



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

**CONTROL PREDICTIVO DIFUSO PARA LA OPTIMIZACIÓN DEL USO DE  
AGUA DE RIEGO EN FRUTICULTURA**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO

**ÁLVARO IGNACIO MANRÍQUEZ BARRA**

PROFESOR GUÍA:

DIEGO MUÑOZ CARPINTERO

PROFESORA CO-GUÍA:

DORIS SÁEZ HUEICHAPAN

COMISIÓN:

DAVID SALAS VIDELA

Este trabajo ha sido parcialmente financiado por el proyecto Fondecyt de iniciación 11221230: Advances on Stochastic Model Predictive Control based on Fuzzy and Neural Models, y por el Proyecto Multidisciplinario UOH MSM2021003: Gestión Inteligente de Recursos Hídricos para la Agricultura

SANTIAGO DE CHILE

2024

RESUMEN DE LA MEMORIA PARA OPTAR  
AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO  
POR: ÁLVARO IGNACIO MANRÍQUEZ BARRA  
FECHA: 2024  
PROF. GUÍA: DIEGO MUÑOZ CARPINTERO

## **CONTROL PREDICTIVO DIFUSO PARA LA OPTIMIZACIÓN DEL USO DE AGUA DE RIEGO EN FRUTICULTURA**

Esta memoria propone métodos para la optimización del uso de agua de riego en fruticultura basados en control predictivo difuso. El estudio se enfoca en un viñedo en la región de O'Higgins, utilizando un planteamiento sustentado en datos para modelar el comportamiento del contenido de agua del terreno en cuatro niveles de profundidad. Los datos disponibles corresponden a un conjunto de muestras reales de los contenidos y flujos de agua de la viña, y un conjunto de datos del mismo tipo generados a partir de un simulador de las dinámicas del terreno de cultivo. Luego, haciendo uso de cada conjunto por separado, se desarrollan modelos en variables de estado lineales y difusos Takagi-Sugeno para predecir el comportamiento del contenido de agua de la viña en las distintas profundidades.

Tras un análisis del rendimiento de cada modelo propuesto, se diseñan dos tipos de controladores predictivos basados en ellos. El primero tiene por objetivo mantener el nivel de humedad en una de las profundidades por sobre un umbral determinado, utilizando una función objetivo que penaliza el uso de agua de riego, intentando así mantener contenidos de agua sobre un nivel determinado usando la menor cantidad de agua posible. El segundo controlador se basa en el primero, añadiendo restricciones que limitan el número de instancias de riego en el horizonte de predicción, acercando así el controlador al caso en que los agricultores no pueden regar todos los días por limitaciones materiales. Los controladores son probados en múltiples experimentos, usando cada uno de los modelos desarrollados, empleando como planta los mismos modelos y el simulador. De esta manera, se tiene experimentos en que la calidad de los modelos no es un factor para evaluar el funcionamiento correcto de los esquemas de control, y experimentos que permiten evaluar el rendimiento hídrico de los planteamientos. Finalmente, se compara el rendimiento de los controladores formulados con un método de riego convencional. Los resultados demuestran el potencial de los esquemas de control predictivo para mejorar la eficiencia de riego, y permiten apreciar las limitaciones de la estructura de los modelos y los métodos de identificación difusa utilizados.

*A Chica, Lala y Lusitania*

# Agradecimientos

Me gustaría dar las gracias a todos quiénes han contribuido al éxito de mi memoria de título y me han ayudado durante la redacción de este informe.

En primer lugar, agradezco la colaboración del proyecto Fondecyt que financió parcialmente este trabajo: *Advances on Stochastic Model Predictive Control based on Fuzzy and Neural Models*, y del Proyecto Multidisciplinario UOH MSM2021003: *Gestión Inteligente de Recursos Hídricos para la Agricultura*.

También quiero agradecer al profesor Diego Muñoz, guía de esta memoria, por su confianza al trabajar conmigo en este proyecto, y por su orientación, consejos y dedicación a lo largo del trabajo.

Deseo igualmente agradecer a la profesora Doris Sáez, co-guía del trabajo, por su apoyo y observaciones.

Agradezco también a mi familia, mi hermano, mi madre y mi padre, que siempre han estado apoyándome a lo largo de mis estudios. Doy las gracias también a mis perros por su apoyo incondicional.

Por último, a mis amigos que me han acompañado durante estos años universitarios, gracias.

# Tabla de Contenido

<b>1. Introducción</b>	<b>1</b>
1.1. Objetivos . . . . .	3
<b>2. Marco teórico</b>	<b>4</b>
2.1. Antecedentes agrícolas . . . . .	4
2.1.1. Características hídricas . . . . .	4
2.1.2. Dinámica del balance hídrico . . . . .	5
2.1.3. Cultivo de uva de vino . . . . .	9
2.2. Modelación difusa . . . . .	10
2.2.1. Modelos Takagi-Sugeno (TS) . . . . .	11
2.2.2. Identificación difusa . . . . .	12
2.3. Control predictivo . . . . .	15
2.3.1. Control predictivo basado en modelos difusos . . . . .	17
<b>3. Estado del arte</b>	<b>19</b>
3.1. Estrategias convencionales de riego . . . . .	19
3.2. Control difuso . . . . .	20
3.3. Control predictivo . . . . .	20
3.4. Discusión . . . . .	21
<b>4. Metodología</b>	<b>24</b>
4.1. Datos . . . . .	26
4.2. Modelamiento lineal . . . . .	26
4.3. Modelamiento TS automático . . . . .	27
4.4. Modelamiento TS híbrido . . . . .	27
4.5. MPC umbral . . . . .	28
4.6. MPC umbral y restricción de frecuencia . . . . .	29
4.7. Análisis de resultados . . . . .	30
<b>5. Modelamiento</b>	<b>31</b>
5.1. Usando datos recopilados de la viña . . . . .	31
5.1.1. Datos . . . . .	31

5.1.2.	Modelamiento lineal . . . . .	33
5.1.3.	Modelamiento difuso . . . . .	36
5.1.3.1.	Modelo Takagi-Sugeno automático . . . . .	36
5.1.3.2.	Modelo Takagi-Sugeno híbrido . . . . .	40
5.1.4.	Análisis comparativo . . . . .	43
5.2.	Usando datos extraídos del simulador . . . . .	45
5.2.1.	Datos . . . . .	45
5.2.2.	Modelamiento lineal . . . . .	47
5.2.3.	Modelamiento difuso . . . . .	49
5.2.4.	Análisis comparativo . . . . .	51
<b>6.</b>	<b>Control Predictivo</b>	<b>53</b>
6.1.	MPC con umbral mínimo . . . . .	54
6.1.1.	Control sobre los modelos . . . . .	56
6.1.2.	Control sobre el simulador . . . . .	59
6.1.3.	Análisis de resultados . . . . .	62
6.2.	MPC con umbral mínimo y restricción de frecuencia de riego . . . . .	64
6.2.1.	Control sobre los modelos . . . . .	66
6.2.2.	Control sobre el simulador . . . . .	69
6.2.3.	Análisis de resultados . . . . .	72
6.3.	Comparación con otras técnicas de riego . . . . .	73
6.3.1.	Riego convencional . . . . .	74
6.3.2.	Riego utilizado en la viña . . . . .	77
6.4.	Costos computacionales . . . . .	79
<b>7.</b>	<b>Conclusiones</b>	<b>81</b>
7.1.	Trabajos futuros . . . . .	83
	<b>Bibliografía</b>	<b>84</b>
	<b>Anexos</b>	<b>88</b>
A.	Parámetros de los modelos . . . . .	88
A.1.	Modelos basados en datos de la viña . . . . .	88
A.1.1.	Modelo lineal . . . . .	88
A.1.2.	Modelo Takagi-Sugeno automático . . . . .	89
A.1.3.	Modelo Takagi-Sugeno híbrido . . . . .	89
A.2.	Modelos basados en datos del simulador . . . . .	90
A.2.1.	Modelo lineal . . . . .	90
A.2.2.	Modelo Takagi-Sugeno automático . . . . .	91
B.	Tiempos de computación experimentos de control . . . . .	92
B.1.	MPC con umbral mínimo . . . . .	92
B.2.	MPC con umbral mínimo y restricción de frecuencia de riego . . . . .	92

B.3.	Comparación con otras técnicas de riego . . . . .	93
B.4.	Discusión . . . . .	93

# Índice de Tablas

5.1.	Error RMSE de predicción de test, a múltiples pasos, del modelo lineal para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día . . . . .	35
5.2.	Error RMSE de predicción de test, a múltiples pasos, del modelo TS automático para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día	40
5.3.	Error RMSE de predicción de test, a múltiples pasos, del modelo TS híbrido para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día	43
5.4.	Error RMSE de predicción de test, a múltiples pasos, del modelo lineal generado usando datos del simulador, para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día . . . . .	49
5.5.	Error RMSE de predicción de test, a múltiples pasos, del modelo TS automático generado usando datos del simulador, para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día . . . . .	51
6.1.	Nomenclatura de los modelos desarrollados modelos, usada en los experimentos subsiguientes . . . . .	54
6.2.	Valores relevantes de los experimentos de MPC con umbral mínimo usando el simulador como planta, con $N = 7$ . . . . .	64
6.3.	Valores relevantes de los experimentos de MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con $N = 7$ y $dias_{max} = 2$	73
6.4.	Valores relevantes de los experimentos con programación convencional y basada en MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con $N = 6$ y $dias_{max} = 1$ . . . . .	76
6.5.	Valores relevantes del control de riego aplicado en la viña y los experimentos con programación basada en MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con $N = 7$ y $dias_{max} = 2$ . . . . .	79
6.6.	Tiempo de computación de los experimentos de MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, para los modelos TS automáticos, con distintos valores de $N$ y $dias_{max}$ . . . . .	80
B.1.	Tiempo de computación de los experimentos de MPC con umbral mínimo usando el mismo modelo como planta, con $N = 7$ . . . . .	92
B.2.	Tiempo de computación de los experimentos de MPC con umbral mínimo usando el simulador como planta, con $N = 7$ . . . . .	92



B.3.	Tiempo de computación de los experimentos de MPC con umbral mínimo y restricción de frecuencia de riego usando el mismo modelo como planta, con $N = 7$ y $dias_{max} = 2$ . . . . .	92
B.4.	Tiempo de computación de los experimentos de MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con $N = 7$ y $dias_{max} = 2$ . . . . .	93
B.5.	Tiempo de computación de los experimentos con programación convencional y basada en MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con $N = 6$ y $dias_{max} = 1$ . . . . .	93
B.6.	Tiempo de computación del control aplicado en la viña y los experimentos con programación basada en MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con $N = 7$ y $dias_{max} = 2$ . . . . .	93

# Índice de Ilustraciones

2.1.	Balance hídrico en el suelo mediante representación del estanque [14] . . . . .	5
2.2.	Evolución de la evaporación y transpiración según el desarrollo del cultivo. IAF corresponde a la razón entre el área de las hojas de la planta y el área de cultivo [14] . . . . .	7
2.3.	Etapas del desarrollo de la uva de vino durante una temporada de cultivo [17]	10
2.4.	Diagrama de flujo identificación difusa . . . . .	13
2.5.	Diagrama de bloques básico de un controlador predictivo . . . . .	16
4.1.	Diagrama de bloques de la metodología del proyecto . . . . .	25
5.1.	Datos de contenido de agua en las distintas profundidades . . . . .	32
5.2.	Datos de los flujos de agua del sistema . . . . .	33
5.3.	Diagrama simplificado de la estructura del modelo lineal . . . . .	34
5.4.	Predicción a 1 paso de los contenidos de agua del sistema, usando el modelo lineal	35
5.5.	Predicción a $n$ pasos de los contenidos de agua del sistema, usando el modelo lineal . . . . .	36
5.6.	Error RMSE promedio de las cuatro salidas según el número de clusters, usando 1 regresor de cada antecedente, clustering FCM y sin normalización de los datos	38
5.7.	Predicción a 1 paso de los contenidos de agua del sistema, usando el modelo TS automático . . . . .	39
5.8.	Predicción a $n$ pasos de los contenidos de agua del sistema, usando el modelo TS automático . . . . .	40
5.9.	Histograma de la distribución de muestras del contenido de agua a 20 cm de profundidad, con marcas en los percentiles 20, 50 y 80 . . . . .	41
5.10.	Predicción a 1 paso de los contenidos de agua del sistema, usando el modelo TS híbrido . . . . .	42
5.11.	Predicción a $n$ pasos de los contenidos de agua del sistema, usando el modelo TS híbrido . . . . .	43
5.12.	Evolución del RMSE de test al variar el número de pasos de predicción, para los modelos desarrollados en cada profundidad . . . . .	44
5.13.	Datos de contenido de agua en las distintas profundidades, obtenidos del simulador	46
5.14.	Datos de los flujos de agua del sistema, obtenidos del simulador . . . . .	47
5.15.	Predicción a 1 paso de los contenidos de agua del simulador, en el conjunto de test, usando el modelo lineal . . . . .	48

5.16.	Predicción a $n$ pasos de los contenidos de agua del simulador, en el conjunto de test, usando el modelo lineal . . . . .	48
5.17.	Predicción a 1 paso de los contenidos de agua del simulador, en el conjunto de test, usando el modelo TS automático . . . . .	50
5.18.	Predicción a $n$ pasos de los contenidos de agua del simulador, en el conjunto de test, usando el modelo TS automático . . . . .	51
5.19.	Evolución del RMSE de test al variar el número de pasos de predicción, para los modelos desarrollados con los datos del simulador, en cada profundidad . . . .	52
6.1.	Diagrama de bloques del sistema . . . . .	56
6.2.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo lineal identificado a partir de los datos de la viña como planta y modelo en el controlador. $N = 7$ . . . . .	57
6.3.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo lineal identificado a partir de los datos del simulador como planta y modelo en el controlador. $N = 7$ . . . . .	57
6.4.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo TS automático identificado a partir de los datos de la viña como planta y modelo en el controlador. $N = 7$ . . . . .	58
6.5.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo TS híbrido identificado a partir de los datos de la viña como planta y modelo en el controlador. $N = 7$ . . . . .	58
6.6.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo TS automático identificado a partir de los datos del simulador como planta y modelo en el controlador. $N = 7$ . . . . .	59
6.7.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo lineal identificado a partir de los datos de la viña. $N = 7$ . . . . .	60
6.8.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo lineal identificado a partir de los datos del simulador. $N = 7$ . . . . .	60
6.9.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo TS automático identificado a partir de los datos de la viña. $N = 7$ . . . . .	61
6.10.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo TS híbrido identificado a partir de los datos de la viña. $N = 7$ . . . . .	61
6.11.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo TS automático identificado a partir de los datos del simulador. $N = 7$ . . . . .	62

6.12.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y costo modificado para penalizar solo el riego instantáneo, usando el modelo TS automático identificado a partir de los datos del simulador como planta y modelo en el controlador. $N = 7$ . . . . .	63
6.13.	Diagrama de bloques del sistema . . . . .	66
6.14.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo lineal identificado a partir de los datos de la viña como planta y modelo en el controlador. $N = 7$ , $dias_{max} = 2$ . . . . .	67
6.15.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo lineal identificado a partir de los datos del simulador como planta y modelo en el controlador. $N = 7$ , $dias_{max} = 2$ . . . . .	67
6.16.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo TS automático identificado a partir de los datos de la viña como planta y modelo en el controlador. $N = 7$ , $dias_{max} = 2$ . . . . .	68
6.17.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo TS híbrido identificado a partir de los datos de la viña como planta y modelo en el controlador. $N = 7$ , $dias_{max} = 2$ . . . . .	68
6.18.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo TS automático identificado a partir de los datos del simulador como planta y modelo en el controlador. $N = 7$ , $dias_{max} = 2$ . . . . .	69
6.19.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo lineal identificado a partir de los datos de la viña. $N = 7$ , $dias_{max} = 2$	70
6.20.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo lineal identificado a partir de los datos del simulador. $N = 7$ , $dias_{max} = 2$	70
6.21.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos de la viña. $N = 7$ , $dias_{max} = 2$ . . . . .	71
6.22.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS híbrido identificado a partir de los datos de la viña. $N = 7$ , $dias_{max} = 2$	71

6.23.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos del simulador. $N = 7$ , $dias_{max} = 2$ . . . . .	72
6.24.	Programación de riego convencional de una temporada, controlando el simulador	74
6.25.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos de la viña. $N = 6$ , $dias_{max} = 1$ . . . . .	75
6.26.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos del simulador. $N = 6$ , $dias_{max} = 1$ . . . . .	76
6.27.	Programación de riego en la viña de una temporada equivalente a una simulada	77
6.28.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos de la viña. $N = 7$ , $dias_{max} = 2$ . . . . .	78
6.29.	Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos del simulador. $N = 7$ , $dias_{max} = 2$ . . . . .	78

# Capítulo 1

## Introducción

Los últimos años han visto un rápido crecimiento demográfico que va de la mano con el aumento del uso de recursos naturales, lo que a su vez ha contribuido al cambio climático que se vive actualmente [1]. En Chile, una de las consecuencias de este fenómeno es la escasez hídrica. El país está pasando por una sequía que se ha prolongado por ya 16 años, siendo así la más impactante y prolongada de la que se tenga registro en territorio nacional [2].

Uno de los sectores más afectados por la sequía es la industria agrícola, que depende en gran medida de la lluvia y las condiciones climáticas para el correcto desarrollo de los cultivos [3]. Esta industria, junto con los sectores de silvicultura y ganadería, es responsable de aproximadamente un 3% del PIB del país [4], siendo así un área económica de gran importancia, de manera que resulta relevante buscar soluciones para facilitar su desarrollo. En este sentido, uno de los enfoques importantes es cómo mejorar la eficiencia en el uso de agua de riego.

Desde el comienzo de los años 2000, el sector agrícola chileno ha vivido una marcada tendencia a la tecnificación de las líneas de riego, principalmente pasando de sistemas de riego por surco y tendido, a sistemas de riego por goteo. Esta tendencia es motivada tanto por las nuevas necesidades hídricas impuestas por la sequía como por la búsqueda de una mejora en la efectividad del rendimiento y rentabilidad de los sistemas de riego [5].

Es en este contexto que el objetivo de esta memoria es el de optimizar el uso de los recursos hídricos en agricultura, planteando el uso de nuevas técnicas para mejorar los sistemas de riego, centrándose en el estudio del caso de una vinífera situada en la región de O'Higgins<sup>1</sup> que, en el marco del proyecto financiador de este trabajo, ha permitido la recopilación de datos del contenido de agua del suelo de sus viñedos.

Estos datos ya han sido utilizados en estudios previos para el desarrollo de sistema de

---

<sup>1</sup> Por motivos de confidencialidad, no se revela más información sobre la viña

control convencionales y basados en aprendizaje reforzado (RL: *Reinforcement Learning*), además del ajuste de un simulador basado en el software Hydrus-1D [6] para reproducir las dinámicas del terreno de cultivo de manera eficiente y precisa [7]. Este simulador permite, luego, la generación de datos de temporadas de cultivo utilizables para la identificación de modelos, y la realización de pruebas de control.

Para abordar las necesidades impuestas por el cultivo de frutos se propone el uso de técnicas de modelación difusa y control predictivo, ajustándolas al caso particular de la uva vinífera, posibilitando así la evaluación oportuna de las necesidades de riego de la plantación. Por un lado, la modelación difusa permite caracterizar sistemas no lineales de forma fácilmente comprensible, al utilizar condiciones en lenguaje natural y parámetros numéricos interpretables para describir las dinámicas del sistema [8]. Además, presenta una necesidad menos extensiva de datos medidos para identificación, en comparación a otros métodos, al poder usar también conocimiento experto [9]. Por otro lado, los controladores predictivos tienen la capacidad de optimizar dinámicas de diversa índole, pudiendo, por ejemplo, minimizar costos económicos como el uso de un recurso. Asimismo, estos esquemas presentan la ventaja de poder utilizar modelos no lineales y emplear directamente las restricciones que pueda poseer el sistema [10], haciendo así más fácil una aproximación a las necesidades de los agricultores locales.

La modelación del sistema de riego se realiza según dos conjuntos de datos. En una primera instancia, se utilizan datos del contenido y flujos de agua de una plantación de uva de vino de la sexta región, recolectados diariamente durante casi 3 años y medio. Luego, se emplea un conjunto mayor de datos, generados utilizando el simulador mencionado anteriormente. De modo que se cuenta con un conjunto de datos correspondiente a datos históricos reales y otro conjunto generado a partir de simulaciones de temporadas de cultivo.

La elaboración de modelos según estas dos aproximaciones tiene relación con verificar, por una parte, el efecto de la cantidad de datos utilizados para la identificación, y, por otra parte, el impacto de la forma de los datos y la representatividad de las dinámicas del sistema, en la calidad de las predicciones de los modelos.

El proceso de identificación comienza con el desarrollo de modelos lineales en variables de estado para establecer un rendimiento base y comparar fácilmente los resultados de la modelación difusa. Esta última se realiza utilizando métodos descritos en la literatura [9], [11], [12].

Una vez las dinámicas del contenido de agua en el suelo son modeladas, se implementan controladores predictivos basados en los modelos diseñados. Estos controladores se plantean para dos casos de control según un umbral mínimo de humedad a mantener, el segundo de los cuales agrega restricciones que limitan la frecuencia del riego, acercando el esquema a las condiciones materiales de los agricultores locales. Los controladores son refinados rea-

lizando pruebas en simulación y su rendimiento se compara con el de estrategias de riego convencionales.

## 1.1. Objetivos

### Objetivo general

Diseñar un sistema de control predictivo difuso que permita mejorar la eficiencia del uso del agua de riego en una vinífera, maximizando a su vez la calidad de la producción.

### Objetivos específicos

- Generar modelos difusos del suelo utilizando los datos de humedad de la viña.
- Diseñar un controlador predictivo basado en los modelos difusos generados.
- Agregar restricciones al controlador para mejorar su especificidad y acercarlo a casos de uso real, donde puede haber problemas de accesibilidad para bombas de riego, necesidad de extraer agua de pozo, etc.
- Comparar el rendimiento del controlador propuesto con el de otros modelos tradicionales y la estrategia planteada en trabajos anteriores.



# Capítulo 2

## Marco teórico

### 2.1. Antecedentes agrícolas

#### 2.1.1. Características hídricas

El contenido de agua o humedad del suelo se designa por  $\theta$  y se puede describir de manera porcentual según (2.1), donde  $V_w$  [m<sup>3</sup>] corresponde al volumen de agua por unidad de volumen del terreno  $V_b$  [m<sup>3</sup>] [13]. Luego el contenido de agua es una magnitud adimensional representable en porcentaje. La determinación del contenido de agua en el terreno permite evaluar la cantidad de agua absorbida por el cultivo y la eficiencia del uso del agua.

$$\theta = \frac{V_w}{V_b} \times 100 \quad (2.1)$$

El agua presente en el suelo puede ser representada esquemáticamente como llenando un estanque (ver Figura 2.1), donde existen distintos puntos demarcados designando distintos efectos en los cultivos [14], [15]:

- Punto de saturación (PS): corresponde al punto en que todos los poros del terreno están ocupados por agua. En este nivel el agua se drena por efectos de la gravedad.
- Capacidad de campo (CC): es la máxima cantidad de agua retenida en el suelo cuando los efectos de drenaje por gravedad resultan despreciables.
- Punto de marchitez permanente (PMP): corresponde al nivel de agua en que la planta ya no es capaz de absorberla, de modo que marchita de manera permanente.
- Agua disponible total (ADT): es la diferencia entre la capacidad de campo y el punto

de marchitez permanente, es decir, el rango en el que el cultivo es capaz de extraer agua del terreno con cierta efectividad.

- Agua fácilmente aprovechable (AFA): es el rango en el cual el cultivo puede extraer agua del suelo de manera ideal. Corresponde a la diferencia entre la capacidad de campo y el umbral de estrés hídrico.
- Umbral de estrés hídrico (EH): es el nivel de agua bajo el cual se asume que el rendimiento del cultivo comienza a disminuir debido a una disminución en la capacidad de absorción de agua de las raíces. Tradicionalmente, se estima en un 50 % del agua disponible total (ADT).




Figura 2.1: Balance hídrico en el suelo mediante representación del estanque [14]

En esta formulación, se suele trabajar con el concepto de Déficit hídrico (o agotamiento), el cual corresponde a la cantidad de agua faltante para llegar a la capacidad de campo.

### 2.1.2. Dinámica del balance hídrico

La cantidad de agua en el terreno es típicamente modelada utilizando la ecuación de balance hídrico (2.2). Esta corresponde a un modelo dinámico tradicional de las dinámicas del balance, y expone las componentes que rigen el cambio en el nivel de humedad del suelo, utilizando el concepto de déficit hídrico (D) en el instante actual  $i$  y en el instante de medición anterior  $i - 1$  [14].

$$D_i = D_{i-1} - (P_i - RO_i) - I_i - CR_i + ET_i + DP_i \quad (2.2)$$

La ecuación (2.2) comprende tres entradas de agua:  $P_i$  las precipitaciones,  $I_i$  la irrigación y  $CR_i$  el ascenso capilar (*Capillary Rise*). Además, las salidas de agua del sistema corresponden a:  $RO_i$  el escurrimiento (*RunOff*),  $ET_i$  la evapotranspiración y  $DP_i$  la percolación profunda (*Deep Percolation*). Todos los componentes son medidos en milímetros de altura, considerando un sistema unidimensional, y son gráficamente representados en la Figura 2.1.

Cada uno de los conceptos utilizados en la ecuación de balance hídrico es detallado a continuación:

### **Precipitaciones (P) e irrigación (I)**

Las precipitaciones e irrigación corresponden a las dos principales fuentes de ingreso de agua al sistema, y su medición se puede realizar utilizando instrumentos como pluviómetros [16].

### **Ascenso capilar (CR)**

El ascenso capilar corresponde a aguas que suben desde la capa freática al terreno de cultivo por efecto de capilaridad. La importancia de este ingreso depende del tipo de suelo, su humedad actual y la profundidad de las napas subterráneas. Suele considerarse despreciable cuando la profundidad del nivel freático es mayor a 1 metro [14].

### **Escurrecimiento (RO)**

Dependiendo del tipo de suelo y su inclinación, las precipitaciones pueden producir escurrimiento superficial al no lograr penetrar el suelo rápidamente. Sin embargo, en eventos de precipitaciones intensas se puede considerar que estas llevarán al terreno a capacidad de campo, de modo que el escurrimiento puede ser ignorado, y, en situaciones con lluvias ligeras, se puede estimar que el fenómeno de escurrimiento no ocurre. Luego, este componente suele asumirse igual a cero o a un porcentaje bajo de las precipitaciones [14].

### **Evapotranspiración (ET)**

La evapotranspiración corresponde a las pérdidas de humedad debido a los fenómenos de evaporación del suelo y transpiración de los cultivos.

La evaporación es afectada principalmente por la radiación, la temperatura del aire, la

humedad atmosférica y la velocidad del viento. Donde la radiación y temperatura del aire fomentan la evaporación, mientras que los otros dos factores afectan la facilidad con que el agua del terreno puede retirarse al ambiente.

La transpiración consiste en la vaporización de agua al interior del cultivo y su escape a la atmósfera. Este fenómeno tiene lugar principalmente en las hojas de la planta y ocurre naturalmente por los procesos de desarrollo de esta, pero también se ve afectada por los mismos factores ambientales que la evaporación.

Ambos procesos suceden en paralelo, y, dada su naturaleza y los múltiples factores que la afectan, resulta difícil aislar sus efectos, de modo que se suele considerar a los dos en conjunto, evaluando así tan solo la evapotranspiración [14]. Además, la proporción entre pérdidas por evaporación y transpiración varía según la etapa de crecimiento del cultivo, donde en etapas iniciales la planta es pequeña y el terreno está descubierto, de modo que la evaporación prepondera, mientras que en fases avanzadas del cultivo este cubre gran parte del terreno en sombra, reduciendo la evaporación y aumentando la transpiración. Esto es ilustrado en la Figura 2.2.




Figura 2.2: Evolución de la evaporación y transpiración según el desarrollo del cultivo. IAF corresponde a la razón entre el área de las hojas de la planta y el área de cultivo [14]

El cálculo de la ET ha sido estudiado extensivamente y se tienen técnicas para su medición diaria. Una de estas es expuesta en [14], y se explica brevemente a continuación.

La ET puede ser calculada en tres partes: ET del cultivo de referencia ( $ET_o$ ), ET del cultivo bajo condiciones estándar ( $ET_c$ ) y la ET del cultivo bajo condiciones no estándares ( $ET_{caj}$ ). Donde cada una de estas depende de variables ambientales o del cultivo. El cálculo comienza con la  $ET_o$ , que representa la tasa de evapotranspiración de una superficie de referencia: un

cultivo de pasto con características particulares y sin restricciones de agua. La disponibilidad de agua permite asumir que las propiedades del suelo no tienen efecto en la ET. Este factor se plantea como una referencia para guiar el cálculo de la ET de otras superficies.

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T+273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (2.3)$$

La  $ET_o$  diaria puede ser calculada utilizando (2.3), donde se utilizan los siguientes parámetros climáticos:  $R_n$  radiación neta en la superficie del cultivo [ $\text{MJ m}^{-2} \text{ día}^{-1}$ ],  $G$  flujo del calor del suelo [ $\text{MJ m}^{-2} \text{ día}^{-1}$ ],  $T$  temperatura media del aire a 2 metros de altura [ $^{\circ}\text{C}$ ],  $u_2$  velocidad media del viento a 2 metros de altura [ $\text{m s}^{-1}$ ],  $e_s$  presión de vapor de saturación [ $\text{kPa}$ ],  $e_a$  presión real de vapor [ $\text{kPa}$ ],  $\Delta$  pendiente de la curva de presión de vapor [ $\text{kPa } ^{\circ}\text{C}^{-1}$ ] y  $\gamma$  constante psicrométrica [ $\text{kPa } ^{\circ}\text{C}^{-1}$ ].

El siguiente paso para la obtención de la ET total es el cómputo de la  $ET_c$ , que corresponde a la ET de cualquier cultivo libre de enfermedades, bien fertilizado y desarrollado en parcelas amplias bajo condiciones óptimas de suelo y agua, alcanzando así la máxima producción posible según las condiciones climáticas. El cálculo de la  $ET_c$  se realiza utilizando la evapotranspiración del cultivo de referencia y el coeficiente del cultivo  $K_c$ , que depende de las características que diferencian al cultivo real del de referencia:

$$ET_c = K_c ET_o \quad (2.4)$$

Por último, se debe calcular el valor de la evapotranspiración del cultivo bajo condiciones no estándar ( $ET_{caj}$ ), que se refiere a la evapotranspiración en cultivos que se desarrollan en condiciones ambientales y de manejo distintas a las estándar. Una forma de calcular  $ET_{caj}$  es utilizando el coeficiente de estrés hídrico  $K_s$ , que refleja los efectos del estrés hídrico del cultivo en la ET.

La estimación del coeficiente  $K_s$  se realiza utilizando el modelo del estanque mostrado en la Figura 2.1, contando así con valores que dependen del nivel de agua en la zona radicular del cultivo. Cuando el déficit hídrico (diferencia entre el nivel actual de agua y la capacidad de campo (CC)) es menor al agua fácilmente aprovechable (AFA), entonces no se imponen limitaciones a la evapotranspiración y el valor de  $K_s$  es igual a 1. En cambio, cuando el déficit hídrico (D) es superior a AFA, es decir, cuando se tiene un nivel de agua por debajo del umbral de estrés hídrico (EH), este es suficientemente alto como para afectar a la evapotranspiración, luego  $K_s$  toma valores inferiores entre 1 y 0.

Así, el valor de  $K_s$  puede ser calculado según:

$$K_s = \begin{cases} 1 & \text{si } D \leq AFA \\ \frac{ADT-D}{ADT-AFA} & \text{si } D > AFA \end{cases} \quad (2.5)$$

De esta forma, se puede obtener  $ET_{caj}$  mediante la siguiente fórmula:

$$ET_{caj} = K_s K_c ET_o \quad (2.6)$$

### Percolación profunda (DP)

Este modelo asume que, cuando la humedad de la zona radicular podría exceder la capacidad de campo, sea tras precipitaciones intensas o riego, este exceso de agua es drenado por efecto de la gravedad, puesto que el terreno no sería capaz de retener más agua. De esta manera, se impone que el contenido de agua no aumenta más allá de la capacidad de campo y cualquier exceso de agua es drenado en forma de percolación profunda.

Luego, el cálculo de DP se realiza utilizando la ecuación de balance hídrico (2.2) tras el humedecimiento del terreno, de modo que se tiene que  $D_i$  es nulo. Así, DP se calcula como:

$$DP_i = (P_i - RO_i) + I_i - CR_i - ET_i - D_{i-1} \quad (2.7)$$

Una vez el nivel de humedad del suelo baje más allá de la capacidad de campo, el terreno es capaz de retener el agua y ya no existe drenaje, de modo que  $DP_i = 0$ .

#### 2.1.3. Cultivo de uva de vino

Dado que el estudio de este trabajo utiliza datos de una viña, es importante detallar ciertos aspectos específicos del cultivo de la uva de vino.

El desarrollo de la vid puede ser separado en cuatro etapas que designan características relevantes del cultivo, sus necesidades hídricas y los efectos de distintas estrategias en su cuidado [17], estas muestran en la Figura 2.3 y se describen a continuación:

- Etapa I: se caracteriza por la alta ocurrencia de división celular. En esta etapa el estrés hídrico afecta de forma importante el crecimiento de la planta y sus frutos.
- Etapa II: esta etapa ve un alto desarrollo de semillas y un bajo desarrollo del pericarpio (piel y pulpa) del fruto. En esta etapa se tiene una menor sensibilidad al estrés hídrico.

- Etapa III: durante esta etapa comienza el envero (proceso de cambio de color de la uva) y aumenta la acumulación de agua en el fruto, aumentando su tamaño. En esta etapa la sensibilidad al estrés hídrico es alta, dado el ingreso de agua a la uva, y también se tiene alta sensibilidad al exceso de agua, que puede reducir la concentración de ácidos y fenoles en el fruto, cambiando el color y sabor de este.
- Etapa IV: en esta etapa termina el proceso de envero, se acumulan azúcares y disminuye la cantidad de ácidos en el fruto. Esta etapa culmina el desarrollo del fruto, definiendo las características de este.

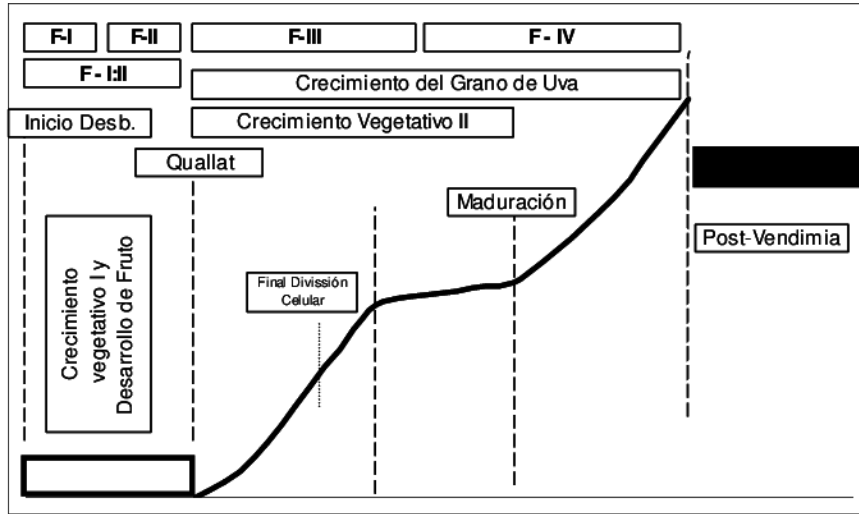


Figura 2.3: Etapas del desarrollo de la uva de vino durante una temporada de cultivo [17]

Además de los efectos mencionados del estrés hídrico en el fruto, existen otros efectos que son aprovechados por la técnica del Riego Deficitario Controlado (RDC), como lo son un aumento en la producción de fenoles y un mejoramiento en la relación piel/pulpa de la uva.

En el caso chileno, la temporada de cultivo de uva vinífera puede comenzar entre agosto y septiembre, terminando entre febrero y abril, dependiendo de la cepa y el lugar de cultivo [18].

## 2.2. Modelación difusa

Los modelos difusos utilizan los conceptos de conjuntos y lógica difusos para representar sistemas en base a reglas, regresiones difusas lineales o estructuras de celdas difusas, la primera de las cuales es utilizada en este trabajo. Los modelos basados en reglas utilizan relaciones entre las variables de entrada y salida del tipo *Si-Entonces* de la forma: “*Si* propo-

sición antecedente *Entonces* proposición consecuente”. De esta forma, cada regla representa el comportamiento local del sistema según condiciones particulares.

Se presentan tres categorías para los modelos basados en reglas, de acuerdo con la estructura de la proposición consecuente: modelos difusos lingüísticos, cuyas proposiciones antecedente y consecuente son difusas. Modelos difusos relacionales, que generalizan los modelos lingüísticos al permitir a una proposición antecedente relacionarse con múltiples proposiciones consecuentes. Y, finalmente, los modelos difusos Takagi-Sugeno, donde los consecuentes son funciones ‘nítidas’ (*crisp* en inglés, contrastando con *fuzzy* o difuso) de las entradas [12]. Esta última clase es empleada durante los trabajos presentes.

### 2.2.1. Modelos Takagi-Sugeno (TS)

Los modelos difusos de Takagi-Sugeno permiten la aproximación de sistemas no lineales complejos por medio de reglas que describen modelos locales. Las reglas de esta clase de modelos presentan consecuentes que son funciones lineales dependientes de las entradas del sistema. Múltiples condiciones pueden ser establecidas en los antecedentes mediante el uso de conectores lógicos, formando reglas de la forma:

$$R_i : \mathbf{Si} \ z_1 \text{ es MF}_1^i \ \mathbf{y} \ z_2 \text{ es MF}_2^i \ \mathbf{y} \ \dots \ \mathbf{y} \ z_n \text{ es MF}_n^i \ \mathbf{entonces} \ y_i = f(z). \quad (2.8)$$

Donde  $R_i$  representa la  $i$ -ésima regla,  $z = [z_1, z_2, \dots, z_n]$  es el vector de variables de entrada,  $\text{MF}_j^i$  representa la  $j$ -ésima función de pertenencia de la regla  $i$ , e  $y_i$  corresponde a la  $i$ -ésima salida local, descrita por una función de los antecedentes,  $f(z)$ . En particular, los antecedentes  $z$  suelen ser usados como un conjunto de  $n_y$  regresores de las salidas y  $n_u$  regresores de las entradas del sistema, de manera que  $z = [y(k), y(k-1), \dots, y(k-n_y), u(k), u(k-1), \dots, u(k-n_u)]$ . Así, las salidas locales, generalmente parametrizadas según (2.9), representan un forma lineal afín que depende de los estados anteriores del sistema.

$$y_i(z) = \phi_0^i + \phi_1^i z_1 + \phi_2^i z_2 + \dots + \phi_n^i z_n \quad (2.9)$$

Con  $\phi_j^i$ , para  $j = 0, \dots, n$ , los parámetros de la función de consecuencia del  $i$ -ésimo modelo local, representando así una combinación lineal de las variables antecedentes, con un desplazamiento afín dado por  $\phi_0^i$ .

Las funciones de pertenencia corresponden a conjuntos difusos de los antecedentes, que detallan las características del estado del sistema. Estas funciones pueden ser descritas según el grado de pertenencia  $\mu_i(z_j)$ , que asigna un valor numérico entre 0 y 1 a la pertenencia de la premisa  $j$  al conjunto difuso  $\text{MF}_j^i$ , de tal manera que 0 indica que la premisa no pertenece



en ningún grado al conjunto, y 1 que la premisa pertenece plenamente al conjunto.

A partir de una operación entre los grados de pertenencia correspondientes a una misma regla se calcula el grado de activación  $\omega_i$  de esta. Comúnmente la operación utilizada es el mínimo o el producto:

$$\omega_i(z) = \text{oper}(\mu_i(z_1), \mu_i(z_2), \dots, \mu_i(z_n)) \quad (2.10)$$

Luego, para obtener la salida global del sistema  $y(z)$ , se realiza una combinación lineal de las  $Nr$  salidas locales:

$$y(z) = \sum_{i=1}^{Nr} \hat{\omega}_i(z) y_i(z) \quad (2.11)$$

Donde los factores que multiplican a las salidas locales corresponden a sus grados de activación normalizados, calculados según:

$$\hat{\omega}_i = \frac{\omega_i}{\sum_{j=1}^{Nr} \omega_j} \quad (2.12)$$

## 2.2.2. Identificación difusa

Los métodos de identificación difusa pueden hacer uso de datos heterogéneos, combinando conocimiento experto y datos medidos del sistema [9]. Luego, los métodos de identificación dependen del origen de la información del sistema. El primero de estos utiliza conocimientos previos sobre el sistema para modelarlo usando funciones de pertenencia y reglas diseñadas directamente por un experto. Este proceso puede ser asistido usando datos de entrada/salida del sistema, tomando así una aproximación híbrida, lo cual permite facilitar la expresión de sistemas que resulta complejo describir en términos de expresiones matemáticas [12]. Finalmente, la modelación basada en datos hace uso de datos recopilados del sistema para diseñar los componentes del modelo difuso a través de algoritmos de optimización y clustering.

### Identificación basada en datos

Un esquema simple para la identificación basada en datos se presenta en la Figura 2.4, donde el proceso se describe en cuatro etapas, comenzando con la recopilación de datos del sistema, pasando por fases de perfeccionamiento del modelo, y terminando con un análisis de rendimiento que, en caso de ser satisfactorio, permite validar el modelo. Si, por el contrario, el modelo no satisface el rendimiento deseado, se puede volver a cualquiera de las etapas

anteriores según se estime conveniente para mejorarlo.




Figura 2.4: Diagrama de flujo identificación difusa

El diseño del experimento de identificación debe tener en cuenta los rangos de operación del sistema y su funcionamiento normal, de tal manera que la recopilación de datos refleje la mayor cantidad posible de las dinámicas del sistema. Existen diversos tipos de señales de excitación diseñados para la obtención de datos útiles en identificación, tales como ruido blanco gaussiano filtrado y señales binarias [19].

Tras la obtención de datos del sistema, es necesario separarlos en conjuntos de entrenamiento, validación y test. Cuando se posee gran cantidad de datos, se puede recomendar usar un 50 % de ellos en el set de entrenamiento, y el resto dividido en partes iguales de un 25 % para los conjuntos de validación y test [20]. No obstante, esta distribución puede ser cambiada para incluir una mayor cantidad de datos en el conjunto de entrenamiento, a fin de asegurar un mejor ajuste a las características del sistema, llegando a distribuciones del tipo 80 %, 10 % y 10 %, para entrenamiento, validación y test, respectivamente, aunque la representatividad de estos conjuntos dependerá de la complejidad de los datos y otros factores del método de identificación [21]. La separación de los datos permite realizar optimizaciones al diseño del modelo mediante experimentos de validación, sin necesidad de extraer más datos del sistema.

Luego, para realizar la identificación inicial a partir de los datos separados, se debe plantear un número de clusters y reglas base para generar un modelo inicial, que luego es ajustado según corresponda. Para la generación de dicho modelo inicial se pueden ejecutar algoritmos de clustering difuso como Gustafson-Kessel (GK) o Fuzzy c-Means (FCM), que permiten separar los datos en la cantidad de clusters deseados según su distribución. La forma de los clusters depende del método utilizado, con conjuntos difusos hiperesféricos (esferas n-dimensionales) al usar FCM, o con una forma más generalizada según la topología de los datos al usar GK [12].

La definición de los clusters permite la descripción de los datos en relación a la pertenencia de estos a cada cluster. Utilizando funciones de pertenencia gaussianas, basta con conocer el centro  $v$  de cada cluster y su desviación estándar  $\sigma$  para obtener los grados de pertenencia de los datos a los conjuntos difusos, usando la fórmula:

$$\mu_i(z) = \exp\left(-\frac{(z - v_i)^2}{2\sigma_i^2}\right) \quad (2.13)$$

A partir de estos grados de pertenencia se pueden calcular los grados de activación normalizados de cada regla según el procedimiento descrito en la sección anterior.

Finalmente, se obtienen modelos locales para cada cluster utilizando mínimos cuadrados, en un proceso denominado identificación de parámetros de las consecuencias, el cual estima parámetros  $\phi$  de manera que se minimice la suma de la diferencia cuadrática entre los  $N$  valores del modelo global estimado  $\hat{y}$  y los datos reales de las salidas  $y$ , según (2.14).

$$\begin{aligned} \min_{\phi} \quad & \sum_{j=1}^N (y_j - \hat{y}_j)^2 \\ \text{s.a.} \quad & \hat{y} = Z_{fuzzy}\phi \end{aligned} \quad (2.14)$$

Este planteamiento estima los parámetros de la salida global directamente, de modo que resulta necesario emplear una matriz que contenga los antecedentes escalados según el grado de activación correspondiente de cada regla [9]. A esta matriz se le denomina  $Z_{fuzzy}$  y su estructura está dada por:

$$Z_{fuzzy} = \begin{bmatrix} \hat{\omega}_1 z_1(1) & \cdots & \hat{\omega}_{Nr} z_1(1) & \cdots & \hat{\omega}_1 z_n(1) & \cdots & \hat{\omega}_{Nr} z_n(1) \\ \vdots & \ddots & \vdots & & \vdots & \ddots & \vdots \\ \hat{\omega}_1 z_1(N) & \cdots & \hat{\omega}_{Nr} z_1(N) & \cdots & \hat{\omega}_1 z_n(N) & \cdots & \hat{\omega}_{Nr} z_n(N) \end{bmatrix} \quad (2.15)$$

Así, se termina por obtener el modelo inicial del sistema, el cual utiliza reglas de la forma (2.8), y que puede ser optimizado siguiendo las siguientes etapas del diagrama de flujo de la Figura 2.4.

Para poder optimizar el rendimiento del modelo es necesario definir una métrica que indique de manera cuantitativa la idoneidad de la representación de las dinámicas del sistema. La raíz del error cuadrático medio (RMSE) es una métrica común para este tipo de análisis, su fórmula es (2.16), y representa la desviación promedio entre los  $N$  valores reales del sistema ( $y_j$ ) y los entregados por el modelo ( $\hat{y}_j$ ). Esta comparación entre el modelo y los datos reales debe realizarse utilizando el conjunto de datos de validación, y la obtención de valores de RMSE cercanos a 0 es deseable, pues esto muestra que el modelo logra aproximar con gran certeza el fenómeno real. Al usar esta métrica, debe tenerse en cuenta su dependencia de la escala de los datos, en virtud de lo cual sus valores deben ser analizados en contexto. Otras métricas de error típicas son el MSE, MAE y MAPE.

$$RMSE = \sqrt{\frac{\sum_{j=1}^N (\hat{y}_j - y_j)^2}{N}} \quad (2.16)$$

Con la métrica de evaluación establecida, se realizan modificaciones al modelo inicial. Una de estas corresponde a la selección de variables relevantes, que se refiere al proceso en que se reduce (o no) el número de variables que el modelo usa como entradas. Comúnmente, el modelo inicial usa más variables de las necesarias para obtener un rendimiento aceptable, al haber escogido un número elevado de regresores de los antecedentes, luego, algunas de estas pueden ser retiradas para observar el cambio en el rendimiento del modelo. Este proceso se realiza porque la reducción de la cantidad de variables a ajustar reduce la complejidad del modelo, y puede llevar a resultados mejores, o similares, con una estructura más sencilla.

Para identificar qué variables pueden ser retiradas sin mayores consecuencias, se puede calcular la sensibilidad del modelo a cada variable de entrada computando las derivadas parciales de la salida respecto a las entradas. Así, las variables correspondientes a una menor sensibilidad podrían ser retiradas de estimarse necesario.

La siguiente etapa corresponde a la optimización de estructura, es decir, el ajuste del número de clusters difusos. Para esto, se vuelve a identificar en diversas ocasiones haciendo variar el total de clusters a usar cada vez. En cada iteración se calcula el error en validación del modelo (ver (2.16)) y se escoge aquel con menor error.

Tras este proceso, se cuestiona el rendimiento del modelo obtenido, preguntándose si este es adecuado. Si la respuesta es no, se puede volver a las etapas anteriores para realizar mejoras al diseño del modelo, o al experimento de identificación, para obtener datos de mayor utilidad. El procedimiento es repetido según se estime conveniente, hasta obtener un modelo idóneo para la aplicación deseada.

## 2.3. Control predictivo

El término control predictivo (MPC: *Model Predictive Control*) designa a múltiples estrategias de control basadas en el uso explícito de un modelo de un proceso, para optimizar su desempeño según una función objetivo, sujeto a restricciones en un horizonte de predicción. Este horizonte designa el número de pasos a futuro a considerar en la formulación en cada instante de optimización. Así, en cada uno de estos instantes, se consideran las dinámicas del sistema en una ventana de tiempo a futuro del mismo tamaño; de este modo es que se habla del uso de un *horizonte deslizante* [22].

Al utilizar modelos de forma directa en la formulación del control, es necesario que este sea capaz de capturar la dinámica del proceso, para así poder predecir las salidas futuras con

suficiente certeza. Asimismo, es recomendable que sea sencillo de usar y comprender.

Este tipo de control ofrece algunas ventajas sobre otros métodos, entre ellas la posibilidad de uso para sistemas de diversa complejidad (sistemas con retraso, sin mínimo de fase, multivariable, etc.) y su inclusión de restricciones del sistema de manera directa a través del problema de optimización [10]. El uso de restricciones aporta un mayor acercamiento a condiciones reales de uso del sistema, sin comprometer su seguridad, pudiendo modelar saturaciones y características intrínsecas de los actuadores [23].

Luego, la estrategia del MPC se basa en la predicción en cada instante de tiempo  $k$ , para un determinado horizonte de predicción  $N$ , de los valores de la salida  $y(k+j|k)$  (léase  $y$  en  $k+j$  dado  $k$ ) para  $j = 0, \dots, N$ , según una secuencia de acciones de control  $u(k+j|k)$  para  $j = 0, \dots, N-1$ . De esta manera, se calcula un set de salidas y acciones de control en cada instante de tiempo  $k$ , lo cual se logra a través del planteamiento de un problema de optimización que busca las soluciones óptimas según la función de costos y restricciones definidas. Un ejemplo típico lleva la trayectoria del sistema a un punto de referencia, regulando el nivel de la acción de control en el horizonte de predicción. Luego, se tiene una trayectoria de acciones de control para los  $N-1$  pasos futuros, de donde solo la primera componente es utilizada en la planta real, y, en el siguiente instante de tiempo, el proceso se repite con el nuevo estado del sistema [10].

El planteamiento de un controlador predictivo utiliza en conjunto un optimizador, una función de costo y restricciones y un modelo del sistema para encontrar la acción de control óptima en cada instante de tiempo según el estado actual del sistema. Esto es expresado en forma de un diagrama de bloques en la Figura 2.5, donde además del bloque MPC y la planta se muestra el uso de un observador de estados, que permite recuperar los estados del sistema a partir de las acciones de control y las salidas del sistema, en el caso de que los estados no sean medibles directamente.

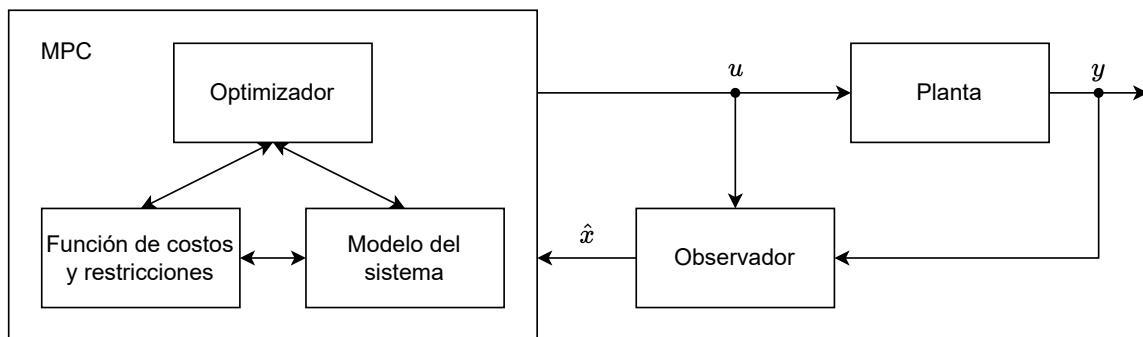


Figura 2.5: Diagrama de bloques básico de un controlador predictivo

Existen formulaciones del problema de optimización para lograr distintos objetivos de seguimiento de referencia y rechazo de perturbaciones, sin embargo, en (2.17) se expone

la formulación de un problema de optimización con una función objetivo genérica. En este planteamiento, se tienen restricciones asociadas al modelo predictivo  $f(y_k, u_k)$ , y a límites sobre la acción de control y los estados, según los conjuntos  $\mathcal{U}$  e  $\mathcal{Y}$ , respectivamente. Vale destacar, nuevamente, que el problema de optimización puede ser ajustado para diversas situaciones, como seguimiento de referencia y rechazo de perturbaciones, entre otras, mediante el ajuste de las restricciones y la función objetivo.

$$\begin{aligned}
\min_{\bar{y}, \bar{u}} \quad & \sum_{j=0}^{N-1} \ell(y_{k+j}, u_{k+j}) \\
\text{s.a.} \quad & y_{k+j} = f(y_k, u_k), \quad j = 0, \dots, N-1 \\
& u_{k+j} \in \mathcal{U}, \quad j = 0, \dots, N-1 \\
& y_{k+j} \in \mathcal{Y}, \quad j = 0, \dots, N-1
\end{aligned} \tag{2.17}$$

El problema de optimización (2.17) debe ser adaptado según las necesidades del sistema, ajustando principalmente los parámetros  $Q$  y  $R$  de la función de costos, además del horizonte de predicción. Este último tiene estrecha relación con el tiempo de establecimiento del sistema, de modo que comúnmente se intenta utilizar un horizonte de predicción que, a lo menos, cubra el tiempo de establecimiento del sistema. Por otra parte, la formulación puede ser modificada agregando, por ejemplo, costos sobre la variación de la acción de control, métodos de penalización exacta para dar holgura a restricciones, garantías de estabilidad mediante el uso de costos y restricciones terminales, o un seguimiento de referencia realizando un cambio de variable para  $y$ .

Un caso particularmente útil en este trabajo es el uso de la función objetivo según un costo económico, penalizando tan solo el uso de algún recurso del sistema, como la acción de control. Al usar esta formulación junto con restricciones adecuadas se puede plantear un problema en que el sistema se mantiene dentro de un rango de operación deseado, optimizando variables para utilizar la menor cantidad de recursos posible.

### 2.3.1. Control predictivo basado en modelos difusos

En el control predictivo basado en modelos difusos, el modelo predictivo base del MPC corresponde a un modelo difuso, lo que permite obtener los beneficios de ambas partes: modelos de fácil comprensión y fácil ajuste, y un controlador que permite resultados óptimos según el modelo de predicción utilizado y la simple introducción de restricciones en el control [23]. Este es un ejemplo de un controlador predictivo no lineal (NMPC), puesto que el modelo de predicción usado para el control, al ser un modelo difuso, es un modelo de carácter no lineal.

Al usar modelos de predicción no lineales, el proceso de optimización se complejiza, au-

mentando así el costo computacional del procedimiento. No obstante, existen técnicas para ayudar a simplificar el problema, una de estas involucra el uso de un horizonte de control  $N_c$  diferenciado y más corto que el horizonte de predicción  $N_p$ . De esta manera, para un esquema de regulación con pesos  $Q$  y  $R$  para los estados y la acción de control, respectivamente, se puede tener una función de costos como la expuesta en (2.18). Este método calcula la trayectoria óptima de las acciones de control hasta la  $N_c$  realización, tras lo cual puede continuar calculando la trayectoria de los estados del sistema, pero con un valor fijo para la acción de control. Otras técnicas más avanzadas hacen uso de la estructura de los modelos Takagi-Sugeno, considerando los modelos locales como linealizaciones del sistema no lineal y resolviendo un problema de programación cuadrática (QP: *Quadratic Programming*) [23], o bien de programación semidefinida [24].

$$J = \sum_{j=0}^{N_p} y_{k+j}^T Q y_{k+j} + \sum_{j=0}^{N_c} u_{k+j}^T R u_{k+j} \quad (2.18)$$

De la misma manera que con el MPC estándar, es posible utilizar funciones de costos y restricciones que permitan abordar distintas estrategias de control y condiciones del sistema a controlar.

# Capítulo 3

## Estado del arte

Esta sección está dedicada a discutir los avances y deficiencias actuales de los sistemas de riego comunes. Además de una exploración de técnicas de riego adyacentes a las planteadas en este trabajo, estudiando sus limitaciones y exponiendo las características de los controladores planteados como mejora.

### 3.1. Estrategias convencionales de riego

Se denomina estrategia convencional de riego a aquellas planificaciones que realizan una programación del riego para cumplir con los requerimientos hídricos del cultivo, utilizando información de los estados hídricos actuales del suelo y la planta.

Convencionalmente, se dice que el riego es requerido para contrarrestar el efecto de la evapotranspiración, teniendo en cuenta la cantidad de agua presente y almacenable en el terreno [17]. De esta manera, el objetivo del riego es agregar agua al suelo en el momento y en la cantidad precisa para suplir las necesidades hídricas del cultivo. La determinación de la cantidad y el momento en que regar el terreno viene dada por el cálculo del balance hídrico diario de la zona radicular (ver ecuación (2.2)). Además, para evitar pérdidas por percolación profunda, lo cual puede producir el lavado de nutrientes del suelo, el riego nunca debe superar el nivel del déficit hídrico ( $D$ ) [14].

En estas estrategias, se suele buscar mantener el nivel de humedad del suelo por sobre el umbral de estrés hídrico, el cual debe ser definido de acuerdo con las características del cultivo y el rendimiento deseado. Esta definición puede ser variable según el desarrollo de la planta y las condiciones climáticas. En el caso de la vid, técnicas como el Riego Deficitario Controlado (RDC) pueden ser aplicadas, manteniendo el cultivo bajo el umbral de estrés hídrico en ciertas etapas del desarrollo de la planta. Esto puede reducir el tamaño de los



frutos o su cantidad, pero también aumentar su calidad, cambiando la relación piel/pulpa y la concentración de azúcares, ácidos y fenoles, entre otros efectos deseables para la producción de vino [17].

Particularmente, en este trabajo se considera la técnica de riego convencional que, frente a una baja de la humedad del terreno más allá del umbral de estrés hídrico, inyecta un 35 % de la cantidad de agua necesaria para llevar el terreno a capacidad de campo, manteniendo así el cultivo en niveles aceptables de humedad y reduciendo la frecuencia del riego.

## 3.2. Control difuso

Existen soluciones para el control de riego utilizando controladores difusos, una de estas se presenta en [25], donde un modelo de tipo Mamdani es utilizado para predecir los requerimientos hídricos de un terreno de cultivo en Catar. El controlador utiliza reglas difusas para la temperatura, radiación solar, humedad del suelo y tiempo de irrigación, en un sistema de riego por goteo. El sistema usa sensores para medir cada uno de los parámetros anteriores y evaluar las acciones de riego. Los resultados preliminares del trabajo muestran un ahorro de consumo de agua de alrededor del 80 %, comparado con las técnicas tradicionalmente usadas en Catar.

Otro ejemplo de control difuso para riego de cultivos es expuesto en [26], donde se utiliza un sistema difuso con 18 reglas, formuladas a partir de tres variables antecedentes: hora del día, humedad del terreno y temperatura, y una variable de consecuencia: intensidad de irrigación. En este caso, los resultados del controlador planteado se comparan con un sistema de riego periódico convencional, el cual irriga el terreno según una programación fija, sin considerar el estado actual de variables como el contenido de agua del terreno o condiciones ambientales. Del análisis de los resultados, se destaca la necesidad de considerar variables ambientales en la formulación del controlador y que un factor importante para el buen funcionamiento del control de la irrigación es el uso de sensores de humedad en profundidades pertinentes. Por ejemplo, para el controlador difuso, al usar datos de la humedad a 23.5 cm de profundidad, el uso de agua se reduce en un 12 % respecto a la técnica convencional evaluada. No obstante, al usar datos de la humedad a 91 cm de profundidad, el uso de agua aumenta en un 20 % respecto a la estrategia convencional.

## 3.3. Control predictivo

Trabajos han planteado el uso de controladores predictivos para atacar el problema de uso de agua en cultivos, un ejemplo de esto es desarrollado en [27], donde se propone el uso de MPC para regular el riego de melones en un invernadero, usando riego por goteo. Este

trabajo utiliza un modelo discreto en variables de estado para calcular el estado hídrico del suelo y decidir sobre la irrigación.

El controlador usa costos cuadráticos para el contenido de agua del suelo y para la diferencia de la acción de control entre muestras. Las restricciones impuestas al optimizador corresponden a límites en la irrigación y la humedad del terreno, asegurando que no se ponga en peligro el crecimiento del cultivo, y que no se ocupe agua en exceso.

Los resultados de la implementación son comparados con los resultados en un invernadero de similares características, que usa un sistema de riego automático por estimación de evapotranspiración. Luego, se muestra que, al usar el controlador predictivo, el uso de agua se reduce, obteniendo 11 gramos de cosecha adicionales por litro de agua. Además, se tiene que los frutos recolectados tienen un mayor contenido de azúcar. Sin embargo, se encuentra también que la masa neta de la cosecha es menor al usar este método, en comparación con el método de estimación de evapotranspiración.

En [28] se explora otra solución de este tipo, donde se diseña un controlador predictivo robusto, que tiene en cuenta perturbaciones ambientales. Además, se prueba el rendimiento del controlador según distintos tipos de cultivos y se comprueba que el uso de agua al usar este tipo de sistema es inferior que al usar técnicas de riego periódico, sin afectar significativamente la biomasa de la cosecha.

Un desarrollo más complejo se plantea en [29], en donde se considera el caso de un terreno de cultivo al aire libre, en donde la disponibilidad de agua de riego depende del llenado de estanques a partir de agua de pozo. De esta manera el problema estudiado tiene en cuenta el uso de agua subterránea y su reposición, como también el uso de energía eléctrica para su extracción. Luego, el controlador planteado considera todos los fenómenos anteriores e incertezas climáticas según intervalos difusos, usando como base del modelo de las dinámicas del contenido de agua la ecuación del balance hídrico (ver (2.2)). Esta propuesta corresponde entonces a un controlador predictivo robusto para el manejo de agua y energía y logra maximizar la producción, a costa de mayores costos operacionales.

### **3.4. Discusión**

Las metodologías convencionales de riego se basan en la medición diaria de las condiciones climáticas y de humedad del suelo para estimar las necesidades hídricas del cultivo y programar el riego de este. Este tipo de formulación no considera las precipitaciones venideras en sus cálculos de las necesidades hídricas, por lo que ante un evento de lluvia se debe realizar una reprogramación del riego. Además, esta estrategia, al igual que algunos de los estudios mencionados en este capítulo, hace uso de la ecuación de balance hídrico (2.2) como modelo de las dinámicas del terreno de cultivo. Este corresponde a un modelo lineal que depende

de aproximaciones al usar mediciones de un punto del terreno y generalizar al resto, no considerando, por ejemplo, efectos introducidos en las dinámicas por los cambios del terreno a distintas profundidades.

En el caso del cultivo de la uva de vino, el uso de técnicas como el Riego Deficitario Controlado hace necesario un conocimiento preciso del estado hídrico del cultivo, de modo que el uso de procedimientos mejor optimizados resulta esencial para el perfeccionamiento del rendimiento del cultivo. En este sentido, el planteamiento de una identificación difusa a partir de muestras reales de contenidos y flujos de agua de un terreno de cultivo puede permitir una mejor adaptación a sus dinámicas no lineales.

En la literatura existen soluciones de riego que implementan controladores difusos, no obstante, resulta complejo establecer una comparación directa con el caso chileno. En [25], preliminarmente, se reportan mejoras del 80 % en ahorro de consumo de agua, sin embargo, esto es comparando el riego por goteo implementado con técnicas de control difuso, contra técnicas de riego por inundación o surcos. Estudios señalan que la implementación de riego por goteo puede generar ahorros de aproximadamente un 60 % en el uso de agua [30], de este modo, gran parte del ahorro visto en el estudio tiene que ver con el paso a riego por goteo.

La implementación de control difuso desarrollada en [26] resalta la relevancia de la consideración de variables ambientales en el control de la irrigación, al comparar resultados con una estrategia convencional que no los toma en cuenta. Además, destaca que las mediciones del contenido de agua del terreno deben realizarse en una profundidad pertinente para el cultivo estudiado, dado que mediciones muy superficiales o muy profundas pueden impactar negativamente el desempeño del controlador. Este último resultado debe ser tomado en cuenta, pero considerando que pueden haber diferencias entre distintas aplicaciones de control, condiciones del terreno, tipo de cultivo, etc.

Por otra parte, ha habido intentos de uso de MPC para controlar el riego de cultivos. En [27] se propone el uso de técnicas de este tipo, mostrando resultados positivos en cuanto al uso de agua, pero se plantea su uso en un ambiente controlado de invernadero. Asimismo, una limitante importante, mostrada en [28], es el tipo de cultivo, pues esto cambia los requisitos hídricos, y los beneficios de usar métodos de control predictivo pueden variar de manera importante. Además, en [29] se presenta un planteamiento de MPC robusto basado en la ecuación de balance hídrico (2.2) que permite maximizar la producción agrícola de distintos cultivos, a costa de un mayor uso de recursos. De esta manera, se tienen resultados que demuestran las capacidades del control predictivo en el ámbito agrícola, pero con objetivos de control distintos a los planteados en esta memoria.

El uso de controladores predictivos difusos permite encontrar acciones de control, en este caso la necesidad de riego, óptimas para el modelo entregado al controlador, según las restricciones utilizadas. Luego, este tipo de controlador puede permitir la obtención de un

rendimiento ajustado a las necesidades del cultivo, lo cual resulta de vital importancia en un contexto de escasez hídrica. No obstante, la obtención de resultados favorables al utilizar estas técnicas requiere un trabajo cuidadoso y un buen aprovechamiento de la información disponible en cuanto a datos históricos y necesidades particulares del cultivo de uva, es decir, la etapa de identificación del sistema es fundamental para el buen funcionamiento del controlador.

# Capítulo 4

## Metodología

Los trabajos realizados siguen una metodología de desarrollo iterativo e incremental. Esta metodología se basa en el desarrollo de tipo cascada, pero utilizando múltiples iteraciones, cada una de las cuales comporta las etapas de: identificación del alcance a desarrollar y requerimientos, análisis y diseño, realización de pruebas y, finalmente, evaluación de los resultados. Cada iteración intenta abordar una parte reducida del proyecto, la cual es desarrollada y probada según corresponda, para luego, en la siguiente iteración, generar modificaciones al diseño y agregar nuevas capacidades funcionales [31]. Esto último corresponde al carácter incremental del proceso.

Tras cada iteración del proceso, se evalúan los resultados obtenidos, permitiendo así estimar de mejor manera el progreso del proyecto durante su realización. El método de evaluación depende de la etapa que se esté llevando a cabo. Por ejemplo, una etapa de modelación difusa puede ser evaluada cuantitativamente según el error de predicción del modelo, respecto a un conjunto de datos de validación, y cualitativamente según la forma de los datos obtenidos y su comparación con el conjunto de validación.

La metodología es, luego, representada por el diagrama de bloques mostrado en la Figura 4.1, donde cada etapa significativa, sobre las que se itera según sea necesario, se encuentra enmarcada en líneas punteadas. Cada una de las etapas presenta un bloque con borde grueso, el cual indica su punto de inicio.

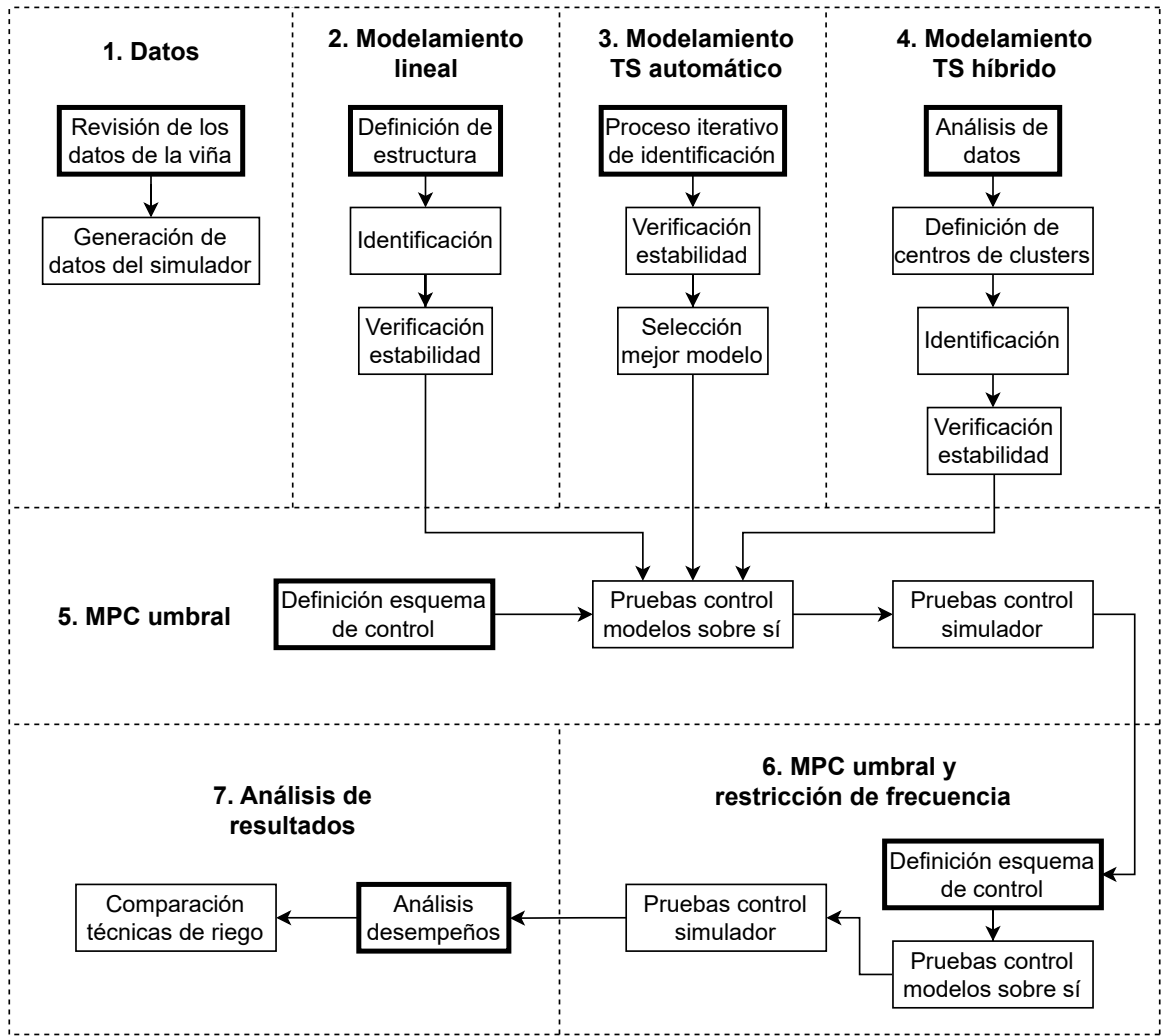


Figura 4.1: Diagrama de bloques de la metodología del proyecto

Los trabajos implican la escritura y desarrollo de código para implementar algoritmos y simulaciones, lo que se realiza utilizando el software MATLAB [32] y algunos de los toolbox ofrecidos por MathWorks [33], [34]. No obstante, las aplicaciones que hacen uso del simulador del terreno de cultivo se llevan a cabo usando la API de MATLAB Engine en Python 3, mediante una instancia de WSL [35], debido a que el simulador es una aplicación de Hydrus-1D [6] a través de la librería Phydrus [36] en Python, funcional en distribuciones de Linux.

A continuación se da una breve descripción de cada una de las etapas de desarrollo de este trabajo.

## 4.1. Datos

Se cuenta con dos fuentes independientes de datos de contenidos y flujos de agua. El primer conjunto de datos corresponde a muestras extraídas una vez por día durante 1227 días en un cultivo de uva de vino. El segundo conjunto debe ser extraído a partir de un simulador de las dinámicas del terreno de cultivo. Ambos grupos de datos son trabajados de forma separada y contienen las mismas siete variables: contenido de agua a 20 cm, 40 cm, 60 cm y 100 cm, irrigación, precipitaciones y evapotranspiración de referencia.

En una primera instancia se realiza una revisión de los datos obtenidos de la viña, verificando la cantidad de muestras disponibles y sus características, además de asegurarse de que tengan el formato adecuado, es decir, valores numéricos dentro de los rangos esperados para el sistema. Asimismo, dado que se posee conocimientos sobre el comportamiento del sistema, se puede comprobar que no existan errores en la sincronización de las entradas y salidas al haber recopilado los datos.

Además, se extraen datos del simulador, generando una cantidad de muestras mayor a las disponibles de la viña mediante la simulación de múltiples temporadas de cultivo con riegos manipulados de tal forma que las dinámicas del sistema se vean bien representadas en los datos, permitiendo, potencialmente, que los modelos identificados a partir de estos datos tengan un mejor rendimiento. Nótese que, según el simulador, una temporada de riego equivale a 155 días, comenzando en septiembre de un año y terminando en febrero del siguiente; de los cuales solo en los últimos 105 se controla el riego. Luego, solo los días de las temporadas en que hay riego controlado son reunidos para la identificación de modelos.

## 4.2. Modelamiento lineal

El modelamiento del sistema comienza con la identificación de modelos lineales, los cuales sirven para establecer un rendimiento de predicción base. El primer paso de este proceso es la definición de la estructura a utilizar, decidiendo sobre el carácter autorregresivo del modelo y su construcción afín.

Una forma genérica en variables de estado de los modelos lineales se muestra en (4.1), donde el estado  $\theta$  corresponde al contenido de agua del terreno en las distintas profundidades,  $u$  es el riego y  $d$  contiene un factor afín y las perturbaciones ambientales (precipitaciones y evapotranspiración). Las matrices  $A$ ,  $B$  y  $D$ , contienen los parámetros del modelo.

$$\theta_{k+1} = A\theta_k + Bu_k + Dd_k \quad (4.1)$$

Con la estructura del modelo determinada, se debe realizar la estimación de los parámetros del modelo mediante el método de mínimos cuadrados (explicado para el caso difuso en la Sección 2.2.2), para finalizar por verificar su estabilidad y comprobar su rendimiento en predicción a múltiples pasos.

### 4.3. Modelamiento TS automático

La identificación basada en datos del sistema utilizando una estructura difusa Takagi-Sugeno implica un procedimiento iterativo descrito en la Subsección 2.2.2, en el cual se realizan distintas optimizaciones para lograr obtener un modelo que prediga de manera adecuada el comportamiento del terreno de cultivo.

Una vez obtenido el mejor modelo posible según las configuraciones utilizadas, se dispone en su forma en espacio de estados (4.2), donde las matrices  $A^i$ ,  $B^i$ ,  $D^i$  contienen los parámetros del modelo, según la regla  $i$ -ésima, y  $\hat{\omega}_i$  corresponde al grado de activación normalizado de la misma regla. Luego, se verifica la estabilidad del modelo calculando valores propios de las matrices  $A^i$  y de sus productos  $A^i A^j$ , para  $i \neq j$ ; comprobando que se encuentren dentro del círculo unitario, lo cual es una condición necesaria para la estabilidad de sistemas de este tipo [37].

$$\theta_{k+1} = \sum_{i=1}^r \hat{\omega}_i \left( A^i [\theta_k, \dots, \theta_{k-n\theta}]^T + B^i [u_k, \dots, u_{k-nu}]^T + D^i [d_k, \dots, d_{k-nd}]^T \right) \quad (4.2)$$

Al examinar el mejor modelo identificado, si este resulta inestable, se procede a verificar la estabilidad del siguiente modelo con mejor rendimiento, hasta encontrar uno que sea estable. Así, se termina revisando el rendimiento del modelo seleccionado al predecir el comportamiento del sistema, utilizando el conjunto de datos de test, a varios pasos de predicción.

Este método se usa tanto con los datos reales de la viña, como con aquellos extraídos del simulador.

### 4.4. Modelamiento TS híbrido

Para comenzar la modelación difusa según un esquema híbrido, se plantea un breve análisis de los datos disponibles, en el cual se calculan medidas de posición de las mediciones del campo, con el objetivo de establecer la separación de los datos en distintos niveles que representen distintas mecánicas del sistema. Esto se realiza en conjunto con el conocimiento de las dinámicas del sistema, permitiendo así definir directamente la posición de los centros



de los clusters del modelo.

En este caso no se usa un método de clustering difuso de manera directa, sin embargo, una vez definidos los centros de los clusters, se necesitan las desviaciones estándar de los datos respecto en los conjuntos difusos. De este modo, se utiliza la estructura de clusters hiperesféricos del método Fuzzy c-Means, con los centros designados manualmente. Tras esto, el procedimiento repite lo realizado en el método basado solo en datos, estimando los parámetros de las consecuencias y verificando la estabilidad del modelo, para, por último, comprobar el rendimiento a más pasos de predicción.

Este método se usa solo con los datos reales de la viña.

## 4.5. MPC umbral

El primer esquema de control a implementar plantea mantener el nivel de humedad, a una profundidad determinada, por sobre un umbral. Para plantear el problema de optimización se inicia por definir qué variable se controla, optando por el contenido de agua a 20 cm de profundidad,  $\theta^{20}$ , puesto que es el nivel que tiene una mayor concentración de raíces a lo largo de la temporada. Luego, se define la función objetivo del problema de optimización, penalizando la cantidad de agua de riego,  $u$ , utilizada en el horizonte de predicción,  $N$ . Se determinan también las restricciones a las que está sometido el sistema, tales como límites inferiores y superiores para las humedades y la irrigación, además de condiciones iniciales y el seguimiento de alguno de los modelos identificados previamente. De esta manera, se tiene el siguiente problema de optimización:

$$\begin{aligned}
 \min_{\theta, u} \quad & \sum_{j=0}^{N-1} u_{k+j} \\
 \text{s.a.} \quad & \theta_{k+j+1} = f(\theta_{k+j}, u_{k+j}, d_{k+j}) \\
 & \theta_k = \theta_0 \\
 & \theta_{min} \leq \theta_{k+j+1} \leq \theta_{max} \quad \forall j \in [0, \dots, N-1] \\
 & 0 \leq u_{k+j} \leq u_{max} \\
 & \bar{\theta} \leq \theta_{k+j+1}^{20}
 \end{aligned} \tag{4.3}$$

donde la función objetivo corresponde la suma de las acciones de control en el horizonte de predicción. No se usa un costo cuadrático puesto que el valor del riego siempre toma valores mayores o iguales a cero.

La determinación del umbral,  $\bar{\theta}$ , a establecer tiene que ver con algún punto clave según los requerimientos hídricos de la plantación, y el horizonte de predicción,  $N$ , se define tomando

en cuenta las dinámicas del sistema, el error de predicción de los modelos y la necesidad de la inclusión de predicciones de factores climáticos (precipitaciones y evapotranspiración) en los datos que ingresan al controlador.

Con el controlador definido, se realizan pruebas usando cada uno de los modelos estimados anteriormente. En una primera instancia, se evalúa el rendimiento del control de cada modelo sobre sí mismo, es decir, el modelo que usa el controlador es utilizado también como la planta a controlar. Esta prueba permite verificar que el controlador no tiene errores en su aplicación, puesto que al usar esta configuración, es capaz de predecir sin error los estados futuros del sistema.

Finalmente, se implementa el controlador en conjunto con el simulador del perfil del terreno de cultivo, y se realizan pruebas para controlar la humedad del terreno durante una temporada en distintas ocasiones con cada modelo desarrollado en el controlador.

## 4.6. MPC umbral y restricción de frecuencia

El siguiente esquema de control es una extensión del anterior, incluyendo restricciones que acercan el problema de riego a la situación real de la viña modelada. Con esta finalidad, se establece como objetivo mantener el nivel de humedad a 20 cm de profundidad,  $\theta^{20}$ , por sobre un umbral,  $\bar{\theta}$ , a la vez que se restringe la frecuencia del riego a como máximo un número determinado de veces,  $dias_{max}$ , en la ventana deslizante impuesta por el horizonte de predicción,  $N$ .

Para implementar la restricción en la frecuencia de riego se plantea el uso de una variable binaria en conjunto con el planteamiento del método de la gran M, que hace uso de un valor  $M$  suficientemente grande para mayorar una variable que se desee restringir [38], en la forma (4.4); donde se acota la variable continua  $u$ , por el producto de una variable binaria  $b$  y  $M$ . De esta manera,  $u$  puede tomar valores distintos de 0, y dentro del rango  $[-M, M]$  sí y solo sí el valor de  $b$  es 1.

$$-bM \leq u \leq bM \quad (4.4)$$

Así, para asegurar el cumplimiento de la restricción en frecuencia del riego, el controlador utiliza el historial de las  $N - 1$  últimas acciones de control. Luego, la función objetivo del problema de optimización penaliza el uso de agua, de manera que se encuentre una programación de riego que permita mantenerse sobre el umbral de humedad, a la vez que se usa una cantidad mínima de agua. De este modo, el planteamiento del problema de optimización se expresa a continuación:

$$\begin{aligned}
& \min_{\theta, u, b} \sum_{j=0}^{N-1} u_{k+j} \\
& \text{s.a. } \theta_{k+j+1} = f(\theta_{k+j}, u_{k+j}, d_{k+j}) \\
& \theta_k = \theta_0 \\
& \theta_{min} \leq \theta_{k+j+1} \leq \theta_{max} \quad \forall j \in [0, \dots, N-1] \\
& 0 \leq u_{k+j} \leq u_{max} \\
& 0 \leq u_{k+j} \leq b_{k+j} M \\
& \sum_{i=j}^{N-2} u_{mem_{k+i}} + \sum_{i=0}^j b_i \leq dias_{max} \\
& \bar{\theta} \leq \theta_{k+j+1}^{20}
\end{aligned} \tag{4.5}$$

El resto del procedimiento de la implementación de este controlador sigue la misma estrategia que el precedente, realizando pruebas con cada uno de los modelos en el MPC controlando a los mismos modelos y al simulador.

## 4.7. Análisis de resultados

Finalmente, habiendo realizado las pruebas de todos los modelos desarrollados junto con los dos esquemas de control implementados, se pasa a analizar los resultados de los distintos experimentos en forma comparativa.

La primera comparación es la del rendimiento de predicción de los modelos identificados, comparándolos en dos grupos, según el origen de los datos. Para evaluar el rendimiento durante el desarrollo, se ha utilizado el RMSE como métrica, de manera que este mismo indicador es usado durante este análisis. Además, se utiliza la forma de las curvas de predicción a uno y múltiples pasos para valorar los rendimientos de forma cualitativa.

Luego, se revisa el rendimiento de los dos esquemas de control, evaluando la cantidad de agua utilizada, el número de instancias de riego y el respeto del umbral, además de un análisis cualitativo según el aspecto de las curvas de humedad.

# Capítulo 5

## Modelamiento

### 5.1. Usando datos recopilados de la viña

La primera etapa de este trabajo corresponde al desarrollo de modelos de las dinámicas del contenido de agua del terreno de cultivo. Este proceso se lleva a cabo, en una primera aproximación, utilizando los datos facilitados por una viña de la sexta región de nuestro país. Tanto los datos como los procesos de modelamiento son detallados a continuación.

#### 5.1.1. Datos

Se dispone de datos de los flujos y contenidos de agua de un terreno de cultivo de uva vinífera, recopilados cada 24 horas, vale decir una vez por día, durante 1227 días continuos, entre los años 2018 y 2022. Estos corresponden a muestras de los contenidos de agua del terreno a cuatro profundidades de interés, la irrigación, las precipitaciones y la evapotranspiración de referencia.

El contenido de agua del terreno se midió utilizando sensores de humedad posicionados a cuatro niveles de profundidad dentro del rango de mayor concentración de raíces [17]: 20 cm, 40 cm, 60 cm y 100 cm. Así, se tienen muestras de la dinámica hídrica del perfil del suelo, las cuales son mostradas gráficamente en la Figura 5.1, donde se identifica una periodicidad en el comportamiento del contenido de agua, con segmentos estables e inestables, los cuales corresponden a temporadas frías y cálidas, respectivamente. Además, se visualiza que el contenido de agua sigue una dinámica más no lineal en los niveles más cercanos a la superficie.

Los datos de irrigación fueron medidos en el lugar, mientras que los datos de las precipitaciones y evapotranspiración de referencia fueron recopilados del sitio Agrometeorología del Instituto de Investigaciones Agropecuarias (INIA) [39]. La Figura 5.2 muestra estos valores

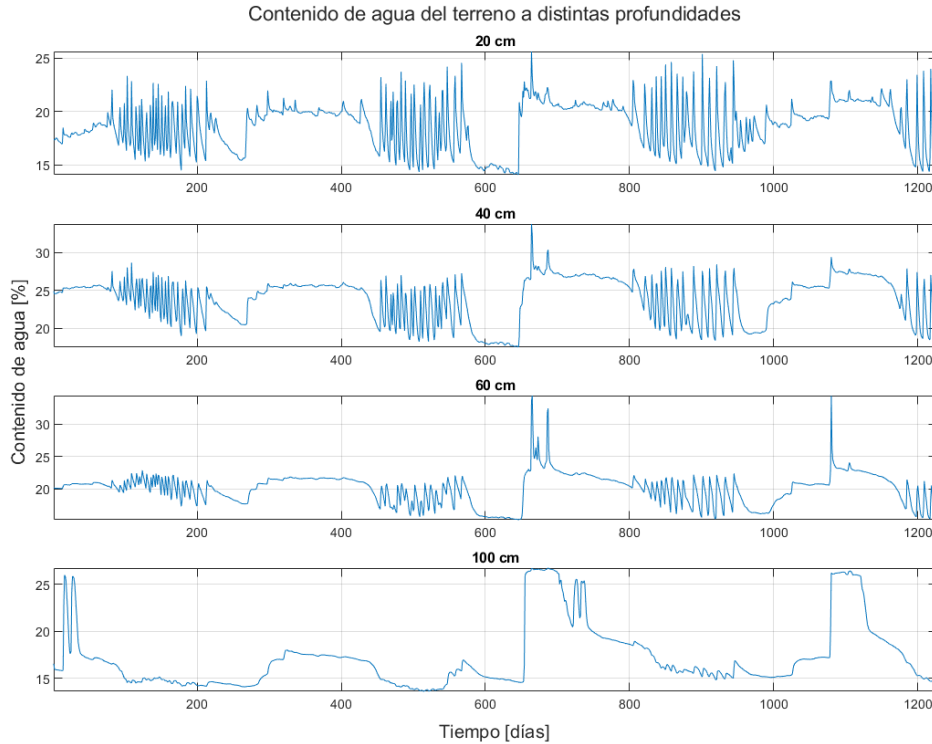


Figura 5.1: Datos de contenido de agua en las distintas profundidades

durante los 1227 días de muestreo. Comparando esta figura con la anterior es notable que los periodos inestables de los contenidos de agua coinciden con tiempos de alta evapotranspiración e irrigación, mientras que los periodos estables corresponden con baja evapotranspiración y mayor nivel de precipitaciones.

Cabe destacar que todas las muestras fueron obtenidas durante el funcionamiento habitual de la viña, de modo que no se tiene acceso a todas las dinámicas del sistema, puesto que este se mantiene en niveles de funcionamiento deseados para el cultivo de uva de vino. A su vez, se debe notar el carácter esporádico de las entradas de agua al terreno, tanto la irrigación como las precipitaciones ocurren en ciertos periodos, y, generalmente, no en días consecutivos. En el primer caso esto se debe a restricciones materiales y a métodos de regadío para el cultivo de uva, mientras que en el segundo se tiene motivos meramente ambientales, al igual que para la distribución de la evapotranspiración.

De esta manera, se identifican las entradas y salidas del sistema: los contenidos de agua en las cuatro profundidades corresponden a las salidas, y se designan por  $\theta = [\theta^{20}, \theta^{40}, \theta^{60}, \theta^{100}]^T$ ; como entrada se tiene la irrigación  $u$ , la única variable manipulada, puesto que las precipitaciones  $p$  y la evapotranspiración  $ET_o$  corresponden a perturbaciones ambientales medibles, por lo cual son simbolizadas en conjunto como  $d = [p, ET_o]^T$ .

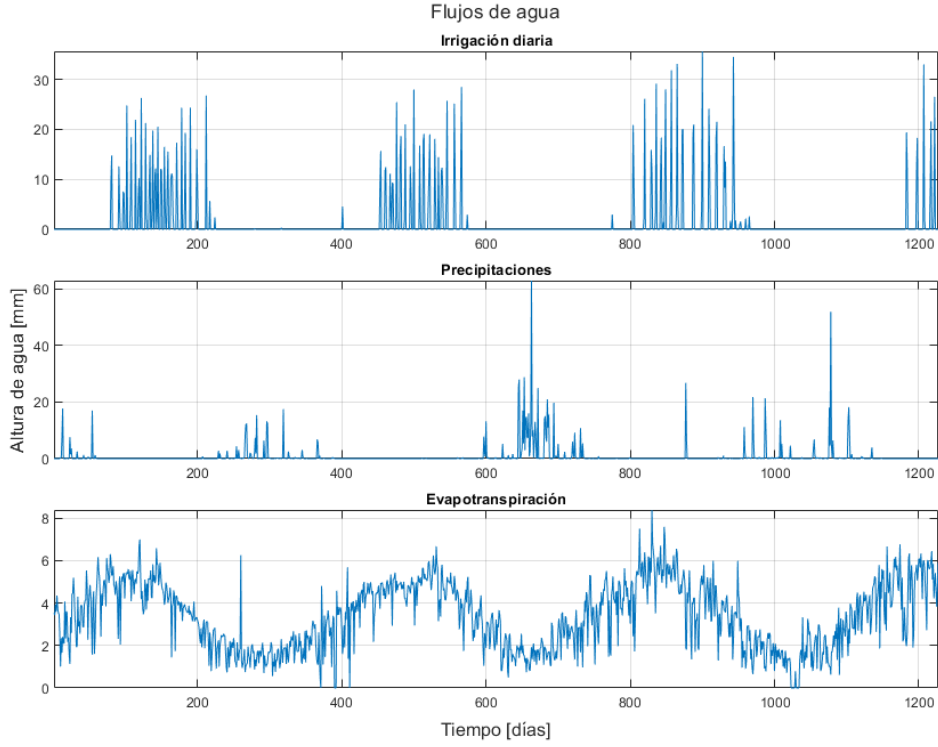


Figura 5.2: Datos de los flujos de agua del sistema

### 5.1.2. Modelamiento lineal

Al ser un sistema de tipo SIMO (Single-Input Multiple-Output), se deben modelar tantos modelos como salidas tiene el sistema. Así, usando un modelamiento lineal autorregresivo, se genera un modelo para cada una de las cuatro salidas del sistema. Estos modelos son, luego, utilizados como base para validar el resto de los modelos elaborados.

La estructura de cada uno de los modelos lineales se muestra en (5.1), donde cada salida  $\theta^i$  en el instante  $k + 1$  corresponde a una combinación lineal de los contenidos de agua  $\theta^i$ , la irrigación  $u$ , las precipitaciones  $p$  y la evapotranspiración  $ET_o$  en el instante  $k$ , según los factores  $\phi^i$ , además de un factor afín  $\phi_0^i$ .

$$\theta_{k+1}^i = \phi_0^i + \phi_1^i \theta_k^{20} + \phi_2^i \theta_k^{40} + \phi_3^i \theta_k^{60} + \phi_4^i \theta_k^{100} + \phi_5^i u_k + \phi_6^i p_k + \phi_7^i ET_{ok} \quad (5.1)$$

De esta manera se tiene cuatro conjuntos de factores  $\phi$  que definen, respectivamente, los modelos de cada salida.

La determinación de los parámetros  $\phi$  se realiza mediante una estimación de mínimos cuadrados utilizando los datos del sistema. Para verificar el rendimiento del modelo desarrollado, un 90 % de los datos son usados en su entrenamiento y el 10 % restante se usa en test.

El método de mínimos cuadrados resuelve un problema de optimización en que se minimiza la distancia cuadrática entre las salidas del modelo estimado y las salidas del conjunto de entrenamiento, según la ecuación (5.2), donde el uso del acento circunflejo designa el carácter de estimación,  $N$  corresponde al total de muestras del conjunto de entrenamiento y  $Z$  es la matriz que contiene las muestras como filas ordenadas de forma que:  $Z_j = [\theta_j^{20}, \theta_j^{40}, \theta_j^{60}, \theta_j^{100}, u_j, p_j, ET_{oj}]$ .

$$\begin{aligned} \min_{\phi^i} \quad & \sum_{j=1}^N (\theta_j^i - \hat{\theta}_j^i)^2 \\ \text{s.a.} \quad & \hat{\theta}_j^i = Z_j \phi^i \end{aligned} \quad (5.2)$$

Resolviendo el problema (5.2) se obtienen cuatro conjuntos de parámetros  $\phi$  que describen cuatro modelos de la forma (5.1). De manera condensada, estos cuatro modelos pueden ser expresados como uno solo en variables de estado de la forma (5.3).

$$\theta_{k+1} = A\theta_k + Bu_k + Dd_k \quad (5.3)$$

Donde  $\theta_k = [\theta_k^{20}, \theta_k^{40}, \theta_k^{60}, \theta_k^{100}]^T$  es el vector de los contenidos de agua en las cuatro profundidades,  $u_k$  es la irrigación,  $d_k = [\mathbb{1}, p_k, ET_{ok}]^T$  es el vector con un  $\mathbb{1}$  del tamaño correspondiente al factor afín y las perturbaciones ambientales (precipitaciones y evapotranspiración), y las matrices  $A$ ,  $B$  y  $D$  (detalladas en Anexo A) contienen los parámetros  $\phi$  correspondientes. Así, la estructura del modelo es representable de manera simplificada por el diagrama de la Figura 5.3.




Figura 5.3: Diagrama simplificado de la estructura del modelo lineal

De particular importancia resulta estudiar la estabilidad del modelo identificado, puesto que se plantea como parte de un esquema de control. Así, al ser un modelo en tiempo discreto, se verifica que los valores propios de la matriz  $A$  del modelo tienen magnitud menor a 1, lo

cual asegura estabilidad.

Luego, se prueba el modelo usando los datos del conjunto de test, generando predicciones entre 1 y 10 pasos, las cuales son mostradas en la Figura 5.4 y la Figura 5.5.




Figura 5.4: Predicción a 1 paso de los contenidos de agua del sistema, usando el modelo lineal

Como medida de rendimiento, la raíz del error cuadrático medio (RMSE) es calculada para cada estimación, obteniendo los valores expuestos en la Tabla 5.1, donde se verifica que el error de estimación aumenta de manera importante al incrementar la cantidad de pasos.

Tabla 5.1: Error RMSE de predicción de test, a múltiples pasos, del modelo lineal para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día

Profundidades	RMSE [%]					
	1 paso	2 pasos	3 pasos	5 pasos	7 pasos	10 pasos
20 cm	0.96	1.29	1.43	1.59	1.63	1.74
40 cm	1.43	1.97	2.30	2.82	3.10	3.43
60 cm	0.90	1.24	1.45	1.64	1.73	1.75
100 cm	0.39	0.55	0.64	0.89	0.95	1.09



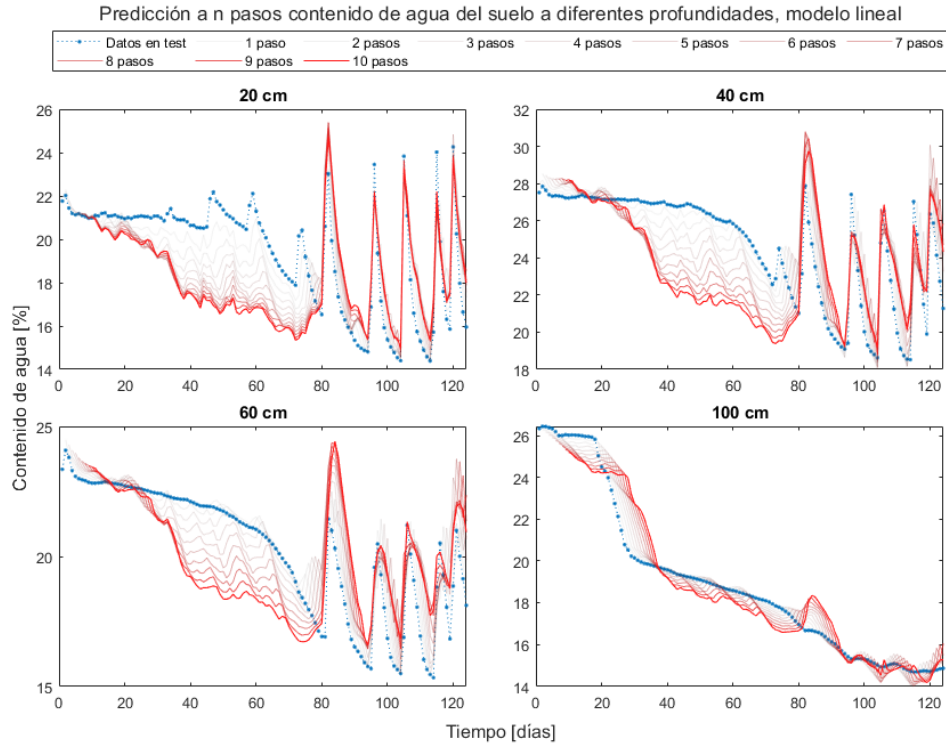


Figura 5.5: Predicción a  $n$  pasos de los contenidos de agua del sistema, usando el modelo lineal

### 5.1.3. Modelamiento difuso

El modelamiento difuso del sistema se realiza utilizando una estructura de tipo Takagi-Sugeno, donde este es descrito por una combinación lineal de modelos lineales autorregresivos, dependiente del punto de operación del sistema.

El proceso se realiza utilizando dos métodos: el primero usa clustering difuso para identificar los clusters adecuados del conjunto de datos del sistema de manera *automatizada* y luego determinar los parámetros de cada modelo local resolviendo un problema de mínimos cuadrados como el mostrado en (2.14); el segundo método tiene un carácter *híbrido*, donde la identificación de los clusters se hace utilizando conocimiento técnico del funcionamiento del sistema y un análisis de los datos disponibles, para luego utilizarlos de la misma manera que en el método *automático*.

#### 5.1.3.1. Modelo Takagi-Sugeno automático

Para comenzar la elaboración del modelo, se separan los datos existentes en conjuntos de entrenamiento, validación y test, cada uno con un 76%, 14% y 10% de los datos, respectivamente. Con esta división, se intenta mantener una cantidad importante de datos en los conjuntos de entrenamiento y validación, debido a la escasez de estos; además de mantener

el mismo conjunto de test que en el resto de los modelos, haciendo así la comparación del rendimiento más directa.

Con los datos separados se procede a desarrollar múltiples instancias del modelo, en una aproximación al método expuesto en el diagrama de flujo de la Figura 2.4. El planteamiento consiste en construir modelos definiendo un número máximo de 8 clusters (reglas) y de 8 regresores de cada antecedente, de forma que se elaboran modelos para cada combinación de cantidad de clusters y regresores en  $[2, 3, \dots, 8] \times [1, 2, \dots, 8]$ . Generando así 56 modelos con salidas locales representables en variables de estado de forma (5.4), donde el superíndice  $r$  indica la regla, la matriz  $A^r$  es de dimensiones  $4 \times 4N_{regs}$ ,  $B^r$  es de dimensiones  $4 \times N_{regs}$  y  $D^r$  es de dimensiones  $4 \times (2N_{regs} + 1)$ . Estas matrices contienen los parámetros identificados mediante mínimos cuadrados, con  $N_{regs}$  la cantidad de regresores utilizada. Los vectores  $\vec{\theta}$ ,  $\vec{u}$  y  $\vec{d}$  tienen tantas filas como columnas la matriz que lo multiplica, puesto que contienen los  $N_{regs}$  regresores de cada una de sus componentes (el “+1” extra en el caso de  $D^r$  viene dado por la presencia del factor afín en  $\vec{d}$ ).

$$\theta_{k+1}^r = A^r \vec{\theta} + B^r \vec{u} + D^r \vec{d} \quad (5.4)$$

Además de variar el número de clusters y regresores a utilizar, se plantea el uso de dos métodos de clustering difuso: Fuzzy C-Means y Gustafson Kessel; y tres métodos de normalización previa de los datos: lineal, gaussiana y sin normalizar. Estos métodos de normalización permiten, para ciertos conjuntos de datos, obtener mejores resultados al cambiar la distancia entre los datos [12]. De esta forma, se identifica un total de 336 modelos distintos.

Cada tupla [#clusters, #regresores, método de clustering, método de normalización] permite generar un modelo difuso distinto tras el proceso de clustering difuso, donde se identifican los centros más adaptados para la configuración actual. Luego, se emplean funciones de pertenencia gaussianas definidas por la función 5.5, donde  $a$  y  $b$  corresponden al inverso de la desviación estándar y el centro de los clusters, respectivamente, de manera que se pueda obtener los grados de activación de cada punto  $z$  del conjunto de entrenamiento.

$$f(x) = \exp\left(-0.5(a(z - b))^2\right) \quad (5.5)$$

Los grados de activación de las reglas son normalizados de modo que, para cada dato, la suma de estos sea igual a 1. Luego, se resuelve un problema de mínimos cuadrados (ver Subsección 2.2.2), donde se obtiene un conjunto de parámetros que determinan los modelos de cada una de las salidas locales del sistema según cada regla. Así, se obtienen modelos para el sistema según distintas configuraciones, cuyos rendimientos son comparados utilizando el RMSE al estimar las salidas del sistema a un paso, usando el conjunto de datos de validación. Este proceso conlleva el disposición de un listado de modelos, ordenados según su rendimiento

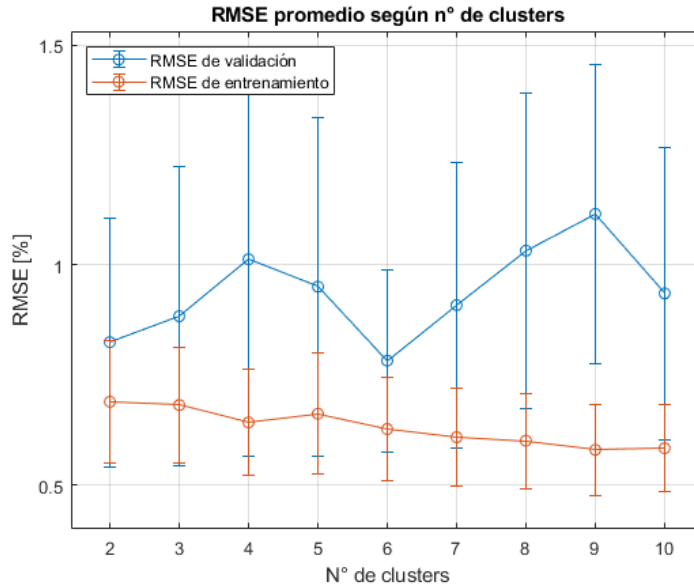


Figura 5.6: Error RMSE promedio de las cuatro salidas según el número de clusters, usando 1 regresor de cada antecedente, clustering FCM y sin normalización de los datos

en validación, cada uno de los cuales es evaluado para verificar su estabilidad según el método descrito en la Sección 4.3, lo cual lleva al descarte de múltiples modelos, estableciendo que el mejor modelo estable corresponde a aquel que utiliza 2 reglas, con 1 regresor de cada antecedente, según el método de clustering FCM y sin normalización de los datos; cuyos parámetros se detallan en el Anexo A.

En la Figura 5.6 se ilustran los valores del RMSE de entrenamiento y validación para los modelos que usa un solo regresor por antecedente, utilizando FCM y sin normalizar, según el número de clusters. Los valores corresponden al promedio del error de cada salida del sistema, y las barras de error representan la desviación estándar de los errores de las salidas. En el gráfico se puede apreciar que el modelo que utiliza 6 clusters tiene un error de validación inferior que el modelo que usa 2 clusters, pero el análisis de estabilidad arroja que al usar 6 clusters no se logra estabilidad, mientras que con 2 sí, lo que lleva a un modelo representado por dos reglas de la forma:

$$R_i : \text{Si } \theta_k^{20} \text{ es MF}_1^i \text{ y } \theta_k^{40} \text{ es MF}_2^i \text{ y ... y } ET_{ok} \text{ es MF}_7^i, \text{ entonces:} \quad (5.6)$$

$$\theta_{k+1}^i = A^i \theta_k + B^i u_k + D^i d_k$$

y con salida global según:




Figura 5.7: Predicción a 1 paso de los contenidos de agua del sistema, usando el modelo TS automático

$$\theta_{k+1} = \sum_{i=1}^2 \hat{\omega}_i \theta_{k+1}^i \quad (5.7)$$

Esta estructura, puede ser esquematizada de la misma forma que aquella del modelo lineal, según el diagrama en la Figura 5.3.

Gráficamente, el rendimiento del modelo TS con clustering automático, a un paso de predicción, en el conjunto de test es mostrado en la Figura 5.7, y las predicciones hasta 10 pasos se muestran en la Figura 5.8, donde las curvas rojas se vuelven menos traslúcidas a medida que aumenta el número de pasos de estimación.

Cuantitativamente, los valores del RMSE para las predicciones del contenido de agua a varios pasos se presentan en la Tabla 5.2.

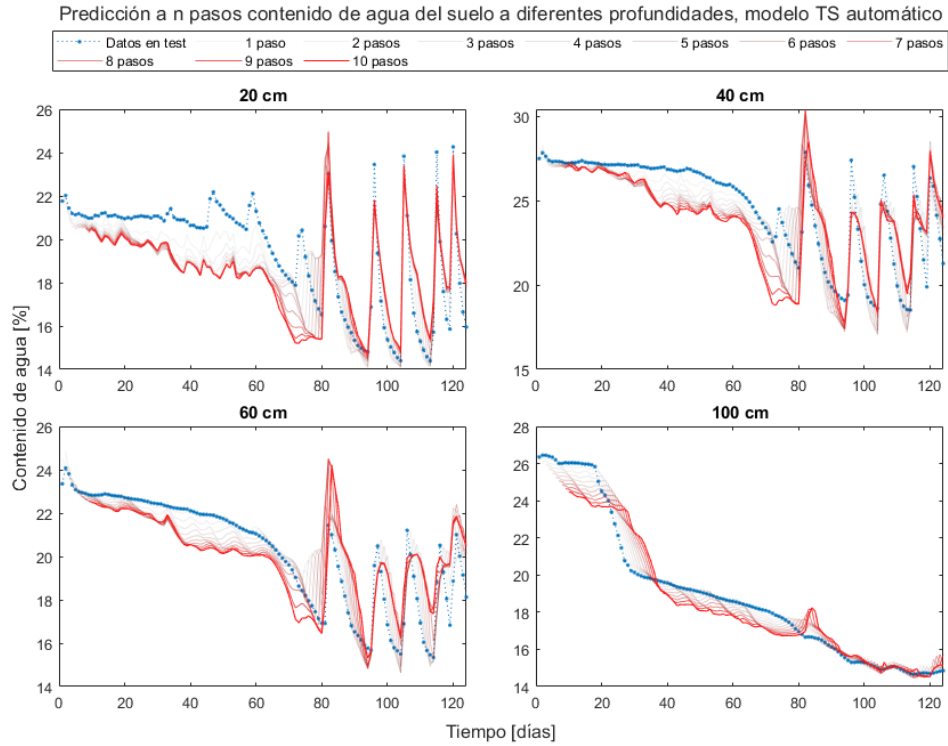


Figura 5.8: Predicción a  $n$  pasos de los contenidos de agua del sistema, usando el modelo TS automático

Tabla 5.2: Error RMSE de predicción de test, a múltiples pasos, del modelo TS automático para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día

Profundidades	RMSE [%]					
	1 paso	2 pasos	3 pasos	5 pasos	7 pasos	10 pasos
20 cm	0.83	1.06	1.16	1.24	1.28	1.39
40 cm	1.36	1.74	1.92	2.10	2.25	2.56
60 cm	0.55	0.77	0.93	1.09	1.26	1.45
100 cm	0.39	0.55	0.65	0.85	0.99	1.14

### 5.1.3.2. Modelo Takagi-Sugeno híbrido

El enfoque híbrido de este proceso de identificación tiene relación con aprovechar el conocimiento que se tiene de las dinámicas del terreno de cultivo, además de los datos disponibles. De esta manera, se plantea definir los centros de clusters para el nivel de humedad a 20 cm de profundidad, con los cuales se construyen reglas siguiendo los pasos restantes del método de clustering difuso Fuzzy C-Means. La estructura del modelo es idéntica a la del modelo TS automático, mostrada en (5.4).

Para comenzar el desarrollo del modelo se realiza un análisis de los datos disponibles y

del sistema a modelar. En primer lugar, se sabe que los terrenos de cultivo tienen ciertos puntos característicos para el contenido de agua, dos de los cuales resultan particularmente importantes para las dinámicas del sistema. El primero de estos puntos es la capacidad de campo, que designa la cantidad máxima de agua que el terreno puede contener de manera estable; luego, cualquier ingreso adicional de agua se pierde rápidamente por acción de la gravedad. El segundo lugar relevante corresponde al umbral de estrés hídrico, pues tiene que ver con la capacidad de la planta para absorber el agua de la tierra de manera efectiva.

Teniendo lo anterior en consideración, se dispone a diseñar tres clusters, uno para niveles de humedad bajos, uno para medios y otro para altos. Luego, se analizan los histogramas de los datos para el contenido de agua a 20 cm de profundidad en la Figura 5.9, para poder definir los centros de los clusters. En la figura se destacan los percentiles 20, 50 y 80 de las muestras, los cuales entregan una idea de los niveles bajos, medios y altos de la distribución.

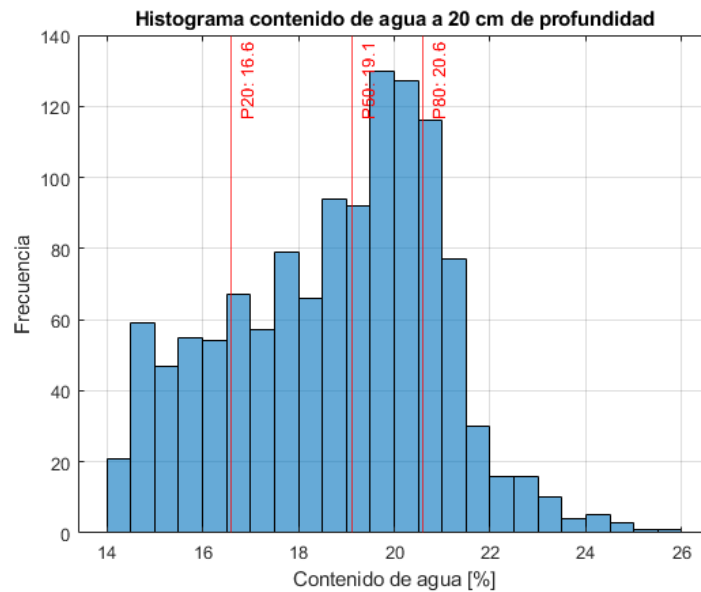


Figura 5.9: Histograma de la distribución de muestras del contenido de agua a 20 cm de profundidad, con marcas en los percentiles 20, 50 y 80

En [7] se estiman los niveles del umbral de estrés hídrico y capacidad de campo, para el nivel de 20 cm de profundidad, en el 14% y 20% de humedad, respectivamente. Por otra parte, el más reciente ajuste del simulador estima el umbral de estrés en el 15% de humedad. Luego, comparando estos valores con los percentiles expuestos en la Figura 5.9 se nota que los valores, coincidentemente, son similares. De esta manera, se decide definir los centros de los conjuntos difusos en los valores: 16%, 19% y 21%, así, el cluster inferior engloba a los valores cercanos al umbral de estrés hídrico, y los clusters superiores corresponden con las dinámicas bajo y sobre la capacidad de campo, a la vez que se tiene una buena cobertura del conjunto completo de datos.

Habiendo seleccionado los centros de los clusters del modelo, se pasa a calcular las des-

viaciones estándar de los conjuntos definidos según el método de clustering FCM (conjuntos hipersféricos). Se computa la distancia al cuadrado entre cada muestra del contenido de agua a 20 cm de profundidad y los centros de los clusters, de manera que se obtiene una *pertenencia* de los puntos a cada cluster, según el centro más cercano. Así, se separa el conjunto de datos en tres partes (una por cada cluster), y se calcula la desviación estándar de cada uno de los conjuntos, obteniendo la dispersión de los clusters.

Luego, se procede de forma similar al método automático, calculando las funciones de pertenencia y realizando la identificación de parámetros mediante mínimos cuadrados. Al usar la misma cantidad de regresores para los antecedentes, la estructura de este modelo es idéntica a la del anterior (ver (5.4)), con la sola diferencia de que este modelo utiliza 3 reglas.

Al evaluar los valores propios de las matrices  $A^i$  del modelo (y de sus productos, según el método descrito en la Sección 4.3), se verifica que estos se encuentran dentro del círculo unitario, de modo que se cumplen condiciones necesarias de estabilidad.

Finalmente, se evalúa el rendimiento del modelo. Visualmente se puede verificar la capacidad de ajustar el sistema a 1 paso de predicción en la Figura 5.10 y hasta 10 pasos en la Figura 5.11. De manera numérica, se puede ver los valores del RMSE a múltiples pasos de predicción en cada profundidad en la Tabla 5.3.

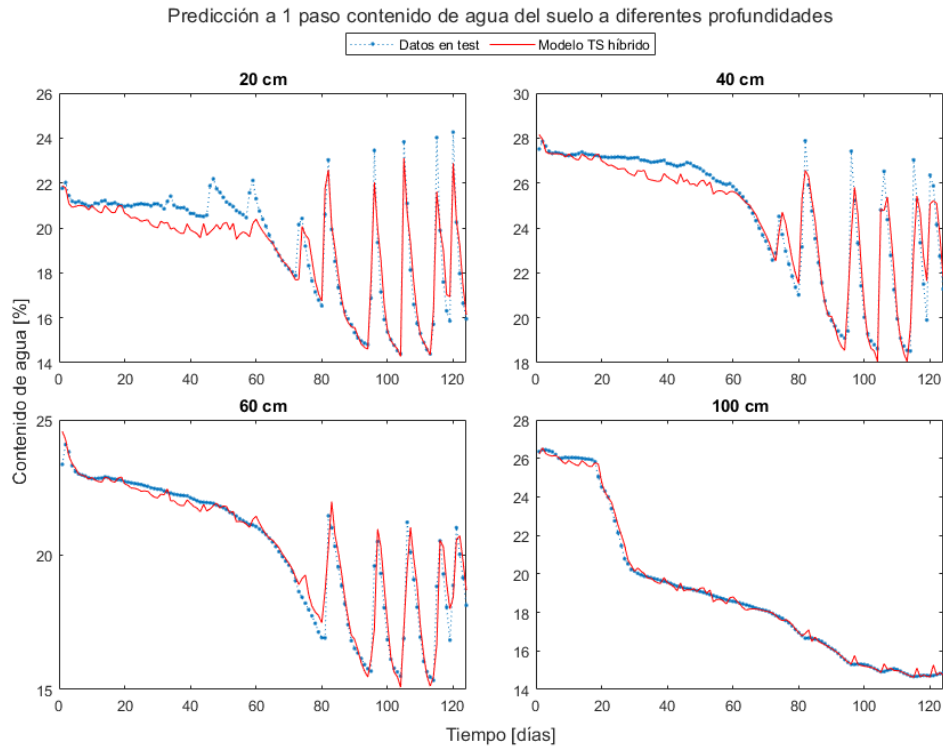


Figura 5.10: Predicción a 1 paso de los contenidos de agua del sistema, usando el modelo TS híbrido




Figura 5.11: Predicción a  $n$  pasos de los contenidos de agua del sistema, usando el modelo TS híbrido

Tabla 5.3: Error RMSE de predicción de test, a múltiples pasos, del modelo TS híbrido para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día

Profundidades	RMSE [%]					
	1 paso	2 pasos	3 pasos	5 pasos	7 pasos	10 pasos
20 cm	0.83	1.09	1.28	1.54	1.69	1.96
40 cm	0.82	1.03	1.32	1.81	1.97	2.09
60 cm	0.54	0.77	0.99	1.43	1.68	1.70
100 cm	0.20	0.32	0.43	0.63	0.84	1.03

#### 5.1.4. Análisis comparativo

De manera gráfica, al comparar las predicciones a  $n$  pasos de los modelos desarrollados (ver Figuras 5.5, 5.8 y 5.11) se puede notar que, por un lado, al aumentar los pasos de predicción, todos los modelos presentan una tendencia a subestimar la capacidad de retener humedad del terreno en periodos largos en los niveles de 20 cm, 40 cm y 60 cm de profundidad, con el esquema lineal fallando en mayor magnitud. Y, por otro lado, se observa que en las zonas de cambios más abruptos (como los últimos días del conjunto de test), se suelen errar los mínimos y máximos. En este último caso, los modelos TS fallan ligeramente más a menudo que los



lineales. Resulta destacable que ambos tipos de modelos tienden a fallar las predicciones en situaciones distintas.

Estos problemas en las predicciones a varios pasos pueden sustentarse en problemas de disponibilidad de datos. Como se menciona en la Subsección 5.1.1, se cuenta con muestras de los contenidos y flujos de agua, obtenidos diariamente durante el funcionamiento normal de la viña por 1227 días continuos. Luego, una parte importante de los datos corresponde a periodos fuera de las temporadas de cultivo, en los cuales no se riega, de manera que no son de interés para el control del riego. Así, se tiene poca disponibilidad de datos en general, pero además se tiene escasez de datos correspondientes a los periodos de interés y poca representatividad de las dinámicas del sistema.

Una mala capacidad de predicción de los modelos puede afectar el rendimiento de controladores predictivos basados en los modelos. Por ejemplo, en ocasiones el controlador podría prever que la humedad se mantendrá estable en el horizonte de predicción, cuando en la realidad esta bajaría, potencialmente dañando los cultivos. De esta forma, se dispone que el horizonte de predicción a utilizar con estos modelos no debe ser más amplio que 7 pasos (una semana) para evitar problemas constantes debido al error de predicción.

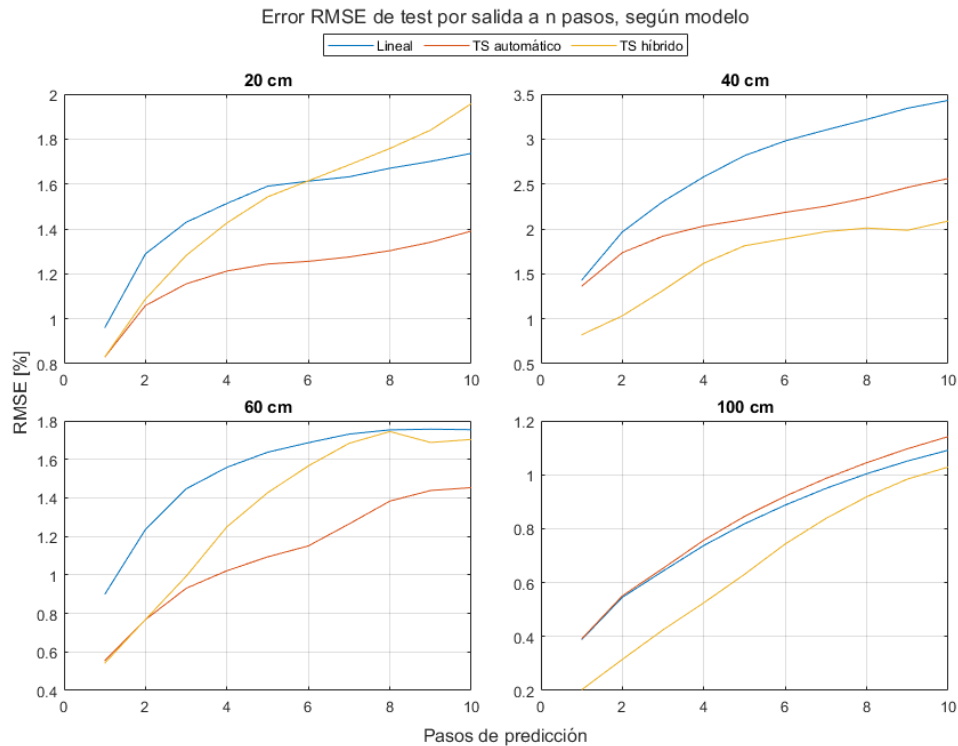


Figura 5.12: Evolución del RMSE de test al variar el número de pasos de predicción, para los modelos desarrollados en cada profundidad

Por otra parte, comparando los valores del error de predicción de los modelos (ver Tablas 5.1, 5.2 y 5.3), se puede notar que los modelos difusos presentan ventajas respecto al modelo lineal. La Figura 5.12 muestra el RMSE de predicción en el conjunto de test para el conte-

nido de agua en cada profundidad, según cada modelo elaborado, permitiendo contrastar el rendimiento de los modelos para cada salida, variando el número de pasos.

Para todos los niveles de profundidad se aprecia que los modelos TS tienen, en promedio, un mejor rendimiento que el modelo lineal. Entre los modelos no lineales, el esquema automático muestra un mejor rendimiento en las capas de 20 cm y 60 cm de profundidad, destacando su exactitud superior en el nivel más superficial.

## 5.2. Usando datos extraídos del simulador

En esta sección se realiza un experimento de identificación completo, recopilando datos desde el simulador desarrollado inicialmente en [7] y reajustado recientemente según las muestras disponibles del viñedo.

La utilización de este enfoque pretende solventar el problema del acceso a datos del comportamiento del sistema, al permitir la simulación de tantas temporadas de cultivo como se estime necesario, además de posibilitar la manipulación del riego para acceder a todas las dinámicas del sistema. Contrastando así con las mediciones obtenidas en la viña durante temporadas normales, donde el rango de humedades es limitado según las necesidades de la plantación.

### 5.2.1. Datos

Se plantea generar datos a partir del simulador del perfil del terreno, para lo cual se estudia primero la técnica de riego convencional utilizada en el simulador. Durante la temporada de cultivo, el riego convencional impone que las instancias de irrigación deben tener una separación mínima de 5 días, y que estas deben realizarse solo si el nivel de humedad a 20 cm de profundidad ha descendido bajo el 15 %, correspondiente al umbral de estrés hídrico. Luego, la cantidad de agua a introducir al terreno corresponde a un 35 % de la cantidad necesaria para alcanzar la capacidad de campo.

Así, se decide manipular tres variables del método convencional, para introducir mayor variabilidad en los datos generados, explorando así el espectro de dinámicas del sistema. La primera variable manipulada es el volumen de riego introduciendo un factor aleatorio entre 0.1 y 1 que multiplica al riego estándar del método. La segunda variable corresponde a la separación entre las instancias de riego, variando de manera aleatoria entre 1 y 8 días. Finalmente, la última variable corresponde al umbral de decisión de riego, el cual es modificado de manera aleatoria entre 11.52 % (valor ligeramente superior al punto de marchitez permanente: 10 %) y 17 %, de manera que se fuerza a que se generen instancias con humedades bajas y altas.

Utilizando la configuración discutida se generan datos de 16 temporadas de cultivo. Particularmente, se guardan los valores correspondientes al periodo en que se realiza un control del riego, de manera que cada temporada implica 105 días, con una muestra por día, llegando al total de 1680 muestras. Los gráficos en las Figuras 5.13 y 5.14 muestran la información recopilada según el procedimiento descrito, donde se aprecia que las curvas de los contenidos de agua tienen formas similares a las de los periodos de riego de las temporadas reales visibles en la Figura 5.1.

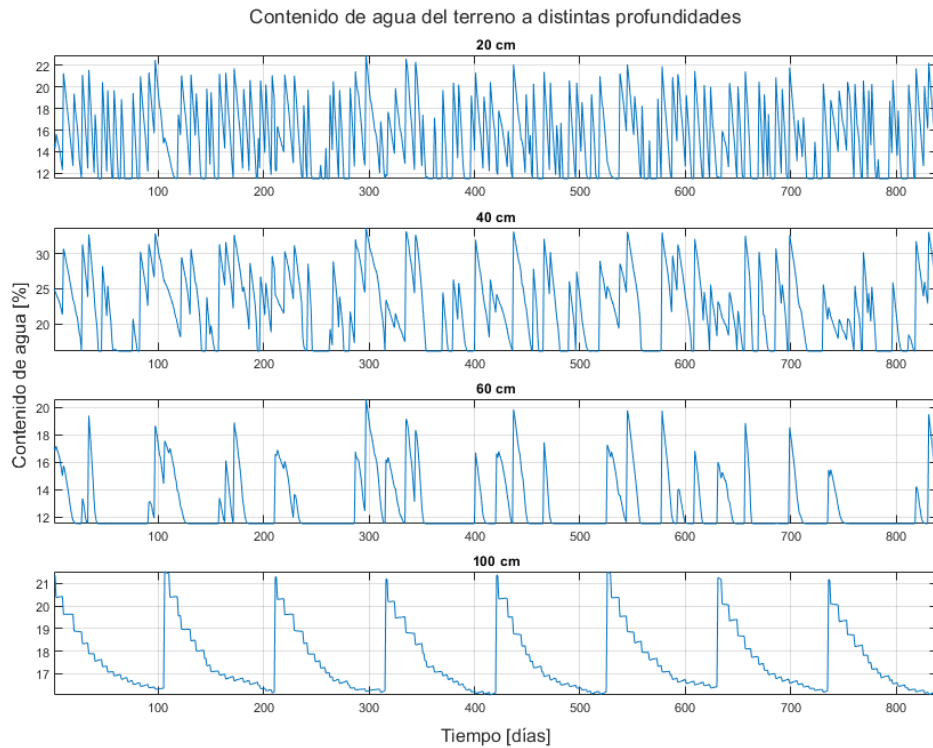


Figura 5.13: Datos de contenido de agua en las distintas profundidades, obtenidos del simulador

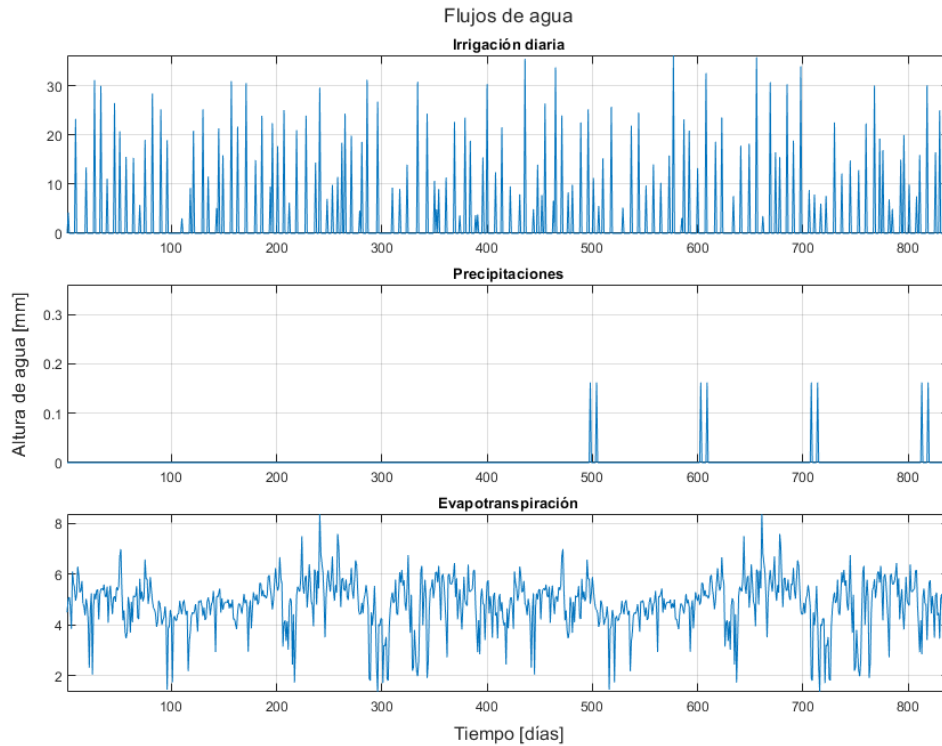


Figura 5.14: Datos de los flujos de agua del sistema, obtenidos del simulador

## 5.2.2. Modelamiento lineal

La identificación del modelo lineal a partir de los datos del simulador se realiza según la misma estructura en espacio de estados del anterior modelo lineal (5.3), donde el contenido de agua en cada nivel de profundidad tiene la estructura dada en (5.1). Nuevamente, la separación del total de datos se hace con un 90 % para la estimación de parámetros mediante mínimos cuadrados y el 10 % restante para el conjunto de test.

Las matrices  $A$ ,  $B$  y  $D$  de la representación en espacio de estados del modelo se muestran en el Anexo A, la primera de las cuales es utilizada en el análisis de estabilidad calculando sus valores propios y obteniendo que estos tienen magnitudes menores a 1, de modo que el modelo es estable. Luego, se utiliza el conjunto de datos de test para evaluar el rendimiento del modelo, con las Figuras 5.15 y 5.16 mostrando el resultado de las predicciones a 1 y múltiples pasos, respectivamente, de los 100 primeros elementos del conjunto.

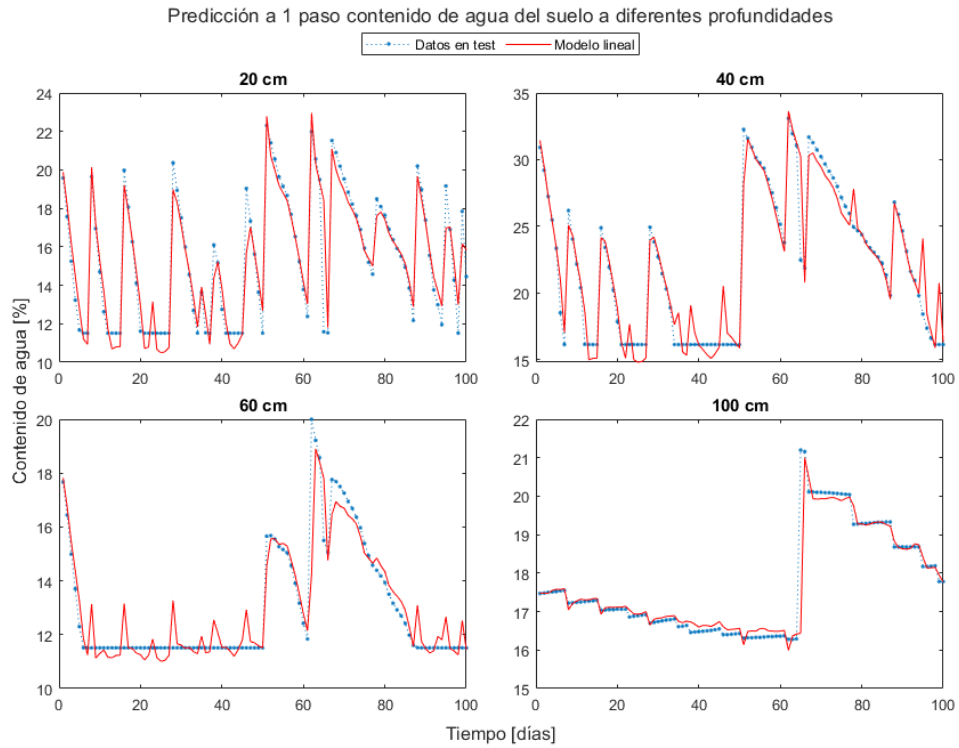


Figura 5.15: Predicción a 1 paso de los contenidos de agua del simulador, en el conjunto de test, usando el modelo lineal

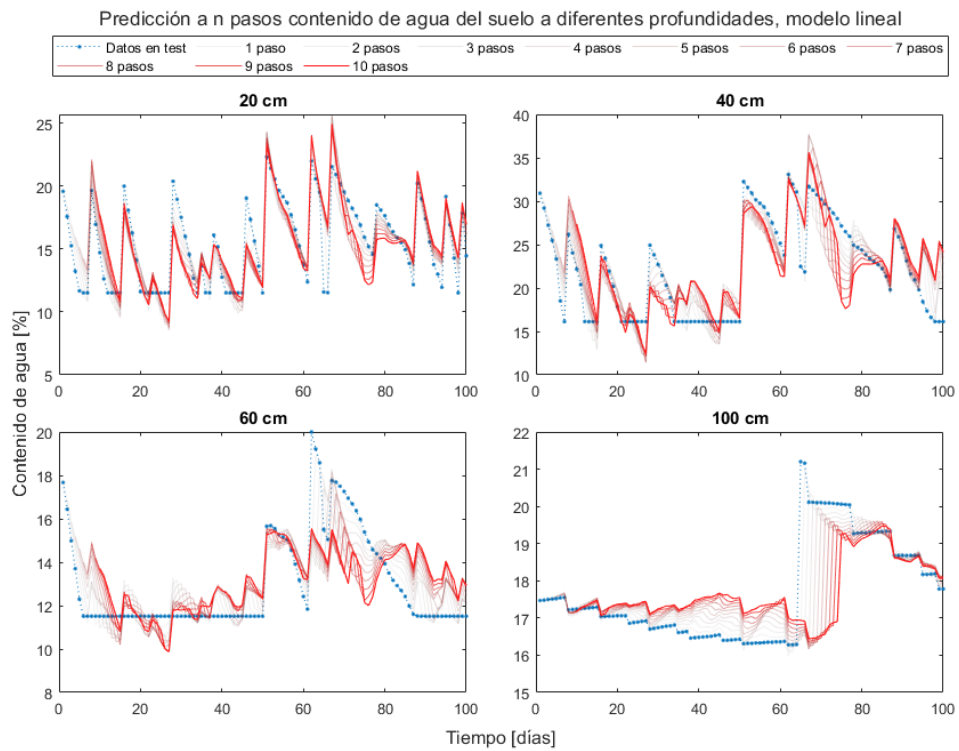


Figura 5.16: Predicción a  $n$  pasos de los contenidos de agua del simulador, en el conjunto de test, usando el modelo lineal

De manera cuantitativa, los resultados del RMSE de test a múltiples pasos de predicción utilizando el modelo lineal se muestran en la Tabla 5.4.

Tabla 5.4: Error RMSE de predicción de test, a múltiples pasos, del modelo lineal generado usando datos del simulador, para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día

Profundidades	RMSE [%]					
	1 paso	2 pasos	3 pasos	5 pasos	7 pasos	10 pasos
20 cm	0.96	1.29	1.43	1.59	1.63	1.74
40 cm	1.43	1.97	2.30	2.82	3.10	3.43
60 cm	0.90	1.24	1.45	1.64	1.73	1.75
100 cm	0.39	0.55	0.64	0.82	0.95	1.09

### 5.2.3. Modelamiento difuso

Usando los datos generados con el simulador, se prepara un modelo difuso Takagi-Sugeno utilizando el esquema anteriormente denominado *automático*, donde se identifican modelos de forma iterativa utilizando la técnica desarrollada durante el modelamiento difuso a partir de los datos de la viña.

De este modo, se identifican modelos TS variando la cantidad de clusters, cantidad de regresores por antecedente, método de clustering y método de linealización de los datos; de la misma manera que en la parte anterior (ver Sección 5.1.3.1), manteniendo también la división del set de datos en conjuntos de entrenamiento, validación y test con un 76 %, 14 % y 10 % de las muestras, respectivamente.

Con este procedimiento se evalúa el rendimiento en el conjunto de validación de cada modelo entrenado, obteniendo que la configuración con menor error de predicción corresponde a la que usa 3 reglas, 1 retardo por antecedente, el método de clustering FCM y ninguna normalización de los datos. No obstante, al analizar la estabilidad de este modelo se verifica que no cumple las condiciones necesarias de estabilidad (ver Sección 4.3), de forma que es descartado y se pasa a revisar el segundo mejor modelo según su rendimiento en validación, cuya estructura difiere de la anterior solo en que usa 2 reglas en vez de 3. Evaluando los valores propios de las matrices  $A^i$  de su representación en espacio de estados (disponible en el Anexo A), y de los productos de estas, se encuentra que ninguno tiene magnitud superior o igual a 1, por lo que es seleccionado como el mejor.

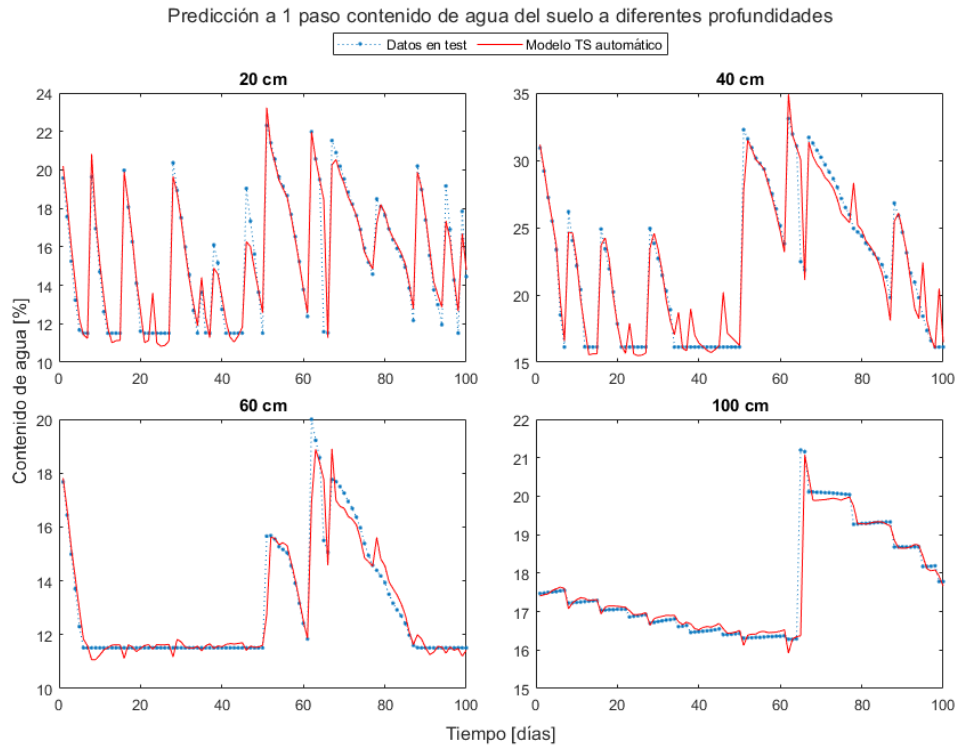


Figura 5.17: Predicción a 1 paso de los contenidos de agua del simulador, en el conjunto de test, usando el modelo TS automático

El rendimiento en el conjunto de test del modelo escogido se presenta en forma gráfica mediante las predicciones a 1 paso y a varios pasos en las Figuras 5.17 y 5.18, respectivamente.

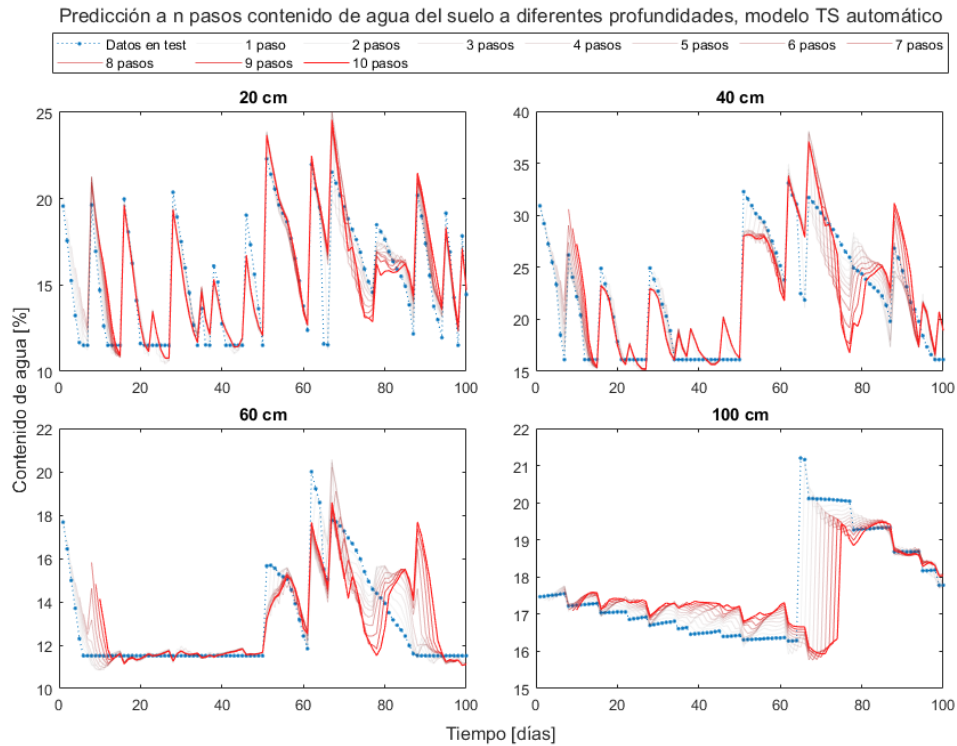


Figura 5.18: Predicción a  $n$  pasos de los contenidos de agua del simulador, en el conjunto de test, usando el modelo TS automático

Además, la Tabla 5.5 presenta los valores del RMSE de predicción del modelo en el conjunto de test para cada nivel de profundidad y para múltiples pasos.

Tabla 5.5: Error RMSE de predicción de test, a múltiples pasos, del modelo TS automático generado usando datos del simulador, para las distintas profundidades, donde 1 paso de predicción corresponde a 1 día

Profundidades	RMSE [%]					
	1 paso	2 pasos	3 pasos	5 pasos	7 pasos	10 pasos
20 cm	0.83	1.06	1.16	1.24	1.28	1.39
40 cm	1.36	1.74	1.92	2.10	2.25	2.56
60 cm	0.55	0.77	0.93	1.09	1.26	1.45
100 cm	0.39	0.55	0.65	0.85	0.99	1.14

#### 5.2.4. Análisis comparativo

Al comparar las curvas de predicción a varios pasos de los modelos lineal y TS desarrollados en esta parte (Figuras 5.16 y 5.18) se observan ciertos comportamientos comunes en todos los niveles, excepto el de 100 cm de profundidad. El modelo lineal tiende a predecir valores más extremos en los peaks y valles, errando además las predicciones en ciertos casos del descenso



de la humedad, mientras que el modelo TS en suele acertar con mayor exactitud los valores altos y bajos, aunque también falla en ocasiones al predecir los descensos del contenido de agua. Por otro lado, las curvas a 100 cm de profundidad tienen un comportamiento similar en ambos modelos.

El RMSE de predicción de cada modelo, hasta 10 pasos de predicción se presenta de forma gráfica en la Figura 5.19, donde se puede notar que el modelo TS tiene un rendimiento superior al modelo lineal, dado que su error de predicción es menor, lo que es especialmente cierto al aumentar los pasos de predicción, con la excepción de la salida a 100 cm, donde el esquema lineal es levemente más certero en predicciones a más pasos.

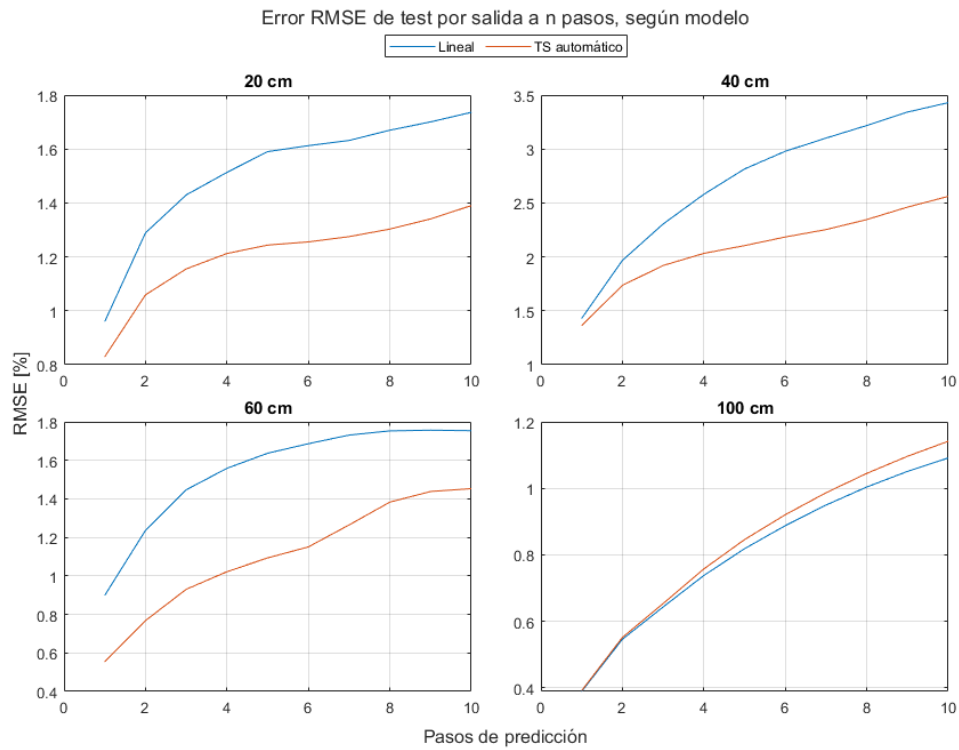


Figura 5.19: Evolución del RMSE de test al variar el número de pasos de predicción, para los modelos desarrollados con los datos del simulador, en cada profundidad

# Capítulo 6

## Control Predictivo

En este capítulo se muestran dos esquemas de control predictivo implementados utilizando los modelos desarrollados en el capítulo anterior y el simulador del perfil del terreno. Ambos diseños intentan mantener el contenido de agua de la tierra por sobre un umbral designado, logrando así que el cultivo pueda desarrollarse correctamente. Además, con el objetivo de mejorar la eficiencia hídrica y de acercar el problema a las condiciones reales del riego del terreno de cultivo, el segundo controlador impone una restricción en la frecuencia del riego, estableciendo una cantidad máxima de instancias de riego durante el horizonte de predicción.

El desarrollo de los controladores se realiza utilizando el software MATLAB [32], y el solver integrado en el Optimization Toolbox [34] *fmincon* usando el algoritmo *sqp*. La elección del solver tiene que ver con la necesidad de resolver problemas de carácter no lineal, y el algoritmo se escoge siguiendo la guía en el sitio de MATLAB [40], probando en un inicio usando el algoritmo *interior-point*, pero obteniendo problemas de factibilidad y rendimiento, de modo que se pasa al siguiente recomendado.

Ambos diseños de control son evaluados utilizando los modelos elaborados anteriormente y el simulador de las dinámicas del viñedo. Los primeros experimentos usan el mismo modelo en el controlador y como planta a controlar, con lo cual se pretende evaluar el buen funcionamiento de los controladores. En esta configuración los controladores son capaces de predecir con certeza los estados futuros, puesto que no hay una discrepancia entre el modelo predictivo y la planta. Tras llevar a cabo esta experiencia con cada uno de los modelos desarrollados, se pasa a utilizar el simulador como planta controlada, pudiendo así evaluar en conjunto el rendimiento de esquemas de control y modelos en una situación más realista. Todas estas pruebas se realizan con la información de una misma temporada de riego de 105 días, es decir, se tiene el mismo punto de partida y las mismas perturbaciones en todos los experimentos anteriormente mencionados.

Finalmente, se realizan comparaciones de los esquemas diseñados con mejor rendimiento,

con un método de control de riego convencional y una temporada de datos reales de riego del viñedo.

Para cada uno de los experimentos se presentan resultados gráficos, mostrando la evolución del contenido de agua del terreno a 20 cm de profundidad, el riego, las precipitaciones y la evapotranspiración, durante una temporada de cultivo. Además, se muestran tablas con los totales de agua usada en mm, número de instancias de riego y cantidad de veces que se estuvo por debajo del umbral definido, para cada experimento. Tanto en las figuras como en las tablas, los resultados son identificadas según el esquema de control usado (MPC con umbral mínimo o MPC con umbral mínimo y restricción de frecuencia de riego) y el modelo usado en el controlador. Para poder presentar los resultados de forma concisa, los modelos son nombrados como se muestra en la Tabla 6.1, donde en primer lugar se tiene la estructura del modelo, lineal o TS (automático o híbrido), y luego entre paréntesis el origen de los datos usados para su desarrollo.

Tabla 6.1: Nomenclatura de los modelos desarrollados modelos, usada en los experimentos subsiguientes

Modelo	Descripción
Lineal (viña)	Modelo lineal diseñado a partir de datos reales recolectados de la viña.
Lineal (simulador)	Modelo lineal diseñado a partir de datos extraídos del simulador de dinámicas del perfil del terreno.
TS auto (viña)	Modelo Takagi-Sugeno diseñado con el método de clustering automático, a partir de datos reales recolectados de la viña.
TS híbrido (viña)	Modelo Takagi-Sugeno diseñado con el método de clustering híbrido, a partir de datos reales recolectados de la viña.
TS auto (simulador)	Modelo Takagi-Sugeno diseñado con el método de clustering automático, a partir de datos extraídos del simulador de dinámicas del perfil del terreno.

## 6.1. MPC con umbral mínimo

El primer esquema de control planteado aborda la necesidad de mantener el contenido de agua del terreno en niveles que permitan a los cultivos desarrollarse de manera correcta. De este modo, en cada paso de predicción del controlador, se intenta mantener el nivel de humedad por sobre el 15 %, correspondiente al umbral de estrés hídrico, a la vez que se trata de consumir la menor cantidad de agua posible.

En una primera instancia, el planteamiento del problema de optimización corresponde al descrito en la Sección 4.5, sin embargo, dados los errores de predicción de los modelos utilizados, al realizar pruebas se llega a circunstancias en que las acciones de control entregadas por

el controlador no son suficientes para mantenerse sobre el umbral. De esta manera, se nota que resulta necesario dar cierta holgura a la restricción del respeto del umbral para mantener la factibilidad. Luego, el problema de optimización es modificado agregando la variable de holgura  $\delta$  para usar un esquema de penalización exacta, permitiendo que, en caso de que se baje del umbral definido, sea debido a perturbaciones o errores de predicción, la optimización siga siendo factible.

$$\begin{aligned}
\min_{\theta, u, \delta} \quad & \sum_{j=0}^{N-1} u_{k+j} + 10^6 \sum_{j=0}^N \delta_{k+j} \\
\text{s.a.} \quad & \theta_{k+j+1} = f(\theta_{k+j}, u_{k+j}, d_{k+j}) \\
& \theta_k = \theta_0 \\
& 0 \leq \theta_{k+j+1} \leq 100 \quad \forall j \in [0, \dots, N-1] \\
& 0 \leq u_{k+j} \leq 30 \\
& 0 \leq \delta_{k+j+1} \leq 5 \\
& \bar{\theta} - \delta_{k+j+1} \leq \theta_{k+j+1}^{20}
\end{aligned} \tag{6.1}$$

En (6.1) se muestra la formulación del problema, correspondiente a un problema de programación lineal, o no lineal, mixta (MILP o MINLP), según el modelo predictivo utilizado. La función objetivo corresponde a la suma de las instancias de riego  $u_{k+j}$  en el horizonte de predicción, y la suma las variables de holgura  $\delta_{k+j}$  según el factor  $10^6$ . El problema está sujeta a restricciones del respeto del modelo predictivo que se esté utilizando (descrito por una función lineal o no lineal  $f(\theta_{k+j}, u_{k+j}, d_{k+j})$ ), la condición inicial, límites superiores e inferiores del contenido de agua, riego y variable de holgura, y la restricción del umbral del contenido de agua  $\bar{\theta}$  a respetar.

Las restricciones de límites superiores e inferiores se definen según el funcionamiento del sistema: la humedad se expresa como un valor porcentual, de modo que está comprendida entre 0 y 100; el riego es siempre 0 o positivo y se le asigna un máximo de 30, puesto que se observa que, según los datos disponibles del sistema (ver Figuras 5.2 y 5.14), riegos de esta magnitud son suficientes para llevar la humedad al nivel que se desee; finalmente, la variable de holgura  $\delta$  es limitada entre 0 y 5, de forma que se permita quedar por debajo del umbral en hasta un 5%, de ser necesario. El límite superior asignado a  $\delta$  se justifica en que al descender un 5% desde el umbral de estrés hídrico, se llega al umbral de marchitez permanente (10% de humedad), de manera que no se permite alcanzar valores tan bajos que el cultivo marchite. Esto reduce también el espacio de soluciones factibles, bajando así el costo computacional de solución.

Cabe mencionar que al plantear la holgura en un esquema de penalización exacta, en teoría, si el problema es factible sin bajar del umbral, entonces la variable  $\delta$  toma el valor 0, al ser altamente penalizada en la función objetivo, de tal manera que el problema corresponde

a aquel sin holgura.

El sistema de control puede ser representado por el diagrama de bloques mostrado en la Figura 6.1, donde el controlador recibe los valores del umbral a respetar, el estado actual de humedad y las perturbaciones medidas (precipitaciones y evapotranspiración), calculando la acción de control a utilizar en la planta.




Figura 6.1: Diagrama de bloques del sistema

### 6.1.1. Control sobre los modelos

Las pruebas del esquema de control comienzan utilizando los modelos en el controlador y como planta controlada, de tal manera que el controlador es capaz de predecir de manera perfecta las dinámicas de la planta. Esta configuración permite realizar un análisis del funcionamiento del controlador que no se ve afectado por la calidad del modelo utilizado. Los resultados son mostrados a continuación para los modelos lineales y difusos, usando en cada caso un horizonte de predicción de 7 días.

## Modelos lineales




Figura 6.2: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo lineal identificado a partir de los datos de la viña como planta y modelo en el controlador.  $N = 7$




Figura 6.3: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo lineal identificado a partir de los datos del simulador como planta y modelo en el controlador.  $N = 7$

## Modelos difusos

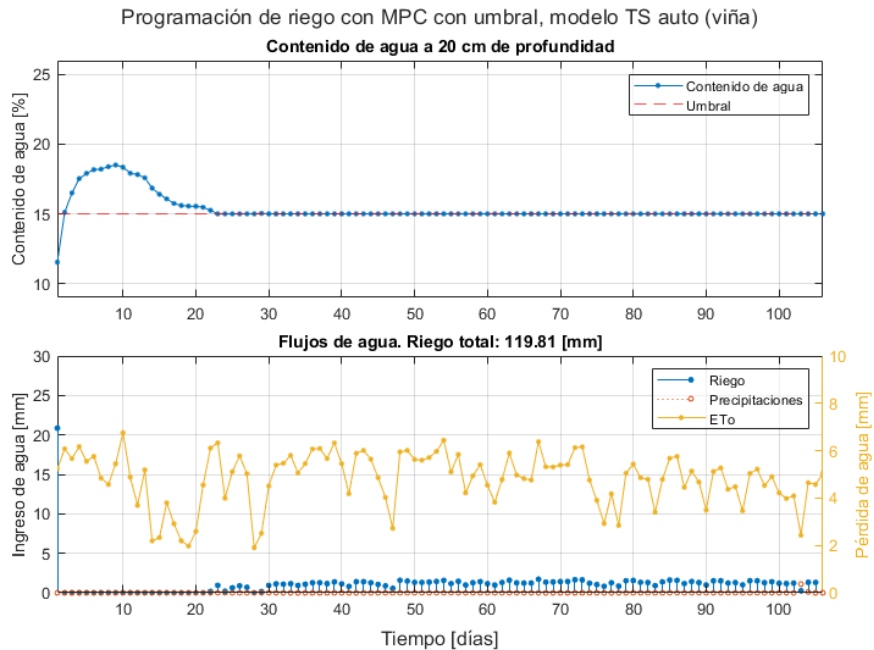


Figura 6.4: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo TS automático identificado a partir de los datos de la viña como planta y modelo en el controlador.  $N = 7$

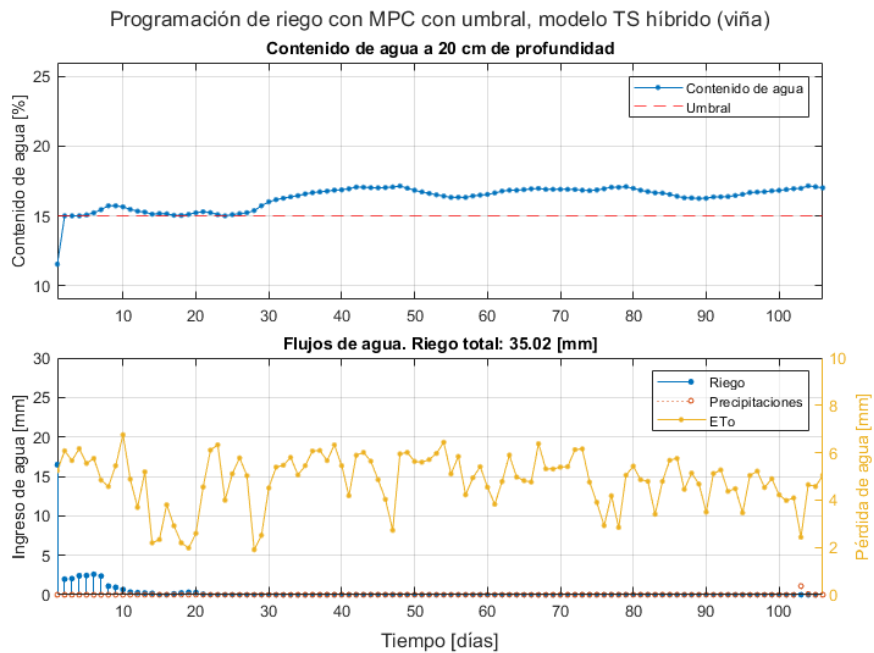


Figura 6.5: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo TS híbrido identificado a partir de los datos de la viña como planta y modelo en el controlador.  $N = 7$




Figura 6.6: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, usando el modelo TS automático identificado a partir de los datos del simulador como planta y modelo en el controlador.  $N = 7$

### 6.1.2. Control sobre el simulador

Tras comprobar el funcionamiento del esquema con cada modelo identificado, se pasa a realizar experimentos controlando el simulador. Se prueba usando cada uno de los modelos en el controlador durante una temporada idéntica. Nótese que las temporadas en el simulador aparecen comenzando en el día número 50 y terminando en el 155, esto se debe a configuraciones internas del simulador.



## Modelos lineales

Programación de riego con MPC con umbral, modelo lineal (viña)




Figura 6.7: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo lineal identificado a partir de los datos de la viña.  $N = 7$

Programación de riego con MPC con umbral, modelo lineal (simulador)




Figura 6.8: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo lineal identificado a partir de los datos del simulador.  $N = 7$

# Modelos difusos

Programación de riego con MPC con umbral, modelo TS auto (viña)




Figura 6.9: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo TS automático identificado a partir de los datos de la viña.  $N = 7$

Programación de riego con MPC con umbral, modelo TS híbrido (viña)




Figura 6.10: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo TS híbrido identificado a partir de los datos de la viña.  $N = 7$

### Programación de riego con MPC con umbral, modelo TS auto (simulador)




Figura 6.11: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad, controlando el simulador usando el modelo TS automático identificado a partir de los datos del simulador.  $N = 7$

### 6.1.3. Análisis de resultados

En primer lugar, al utilizar los modelos identificados en el controlador y en la planta, todos los resultados muestran que, después del punto inicial, el umbral es siempre respetado, con algunas variaciones respecto a la estrategia de riego. Los modelos diseñados a partir de los datos reales de la viña tienen cierta tendencia a estimar valores superiores al umbral, de manera que se tiene segmentos en que, a pesar de no regar, la humedad se mantiene sobre el umbral (Figuras 6.2, 6.4, 6.5). Este comportamiento coincide con los análisis realizados en el Capítulo 5, donde se estima que los datos obtenidos de la viña no muestran todas las dinámicas del sistema, al concentrarse en puntos de funcionamiento que favorecen el desarrollo de los cultivos, dejando así una infrarrepresentación de valores cercanos, o bajo el umbral de estrés hídrico, lo que impacta negativamente las predicciones de los modelos para niveles cercanos a este.

La determinación de que el fenómeno anterior se debe a un error de los modelos se sustenta en que la temporada simulada corresponde a un periodo con alta evapotranspiración y casi sin precipitaciones, de forma que, comparando con los datos de las Figuras 5.1, 5.2, 5.13 y 5.14, se nota que en los periodos de temporada (momentos en que hay riegos) la humedad tiene una alta tendencia al descenso, y que los valores altos de humedad obtenidos en dichos periodos ocurren solo tras instancias de riego o precipitaciones.




Figura 6.12: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y costo modificado para penalizar solo el riego instantáneo, usando el modelo TS automático identificado a partir de los datos del simulador como planta y modelo en el controlador.  $N = 7$

Los modelos desarrollados usando datos del simulador, por otra parte, requieren de riego constante para mantener valores iguales o superiores al umbral. Además, los experimentos realizados con estos modelos muestran un comportamiento en que la humedad, en vez de mantenerse exactamente en el umbral, se mantiene en niveles ligeramente superiores a este; lo que se debe a la capacidad del optimizador de predecir los instantes futuros y optimizar el uso de agua acorde a las condiciones que se tendrá más adelante, esto es validado mediante un experimento en que se modifica la función de costos de tal manera que solo se penalice el uso de agua instantáneo y no los usos futuros.

El resultado de esta experiencia se muestra en la Figura 6.12, donde se observa que el contenido de agua es mantenido exactamente en el umbral todo el tiempo y que el riego total es de 432.27 mm, cifra ampliamente mayor a los 272.21 mm usados en el caso normal, lo cual permite observar el efecto de la optimización del uso de agua durante todo el horizonte de predicción, pues al no considerar los riegos futuros en el costo, se puede decidir regar más en ellos, privilegiando un riego menor en el instante presente, sin embargo, al avanzar en el tiempo, se llega a los puntos en que se debe regar más, siendo este entonces un ejercicio que resulta contraproducente.

Al utilizar el simulador como planta los resultados difieren de los anteriores, debido a la diferencia entre los modelos utilizados y las dinámicas del simulador. Al tener modelos que estiman las dinámicas de la planta de manera imperfecta, se tiene errores en las predicciones

futuras, tal como se vio al evaluar el rendimiento de los modelos en el capítulo anterior. Luego, la exactitud del modelo designa ciertos aspectos del rendimiento del controlador.

Tabla 6.2: Valores relevantes de los experimentos de MPC con umbral mínimo usando el simulador como planta, con  $N = 7$

Modelo	Uso de agua [mm]	Nº de riegos	Días bajo umbral
Lineal (viña)	428.84	89	70
Lineal (simulador)	515.26	104	26
TS auto (viña)	437.96	73	45
TS híbrido (viña)	409.95	58	56
TS auto (simulador)	531.69	102	5

De manera similar a los experimentos previos, al usar los modelos identificados a partir de los datos de la viña el desempeño del controlador puede diferenciarse claramente del obtenido usando los modelos diseñados con las muestras del simulador. En el primer grupo mencionado, el contenido de agua tiende a oscilar en torno al umbral, quedando bajo este en múltiples ocasiones. Mientras que en el segundo grupo de experimentos el nivel de humedad es mantenido sobre el umbral la mayor parte del tiempo. Esto conlleva, no obstante, un mayor uso de agua y un número superior de días con irrigación, como se ve en la Tabla 6.2, donde se presentan los valores del riego total en mm, la cantidad de instancias de riego y el total de días bajo el umbral de estrés hídrico en los experimentos con el simulador como planta. En dicha tabla, los valores de la columna *Modelo* se presentan según la nomenclatura detallada en la Tabla 6.1, con el origen de los datos usados en el desarrollo del modelo correspondiente entre paréntesis.

Cabe destacar que en todos los casos se tiene al menos 2 días bajo el umbral. Esto es debido a la configuración del simulador, donde el punto inicial corresponde a un 11.58% de humedad y la primera decisión de riego se impone con valor nulo.

## 6.2. MPC con umbral mínimo y restricción de frecuencia de riego

Una de las principales limitaciones para el riego en el viñedo modelado es de carácter material, puesto que no se tiene la capacidad de regar todo el terreno todos los días, de manera que las instancias de riego son dispersas. Luego, el segundo planteamiento de control predictivo agrega restricciones al anterior, acercándolo a las restricciones reales de los agricultores locales, al imponer una cantidad máxima de instancias de riego en cada ventana de predicción.

El problema de optimización de este esquema se muestra en (6.2), y corresponde a una variación del primer MPC diseñado (ver (6.1)), incorporando dos restricciones nuevas que permiten limitar la cantidad de veces que se riega durante el horizonte de predicción, al utilizar una variable binaria  $b$  que toma valores 1 cuando se permite el riego y 0 en el caso contrario. Al igual que con el método anterior, se utiliza la variable de holgura  $\delta$  según un esquema de penalización exacta para poder mantener la factibilidad del problema en los experimentos.

$$\begin{aligned}
& \min_{\theta, u, \delta, b} \quad \sum_{j=0}^{N-1} u_{k+j} + 10^6 \sum_{j=0}^N \delta_{k+j} \\
& \text{s.a.} \quad \theta_{k+j+1} = f(\theta_{k+j}, u_{k+j}, d_{k+j}) \\
& \quad \theta_k = \theta_0 \\
& \quad 0 \leq \theta_{k+j+1} \leq 100 \quad \forall j \in [0, \dots, N-1] \\
& \quad 0 \leq u_{k+j} \leq 30 \\
& \quad 0 \leq \delta_{k+j+1} \leq 5 \\
& \quad u_{k+j} \leq b_{k+j} M \\
& \quad \sum_{i=j}^{N-2} u_{mem_{k+i}} + \sum_{i=0}^j b_i \leq dias_{max} \\
& \quad \bar{\theta} - \delta_{k+j+1} \leq \theta_{k+j+1}^{20}
\end{aligned} \tag{6.2}$$

La primera restricción añadida involucra el uso del método de la gran M explicado en la Sección 4.6, el cual depende de la variable binaria  $b$ . Para que el optimizador pueda decidir en qué días regar correctamente, necesita tener acceso a un historial o memoria de riegos recientes. Luego, la segunda restricción agregada utiliza una variable de memoria, llamada  $u_{mem}$ , que guarda las últimas  $N-1$  instancias de riego en forma binaria de la misma manera que  $b$  (1 si hubo irrigación, 0 si no), para así verificar que en cada ventana de  $N$  días la suma de la cantidad de riegos anteriores y de los riegos planeados en el horizonte de predicción no sean superiores al límite  $dias_{max}$  establecido.

Este problema de optimización, al requerir la utilización de variables binarias, no es directamente aplicable con el método *fmincon* que se usó con el controlador anterior, sin embargo, se tuvo dificultad a la hora de encontrar un solver no lineal capaz de utilizar variables binarias y que sea funcional en Linux. De este modo, para poder aplicar el problema de optimización utilizando *fmincon*, se plantea un algoritmo que utiliza la variable binaria  $b$  como un arreglo definido por múltiples posibles combinaciones de valores binarios de largo  $N$ .

Así, se define el Algoritmo 1 como el procedimiento a seguir en cada paso de predicción, de manera que para cada combinación de valores binarios  $b$  válida se resuelve el problema de optimización (6.2), pero sin usar  $b$  como una variable de optimización, puesto que es

usada con valores fijos. Las soluciones del problema son guardadas, con  $z_b$  la trayectoria de valores de  $\theta$ ,  $u$  y  $\delta$ , y  $J_b$  el valor de los costos evaluados de la solución. Tras evaluar todas las combinaciones binarias aceptables para  $b$ , el resultado final  $z$  es asignado como aquella instancia de  $z_b$  que corresponde al menor costo  $J_b$ .

---

**Algoritmo 1** Paso de MPC con restricción de frecuencia de riego

---

- 1: Definir  $b_{list}$  como la lista de  $N_b$  combinaciones binarias  $b$  de largo  $N$  que cumplen:  $\sum b \leq dias_{max}$
  - 2: **for**  $i \leftarrow 1, N_b$  **do**
  - 3:      $b \leftarrow b_{list}(i)$
  - 4:     Resolver el problema (6.2) con  $b$  fijo
  - 5:     Guardar los resultados de la optimización:  $(z_b(i), J_b(i))$
  - 6: **end for**
  - 7: Buscar el índice  $j$  del menor costo  $J_b$
  - 8:  $z \leftarrow z_b(j)$
- 

De manera gráfica, el esquema de control se puede representar según el diagrama de bloques mostrado en la Figura 6.13, donde, respecto al diagrama del método anterior (Figura 6.1), se añade un bloque de memoria que guarda las últimas realizaciones de la acción de control y las entrega al controlador.

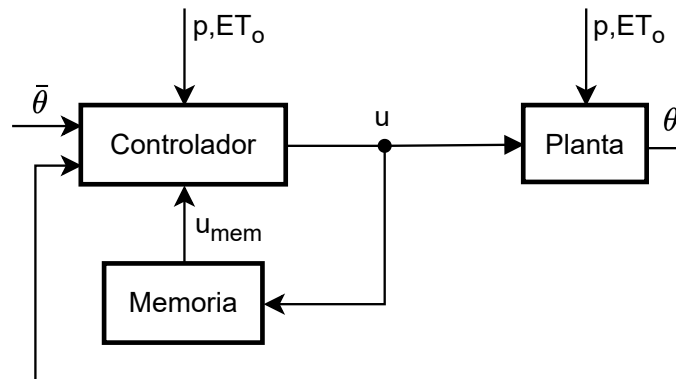


Figura 6.13: Diagrama de bloques del sistema

### 6.2.1. Control sobre los modelos

De forma similar a la utilizada en los experimentos con el método de control previo, se comienza usando los modelos como base del controlador y como planta, validando la buena implementación del esquema de control y planteando un ideal del funcionamiento de este. A continuación se muestran los resultados de las pruebas del MPC usando un horizonte de predicción de 7 días, con un máximo de 2 días de riego en el horizonte.

## Modelos lineales

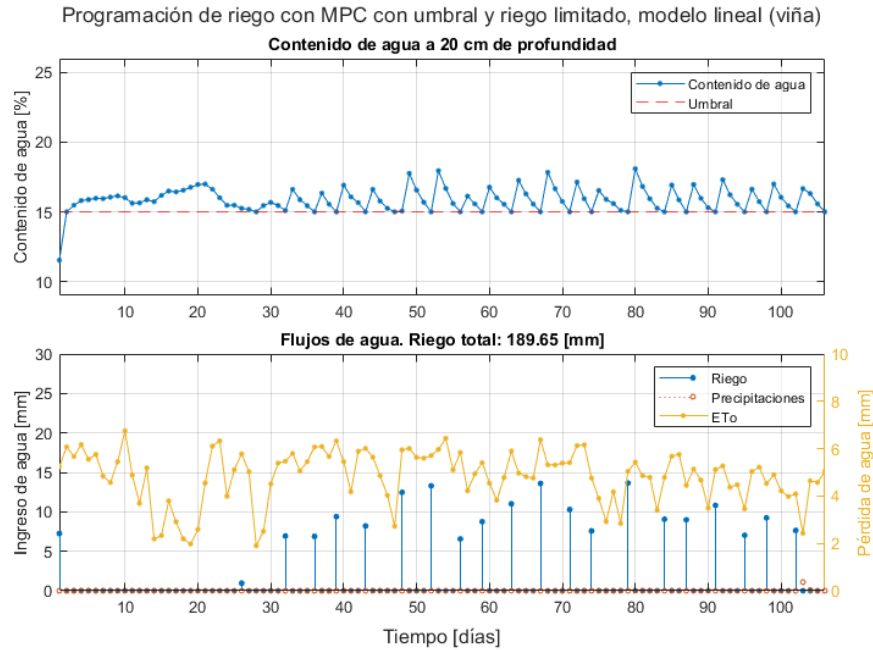


Figura 6.14: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo lineal identificado a partir de los datos de la viña como planta y modelo en el controlador.  $N = 7$ ,  $dias_{max} = 2$

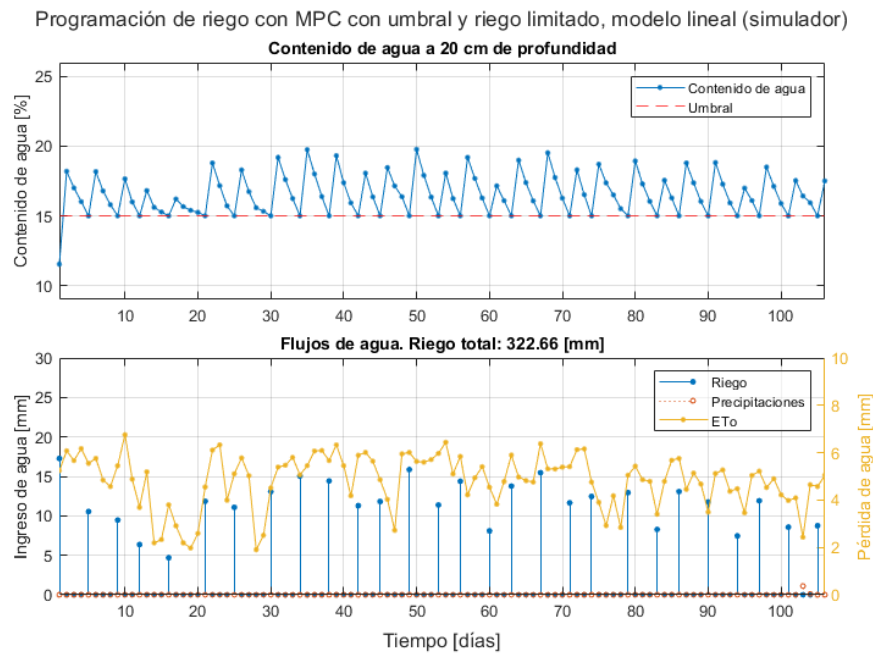


Figura 6.15: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo lineal identificado a partir de los datos del simulador como planta y modelo en el controlador.  $N = 7$ ,  $dias_{max} = 2$



## Modelos difusos




Figura 6.16: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo TS automático identificado a partir de los datos de la viña como planta y modelo en el controlador.  $N = 7$ ,  $dias_{max} = 2$




Figura 6.17: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo TS híbrido identificado a partir de los datos de la viña como planta y modelo en el controlador.  $N = 7$ ,  $dias_{max} = 2$

Programación de riego con MPC con umbral y riego limitado, modelo TS auto (simulador)

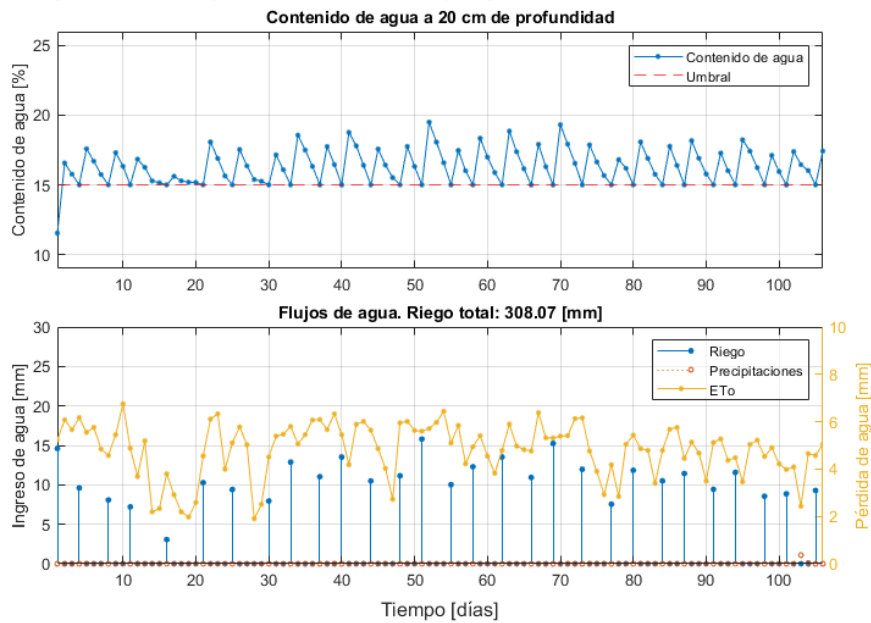


Figura 6.18: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, usando el modelo TS automático identificado a partir de los datos del simulador como planta y modelo en el controlador.  $N = 7$ ,  $dias_{max} = 2$

### 6.2.2. Control sobre el simulador

Las siguientes figuras muestran los resultados de experimentos usando el controlador en el simulador, durante una temporada idéntica a las pruebas anteriores.

## Modelos lineales

Programación de riego con MPC con umbral y riego limitado, modelo lineal (viña)




Figura 6.19: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo lineal identificado a partir de los datos de la viña.  $N = 7$ ,  $dias_{max} = 2$

Programación de riego con MPC con umbral y riego limitado, modelo lineal (simulador)




Figura 6.20: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo lineal identificado a partir de los datos del simulador.  $N = 7$ ,  $dias_{max} = 2$

## Modelos difusos

Programación de riego con MPC con umbral y riego limitado, modelo TS auto (viña)




Figura 6.21: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos de la viña.  $N = 7$ ,  $dias_{max} = 2$

Programación de riego con MPC con umbral y riego limitado, modelo TS híbrido (viña)




Figura 6.22: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS híbrido identificado a partir de los datos de la viña.  $N = 7$ ,  $dias_{max} = 2$




Figura 6.23: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos del simulador.  $N = 7$ ,  $dias_{max} = 2$

### 6.2.3. Análisis de resultados

Las pruebas con los modelos en el controlador y como planta controlada permiten observar un comportamiento *ideal* del controlador, donde las predicciones realizadas por este corresponden exactamente a los resultados que se obtendrían según la trayectoria de acciones de control calculada. De este modo, en todos los casos evaluados el nivel de humedad se mantiene correctamente sobre el umbral del 15 % (ver Figuras 6.14, 6.15, 6.16, 6.17 y 6.18). Cuando el contenido de agua baja a niveles cercanos al umbral o cae directamente en este, el controlador impone una cantidad de riego suficiente para aumentar la humedad del terreno por un número de días adecuado para cumplir con la restricción de la frecuencia del riego, obteniendo entonces una serie de peaks altos seguidos de algunos días de descenso hasta el umbral de estrés hídrico.

Al igual que con la estrategia de control de la sección anterior, los modelos basados en los datos reales de la viña tienen momentos en que la humedad se mantiene sobre el umbral sin necesidad de riego, y esto se debe simplemente a las dinámicas de estos modelos.

Cuando se usa el simulador como planta ya no se tiene el caso ideal, y el controlador presenta errores de predicción, más o menos graves dependiendo del modelo utilizado. Por una parte, con los modelos lineal y TS híbrido identificados usando los datos reales de la viña (Figuras 6.14 y 6.17) los errores de predicción son serios, y llevan a tramos de múltiples

días consecutivos bajo el umbral de estrés hídrico (hasta 20 con el modelo lineal), poniendo en grave riesgo el desarrollo del cultivo. Por otra parte, al usar los modelos TS automático basado en datos de la viña y los modelos desarrollados con las muestras del simulador, el rendimiento es más cercano al ideal, con pocas instancias donde se queda bajo el umbral y con totales de riego inferiores a los encontrados con el esquema de control sin límites de frecuencia de riego (ver Tabla 6.2). La Tabla 6.3 muestra la irrigación total, número de instancias de riego y total de días bajo el umbral para cada experimento de control con el simulador como planta durante una temporada de 105 días. Nuevamente, los valores de la columna *Modelo* se presentan según la nomenclatura expuesta en la Tabla 6.1.

Tabla 6.3: Valores relevantes de los experimentos de MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con  $N = 7$  y  $dias_{max} = 2$

Modelo	Uso de agua [mm]	Nº de riegos	Días bajo umbral
Lineal (viña)	265.3	30	87
Lineal (simulador)	383.9	27	8
TS auto (viña)	379.5	25	6
TS híbrido (viña)	261.7	28	63
TS auto (simulador)	378.2	29	6

Los mejores resultados se obtienen al utilizar los modelos TS automáticos, cayendo bajo el umbral en sólo seis ocasiones durante la temporada, dos de las cuales se deben a la configuración inicial del simulador. En particular, el controlador que usa el modelo TS automático identificado con los datos de la viña ofrece el mejor rendimiento, usando 3.2 mm menos de agua que al usar el TS automático basado en datos del simulador.

### 6.3. Comparación con otras técnicas de riego

Finalmente, en esta sección se compara el rendimiento de las técnicas de riego estudiadas con una estrategia de riego convencional implementada con el simulador en [7], y con datos reales de temporadas de cultivo del viñedo. Este último ejercicio se realiza pretendiendo que el simulador es directamente comparable con el terreno de cultivo real de la viña, sin embargo, esto no es estrictamente cierto y se debe considerar a la hora de analizar los resultados.

Se deseaba también establecer una comparación con otra técnica diseñada en [7], basada en aprendizaje reforzado, sin embargo, el simulador del perfil de riego ha sido actualizado desde dicha aplicación, de modo que ya no se tiene la capacidad de contrastar de forma válida los rendimientos de dicha estrategia de riego con las desarrolladas en este capítulo.

### 6.3.1. Riego convencional

La estrategia de riego convencional considerada es aquella mencionada al final de la Sección 3.1, consistente de riegos de un 35% de la cantidad necesaria para llevar el terreno a capacidad de campo cuando el contenido de agua baja del umbral de estrés hídrico, y solo si han pasado al menos 5 días desde la última instancia de riego. Además, para poder realizar una comparación más justa con las estrategias de irrigación desarrolladas en este capítulo, se limita el riego a un máximo de 30 mm en cada ocasión. Esta programación se ve reflejada en la Figura 6.24, donde se utiliza un total de 365.31 mm de agua para intentar mantener la humedad del terreno en rangos adecuados.

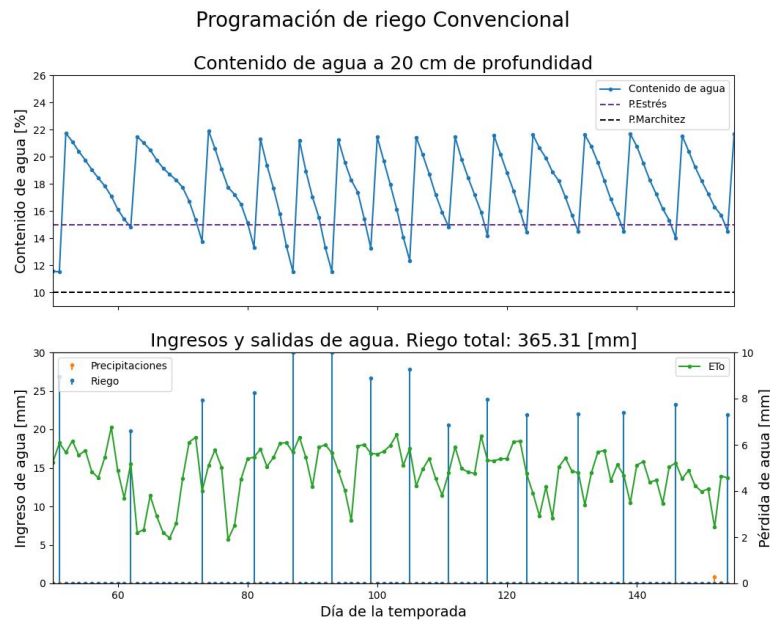


Figura 6.24: Programación de riego convencional de una temporada, controlando el simulador

Para establecer una comparación con la estrategia convencional de riego, se utiliza el esquema de control predictivo con restricción de la frecuencia de riego, usando un horizonte de predicción de 6 días con un máximo de 1 riego durante cada horizonte. Así, se acerca el esquema a las limitaciones establecidas con la programación convencional. Luego, esta configuración es usada para controlar el simulador usando ambos modelos TS automáticos para las predicciones del controlador. El uso de estos dos modelos tiene que ver con que corresponden a aquellos que entregaron un mejor rendimiento en los experimentos anteriores (ver Tabla 6.3). Las Figuras 6.25 y 6.26 muestran los resultados de la prueba utilizando los modelos basado en los datos de la viña y del simulador, respectivamente.

Ambas pruebas con MPC presentan curvas de humedad similares, teniendo los peores

resultados en la zona entre los días 80 y 100, donde se tienen contenidos de agua bajo el umbral por dos o más días consecutivos, en más de una ocasión. Verificando las predicciones de los controladores se observa que ambos controladores, durante este periodo que presenta los niveles más altos de evapotranspiración, predicen que no serán capaces de mantener el contenido de agua sobre el umbral durante todo el horizonte de predicción, de manera que la decisión que toman intenta quedar lo más cerca del umbral por debajo cuando no haya alternativa, y usando la menor cantidad de agua posible. Esto muestra que la restricción en la frecuencia del riego resulta demasiado fuerte y que la cantidad máxima de riego no resulta suficiente para poder mantener la humedad sobre el umbral durante los intervalos entre las instancias de irrigación.

Programación de riego con MPC con umbral y riego limitado, modelo TS auto (viña)




Figura 6.25: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos de la viña.  $N = 6$ ,  $dias_{max} = 1$



Programación de riego con MPC con umbral y riego limitado, modelo TS (simulador)

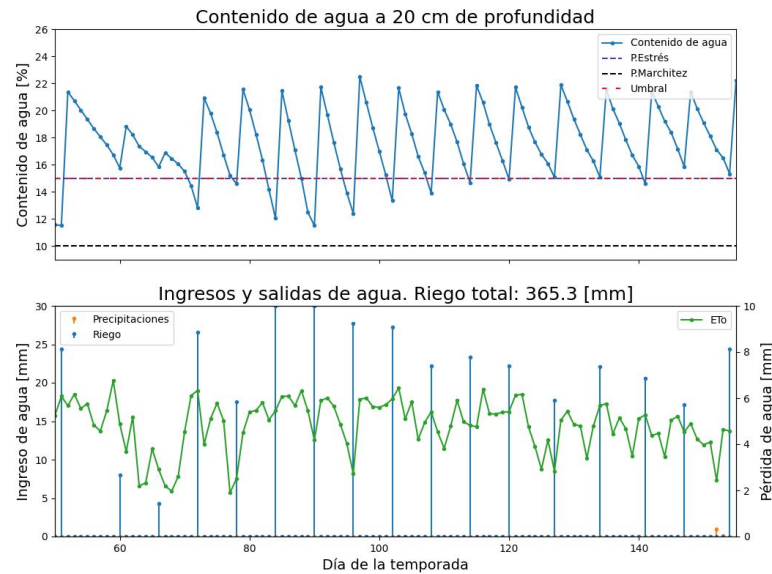


Figura 6.26: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos del simulador.  $N = 6$ ,  $dias_{max} = 1$

Cuantitativamente, la Tabla 6.4 compara el riego total, la cantidad de instancias de riego y el total de días pasados bajo el umbral, según las tres estrategias utilizadas para controlar el simulador. De esta forma se puede apreciar que los tres esquemas usan cantidades de agua muy similares, y que las ventajas y desventajas que ofrece cada método de riego tienen que ver con el total de instancias de riego y el respeto del umbral. El riego convencional riega en menos ocasiones, pero requiere bajar del umbral para tomar la decisión de riego, de modo que pasa numerosos instantes bajo el umbral. Los MPC usados permiten respetar el umbral con mayor frecuencia, con la desventaja de regar en más ocasiones. Luego se verifica que el método con control predictivo ofrece mejores resultados que el esquema convencional, con los dos modelos utilizados, usando una cantidad de agua ligeramente inferior al método convencional y cayendo bajo el umbral establecido menos frecuentemente.

Tabla 6.4: Valores relevantes de los experimentos con programación convencional y basada en MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con  $N = 6$  y  $dias_{max} = 1$

Esquema	Uso de agua [mm]	Nº de riegos	Días bajo umbral
Convencional	365.31	15	20
MPC TS auto (viña)	364.40	17	12
MPC TS auto (simulador)	365.30	17	16

### 6.3.2. Riego utilizado en la viña

La estrategia de riego utilizada en la viña durante las temporadas muestreadas irriga el terreno de tal manera que el nivel de humedad no llegue al umbral de estrés hídrico, regando esporádicamente y, usualmente, durante dos días consecutivos.

Las temporadas de riego del conjunto de datos de la viña no coinciden exactamente, en cuanto a fechas, con aquellas estudiadas con el simulador. Luego, para facilitar la comparación, en la Figura 6.27 se muestra un periodo de 105 días de una temporada del viñedo, equivalente a una temporada del simulador utilizada en las Figuras 6.28 y 6.29. Estas últimas figuras muestran los resultados de la aplicación del método de riego basado en MPC con restricción de frecuencia del riego al simulador, utilizando un horizonte de predicción de 7 días con máximo 2 días de riego en este, usando los modelos TS automáticos basados en los datos de la viña y del simulador, respectivamente.




Figura 6.27: Programación de riego en la viña de una temporada equivalente a una simulada

Programación de riego con MPC con umbral y riego limitado, modelo TS auto (viña)




Figura 6.28: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos de la viña.  $N = 7$ ,  $dias_{max} = 2$

Programación de riego con MPC con umbral y riego limitado, modelo TS (simulador)




Figura 6.29: Programación de riego de una temporada utilizando MPC con umbral mínimo de humedad y restricción de frecuencia de riego, controlando el simulador usando el modelo TS automático identificado a partir de los datos del simulador.  $N = 7$ ,  $dias_{max} = 2$

Para realizar la comparación primero se debe destacar un aspecto de los experimentos en simulación, el punto de inicio que se observa en las figuras es distinto al visto en los datos de la viña, y tiene que ver con configuraciones internas del simulador que llevan al estado inicial de la temporada de riego a un punto bajo el umbral. Además, el simulador sigue teniendo ciertas diferencias con el terreno real, inherentes a un ejercicio de simulación. De este modo el contraste de los rendimientos debe tener en cuenta estos aspectos.

Tabla 6.5: Valores relevantes del control de riego aplicado en la viña y los experimentos con programación basada en MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con  $N = 7$  y  $días_{max} = 2$

Esquema	Uso de agua [mm]	Nº de riegos	Días bajo umbral
Viñedo	391.06	26	0
MPC TS auto (viña)	388.80	25	11
MPC TS auto (simulador)	383.30	27	9

Al comparar los resultados de estos experimentos se nota, en primer lugar, que la estrategia utilizada en la viña no permite que la humedad baje del umbral en ningún instante, mientras que los controladores encuentran ciertos problemas en ocasiones, dejando caer el contenido de agua más allá del umbral. Como se muestra en la Tabla 6.5, el total de agua usada y la cantidad de veces que se riega es similar en los tres casos, con una leve ventaja en el uso de agua en los riegos que usan control predictivo.

## 6.4. Costos computacionales

Los experimentos anteriores requieren la resolución de problemas de optimización en 105 iteraciones, de manera que imponen costos computacionales no despreciables. No obstante, dado que el riego del terreno de cultivo se planifica diariamente, ninguno de los tiempos de resolución presentados enseguida implica un problema para la aplicación de los esquemas de control desarrollados.

A continuación se muestran algunos de los tiempos de resolución que resultan más relevantes para la aplicación de los controladores. La totalidad de los tiempos de computación pueden encontrarse en el Anexo B.

Tabla 6.6: Tiempo de computación de los experimentos de MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, para los modelos TS automáticos, con distintos valores de  $N$  y  $dias_{max}$

Esquema	Tiempo total [s]	Tiempo medio iteración [s]
TS auto (viña), $N = 7, dias_{max} = 2$	477.62	4.55
TS auto (viña), $N = 6, dias_{max} = 1$	67.96	0.65
TS auto (simulador), $N = 7, dias_{max} = 2$	488.76	4.65
TS auto (simulador), $N = 6, dias_{max} = 1$	47.80	0.46

Los experimentos de MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta son los más costosos computacionalmente, puesto que implican la aplicación del Algoritmo 1 para limitar la frecuencia del riego según se desee. Cada instancia del problema de optimización implica la resolución de  $\sum_{k=0}^{dias_{max}} \binom{N}{k}$  sub-problemas de optimización adicionales. De esta manera, los valores del horizonte de predicción,  $N$ , y la cantidad máxima de días de riego en dicho horizonte,  $dias_{max}$ , afectan de manera significativa el esfuerzo computacional requerido para la resolución del problema principal.

La Tabla 6.6 presenta algunos de los tiempos de computación del experimento discutido, con dos configuraciones para los valores de  $N$  y  $dias_{max}$ . Se observa que el tiempo de ejecución en las experiencias que usan un horizonte más largo y que permiten más días de riego en el horizonte, es significativamente mayor al tiempo de los otros experimentos, aun usando los mismos modelos. Sin embargo, en estos casos, los tiempos de resolución de cada iteración del problema principal siguen siendo órdenes de magnitud inferiores al tiempo disponible entre instancias de irrigación (1 día). En caso de requerir el uso de valores mayores de  $N$  y  $dias_{max}$ , se debe considerar que el tiempo de computación puede aumentar en gran medida.

# Capítulo 7

## Conclusiones

En esta memoria de título se planteó el diseño de controladores predictivos difusos, con el objetivo de mejorar la eficiencia del uso de agua de riego en una vinícola. Para esto se utilizaron datos del contenido y flujos de agua provenientes de un viñedo en la sexta región del país y de un simulador del perfil del terreno de la viña, usando modelos no lineales en variables de estado del tipo Takagi-Sugeno; para luego utilizar dichos modelos como parte de dos esquemas de control predictivo. El primer diseño de control busca trayectorias del contenido de agua y del riego que minimicen el uso de agua, según el modelo predictivo que se use, de tal manera que el contenido de agua no baje de un umbral determinado. El segundo esquema de control, usa la misma estrategia que el anterior, pero añade restricciones en la frecuencia del riego, acercando el problema a las condiciones reales de los agricultores locales.

Sobre la base de los resultados obtenidos con los esquemas de control diseñados se resalta, en primer lugar, que el desempeño en predicción de los modelos identificados es deficiente, tanto a partir de los datos reales de la viña como de las muestras generadas con el simulador, induciendo errores en las decisiones tomadas durante la programación del riego. Al usar información generada con el simulador se descarta que los problemas de exactitud de los modelos tengan relación con un conjunto de datos muy pequeño o poco representativo de las dinámicas del sistema; aunque sí se constata que el uso de un conjunto de datos de mayor calidad permite que el rendimiento mejore. Luego, se hipotetiza que los problemas de rendimiento pueden relacionarse con la estructura seleccionada para los modelos, más que con la disponibilidad de datos.

No obstante lo anterior, cabe destacar que la capacidad de aproximar el sistema de los modelos Takagi-Sugeno diseñados mediante el proceso de identificación basado únicamente en datos, denominado *automático*, es notablemente mejor que la de los modelos lineales. Siendo los modelos TS aquellos que ofrecieron un mejor rendimiento al ser usados en los esquemas de control.

Por otra parte, el uso del esquema de identificación TS *híbrido*, vale decir, aquel en que se utilizó conocimiento del sistema en conjunto con datos de este, permitió verificar la intuitividad de las estructuras difusas de este tipo, al plantear una aproximación más práctica a la identificación. El modelo obtenido mediante este método, a pocos pasos de predicción, aproxima las dinámicas del sistema con exactitud similar a la obtenible mediante métodos algorítmicos más complejos como la implementación *automática* también utilizada. Pese a esto, a múltiples pasos de predicción, el rendimiento del modelo TS diseñado con la modalidad híbrida decae rápidamente, de modo que, en su estado actual, no resulta útil en el contexto de control predictivo.

El estudio de los controladores se realizó según dos escenarios, el primero de los cuales propone experimentos en que el modelo predictivo del controlador es también usado como la planta a controlar. De esta manera, se busca evaluar el desempeño de los esquemas de control directamente, sin los errores introducidos por los modelos de predicción. En cuanto a los resultados de estos experimentos, se remarca que el rendimiento de los controladores es sobresaliente, cumpliendo con las restricciones impuestas sin problemas y utilizando una cantidad de agua mínima según el modelo predictivo usado.

El segundo escenario de los experimentos de control hace uso del simulador como planta, y entrega resultados variados según el modelo usado para predecir los estados del sistema. En general, al utilizar los modelos lineales el rendimiento es inferior al logrado empleando sus homólogos difusos. Además, al usar los modelos predictivos diseñados usando muestras reales de la viña, se tiene un mayor error de predicción y, por lo tanto, un peor desempeño en el control del riego que al usar los modelos desarrollados a partir de los datos del simulador. Luego, se logra validar que, tanto la aplicación de identificación difusa, como el uso de una base de datos más extensiva y diversa, ofrecen resultados superiores para este tipo de sistema.

Al contrastar el desempeño de las estrategias de riego desarrolladas con un método convencional y el utilizado en la viña, se observó que aun con los problemas de predicción de los modelos, los resultados son semejantes a los obtenidos con los métodos comparados. En la primera de estas comparaciones se verifica que el método de control predictivo con restricciones en la frecuencia del riego logra un rendimiento superior a la estrategia convencional, usando una cantidad de agua ligeramente inferior y manteniendo el contenido de agua del terreno en rangos más adecuados para los cultivos. Por otro lado, al comparar con los datos disponibles de una temporada de cultivo de la viña, se observa que se consigue disminuir el uso de agua, a costa de estresar el cultivo ocasionalmente.

Finalmente, respecto al cumplimiento de los objetivos establecidos, a partir de los resultados y el análisis anterior, se concluye que el objetivo general fue cumplido parcialmente. El segundo esquema de control diseñado muestra un rendimiento superior al método convencional estudiado, incluso utilizando modelos predictivos que no logran predecir los estados futuros con suficiente certeza. Luego, se estima que, disponiendo de modelos predictivos de

mayor calidad, el controlador tendría un rendimiento superior, aunque esto no es comprobable con los modelos actuales. De esta manera, si bien los objetivos específicos son cumplidos, y la estructura del controlador es adecuada, los modelos identificados no son suficientemente certeros en sus predicciones para permitir al controlador estimar de buena manera las condiciones futuras y decidir pertinentemente.

## 7.1. Trabajos futuros

En virtud de los resultados conseguidos, ciertos aspectos destacan como posibles puntos de mejora. El primero de estos, considerando una estrategia de control predictivo, corresponde a la necesidad de usar métodos de identificación más robustos para obtener mejores predicciones de los estados futuros del sistema. Adyacente a esto, también puede resultar relevante utilizar técnicas de identificación en lazo cerrado, abordando así el problema de la estimación de modelos inestables en lazo abierto.

En otra perspectiva, el modelamiento podría ser mejorado considerando otras variables del terreno de cultivo, además, o como alternativa, de las usadas en este trabajo, como el uso de la evapotranspiración del cultivo bajo condiciones estándares o no estándares, siendo así más específico en el efecto de este fenómeno en el contenido de agua del terreno.

Por otra parte, las decisiones de los controladores pueden extenderse para considerar los estados del contenido de agua en las distintas profundidades simultáneamente, introduciendo así condiciones que requieran, por ejemplo, que todos los estados estén por sobre el umbral de estrés hídrico correspondiente a su profundidad. Esto podría realizarse además con pesos asignados a los distintos niveles. Además, los experimentos de control pueden ser acercados a condiciones más realistas al presentar al controlador con predicciones de las perturbaciones que presenten incertezas.

En último lugar, los desarrollos presentados se realizaron para el caso de un viñedo, no obstante, la metodología utilizada puede ser aplicada a otros cultivos, requiriendo el uso de datos pertinentes al caso de estudio.



# Bibliografía

- [1] Khan, I., Hou, F., y Le, H. P., “The impact of natural resources, energy consumption, and population growth on environmental quality: Fresh evidence from the United States of America”, *Science of The Total Environment*, vol. 754, 2021, [doi:10.1016/j.scitotenv.2020.142222](https://doi.org/10.1016/j.scitotenv.2020.142222).
- [2] Oficina Cambio Climático de la Sección Climatología de la Dirección Meteorológica de Chile, “Reporte anual de la evolución del clima en Chile”, 2023.
- [3] Schaffer, B. y Andersen, P., *Handbook of Environmental Physiology of Fruit Crops. Volume I: Temperate Crops*. CRC Press, 1994, [doi:10.1201/9780203719299](https://doi.org/10.1201/9780203719299).
- [4] Oficina de Estudios y Políticas Agrarias, “Estadísticas económicas”, 2022, <https://www.odepa.gob.cl/estadisticas-del-sector/estadisticas-economicas>.
- [5] Alejandro Muñoz Quiroz, “Análisis de la evolución del sistema de riego en la Región del Libertador Bernardo O’Higgins en el período comprendido entre los catastros frutícolas Odepa-Ciren de los años 2018 y 2021”, 2022.
- [6] Šimůnek, J., van Genuchten, R., Brunetti, G., y Šejna, M., “HYDRUS Technical Manual I. Hydrus 1D Version 5”, 2024, [https://www.pc-progress.com/Downloads/Pgm\\_hydrus1D/HYDRUS1D-4.17.pdf](https://www.pc-progress.com/Downloads/Pgm_hydrus1D/HYDRUS1D-4.17.pdf) (visitado el 2024-07-15).
- [7] Basualto Cortés, I., “Diseño de sistemas de control para la optimización de uso de agua de riego en fruticultura”, *Repositorio Académico de la Universidad de Chile*, 2023, <https://repositorio.uchile.cl/handle/2250/192882>. Accepted: 2023-04-19T14:32:12Z Publisher: Universidad de Chile.
- [8] Driankov, D., Hellendoorn, H., y Reinfrank, M., *An Introduction to Fuzzy Control*. Springer Science & Business Media, 2013.
- [9] Abonyi, J., *Fuzzy Model Identification for Control*. Boston, MA: Birkhäuser, 2003, [doi:10.1007/978-1-4612-0027-7](https://doi.org/10.1007/978-1-4612-0027-7).
- [10] Camacho, E. F. y Bordons, C., *Model Predictive control. Advanced Textbooks in Control and Signal Processing*, London: Springer, 2007, [doi:10.1007/978-0-85729-398-5](https://doi.org/10.1007/978-0-85729-398-5).
- [11] Piegat, A., *Fuzzy Modeling and Control*, vol. 69 de *Studies in Fuzziness and Soft Computing*. Heidelberg: Physica-Verlag HD, 2001, [doi:10.1007/978-3-7908-1824-6](https://doi.org/10.1007/978-3-7908-1824-6).

- [12] Robert Babuška, *Fuzzy Modeling for Control*, vol. 12 de *International Series in Intelligent Technologies*. Dordrecht: Springer Netherlands, 1998, [doi:10.1007/978-94-011-4868-9](https://doi.org/10.1007/978-94-011-4868-9).
- [13] Carter, M. R. y Gregorich, E. G., eds., *Soil Sampling and Methods of Analysis*. Boca Raton: CRC Press, 2 ed., 2007, [doi:10.1201/9781420005271](https://doi.org/10.1201/9781420005271).
- [14] Richard G. Allen, Luis S. Pereira, Dirk Raes, y Martin Smith, “Evapotranspiración del cultivo”, 2006, <https://www.fao.org/3/x0490s/x0490s00.htm>.
- [15] Scherer, T. F. y Steele, D. D., “Irrigation Scheduling by the Checkbook Method”, 2019.
- [16] Bois, B., Pauthier, B., Brillante, L., Mathieu, O., Leveque, J., Van Leeuwen, C., Castel, T., y Richard, Y., “Sensitivity of Grapevine Soil–Water Balance to Rainfall Spatial Variability at Local Scale Level”, *Frontiers in Environmental Science*, vol. 8, 2020, <https://www.frontiersin.org/articles/10.3389/fenvs.2020.00110>.
- [17] Instituto de Investigaciones Agropecuarias Centro Regional de Investigación La Platina, “Curso Internacional. Manejo de Riego y Suelo en Vides para Vino y Mesa”, 2005, <https://biblioteca.inia.cl/handle/20.500.14001/36714>.
- [18] Claret M., M., Reyes M., M., y Ruiz S., C., “Condiciones edafoclimáticas y productos enológicos en el Valle del Itata”, 2020, <https://biblioteca.inia.cl/handle/20.500.14001/67463> (visitado el 2024-07-14). Accepted: 2021-03-31T16:11:01Z.
- [19] Ljung, L., *System Identification: Theory for the User*. Prentice Hall PTR, 1999. Google-Books-ID: nHFoQgAACAAJ.
- [20] Hastie, T., Tibshirani, R., y Friedman, J., *The Elements of Statistical Learning*. Springer Series in Statistics, New York, NY: Springer, 2009, [doi:10.1007/978-0-387-84858-7](https://doi.org/10.1007/978-0-387-84858-7).
- [21] Guyon, I. M., “A Scaling Law for the Validation-Set Training-Set Size Ratio”, AT&T Bell Laboratories, 1997, <https://www.semanticscholar.org/paper/A-Scaling-Law-for-the-Validation-Set-Training-Set-Guyon/452e6c05d46e061290feff8b46d0ff161998677>.
- [22] James B. Rawlings, David Q. Mayne, y Moritz M. Diehl, *Model Predictive Control: Theory, Computation, and Design*. Santa Barbara, California: Nob Hill Publishing, 2017, <https://sites.engineering.ucsb.edu/~jbrow/mpc/>.
- [23] Espinosa, J., Vandewalle, J., y Wertz, V., *Fuzzy Logic, Identification and Predictive Control*. *Advances in Industrial Control*, London: Springer, 2005, [doi:10.1007/b138626](https://doi.org/10.1007/b138626).
- [24] Nova, M., Muñoz-Carpintero, D., y Sáez, D., “Fuzzy Model Predictive Control for Takagi & Sugeno Systems with Optimised Prediction Dynamics”, en *2022 European Control Conference (ECC)*, pp. 1790–1796, 2022, [doi:10.23919/ECC55457.2022.9838066](https://doi.org/10.23919/ECC55457.2022.9838066).
- [25] Touati, F., Al-Hitmi, M., Benhmed, K., y Tabish, R., “A fuzzy logic based irrigation system enhanced with wireless data logging applied to the state of Qatar”, *Computers and Electronics in Agriculture*, vol. 98, pp. 233–241, 2013, [doi:10.1016/j.compag.2013.08.018](https://doi.org/10.1016/j.compag.2013.08.018).

- [26] Neugebauer, M., Akdeniz, C., Demir, V., y Yurdem, H., “Fuzzy logic control for watering system”, *Scientific Reports*, vol. 13, p. 18485, 2023, [doi:10.1038/s41598-023-45203-2](https://doi.org/10.1038/s41598-023-45203-2). Number: 1 Publisher: Nature Publishing Group.
- [27] Abioye, A. E., Abidin, M. S. Z., Mahmud, M. S. A., Buyamin, S., Mohammed, O. O., Otuoze, A. O., Oleolo, I. O., y Mayowa, A., “Model based predictive control strategy for water saving drip irrigation”, *Smart Agricultural Technology*, vol. 4, p. 100179, 2023, [doi:10.1016/j.atech.2023.100179](https://doi.org/10.1016/j.atech.2023.100179).
- [28] Delgoda, D., Malano, H., Saleem, S. K., y Halgamuge, M. N., “Irrigation control based on model predictive control (MPC): Formulation of theory and validation using weather forecast data and AQUACROP model”, *Environmental Modelling & Software*, vol. 78, pp. 40–53, 2016, [doi:10.1016/j.envsoft.2015.12.012](https://doi.org/10.1016/j.envsoft.2015.12.012).
- [29] Ocaranza, J., Sáez, D., Daniele, L., y Ahumada, C., “Energy-water management system based on robust predictive control for open-field cultivation”, *Science of The Total Environment*, vol. 946, p. 174241, 2024, [doi:10.1016/j.scitotenv.2024.174241](https://doi.org/10.1016/j.scitotenv.2024.174241).
- [30] Choudhary, K., Dahiya, R., y Phogat, V., “Effect of drip and furrow irrigation methods on yield and water use efficiency in cotton”, *Research on Crops*, vol. 17, pp. 823–828, 2016, [doi:10.5958/2348-7542.2016.00139.X](https://doi.org/10.5958/2348-7542.2016.00139.X).
- [31] Larman, C. y Basili, V., “Iterative and incremental developments: a brief history”, *Computer*, vol. 36, 2003, [doi:10.1109/MC.2003.1204375](https://doi.org/10.1109/MC.2003.1204375).
- [32] The MathWorks Inc., “Matlab version: 24.1.0.2628055 (r2024a)”, 2024, <https://www.mathworks.com>.
- [33] The MathWorks Inc., “Fuzzy logic toolbox version 24.1 (r2024a)”, 2024, <https://www.mathworks.com>.
- [34] The MathWorks Inc., “Optimization toolbox version 24.1 (r2024a)”, 2024, <https://www.mathworks.com>.
- [35] Loewen, C., Wojciakowski, M., Jenks, A., Coulter, D., Cooley, S., y Kumar, S., “Windows Subsystem for Linux Documentation”, 2022, <https://learn.microsoft.com/en-us/windows/wsl/>.
- [36] Collenteur, R., Brunetti, G., y Vremec, M., “Phydrus: Python implementation of the HYDRUS-1D unsaturated zone model”, 2019, <https://github.com/phydrus/phydrus>.
- [37] Tanaka, K. y Sugeno, M., “Stability analysis and design of fuzzy control systems”, *Fuzzy Sets and Systems*, vol. 45, pp. 135–156, 1992, [doi:10.1016/0165-0114\(92\)90113-I](https://doi.org/10.1016/0165-0114(92)90113-I).
- [38] Griva, I., Nash, S. G., y Sofer, A., *Linear and Nonlinear Optimization: Second Edition*. SIAM, 2009.
- [39] Instituto de Investigaciones Agropecuarias, “Agrometeorología | INIA”, 2024, <https://agrometeorologia.cl/>.
- [40] The MathWorks Inc., “Choosing the Algorithm - MATLAB & Simulink - MathWorks”.

<https://se.mathworks.com/help/optim/ug/choosing-the-algorithm.html>.

# Anexos

## Anexo A. Parámetros de los modelos

En este anexo se detallan los valores de las matrices de parámetros de los modelos desarrollados, siguiendo la forma en espacio de estados.

### A.1. Modelos basados en datos de la viña

#### A.1.1. Modelo lineal

$$\begin{aligned} A &= \begin{bmatrix} 0.7561 & 0.0569 & -0.0624 & 0.1043 \\ 0.1756 & 0.9432 & -0.2011 & 0.0974 \\ 0.1757 & 0.1962 & 0.5776 & 0.0383 \\ 0.0573 & -0.0127 & 0.0192 & 0.9655 \end{bmatrix}, B = \begin{bmatrix} 0.2646 \\ 0.2221 \\ 0.0930 \\ 0.0017 \end{bmatrix}, \\ D &= \begin{bmatrix} 2.8742 & 0.0476 & -0.1952 \\ 0.5404 & 0.0318 & -0.1382 \\ -0.2687 & 0.0643 & -0.0241 \\ -0.4995 & 0.0175 & -0.0229 \end{bmatrix} \end{aligned} \tag{A.1}$$

### A.1.2. Modelo Takagi-Sugeno automático

$$\begin{aligned}
 A^1 &= \begin{bmatrix} 1.0862 & -0.3478 & 0.1771 & -0.0165 \\ 0.7147 & 0.4328 & 0.0128 & -0.0540 \\ 0.3926 & 0.0443 & 0.6692 & 0.0198 \\ 0.0065 & 0.0088 & -0.0059 & 0.9789 \end{bmatrix}, B^1 = \begin{bmatrix} 0.2647 \\ 0.2163 \\ 0.0861 \\ 0.0000 \end{bmatrix}, \\
 D^1 &= \begin{bmatrix} 2.7473 & 0.1217 & -0.0765 \\ 0.6717 & 0.0107 & -0.1277 \\ -1.6950 & 0.0009 & -0.0849 \\ 0.1373 & 0.0004 & -0.0137 \end{bmatrix}
 \end{aligned} \tag{A.2}$$

$$\begin{aligned}
 A^2 &= \begin{bmatrix} 0.5791 & -0.0937 & -0.0108 & 0.1103 \\ -0.1227 & 0.9731 & -0.1722 & 0.0888 \\ 0.1319 & 0.1277 & 0.5783 & 0.0498 \\ 0.0541 & 0.0457 & -0.0050 & 0.9537 \end{bmatrix}, B^2 = \begin{bmatrix} 0.1993 \\ 0.1483 \\ 0.1111 \\ -0.0087 \end{bmatrix}, \\
 D^2 &= \begin{bmatrix} 9.2832 & 0.0433 & -0.2231 \\ 5.3845 & 0.0502 & -0.1522 \\ 2.1580 & 0.0935 & -0.0338 \\ -1.1547 & 0.0140 & -0.0415 \end{bmatrix}
 \end{aligned} \tag{A.3}$$

### A.1.3. Modelo Takagi-Sugeno híbrido

$$\begin{aligned}
 A^1 &= \begin{bmatrix} 1.1881 & -0.0273 & -0.1706 & -0.0369 \\ 0.4487 & 0.9712 & -0.3367 & -0.0285 \\ 0.2365 & 0.1608 & 0.6679 & 0.0074 \\ 0.0143 & -0.0099 & 0.0047 & 0.9416 \end{bmatrix}, B^1 = \begin{bmatrix} 0.2717 \\ 0.2118 \\ 0.0726 \\ -0.0008 \end{bmatrix}, \\
 D^1 &= \begin{bmatrix} 1.0382 & 0.0817 & -0.0511 \\ -0.1879 & 0.0094 & -0.1435 \\ -1.2187 & -0.0005 & -0.1236 \\ 0.7442 & 0.0035 & -0.0097 \end{bmatrix}
 \end{aligned} \tag{A.4}$$

$$\begin{aligned}
A^2 &= \begin{bmatrix} 1.0464 & -0.0069 & -0.1275 & 0.1625 \\ 0.0588 & 0.9914 & -0.2024 & 0.1535 \\ 0.1693 & 0.0049 & 0.9355 & 0.0472 \\ -0.0797 & 0.0669 & -0.0383 & 0.9526 \end{bmatrix}, B^2 = \begin{bmatrix} 0.2716 \\ 0.3478 \\ 0.1916 \\ 0.0013 \end{bmatrix}, \\
D^2 &= \begin{bmatrix} -0.7695 & 0.0511 & -0.1064 \\ 0.5680 & -0.0078 & -0.0483 \\ -2.7714 & -0.0285 & -0.0234 \\ 1.3663 & -0.0010 & 0.0220 \end{bmatrix}
\end{aligned} \tag{A.5}$$

$$\begin{aligned}
A^3 &= \begin{bmatrix} 0.3709 & -0.1473 & 0.0308 & 0.1197 \\ -0.0120 & 0.5228 & -0.0261 & 0.1122 \\ 0.2331 & 0.1932 & 0.4624 & 0.0672 \\ 0.1510 & 0.0599 & -0.0230 & 0.9479 \end{bmatrix}, B^3 = \begin{bmatrix} 0.1850 \\ 0.1747 \\ 0.1392 \\ -0.0027 \end{bmatrix}, \\
D^3 &= \begin{bmatrix} 13.7938 & 0.0510 & -0.1721 \\ 11.2747 & 0.0531 & -0.1314 \\ 0.5728 & 0.1017 & -0.0856 \\ -2.7158 & 0.0196 & -0.1394 \end{bmatrix}
\end{aligned} \tag{A.6}$$

## A.2. Modelos basados en datos del simulador

### A.2.1. Modelo lineal

$$\begin{aligned}
A &= \begin{bmatrix} 0.7944 & 0.0322 & 0.0928 & 0.0860 \\ 0.1996 & 0.7997 & 0.1842 & -0.0435 \\ 0.0344 & -0.0062 & 0.8804 & 0.0057 \\ -0.0058 & 0.0025 & -0.0015 & 0.9297 \end{bmatrix}, B = \begin{bmatrix} 0.3766 \\ 0.4054 \\ 0.0887 \\ -0.0181 \end{bmatrix}, \\
D &= \begin{bmatrix} -0.1550 & 0.0381 & -0.2341 \\ -0.0335 & 0.0147 & -0.2658 \\ 1.7192 & 0.0260 & -0.1887 \\ 1.4986 & -0.0039 & -0.0329 \end{bmatrix}
\end{aligned} \tag{A.7}$$

### A.2.2. Modelo Takagi-Sugeno automático

$$\begin{aligned}
 A^1 &= \begin{bmatrix} 0.5677 & 0.0327 & 0.5395 & 0.0476 \\ 0.1448 & 0.4077 & 0.2150 & -0.1561 \\ -0.0329 & -0.0088 & 0.5568 & -0.0428 \\ -0.0186 & 0.0206 & -0.0360 & 0.9133 \end{bmatrix}, B^1 = \begin{bmatrix} 0.3947 \\ 0.3577 \\ -0.0291 \\ -0.0168 \end{bmatrix}, \\
 D^1 &= \begin{bmatrix} -1.6550 & 0.6252 & -0.2432 \\ 8.4789 & 13.6382 & -0.1629 \\ 6.5596 & 11.3425 & -0.0159 \\ 1.9408 & 11.5445 & -0.0213 \end{bmatrix}
 \end{aligned} \tag{A.8}$$

$$\begin{aligned}
 A^2 &= \begin{bmatrix} 0.9415 & 0.0046 & 0.0742 & 0.1462 \\ 0.1823 & 0.7736 & 0.1227 & -0.0369 \\ 0.1039 & -0.0614 & 0.9069 & 0.0216 \\ -0.0056 & -0.0110 & 0.0004 & 0.9345 \end{bmatrix}, B^2 = \begin{bmatrix} 0.3663 \\ 0.4312 \\ 0.1922 \\ -0.0213 \end{bmatrix}, \\
 D^2 &= \begin{bmatrix} -2.6300 & 0.0356 & -0.2663 \\ 2.1140 & -0.0003 & -0.2999 \\ 1.4600 & 0.0197 & -0.2306 \\ 1.6952 & -0.0036 & -0.0232 \end{bmatrix}
 \end{aligned} \tag{A.9}$$



## Anexo B. Tiempos de computación experimentos de control

### B.1. MPC con umbral mínimo

Tabla B.1: Tiempo de computación de los experimentos de MPC con umbral mínimo usando el mismo modelo como planta, con  $N = 7$

Modelo	Tiempo total [s]	Tiempo promedio iteración [s]
Lineal (viña)	1.03	0.01
Lineal (simulador)	1.02	0.01
TS auto (viña)	5.50	0.05
TS híbrido (viña)	5.19	0.05
TS auto (simulador)	7.55	0.07

Tabla B.2: Tiempo de computación de los experimentos de MPC con umbral mínimo usando el simulador como planta, con  $N = 7$

Modelo	Tiempo total [s]	Tiempo promedio iteración [s]
Lineal (viña)	12.80	0.12
Lineal (simulador)	12.19	0.12
TS auto (viña)	15.44	0.15
TS híbrido (viña)	15.73	0.15
TS auto (simulador)	16.63	0.16

### B.2. MPC con umbral mínimo y restricción de frecuencia de riego

Tabla B.3: Tiempo de computación de los experimentos de MPC con umbral mínimo y restricción de frecuencia de riego usando el mismo modelo como planta, con  $N = 7$  y  $dias_{max} = 2$

Modelo	Tiempo total [s]	Tiempo promedio iteración [s]
Lineal (viña)	38.44	0.36
Lineal (simulador)	45.36	0.43
TS auto (viña)	81.43	0.78
TS híbrido (viña)	52.41	0.50
TS auto (simulador)	372.70	3.55

Tabla B.4: Tiempo de computación de los experimentos de MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con  $N = 7$  y  $dias_{max} = 2$

Modelo	Tiempo total [s]	Tiempo promedio iteración [s]
Lineal (viña)	47.04	0.45
Lineal (simulador)	55.06	0.52
TS auto (viña)	477.62	4.55
TS híbrido (viña)	159.88	1.52
TS auto (simulador)	488.76	4.65

### B.3. Comparación con otras técnicas de riego

Tabla B.5: Tiempo de computación de los experimentos con programación convencional y basada en MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con  $N = 6$  y  $dias_{max} = 1$

Esquema	Tiempo total [s]	Tiempo promedio iteración [s]
Convencional	5.33	0.05
MPC TS auto (viña)	67.96	0.65
MPC TS auto (simulador)	47.80	0.46

Tabla B.6: Tiempo de computación del control aplicado en la viña y los experimentos con programación basada en MPC con umbral mínimo y restricción de frecuencia de riego usando el simulador como planta, con  $N = 7$  y  $dias_{max} = 2$

Esquema	Tiempo total [s]	Tiempo promedio iteración [s]
Viñedo	-	-
MPC TS auto (viña)	418.76	3.99
MPC TS auto (simulador)	442.69	4.22

### B.4. Discusión

En las Secciones B.1 y B.2 se observa que, los experimentos que usan el mismo modelo en el controlador y como planta tienen un tiempo de computación menor que su contraparte en que se controla el simulador. Esto se debe en parte a los costos que añade el uso del simulador (iniciación de la API de MATLAB en Python y funcionamiento de Hydrus-1D), y también a que los cálculos de optimización son en ocasiones más complejos al usar el simulador, puesto que este suele tener pérdidas de humedad más rápidas que algunos de los modelos.

Por otro lado, se puede notar que para los esquemas con restricción de la frecuencia de

riego, el uso de un valor mayor para la variable  $dias_{max}$  aumenta considerablemente el tiempo de computación. Esto tiene que ver con la implementación usada para este esquema en que se transformó la variable binaria  $b$  en múltiples secuencias fijas de valores binarios (ver Algoritmo 1). Al permitir una mayor cantidad de días de riego en el horizonte de predicción, aumenta la cantidad de combinaciones binarias válidas, aumentando así la cantidad de cálculos a realizar en cada iteración de la simulación.