 00:00 hasta 2020-01-12 00:00, lo que da un total de 11,665 datos. Es decir, se tienen 74 días de simulación más 7 días en el que se recolectan los primeros datos con los que trabajan las primeras predicciones. Estos 7 días hacen que la edad de los cultivos al inicio de la simulación sea de 21 días.

La primera simulación usa las mismas condiciones que la simulación a corto plazo (esto incluye que el volumen mínimo del estanque sea 200[L]) y considera una zona de agotamiento de raíz inicial $Dr = 15[mm]$. A esta simulación se le denomina “riego exclusivo” pues el controlador es el único que utiliza agua del estanque. En cambio, la segunda simulación considera la existencia de un riego paralelo que no contribuye al objetivo pues está destinado a otro grupo de cultivos; por eso, a esta simulación se le denomina “riego compartido”. Esta simulación considera que cada día se hacen dos riegos de 75[L] que duran 1:30 horas, estos se realizan a las 6:00 y a las 21:00. Debido al riego extra, el sistemas considera que el volumen mínimo de agua en el estanque es de 50[L]. Además, se tiene que el controlador sabe cuándo se realizarán estos riegos. Los resultados de estas simulaciones se presentan en las tablas 5.19 y 5.20 y en las figuras 5.21, 5.22, 5.23 y 5.24.

Tabla 5.19: Uso de agua

	Supuesto base	Riego exclusivo	Riego compartido
Riego diario promedio	150[L]	130.5394[L]	135.2151[L]

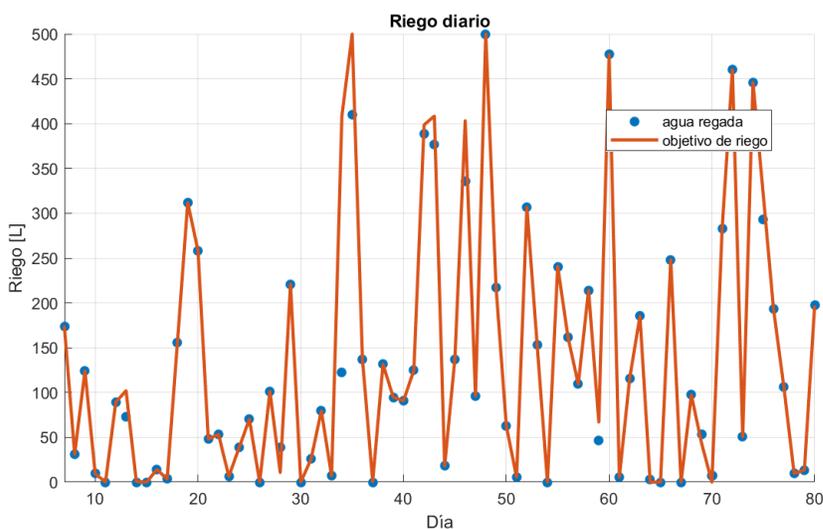


Figura 5.21: Riego entregado en la simulación de riego exclusivo.

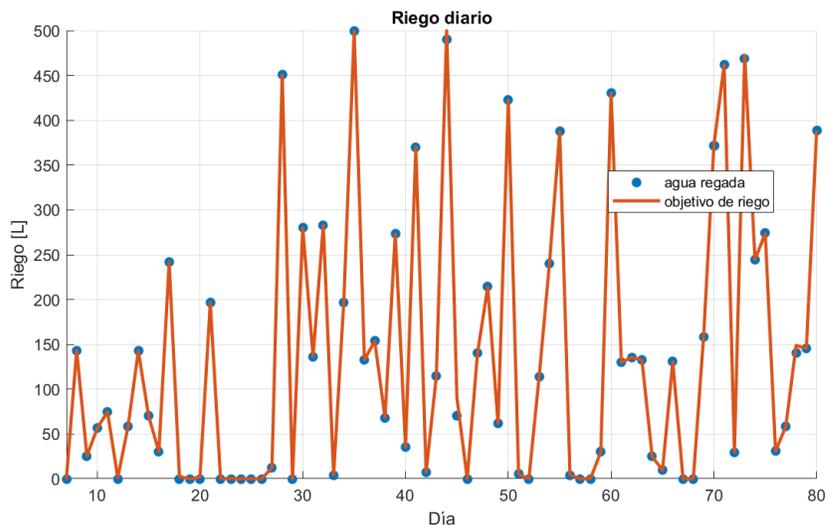


Figura 5.22: Riego entregado en simulación de riego compartido.

En la tabla 5.19, se observa que ambas simulaciones utilizan menos agua que el caso base. Por otra parte, en las figuras 5.21 y 5.22, se puede notar que el sistema con riego paralelo cumple mejor sus objetivos diarios que el sistema sin riego paralelo. Esto puede deberse a la mayor holgura en el volumen mínimo del estanque, que le permite realizar una mejor planeación aún cuando existe otra entidad extrayendo agua del estanque. Igualmente, en ambos casos, existen días en los que no se riega; esto podría causar problemas para la adopción del sistema por parte de la comunidad, pues en ella se acostumbra hacer un riego diario.

Tabla 5.20: Rendimiento relativo total

	Riego exclusivo	Riego compartido
$Y_r = \prod \frac{ET_a}{ET_p}$	0.9867	0.9869

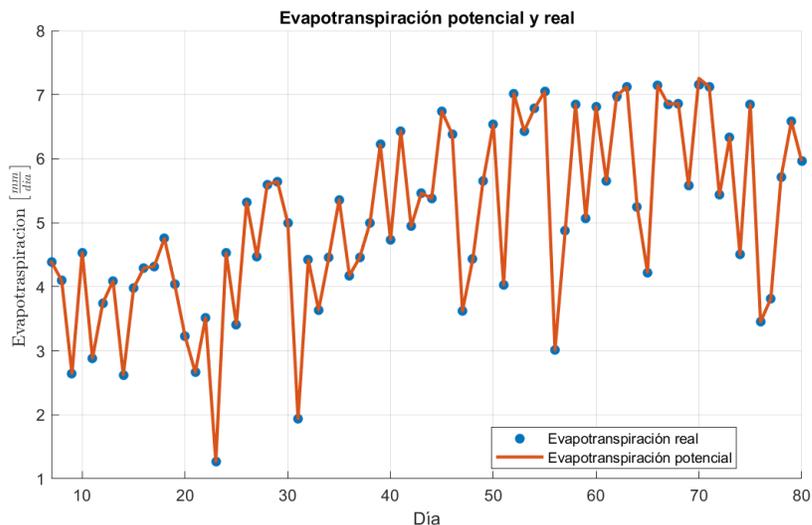


Figura 5.23: Evapotranspiración real y potencial en la simulación sin riego paralelo.

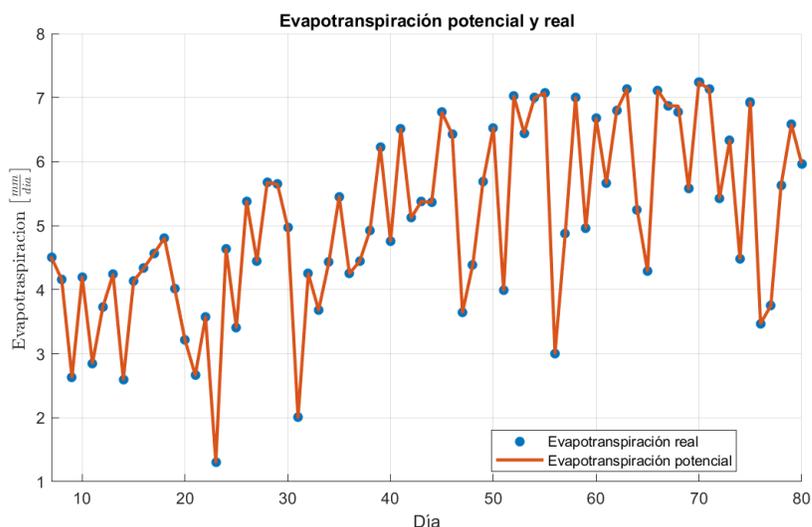


Figura 5.24: Evapotranspiración real y potencial en la simulación con riego paralelo.

En las figuras 5.23 y 5.24, se muestra que durante toda la simulación la evapotranspiración real y la potencial se mantienen con el mismo valor o similares. Además se puede observar en la tabla 5.20 que el rendimiento relativo total de ambos caso son cercanas a 1. Esto significa que el sistema planteado logra cumplir con su objetivo principal de mantener el riego de los cultivos.

5.5. Discusión

En esta sección, se calibraron y se probaron todas las partes del sistema de gestión de agua y energía; esto incluyó la predicción climática a corto plazo, el controlador de ventanas,

el sistema de gestión a corto plazo, la predicción a mediano plazo y finalmente el sistema de gestión de agua y energía. Cada una de estas partes implicó una serie de experimentos distintos que evaluaron distintas métricas.

La predicción a corto plazo se dividió en dos resultados: los de variables externas y los de variables internas. Los resultados de las variables externas consisten en el rendimiento de distintas estrategias auto-regresivas de predicción, de las cuales se eligieron las redes neuronales para predecir la temperatura, la humedad relativa y la irradiancia. En cambio para la velocidad del viento se optó por la media móvil debido a su alta estocasticidad. Se determinó que los resultados son suficientemente buenos para la implementación. En cuanto a los resultados de las variables internas, que son la temperatura del invernadero, la humedad relativa del invernadero y la temperatura del subsuelo del invernadero, debido a la ausencia de datos reales, se calibró el tiempo de interpolación usando como referencia un tiempo de interpolación pequeño ($\Delta t_i = 0.1[s]$). El mayor tiempo de interpolación que logró seguir adecuadamente a la referencia fue $\Delta t_i = 25[s]$, por lo que se eligió este para realizar las predicciones.

Para el controlador de ventanas, primero se probaron distintas funciones objetivo, así como distintos valores para el peso de la acción de control λ_{W_s} . Se observó un comportamiento similar entre todas las funciones y λ_{W_s} , por lo que se optó continuar el resto de los experimentos con $\lambda_{W_s} = 0.1$. Posteriormente se probó añadir restricciones duras a las funciones, las cuales obtuvieron peores resultados que las versiones originales. Finalmente, las funciones sin restricciones duras se probaron en otro conjunto de datos y la función objetivo difusa mostró mayor capacidad para permanecer en las zonas de seguridad que las otras funciones. Esto podría deberse a que la función difusa actúa como una restricción suave. Por esta razón, se decidió continuar con el desarrollo utilizando esta función objetivo.

La evaluación del sistema de gestión a corto plazo se realizó estableciendo el objetivo de regar $250[L]$ diarios (el riego máximo diario que se dedujo a partir de las entrevistas). Para conocer su rendimiento, se evaluó el error de seguimiento, el ciclo de batería, la cantidad de veces que se recargó el estanque y el promedio de veces que se regó cada día. Con respecto al volumen regado cada día, se obtuvo un error $\approx 2[L]$, lo cual muestra que logra su objetivo primario de cumplir los riegos diarios. En cuanto al ciclo de batería y la cantidad de recargas de estanque, se obtuvo que el sistema usó 0.9 ciclos de batería menos que cuando el estanque se recarga de noche. Por eso, se puede decir que el sistema también logró minimizar el uso de la batería. En cuanto a la cantidad de instancias de riego por día, se tiene que el promedio obtenido (5 veces) coincide con la mínima cantidad de riegos que el sistema necesita para cumplir con el objetivo entregado.

En lo que compete a la predicción a mediano plazo, todas las variables (temperatura mínima y máxima del invernadero, humedad relativa mínima y máxima del invernadero, velocidad del viento a 2 metros dentro del invernadero y radicación neta dentro del invernadero) presentaron errores significativos, lo que era esperable debido a la magnitud de tiempo en las que se busca predecir y la poca cantidad de datos disponibles. Se analizó el error de cada variable, lo cual puede ayudar a plantear mejores estrategias en el futuro. Con los resultados obtenidos no es posible determinar si la estrategia utilizada entrega predicciones con la precisión suficiente para el sistema de gestión de agua y energía.

Finalmente, el último experimento consistió en probar el sistema de gestión de agua y energía completo. Para esto se consideraron dos casos: uno donde solo el sistema tenía acceso al estanque y otro donde este se compartía con un riego paralelo. En el primero, se determinó que el volumen mínimo del estanque era de $200[L]$, mientras que en el segundo era $50[L]$, ya que el riego paralelo es de $150[L]$. Los resultados de la simulación indican que ambos sistemas usaron menos riego diario que la referencia obtenida de las entrevistas con el agricultor. Asimismo lograron mantener la evapotranspiración real y la de referencia en valores cercanos. Solo el sistema con uso exclusivo del estanque tuvo problemas para cumplir con todos sus objetivos diarios. Esto probablemente sea porque tiene un volumen mínimo más estricto. Por último, cabe destacar que ambos sistemas decidieron no regar en ciertos días, lo que puede producir problemas para su adopción por parte de algunas comunidades que acostumbran regar diario.

Dados estos resultados, se puede decir que el sistema logra los objetivos propuestos en el contexto de la simulación.

Capítulo 6

Conclusión

En este trabajo se propuso un sistema de gestión de agua y energía para invernaderos en comunidades rurales indígenas. El sistema planteado se compone de un bloque de corto plazo y uno de mediano plazo. El sistema de mediano plazo tiene la función de definir el volumen de riego diario para los próximos 28 días usando la menor cantidad de agua posible. Mientras que el de corto plazo busca decidir los horarios de riego para las próximas 48 horas cada 10 minutos, a la vez que regula el micro-clima del invernadero. El funcionamiento del bloque de corto plazo se separó en dos partes: un controlador de ventanas para regular el micro-clima del invernadero y un sistema de gestión que debe cumplir con los riegos diarios.

Tanto para regular el micro-clima como para cumplir con restricciones de riego relacionadas a la temperatura, se derivó un modelo fenomenológico climático del invernadero. El modelo derivado entrega valores de temperatura, humedad relativa y temperatura del subsuelo del invernadero cada 10 minutos. Debido a la dinámica del modelo, la cual es más rápida que las muestras de cada 10 minutos, se requirió implementar una interpolación para calcular valores intermedios. Por medio de simulaciones, se encontró que el mejor tiempo para esto es $\Delta t_i = 25[s]$.

Otro elemento que se requirió para predecir el micro-clima del invernadero fueron los valores futuros de las variables externas. Estas eran la temperatura ambiental, la humedad relativa ambiental, la irradiancia y la velocidad del viento. Para realizar estas predicciones, se consideraron medias móviles, modelos lineales autorregresivos y redes neuronales. A todos los modelos se les dio un máximo de 144 regresores (24 horas de información). Al probar los resultados de cada uno, se tuvo que el mejor rendimiento en cuanto a la temperatura, la humedad relativa y la irradiancia ocurrió con la red neuronal. Sin embargo, el viento presentó una alta estocasticidad, por lo que se decidió usar un modelo de media móvil para él. Dado el rendimiento de estos modelos, se puede afirmar que tienen la precisión suficiente para el sistema diseñado.

Teniendo un método para predecir el micro-clima del invernadero, se procedió a diseñar el controlador de ventanas. Este busca regular el micro-clima del invernadero abriendo o cerrando las ventanas. El controlador es un MPC que minimiza una función objetivo con PSO. Para esto se propusieron tres tipos de función objetivo: seguimiento de referencia, penalización y optimización difusa. Las tres funciones tienen como objetivo minimizar la cantidad de tiempo que la temperatura o la humedad relativa se sale de los rangos considerados como seguros,

al mismo tiempo que usa la menor cantidad posible de cambios de estado de la ventana. Al probar con las tres funciones objetivo en dos conjuntos de datos, se determinó usar la función de optimización difusa, pues esta logró mantener la humedad y la temperatura en la zona de seguridad por más tiempo en total que las otras opciones. Así, la temperatura estuvo un 97 % del tiempo en la zona segura en un conjunto de datos y 90 % del tiempo en el otro. En el caso de la humedad relativa, estos valores fueron 67 % y 94 %. Este rendimiento podría explicarse por que la optimización difusa se asemeja a una restricción suave, lo que le permite cumplir con el objetivo planteado.

Para terminar el bloque de corto plazo, se diseñó el sistema de gestión a corto plazo. Este sistema debe entregar el riego diario a la vez que debe considerar el agua y energía disponibles. El sistema puede tomar dos decisiones: la cantidad de tiempo que se riega en cada instante y cuándo recargar el estanque. Para este objetivo, se implementó un MPC, que minimiza su función objetivo con PSO. La función objetivo utilizada tiene tres propósitos: cumplir el objetivo de riego, minimizar las instancias de riego y minimizar la energía extraída de la batería. El sistema se probó en una simulación en la cual tuvo que regar de forma diaria $250[L]$, y donde hubo un error de apenas $2[L]$ aproximadamente. El sistema usó cerca de 19.2 ciclos de baterías, que representa 0.9 ciclos menos que el caso donde la recarga del estanque no utiliza el panel solar. En cuanto al número de riegos, se tuvo que el promedio de veces que se regó por día fue 5, lo cual coincide con la cantidad mínima de instancias necesarias dado el objetivo.

En conjunto, el sistema de gestión de corto plazo y el control de ventanas forman un bloque de control de corto plazo, que es capaz de regular el micro-clima del invernadero, a la vez que realiza eficientemente el riego diario que se le entrega.

El bloque de mediano plazo se diseñó para determinar el riego diario futuro con base en la evapotranspiración. Para determinar la evapotranspiración, se identificaron 6 variables que se deben predecir: temperatura mínima y máxima diaria del invernadero, humedad relativa mínima y máxima diaria del invernadero, la radiación neta diaria dentro del invernadero y la proyección a dos metros de altura de la velocidad del viento promedio dentro del invernadero. Debido a la escasez de datos diarios (habiendo solo dos series de 81 días cada una) se debió implementar estrategias simples para estimar los valores futuros de estas. En el caso de las temperaturas y humedades, se hizo una proyección de sus respectivos valores de acuerdo con las predicciones a corto plazo de los primeros dos días. En el caso de la radiación neta, se realizó una media móvil de la irradiancia promedio usando 7 días de regresores y a partir de eso, se calculó la radiación. Finalmente, para la velocidad del viento, se fijó una constante que se calculó con los datos y el comportamiento del controlador de ventanas. Al probar estos métodos en los conjuntos de datos, se obtuvieron resultados imprecisos, lo que era de esperarse por la escala de las predicciones y la escasez de datos. La evapotranspiración obtenida presentaba un error porcentual del 64.4 % a los 14 días de predicción en un conjunto y 30.8 % en el otro. En cuanto a la predicción de 28 días, estos cambian a 57.2 % y 28.2 % respectivamente. Debido a los pocos datos disponibles y ya que este experimento no evalúa cómo actuaría el controlador con estas predicciones, no es posible asegurar que estas predicciones tengan la precisión suficiente para el buen funcionamiento del sistema.

Finalmente, se diseñó el sistema de gestión a mediano plazo, que define el volumen de rie-

go para los próximos 28 días. Esto lo hace por medio de un MPC, que maximiza su función objetivo con PSO. La función objetivo del controlador busca maximizar el rendimiento de los cultivos usando la menor cantidad de agua posible. Para probar el sistema, se realizaron dos experimentos que incluyeron todos los sistemas mencionados anteriormente: uno en donde el sistema tiene uso exclusivo del estanque y otro en donde el estanque se comparte con otro riego. En el segundo experimento, se le permitió al sistema tener un volumen mínimo de estanque más pequeño para compensar la mayor demanda. Ambos casos lograron mantener un buen riego de los cultivos pues ambos lograron un rendimiento relativo de 0.987. Esto se logro utilizando menos agua que el caso base ($150[L]$), usando $130.5[L]$ y $135.2[L]$ respectivamente, con lo que lograron ahorrar agua. Solo el experimento donde había uso exclusivo del estanque, el sistema no logró cumplir todos sus objetivos diarios, pero esto no afecto el rendimiento. Además, ambos casos tuvieron días en los que no se regó. Esto podría complicar su adopción por parte de ciertas comunidades que acostumbran tener riego diario.

Dados los resultados obtenidos es posible afirmar que el sistema propuesto cumple sus objetivos planteados. En cuanto a la implementación de este sistema se recomienda realizar cambios a las distintas partes de este en base a sus resultados. En el caso de los sistemas de predicción se tiene que el uso de redes neuronales es efectivo, pero requiere de mayor diversidad de datos. En cuanto a las predicciones diarias se recomienda desarrollar mejores estrategias de predicción y tener mayor disponibilidad de datos (mínimo 5 años), dando énfasis a predecir la radiación neta.

Al usar modelo fenomenológico derivado se recomienda el uso de parámetros basados en los datos reales del invernadero. Para el sistema de control del micro-clima se prefiere que se mantenga el diseño planteado de forma de seguir usando los métodos de la comunidad, pero se requiere que el modelo del invernadero este ajustado a este. Finalmente tanto el EMS y el WMS desarrollado muestran que logran cumplir los objetivos deseados por lo que si se recomiendan su uso en su forma actual dado que se cumpla lo anteriormente dicho.

6.1. Trabajo futuro

Varios aspectos de este trabajo pueden desarrollarse para mejorar el diseño o rendimiento del sistema, los cuales se presentan a continuación:

1. Modelación con datos de invernadero: un problema que presenta el sistema es que este no posee datos climáticos reales del invernadero a controlar. En caso de tenerlos, sería posible calibrar de mejor manera el modelo fenomenológico y así lograr mejores estimaciones.
2. Planteamiento del sistema de predicción a mediano plazo: el sistema necesita de un mejor sistema de predicción para la evapotranspiración a mediano plazo. Con mayor disponibilidad de datos, sería posible implementar mejores estrategias de predicción para el mediano plazo. También es posible compensar el error de las predicciones futuras con un planteamiento robusto.
3. Expansión para múltiples cultivos e invernaderos: el sistema en su forma actual considera un solo tipo de cultivo, lo cual no es conveniente para un pequeño agricultor. Agregar más cultivos involucra agregar más variables de decisión, tanto para los sistemas de

corto plazo como para los de largo plazo; además se necesitaría una ponderación entre los cultivos. En el caso de agregar invernaderos al sistema, también se tendría que considerar el micro-clima de estos.

4. Vender energía excedente a la red: si bien el sistema está diseñado para ser independiente de la red, podría plantearse un sistema que esté conectado a la red eléctrica a fin de vender los excesos de energía.
5. Considerar situaciones de escasez de agua: el diseño del sistema actual no considera casos en los que la extracción de agua sea infactible o limitada, por lo que podría presentar problemas al enfrentarse a esas situaciones. La forma más directa de implementar este cambio sería estableciendo un volumen máximo de agua diaria o una ponderación entre el agua diaria y el desarrollo del cultivo en el controlador a mediano plazo.

Bibliografía

- [1] *The Water-Energy-Food Nexus. A New Approach in Support of Food Security and Sustainable Agriculture*. Rome: Food and Agriculture Organization of the United Nations, 2014.
- [2] R. D. Garreaud, J. P. Boisier, R. Rondanelli, A. Montecinos, H. H. Sepúlveda, and D. Veloso-Aguila, “The central chile mega drought (2010–2018): A climate dynamics perspective,” *International Journal of Climatology*, vol. 40, no. 1, pp. 421–439, 2020.
- [3] C. Zhang, X. Chen, Y. Li, W. Ding, and G. Fu, “Water-energy-food nexus: Concepts, questions and methodologies,” *Journal of Cleaner Production*, vol. 195, pp. 625–639, 2018.
- [4] T. Roje, D. Sáez, C. Muñoz, and L. Daniele, “Energy–water management system based on predictive control applied to the water–food–energy nexus in rural communities,” *Applied Sciences*, vol. 10, p. 7723, 10 2020.
- [5] F. Suárez, J. F. Muñoz, B. Fernández, J.-M. Dorsaz, C. K. Hunter, C. A. Karavitis, and J. Gironás, “Integrated water resource management and energy requirements for water supply in the copiapó river basin, chile,” *Water*, vol. 6, no. 9, pp. 2590–2613, 2014.
- [6] W. Zhang, A. Valencia, L. Gu, Q. P. Zheng, and N.-B. Chang, “Integrating emerging and existing renewable energy technologies into a community-scale microgrid in an energy-water nexus for resilience improvement,” *Applied Energy*, vol. 279, p. 115716, 2020.
- [7] N. Naval and J. M. Yusta, “Water-energy management for demand charges and energy cost optimization of a pumping stations system under a renewable virtual power plant model,” *Energies*, vol. 13, 06 2020.
- [8] F. Moazeni, J. Khazaei, and A. Asrari, “Step towards energy-water smart microgrids; buildings thermal energy and water demand management embedded in economic dispatch,” *IEEE Transactions on Smart Grid*, vol. 12, no. 5, pp. 3680–3691, 2021.
- [9] E. Karan, S. Asadi, R. Mohtar, and M. Baawain, “Towards the optimization of sustainable food-energy-water systems: A stochastic approach,” *Journal of Cleaner Production*, vol. 171, pp. 662–674, 2018.
- [10] N. Mousavi, G. Kothapalli, D. Habibi, C. K. Das, and A. Baniasadi, “A novel photovoltaic-pumped hydro storage microgrid applicable to rural areas,” *Applied Energy*, vol. 262, p. 114284, 2020.
- [11] F. Jooste, A. Kumar, and G. Hancke, “Energy efficient irrigation scheduling system based on the iso/iec/ieee 21451 standards,” *2017 IEEE International Conference on Industrial Technology (ICIT)*, pp. 1441–1446, 03 2017.

- [12] Z. Hidayat, R. Babuška, A. Núñez, and B. De Schutter, “Identification of distributed-parameter systems from sparse measurements,” *Applied Mathematical Modelling*, vol. 51, pp. 605–625, 2017.
- [13] J. Reca, C. Trillo, J. Sánchez, J. Martínez, and D. Valera, “Optimization model for on-farm irrigation management of mediterranean greenhouse crops using desalinated and saline water from different sources,” *Agricultural Systems*, vol. 166, pp. 173–183, 2018.
- [14] A. M. Hassabou and M. A. Khan, “Towards autonomous solar driven agricultural greenhouses in qatar - integration with solar cooling,” in *2019 7th International Renewable and Sustainable Energy Conference (IRSEC)*, pp. 1–8, 2019.
- [15] Y. Achour, A. Ouammi, D. Zejli, and S. Sayadi, “Supervisory model predictive control for optimal operation of a greenhouse indoor environment coping with food-energy-water nexus,” *IEEE Access*, vol. 8, pp. 211562–211575, 2020.
- [16] A. Ouammi, O. Choukai, D. Zejli, and S. Sayadi, “A decision support tool for the optimal monitoring of the microclimate environments of connected smart greenhouses,” *IEEE Access*, vol. 8, pp. 212094–212105, 2020.
- [17] D.-L. V. Martínez, F. D. Molina, and A. J. Álvarez, *Ahorro y eficiencia energética en invernaderos*. Madrid Idae, 2008.
- [18] S. Raquel, A. Mauricio Pérez, I. Lopez-Cruz, and A. Rojano-Aguilar, “A model of humidity within a semi-closed greenhouse,” *Revista Chapingo Serie Horticultura*, vol. 22, pp. 27–43, 04 2016.
- [19] R. Allen, L. S. Pereira, D. Raes, and M. Smith, *Crop evapotranspiration : guidelines for computing crop water requirements*. Rome, Italy: Food and Agriculture Organization of the United Nations, 1998.
- [20] R. Snyder and S. Eching, “Penman-monteith (hourly) reference evapotranspiration equations for estimating etos and etrs with hourly weather data,” *Regents Univ. Calif*, 01 2002.
- [21] C. Stanghellini and T. de Jong, “A model of humidity and its applications in a greenhouse,” *Agricultural and Forest Meteorology*, vol. 76, no. 2, pp. 129–148, 1995.
- [22] N. H. Rao, P. B. S. Sarma, and S. Chander, “Optimal multicrop allocation of seasonal and intraseasonal irrigation water,” *Water Resources Research*, vol. 26, no. 4, pp. 551–559, 1990.
- [23] D. Saez, M. Sanz-Bobi, and A. Cipriano, “Prediction of water chemical properties in the cycle of a coal power plant using artificial neural networks,” in *1998 IEEE International Joint Conference on Neural Networks Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98CH36227)*, vol. 3, pp. 1981–1986, 1998.
- [24] D. Schwarz, A. J. Thompson, and H.-P. Kläring, “Guidelines to use tomato in experiments with a controlled environment,” *Frontiers in Plant Science*, vol. 5, p. 625, 2014.
- [25] W. A. Lodwick and J. KACPRZYK, *Fuzzy Optimization: Recent Advances and Applications*, vol. 254 of *Studies in Fuzziness and Soft Computing*. Berlin, Heidelberg: Springer Berlin / Heidelberg, 2010.
- [26] A. Flores, D. Saez, J. Araya, M. Berenguel, and A. Cipriano, “Fuzzy predictive control

- of a solar power plant,” *IEEE Transactions on Fuzzy Systems*, vol. 13, pp. 58–68, Feb 2005.
- [27] S. Fidanova, *Recent advances in computational optimization: results of the Workshop on Computational Optimization WCO 2016*. Springer, 2018.
- [28] L. G. Marín, M. Sumner, D. Muñoz-Carpintero, D. Köbrich, S. Pholboon, D. Sáez, and A. Núñez, “Hierarchical energy management system for microgrid operation based on robust model predictive control,” *Energies*, vol. 12, no. 23, 2019.
- [29] N. H. Abu-Hamdeh, “Thermal properties of soils as affected by density and water content,” *Biosystems Engineering*, vol. 86, no. 1, pp. 97–102, 2003.
- [30] C. Brouwer, K. Prins, and M. Heibloem, *Irrigation Water Management: Training Manual No. 4: Irrigation scheduling*. Rome, Italy: Food and Agriculture Organization of the United Nations, 1985.

Anexo A

A.1. Parámetros

Se presentan los parámetros utilizados para las simulaciones del invernadero. Estos valores están ajustados a las características del invernadero real.

A.1.1. Arquitectura del invernadero

- ρ_r : Flujo de agua de riego = $0.0001 \left[\frac{m^3}{s} \right]$
- ρ_{rec} : Flujo de agua de la bomba = $\frac{0.5}{25 \cdot 60} \left[\frac{m^3}{s} \right]$, el valor se basa en que de acuerdo a las entrevistas el estanque se llena en 25 minutos.
- η_{cahr} : Eficiencia de carga de la batería = 0.85
- η_{dis} : Eficiencia de descarga de la batería = 0.85
- η_{inv} : Eficiencia del inversor = 0.9
- T_{STC} : Temperatura estándar = $25[^\circ C]$
- T_n : Temperatura nominal de operación = $25[^\circ C]$
- α_{fv} : Coeficiente de temperatura del panel = $-0.39 \left[\frac{\%}{^\circ C} \right]$
- I_{STC} : Irradiancia media en condiciones estándar = $1000 \left[\frac{W}{m^2} \right]$
- $P_{fv,n}$: Potencia nominal del panel = $320[W]$
- P_{Bomba} : Potencia de la bomba a utilizar = $745.699[W]$

A.1.2. Modelo fenomenológico

- ρ_{air} : densidad del aire = $1.225 \left[\frac{kg}{m^3} \right]$. Se asume su valor a nivel del mar.
- V_{inv} : Volumen del invernadero = $152.4000 [m^3]$. Calculado en base al diseño de este.
- c_{pa} : Calor específico del aire seco (a $0[^\circ C]$) = $1006.92540 \left[\frac{J}{KgK} \right]$ [17]
- c_{pv} : Calor específico del vapor (a $0[^\circ C]$) = $1875.6864 \left[\frac{J}{KgK} \right]$ [17]

- A_g : Área del suelo del invernadero= $60[m^2]$
- L_{ss} : Profundidad de medición de la temperatura del sub-suelo= $0.15[m]$
- ρ_g : Densidad de la tierra (suelo arcilloso)= $1300 \left[\frac{Kg}{m^3} \right]$ [29]
- c_{pv} : Calor específico de la tierra (suelo arcilloso)= $1700 \left[\frac{J}{KgK} \right]$ [29]

A.1.2.1. Efecto de la radiación solar

- A_{cu} : Área de la cubierta del invernadero= $136.002[m^2]$. Calculado en base al diseño.
- α_{inv} : Coeficiente de absorción de la cubierta (policarbonato)= 0.08 [17]
- τ_{inv} : Coeficiente de transmisividad de la cubierta (policarbonato)= 0.78 [17]
- ε_{inv} : Coeficiente de emisividad de la cubierta (policarbonato)= 0.97 [17]
- α_c : Coeficiente de absorción de los cultivos (suponiendo $LAI = 4$ por dificultad del seguimiento)= 0.81 [17]
- α_g : coeficiente de absorción de la tierra = 1-albedo del suelo= $1 - 0.05$. Suponiendo arcilla húmeda [17].
- f_c : Proporción del suelo cultivada= 0.8 , se supone que los cultivos cubrirán el 80 % del suelo.
- f_n : Nubosidad, debido a la dificultad de estimar este valor se supone $f_n = 0.95$
- σ : Constante de Stefan-Boltzman= $5.67 \cdot 10^{-8} \left[\frac{J}{KgK} \right]$

A.1.2.2. Efecto de la conducción y convección

- e_c : Espesor del material de la cubierta= $0.004[m]$
- λ_c : Conductibilidad térmica de la cubierta (Policarbonato ondulado)= $0.19 \left[\frac{W}{m^3K} \right]$ [17].

A.1.2.3. Efecto del intercambio de calor con el suelo

- K_g : Conductibilidad térmica del suelo (tierra húmeda)= $2 \left[\frac{W}{mK} \right]$ [17].

A.1.2.4. Efecto del intercambio de calor con el suelo

- R_{Inf} : Tasa de infiltración de la cubierta (laminas de plástico)= $1 \left[\frac{1}{hr} \right]$ [17].
- A_{vent} : Área de la ventana= $0.9[m^2]$
- z : Altura a la que se mide el viento= $4[m]$
- z_v : Altura de la mitad de la ventana= $1.2[m]$

A.1.2.5. Efecto de la evapotranspiración

- γ : Constante psicrométrica=0.0671 $\left[\frac{kPa}{^\circ C}\right]$ usando las formulas de [19] y suponiendo una altura de 30[m] respecto al mar
- C_n : Para evapotranspiración por hora se usa $37\left[\frac{K}{kg} \frac{mms^3}{hr}\right]$ [20]
- C_d : Para evapotranspiración por hora se usa $0.24\left[\frac{s}{m}\right]$ de día y $0.96\left[\frac{s}{m}\right]$ de noche [20]

A.1.3. Demanda de riego

- K_c : Constante que depende del cultivo, esta cambia de valor dependiendo de la fase de desarrollo de este y se puede calcular con el método presentado en [19]
- K_y : Factor de respuesta del rendimiento=1 [19]
- C_n : Para evapotranspiración por día se usa $900\left[\frac{K}{kg} \frac{mms^3}{day}\right]$ [19]
- C_d : Para evapotranspiración por día se usa $0.34\left[\frac{s}{m}\right]$ [19]
- p_c : Coeficiente dependiente del cultivo=0.4[19]
- Z_r : Largo de raíz (tomate), se fija como máximo =1.1[m][19]
- θ_{FC} : Capacidad de campo (Suelo arcilloso)= $0.96\left[\frac{m^3}{m^3}\right]$ [19]
- θ_{WP} : Punto de marchitamiento (Suelo arcilloso)= $0.96\left[\frac{m^3}{m^3}\right]$ [19]
- η_r : Eficiencia de riego (goteo)=0.9 [30]
- p_t : Porosidad total del terreno=1. Supuesto

A.1.4. Parámetros controladores

A.1.4.1. Sistema de gestión de agua-energía a corto plazo

- C_{ex} : Costo de regar excesivamente=0.25
- C_{lack} : Costo de no regar suficiente=0.25
- λ_I : Parámetro de costo de decisión de riego= $\frac{1}{10}$
- λ_P : Parámetro de costo de uso de batería= $\frac{1}{2.88 \cdot 10^6}$
- $V_{estanque_{min}}$: Volumen de estanque mínimo, varía entre $0.2[m^3]$ y $0.05[m^3]$ dependiendo del experimento.
- $V_{estanque_{max}}$: Volumen máximo del estanque = $0.5[m^3]$
- SoE_{min} : Capacidad de energía mínima de la batería= $576[kJ]$
- SoE_{max} : Capacidad de energía máxima de la batería= $2880[kJ]$

A.1.4.2. Sistema de gestión a mediano plazo

- γ_w : Parámetro de costo de decisión de volumen de agua= $\frac{1}{10}$

A.2. Controladores de ventanas por reglas

$$V_s(k) = \begin{cases} 1 & , T_{inv}(k) \geq 28[^\circ C] \wedge Ir(k) \geq 100[\frac{W}{m^2}] \\ 0 & , T_{inv}(k) \leq 16[^\circ C] \wedge Ir(k) \geq 100[\frac{W}{m^2}] \\ 1 & , T_{inv}(k) \geq 23[^\circ C] \wedge Ir(k) < 100[\frac{W}{m^2}] \\ 0 & , T_{inv}(k) \leq 11.5[^\circ C] \wedge Ir(k) < 100[\frac{W}{m^2}] \\ V_s(k-1) & , \sim \end{cases} \quad (A.1)$$

$$V_s(k) = \begin{cases} 1 & , HR_{inv}(k) \geq 82.5 \% \\ 0 & , HR_{inv}(k) \leq 42.5 \% \\ V_s(k-1) & , \sim \end{cases} \quad (A.2)$$

$$V_s(k) = \begin{cases} 1 & , Ir(k) \geq 100[\frac{W}{m^2}] \\ 0 & , Ir(k) < 100[\frac{W}{m^2}] \end{cases} \quad (A.3)$$

A.3. Redes neuronales

Las redes neuronales tienen la característica de ser aproximadores universales. Esto les permite ser una buena herramienta para la predicción de sistemas estocásticos como el clima o eventos derivados de este. Un tipo de red neuronal que se puede aplicar para esta función corresponde al perceptrón multicapa auto-regresivo como se ve en la figura A.1. Este tipo de red al igual que cualquier sistema auto-regresivo tiene la debilidad de que cada predicción en una secuencia se vuelve menos precisa debido a la acumulación de error de cada predicción lo que hace las predicciones sean útiles hasta un cierto límite.

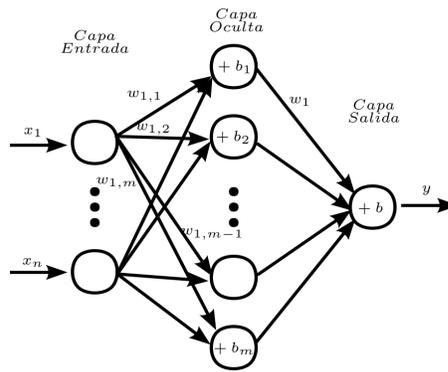


Figura A.1: Representación de un perceptrón multicapa

En la figura se observa que cada neurona recibe información de la capa anterior multiplicada por un peso. La suma de estos valores en conjunto de un sesgo se pasan por una función que depende de la capa.

A.4. Estrategia de análisis de sensibilidad

Como se menciona en la sección 4.3.1 en este trabajo el análisis de sensibilidad se realizó de manera distinta al procedimiento estándar. Normalmente para entrenar redes se debería seleccionar un conjunto de configuración de neuronas en capa oculta y en cada uno de esas configuraciones realizar análisis de sensibilidad para eliminar entradas. Sin embargo, dada la alta cantidad de regresores utilizados (144) y la cantidad de neuronas de capa oculta que eso implica, el proceso de entrenar una red involucraría una cantidad significativa de tiempo. Por esto se realiza un proceso más rápido pero con menos precisión en donde se parte con un conjunto inicial de entradas las cuales se evalúan en distintas configuraciones de neuronas en la capa oculta y en base a la que tenga el mejor rendimiento en el conjunto de validación se realiza el análisis de sensibilidad para descartar una entrada. Después con el nuevo conjunto de entradas se repite el proceso. Esto se hace hasta llegar a un criterio de detención, en este trabajo fue 5 iteraciones sin mejoras.