

Tesis Doctoral

**OPTIMIZACIÓN DE LA PRODUCCIÓN
DE UN INVERNADERO MEDIANTE
CONTROL PREDICTIVO NO LINEAL**

Mohammed Yassine El Ghoumari

Índice General

Índice de Figuras	viii
1 Introducción	3
1.1 MPC y invernaderos	4
1.2 Objetivos de la tesis	6
1.3 Metodologías usadas	6
1.4 Organización de la tesis	8
2 Control avanzado	11
2.1 Control Predictivo Basado en Modelos: CPBM	12
2.1.1 Una breve historia	13
2.1.2 Puntos claves de CPBM	16
2.2 Aspectos de implementación en control predictivo	17
2.2.1 Modelado	18
2.2.1.a Modelado lineal	18
2.2.1.b Modelado no lineal	19
2.2.2 Cálculo de las predicciones	27
2.2.3 Función de coste y optimización	28
2.2.4 Sintonía del controlador	29
2.2.5 Generación de la trayectoria interna	30
2.3 Control predictivo no lineal	30
2.3.1 Consideraciones computacionales	31

2.3.2	Estado del arte del Control Predictivo no lineal . . .	31
2.3.2.a	Estabilidad	32
2.3.2.b	Desarrollo de modelos	36
2.3.2.c	Aplicaciones en la industria	41
2.4	Resumen	43
3	Modelado del invernadero	45
3.1	Descripción del proceso	46
3.1.1	Ventilación	48
3.1.1.a	Características de flujo de aire en una ventana	48
3.1.1.b	Fuerzas Involucradas en la ventilación . . .	49
3.1.1.c	Ventilación resultante	52
3.1.2	Radiación solar	53
3.1.3	Procesos de intercambio por convección-conducción .	55
3.2	Modelo dinámico del invernadero	56
3.2.1	Temperatura interna	57
3.2.1.a	Calefacción	58
3.2.1.b	Radiación solar	59
3.2.1.c	Ventilación	59
3.2.1.d	Influencia del suelo	61
3.2.1.e	Submodelo de temperatura	61
3.2.2	Humedad interna	62
3.2.2.a	Ventilación	62
3.2.2.b	Transpiración	63
3.2.2.c	Humidificación (<i>fogging</i>)	64
3.2.2.d	Submodelo de humedad	64
3.2.3	Concentración de CO ₂	65
3.2.3.a	Consumo de la vegetación	65
3.2.3.b	Ventilación	66
3.2.3.c	Aporte de CO ₂	67
3.2.3.d	Submodelo de CO ₂	67

3.3	Modelo de crecimiento	67
3.4	Modelo Integral del invernadero	69
3.5	Resumen	71
4	Control predictivo no lineal	73
4.1	Control predictivo lineal	74
4.1.1	Modelos en el espacio de estados	74
4.1.2	Descripción de la planta en el espacio de estados . . .	74
4.1.3	El algoritmo de control	75
4.2	El control predictivo no lineal mediante optimización global	78
4.2.1	Aspectos de implementación	79
4.2.2	Ventajas e inconvenientes	80
4.3	Control predictivo no lineal mediante linealización <i>on-line</i>	80
4.3.1	El <i>Extended Linearised Predictive Controller</i> ELPC	81
4.3.1.a	Linealización en un punto no estacionario .	81
4.3.1.b	Implementación del ELPC	86
4.3.2	El <i>Modified Extended Linearised Predictive Controller</i>	88
4.3.2.a	Integración de las ecuaciones diferenciales .	88
4.3.2.b	Aspectos de implementación del MELPC .	89
4.3.3	MELPC con restricciones	91
4.3.3.a	Formulación de las restricciones	93
4.3.3.b	Incorporación de las restricciones en el controlador MELPC	94
4.3.4	EPSAC	97
4.3.5	EPSAC con modelo de predicción lineal variante en el tiempo	101
4.3.6	Estudio comparativo de los diferentes controladores .	101
4.3.6.a	Descripción del sistema	102
4.3.6.b	Descripción de las simulaciones	105
4.3.6.c	Control EPSAC: Resultados de simulación .	106

4.3.6.d	Control MELPC: Resultados de simulación	107
4.3.6.e	Control ELPC: Resultados de simulación . .	107
4.3.6.f	Control lineal: Resultados de simulación . .	108
4.3.6.g	Control no-lineal: Resultados de simulación	108
4.3.6.h	Análisis y comparación de los resultados . .	109
4.4	Ejemplos de aplicación del MELPC	114
4.4.1	Sistemas rápidos: Robot de tres grados de libertad . .	114
4.4.2	Sistemas con respuesta inversa: Reactor químico . . .	120
4.4.3	Sistema en un entorno muy hostil: Control del clima dentro de un invernadero	124
4.4.4	Conclusión	128
4.5	Resumen	129
5	Resultados experimentales	131
5.1	Validación del modelo	132
5.1.1	Descripción del invernadero real	133
5.1.2	Estimación	135
5.1.3	Calibración	135
5.1.4	Validación	136
5.1.5	Parámetros del modelo del clima	138
5.2	Control en tiempo real del clima	141
5.2.1	Estructura del controlador	141
5.2.2	Resultados experimentales	142
5.3	Resumen	147
6	Control jerárquico	149
6.1	Control Jerárquico	150
6.1.1	Nivel 1: Control del micro-clima interior	151
6.1.2	Nivel 2: Crecimiento de desarrollo del cultivo a corto plazo	153
6.1.3	Nivel 3: Crecimiento del cultivo a largo plazo	153

6.2	Ejemplo de simulación	154
6.2.1	Descripción del experimento de simulación	156
6.2.2	Resultados de simulación	157
6.2.3	Análisis de los resultados	159
6.2.4	Conclusión	161
7	Conclusiones	163
	Bibliografía	167

Índice de Figuras

2.1	Esquema general del CPBM	17
2.2	MLP de tres capas	20
2.3	Predicciones con un modelo en redes neuronales	22
2.4	Modelo de Hammerstein	25
2.5	Modelo de Weiner	26
2.6	Cálculo interno de las predicciones	27
3.1	Cambios energéticos en un invernadero	47
3.2	Ventana de ventilación	50
3.3	Reflexión I_R , Absorción I_a , y transmisión I_t de una radiación incidente I	54
4.1	señales de control usadas por el EPSAC	98
4.2	Reactor de van der vusse	102
4.3	Reactor de Van de Vusse controlado por el EPSAC	106
4.4	Reactor de Van der Vusse controlado por el MELPC	107
4.5	Reactor de Van der Vusse controlado por el ELPC	108
4.6	Reactor de Van der Vusse controlado por el controlador lineal	109
4.7	Reactor de Van der Vusse controlado por el controlador no- lineal	110
4.8	Lineal	112
4.9	ELPC	112
4.10	MELPC	112

4.11	EPSAC	112
4.12	No Lineal	112
4.13	Rechazo de la perturbaciones de cada controlador	112
4.14	Robot de 3 grados de libertad	114
4.15	Control MELPC de las posiciones del robot	119
4.16	Reactor químico exotérmico encamisado	121
4.17	Respuesta del reactor encamisado	123
4.18	Temperatura interior y concentración de CO ₂	126
4.19	Variables de control	127
4.20	Condiciones externas (radiación solar y temperatura exterior)	128
4.21	Condiciones externas (velocidad del viento y humedad exterior)	128
5.1	Etapas de validación	132
5.2	Invernadero real	133
5.3	Condiciones externas: Radiación solar y Temperatura exterior	137
5.4	Resultados experimentales y de simulación	138
5.5	Condiciones externas: Velocidad del viento y Humedad relativa	142
5.6	Estructura del controlador: Controladores maestro y esclavo	143
5.7	Controlador predictivo: respuesta en lazo cerrado	144
5.8	Controlador PI adaptativo: respuesta en el lazo cerrado . . .	146
6.1	Los tres niveles del proceso de producción bajo invernadero .	151
6.2	Optimización de producción: esquema de control	155
6.3	Consignas óptimas de día (discontinuo) y de noche (continuo)	158
6.4	Peso óptimo	159

Agradecimientos

Mucha gente me ha dado ayuda, soporte y orientación durante el tiempo que me he pasado para realizar esta tesis. La más grande y agradecida fue la presencia de mi supervisor, el doctor Javier Serrano García. Sin su ayuda, esta tesis habría sido diferente incluso imposible.

Todos los participantes en los trabajos de investigación derivados de esta tesis merecen una mención individual por sus valiosas contribuciones, especialmente al doctor David Megías Jiménez que proporcionó consejos y aportaciones básicas para el desarrollo de este trabajo en todas sus etapas.

Un agradecimiento a la señora Carmen Ramírez por su esfuerzo al corregir el estilo lingüístico de esta memoria, y por su empeño en enseñar me la cultura Catalano-Española.

Un agradecimiento especial a todos los compañeros de trabajo del departamento de Telecomunicaciones y Ingeniería de Sistemas por su amabilidad y el entorno de trabajo amistoso que me ofrecieron durante los años de desarrollo de esta tesis.

Y para terminar, mi más bueno agradecimiento a toda mi familia y a mis amigos, que me ofrecieron toda la ayuda moral y soportaron que todos estos años estuviera lejos de ellos.

Capítulo 1

Introducción

Actualmente al contrario de los mercados estables de las décadas pasadas, los productores agrícolas deben adoptar técnicas innovadoras para tener ventaja, debido a la globalización de los mercados, al cambio en las necesidades y exigencias de los clientes, a la rápida evolución en las tecnologías y a la gran importancia del respeto del medio ambiente tanto por parte de las leyes europeas como por parte de los clientes. Esto se consigue teniendo un buen conocimiento del sistema de producción bajo el invernadero sujeto a todas las restricciones económicas, climáticas, medioambientales, y cambio de los objetivos de producción de un año a otro.

En consecuencia, hoy en día se ha dado mucha importancia a la gestión óptima de la producción bajo invernaderos para poder adoptar las medidas óptimas cada día. Es un gran estímulo ver como varía el beneficio de un sistema de producción a otro sólo porque hay diferencias en las técnicas de gestión. Los más exitosos son los que usan técnicas de predicción y anticipación de las situaciones futuras que puedan ocurrir, con el fin de asegurar el buen funcionamiento de sus sistemas de producción.

1.1 MPC y invernaderos

La técnica propuesta para este fin es la del control predictivo no lineal. En particular el algoritmo **MELPC** descrito en el capítulo 4. Esta técnica necesita una serie de requerimientos como:

- Modelo del invernadero.
- Modelo de crecimiento del cultivo.
- Algoritmo de control predictivo no lineal.
- Algoritmo de optimización de producción con una función de coste económica.
- Programa de control en tiempo real.

Esta técnica es muy adecuada para la optimización de la producción debido a las siguientes ventajas:

- No-lineal: La no-linealidad del sistema invernadero se ilustra en el capítulo 3, lo que implica la utilización de un algoritmo adecuado para sistemas no-lineales.
- Considera las restricciones: Las variables de este sistema tienen intervalos de variación muy críticos, así la temperatura o la humedad no pueden superar ciertos valores, la violación de estos valores puede generar pérdidas irrecuperables a nivel del cultivo. Otro tipo de restricciones que hay que considerar, son de tipo lógico como las que se consideran en este trabajo en la relación que hay entre las variables de control calefacción y apertura de las ventanas, donde no se puede activar las dos variables de control en un mismo tiempo, lo que puede

causar pérdidas económicas enormes y reducir la utilidad de todo el sistema de producción.

- No requiere un gran coste computacional: La fuerte no linealidad del sistema, su funcionamiento bajo restricciones, y la presencia de fuertes perturbaciones con dinámicas rápidas (Condiciones meteorológicas) que hacen que el invernadero se transforma en un sistema muy rápido, con todas estas razones es imperativo usar una técnica de control que no requiere un gran coste computacional para el cálculo de las señales de control óptimas en cada periodo de muestreo.
- Acepta criterios económicos: La optimización de la producción requiere una función de coste económica, para encontrar un resultado óptimo al final de la cosecha. El algoritmo de control predictivo usado en el segundo nivel del control jerárquico utiliza una función de coste económica que maximiza el beneficio neto durante el periodo de la cosecha.
- Sirve para el control jerárquico: La optimización de la producción en invernaderos requiere resolver un problema de control jerárquico con tres niveles de decisión. La técnica de control predictivo usada en este trabajo se puede usar perfectamente (capítulo 4).
- Multivariable: La utilización de un algoritmo de control multivariable es obligatoria, debido a la fuerte interrelación que hay entre los diferentes lazos de control en este sistema. En el primer nivel de control, la relación entre las variables temperatura, humedad interna y concentración de CO_2 es muy fuerte, y en el segundo nivel se añaden aun más variables con la incorporación del modelo de crecimiento cuyo número depende del tipo de cultivo plantado.

1.2 Objetivos de la tesis

La presente tesis tiene tres objetivos principales:

- ✦ Elaboración de un algoritmo de control predictivo no lineal, multi-variable, basado en la linealización en línea y que no requiere un gran esfuerzo computacional.
- ✦ Optimización de la producción de un invernadero.
- ✦ Mostrar que estas técnicas pueden funcionar en un caso real.

Los objetivos se complementan en el sentido de que el sistema sirve como prueba del buen funcionamiento del algoritmo, y al mismo tiempo el control predictivo no lineal es una buena estrategia para optimizar la producción dentro del invernadero.

La optimización de la producción conlleva un control jerárquico que incluye dos niveles de control, en el primero se controlan las variables climáticas dentro del invernadero, y en el segundo nivel se trata de optimizar la producción maximizando una función de coste económica y por medio de un modelo de crecimiento del cultivo.

También se hace una aplicación práctica sobre un invernadero real, el sistema se sitúa en el *Institute for Horticultural and Agricultural Engineering (ITG)* de la Universidad de Hannover (Alemania).

1.3 Metodologías usadas

Las metodologías usadas a lo largo de esta tesis es la siguiente:

- Control predictivo lineal: El control predictivo lineal es la base del trabajo para elaborar una técnica de control predictivo no lineal. La formulación usada esta en el espacio de estados (ver capítulo 2).
- Control predictivo no lineal con restricciones: El algoritmo de control usado en esta tesis es el *Modified Extended Linearised Predictive Controller (MELPC)*, usa la técnica de la linealización del modelo en cada instante de muestreo. Este algoritmo tiene la capacidad de considerar las restricciones, ya que es imprescindible tenerlas en cuenta en el control de un sistema de producción bajo invernaderos (ver capítulo 4).
- Modelado de sistemas: Como estamos usando la técnica del control predictivo basado en modelos es obvio obtener un modelo del sistema a controlar. La técnica que se ha usado para modelar este sistema esta basada en principios fundamentales, usando las leyes físicas de la termodinámica (ver capítulo 3).
- Optimización de la producción y control Jerárquico: Los algoritmos de optimización son temas de gran interés en esta tesis. Por ello, es imprescindible una formulación de las diferentes funciones de coste para la resolución del problema de optimización de la producción, en todos los niveles del control jerárquico (ver capítulo 6).
- Control en tiempo real: La aplicación de todas las técnicas de control y de optimización es uno de los objetivos de la tesis más importantes, por ello se usa los paquetes de MATLAB y de CONTROL ACTIVEX para la comunicación entre el sistema real y el algoritmo de control (ver capítulo 5).

1.4 Organización de la tesis

La presente memoria se ha desarrollado según la organización siguiente:

En el segundo capítulo se presenta un estudio sobre las técnicas del control predictivo basado en modelos. Este estudio incluye una breve historia de su desarrollo, sus puntos claves y sus aspectos de implementación. Este estudio incluye las dos familias de control predictivo, lineal y no lineal. Además se hace un informe sobre el estado de arte del control predictivo no lineal en las líneas de investigación de más interés y que son la estabilidad, el modelado y las aplicaciones en la industria.

En el tercer capítulo se hace un desarrollo del modelo del sistema sobre el que se ha desarrollado la aplicación práctica, el invernadero. Se estudian los fenómenos involucrados en sus dinámicas. También se hace el desarrollo del modelo de crecimiento del cultivo plantado en el invernadero. Por fin se hace una validación del modelo obtenido comparando los valores experimentales y teóricos.

En el cuarto capítulo se desarrollo el algoritmo de control predictivo no lineal propuesto en esta tesis para resolver los problemas de control. Este algoritmo se ha desarrollado bajo el objetivo de ser capaz de controlar sistemas no-lineales, rápidos, trabajan bajo restricciones, y aplicable en la práctica. Por ello se presenta una serie de experimentos en simulaciones y prácticos sobre varios tipos de sistemas químicos, mecatrónicos, y agrícola (invernadero)

En el quinto capítulo se presentan los resultados experimentales que se han llevado a cabo en esta tesis, la aplicación del algoritmo de control predictivo, y su integración en el sistema de producción en un invernadero.

En el sexto capítulo se hace un estudio sobre el control jerárquico en el

sistema de producción en invernaderos. También se presenta un experimento en simulación y sus resultados.

Un sumario de las aportaciones realizadas en esta tesis terminan esta memoria, así como las posibles líneas futuras de investigación.

Capítulo 2

Control avanzado

La implantación del control avanzado en cualquier planta de producción, se impone con el fin de aumentar la productividad. Esta técnica permite proporcionar estabilidad, seguridad y grandes beneficios económicos.

Para asegurar el éxito de cualquier proyecto de implantación de control avanzado, hay que revisar toda la instrumentación, identificar y ajustar todos los lazos de control, y en algunos casos rediseñarlos.

En la mayoría de los procesos, se consiguen grandes beneficios cuando se aplica el control avanzado, y revela a menudo relaciones importantes que generan una mejora del proceso y de la instrumentación.

La tarea de formular los objetivos y restricciones en un problema de optimización en aplicaciones industriales no siempre es fácil. El éxito de la aplicación de los métodos de optimización depende principalmente de la correcta formulación del propio problema de optimización. La buena elección de los objetivos, restricciones y el grado de sus violaciones son las claves para una exitosa implementación del control predictivo basado en

modelos.

Los algoritmos de control predictivo son muy versátiles y robustos en las aplicaciones de control de procesos. Se pueden aplicar a una gran variedad de sistemas: de fase no mínima, inestables, con retardo y multivariables. Los controladores predictivos necesitan un modelo del proceso a controlar, para predecir el comportamiento de este último.

2.1 Control Predictivo Basado en Modelos: CPBM

El Control Predictivo Basado en Modelos (CPBM) es una tecnología que fue desarrollada inicialmente para las plantas de energía y la industria petrolera. Poco a poco fue ganando terreno en casi todas las industrias, químicas, alimentarias, automóvil, aeroespacial y metalúrgica. (Qin and Badgwell, 1996).

El éxito del Control predictivo se puede atribuir a tres razones principales. La primera es la incorporación de los modelos en el proceso de control, lo que permite al controlador operar directamente con las características significantes del proceso a controlar. La segunda razón es la "visión" del control predictivo hacia el futuro, a lo largo de un horizonte de predicción, característica que le permite anticipar y eliminar todos los efectos de las perturbaciones. La última razón es la consideración de las entradas del proceso, restricciones de estado y de salidas directamente en el cálculo de la señal de control óptima.

El control predictivo usa un modelo dinámico del proceso para predecir su comportamiento futuro. Las variables controladas predichas son usadas en un proceso de optimización, para minimizar una función de coste, con el

fin de calcular las secuencias de control futuras. Generalmente la función de coste depende del error cuadrático entre la referencia y la variable controlada en un horizonte de control. Esta operación se repite en cada instante de muestreo.

El control predictivo presenta una serie de ventajas, se puede aplicar a una gran variedad de procesos, introduce compensaciones *feedforward* de una manera natural para eliminar las perturbaciones, tiene compensaciones para retardos, tiene un tratamiento completo de las restricciones, y por último se puede extender al caso multivariable de una manera simple.

2.1.1 Una breve historia

El desarrollo del **control predictivo basado en modelos (CPBM)** fue ligado a los trabajos hechos sobre la existencia de soluciones a los problemas de control óptimo, dentro de ellos citamos los que fueron propuestos por Lee y Markus (1967) y Fleming y Rishel (1975):

- La caracterización de las soluciones óptimas (necesarias y suficientes condiciones de optimalidad).
- La estabilidad de Lyapunov de los sistemas controlados por una técnica de control óptimo.
- Los algoritmos para el cálculo de un controlador feedback óptimo (cuando es posible).
- Los algoritmos de control óptimo en lazo abierto.

Una idea muy importante del control óptimo en relación al control predictivo basado en modelos, une dos grandes temas en la teoría del control de los años 60: La teoría de Hamilton-Jacobi-Bellman (Programación

dinámica) que proporciona las condiciones suficientes para la optimalidad, y el principio que proporciona las condiciones necesarias para la optimalidad.

Los controladores óptimos no son siempre estables (Kalman 1960), pero bajo algunas condiciones, un controlador óptimo de horizonte infinito es estabilizante, escogiendo una función de Lyapunov adecuada.

Un controlador óptimo con horizonte infinito no es muy práctico de usar, sobre todo en-línea (a parte del control H_2 y H_∞ de los sistemas lineales), entonces una idea relevante es la formulación del control óptimo de horizonte deslizante en el lazo abierto cuya solución proporciona un control estabilizante. El primer resultado en este sentido fue el de Kleinman (1970) y Thomas (1975). Kleinman demuestra que un controlador $u = Kx$ (donde K es la matriz de controlabilidad de Grammian a lo largo de un intervalo T) es estabilizante usando una función de Lyapunov $V(x) = x^T Px$, donde P es la inversa de la matriz K en el intervalo $[0, T]$. Thomas obtuvo el mismo resultado considerando un problema de control lineal cuadrático con un factor de peso en la señal de control sin pesar los estados, y con un coste terminal infinito, que implícitamente añade una estabilidad $x(T) = 0$ al problema de control óptimo. Esto se consigue usando $M = P^{-1}$ al lugar de la variable de Riccati P y resolviendo la ecuación de Riccati como una ecuación diferencial de M con un coste terminal $M(T)=0$; esta elección fuerza a que el estado terminal de ser en el origen. Otras extensiones para este resultado fueron propuestas por Brickstein y Kailath (1983) donde consideran un problema general cuadrático lineal (con factores de peso en el control y en los estados). En los dos trabajos la ecuación de Riccati asociada se analiza extensivamente. Se impone una condición de estabilidad que fuerza a que el estado sea en el origen $x(T) = 0$ (usando una condición terminal $M(T) = 0$ donde M es la inversa de la matriz de Riccati P). En este trabajo el sistema considerado es lineal y variante en el tiempo, con una función de coste cuadrática y variante en el tiempo, por consecuencia

el control óptimo es lineal y variante en el tiempo ($u = K(t)x$). $K(t)$ se determina resolviendo una ecuación de Riccati diferencial matricial en el intervalo de tiempo $[t, t + T]$. Los resultados de Kleinman y Thomas son muy importantes porque demuestran que una restricción terminal asegura la estabilidad, pero esta limitada, porque los argumentos de estabilidad son apropiados solamente para sistemas lineales sin restricciones.

Con esta literatura, todos los ingredientes estaban dispuestos para definir una estrategia de control predictivo estabilizante para sistemas con restricciones.

El **control predictivo basado en modelos (CPBM)** fue introducido por Richalet en 1978 con el controlador ” *Model Predictive Heuristic Control*” y de otra parte independientemente, Cutler y Ramaker dos ingenieros de la compañía Shell presentaron sus controlador ” *Dynamic Matrix Control*” (DMC) (Cutler and Hawkins, 1987) con varias aplicaciones industriales. Los dos algoritmos usan modelos dinámicos explícitos de la planta para predecir la evolución de las variables controladas (salidas) a lo largo de un horizonte predeterminado. El cálculo de los valores futuros de las variables manipuladas (señales de control) se hace minimizando una función de coste con el objetivo de minimizar el error predicho y bajo ciertas restricciones. El proceso de optimización se repite en cada instante de muestreo actualizando las informaciones del proceso.

Posteriormente fue introducido el Generalized Predictive Controller (GPC) por Clarcke, Mohtadi y Tuffs (1987). Este algoritmo surgido en un entorno académico fue probado con éxito en varias aplicaciones industriales, y ha conseguido un nivel de aceptación muy importante en la industria.

Hoy en día, después de muchos cambios en la industria, varios paquetes de control predictivo han penetrado en el mercado industrial y están comercialmente disponibles. Los más conocidos son el DMCplus de *Aspen Tech*,

Robust Model Predictive Controller Technology (RMPCT) de *Honeywell*, IDCOM y PFT de *Adersa*, DOT y INOVA.

2.1.2 Puntos claves de CPBM

Las técnicas del control predictivo comparten cuatro conceptos comunes:

- Un modelo del proceso está usado para predecir la salida. La respuesta futura $y(t+j)$ se predice en cada instante de muestreo a lo largo de un horizonte de predicción (figura 2.1). Las salidas predichas dependen de las señales pasadas (entradas, salidas) y también de las señales de control actuales.
- Trayectoria de referencia $w(t+j)$ que depende de la consigna $r(t+j)$, establece la manera como hay que llegar a la consigna desde el estado actual.
- La señal de control óptima $u(t+j)$ durante un horizonte de predicción N_2 , se calcula optimizando una función de coste para acercarse al máximo la respuesta a la trayectoria de referencia $w(t+j)$. Esta función de coste generalmente es una función cuadrática del error entre la salida predicha y la trayectoria de referencia interna. La señal de control también está incluida en la función de coste.
- Usan la estrategia del horizonte móvil. En cada instante de muestreo se aplica solamente la primera señal de control $u(t)$ de toda la secuencia de control calculada. Este proceso de cálculo se repite en cada instante de muestreo.

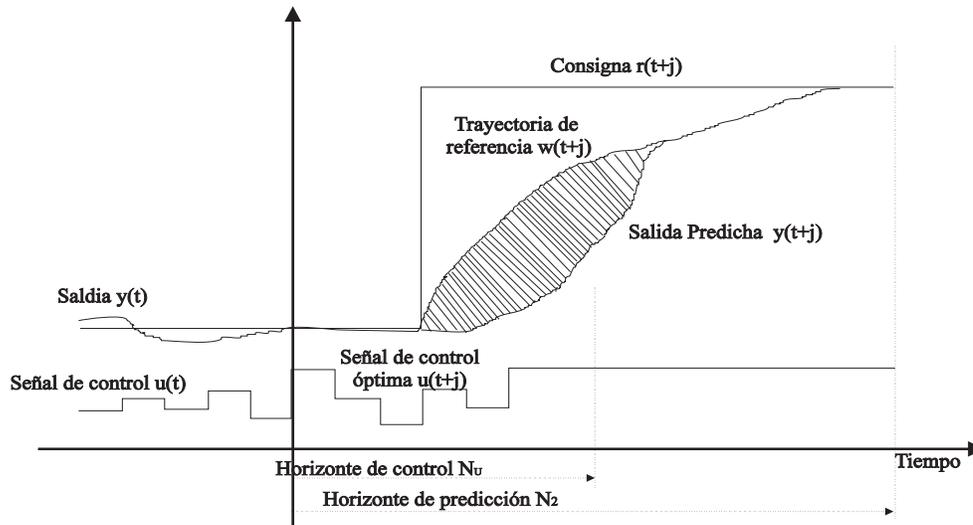


Figura 2.1: Esquema general del CPBM

2.2 Aspectos de implementación en control predictivo

El control predictivo se desarrolla siguiendo los siguientes pasos:

- Modelado
- Cálculo de predicciones
- Optimización de la función de coste

A continuación se describen con más detalle estos puntos

2.2.1 Modelado

2.2.1.a Modelado lineal

El pilar más importante de un controlador predictivo es el modelo, (Allwright, 1994). Un buen diseño incluye todos los mecanismos para obtener el mejor modelo con el fin de implementar un controlador robusto frente a los errores de modelado. Un modelo usado frecuentemente es el modelo CARIMA (Controller Auto-Regressive and Moving Average). Este modelo es equivalente a las otras representaciones lineales existentes como son los modelos en funciones de transferencia o los modelos en espacio de estados detallados en el capítulo 4.

$$A(q^{-1}).y(t) = \left(B(q^{-1}).u(t) + D(q^{-1}).v(t) + \frac{T(q^{-1})}{\Delta} \right) \zeta(t) \quad (2.1)$$

donde:

A,B,D,T son polinomios en q^{-1}

Δ es el operador diferencial $1 - q^{-1}$

$y(t)$ Salida del sistema

$u(t)$ Entrada del sistema

$v(t)$ Perturbaciones medibles

ζ Ruido blanco

Se define una trayectoria de referencia $w(t+j)$, para fijar como debe de responder el proceso desde la salida actual hasta la consigna deseada $r(t+j)$.

2.2.1.b Modelado no lineal

La característica principal del control predictivo no lineal es su base de modelado no lineal. En este apartado se presenta un resumen de los diferentes métodos de modelado no lineal.

☛ Modelos en ecuaciones diferenciales

Estos modelos derivan de las propiedades físicas y de los balances másicos y energéticos de los sistemas. Estos modelos se caracterizan por su eficacia para predecir el comportamiento de los sistemas, ya que se basan en leyes físicas.

Se describen generalmente por modelos no lineales en espacio de estados:

$$\begin{aligned}\mathbf{x}(t + 1) &= f(\mathbf{x}(t), \mathbf{u}(t), \mathbf{v}(t)) \\ \mathbf{y}(t) &= g(\mathbf{x}(t))\end{aligned}\tag{2.2}$$

donde:

$\mathbf{x}(t)$ es el vector de estados.

\mathbf{u} es el vector de entradas.

\mathbf{y} es el vector de salidas.

\mathbf{v} es el vector de perturbaciones.

La obtención de un buen modelo depende de la complejidad que presenta cada sistema y el conocimiento que disponemos a la hora de modelarlo.

Los modelos obtenidos con este método, son generalmente complejos, basados en ecuaciones diferenciales que en muchos casos no tienen

solución analítica. Por esta razón su uso se limita usualmente a la simulación y al estudio y diseño de plantas, y no al control porque conlleva un gran esfuerzo computacional (Prada, 1990). Sin embargo existen algoritmos que si usan estos modelos para control aprovechando su capacidad predictiva y reducen al máximo el esfuerzo computacional (El Ghoumari, 1998).

➤ Redes Neuronales

La idea básica de una red neuronal se puede ilustrar con el caso muy representativo del perceptrón multi-capa (*multi-layer perceptron* MLP).

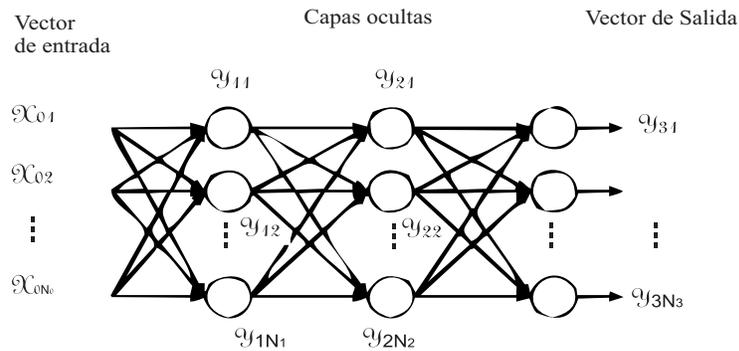


Figura 2.2: MLP de tres capas

El MLP es una red compuesta por H capas. La figura 2.2 representa tres capas MLP. $X = [x_1 \ x_2 \ x_3]$ es un vector de N_1 entradas y $\hat{Y} = [\hat{y}_{31} \ \hat{y}_{32} \ \hat{y}_{3M}]$ es un vector de N_3 salidas. Las dos capas ocultas son respectivamente compuestas por N_1 y N_2 perceptrones.

Cada perceptron j de la capa i , recibe las entradas de todas las unidades de atrás. Sus salidas implican dos acciones (figura 2.2). La primera es que el perceptron j realiza una suma de los pesos de las

entradas. Esto implica una activación potencial p_k

$$p_k = \sum_{j=0}^{N_i-1} x_{ij} w_{jk} \quad (2.3)$$

Donde $x_{ij} = \hat{y}_{i-1}$, $x_{i0} = 1$, w_{jk} es el peso j del perceptron $k = ij$ y w_{ok} es el peso de activación del perceptron.

El potencial p se introduce dentro de una función lineal o no-lineal para determinar la salida \hat{y}_{ij} del perceptron $k = ij$. Usualmente se usa la función sumatorio pero se puede usar otras funciones. La salida del perceptron usando una función suma es:

$$y_{ij} = \frac{1}{1 + e^{\tau p_{ij}}} \quad (2.4)$$

Donde τ es una constante (a menudo escogida como 1) que afecta la forma del sumatorio.

Usando la figura 2.2 podemos determinar la predicción de la MLP activando la red desde la izquierda hacia la derecha (i.e. *feed-forward* activation):

$$y_{Lj} = \sum_{i=1}^H \sum_{j=0}^{N_i} y_{ij} \quad (2.5)$$

Donde $L = H + 1$ es el número de capas de la red.

Como se ilustra en la ecuación 2.5 la salida se calcula como sumatorio del sumatorio de un *mapping* no-lineal. Esto da un idea intuitiva de la gran capacidad de modelización de este algoritmo.

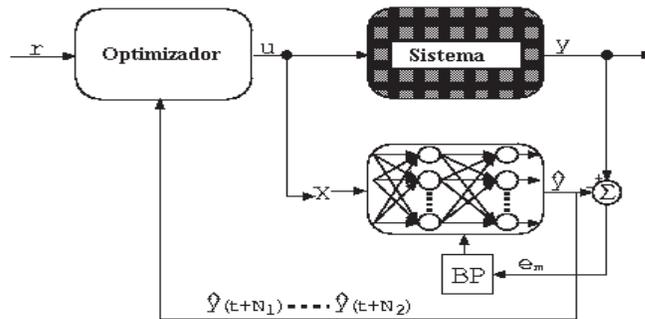


Figura 2.3: Predicciones con un modelo en redes neuronales

La mayor ventaja de esta técnica de modelado es su capacidad de aprendizaje basada en la minimización del error cuadrático, sin embargo el modelo obtenido no deja de ser un modelo de "Caja negra" que su análisis puede ser muy difícil (M.R. Arahal, 1997; JM Zamareno, 1999).

En el área del control predictivo este método de modelado se usa, sobre todo, para controlar sistemas de alto grado de no-linealidades y también para acelerar la obtención de las predicciones.

☛ Modelos *Fuzzy*

La idea principal del modelado *Fuzzy* es el uso de una simple descripción lingüística del proceso, en vez de precisar las relaciones matemáticas entre las variables. Los modelos *Fuzzy* son muy útiles para la descripción de los procesos complejos en los que no se conocen todas las dinámicas involucradas (Babuska, 1996).

El modelo *Fuzzy* se obtiene a partir de los datos del proceso usando la capacidad funcional de aproximación de los sistemas *Fuzzy* y su capacidad de reducir el tiempo de cómputo considerablemente.

Este tipo de modelado tiene la ventaja de ser:

- Fácil de representar.
- Fácil de entender y de depurar.
- Permite adaptaciones.
- Reduce mucho el número de datos y el esfuerzo de ingeniería.
- Muy aceptado en la industria.
- Fácil de hacer las predicciones.

☛ **Multimodelos**

El modelo no-lineal obtenido por esta técnica es una combinación convexa de varios modelos lineales. El número de estos modelos depende del grado de la no-linealidad que presenta el proceso. Varias estrategias usan los resultados de cada modelo para calcular la secuencia de control óptima, mientras otros métodos sólo interpolan entre los diferentes modelos usando los algoritmos de interpolación *i.e.* Métodos *Fuzzy*

Otra alternativa es linealizar el modelo no-lineal del proceso alrededor de muchos puntos de operación, minimizando el coste computacional y usando un algoritmo de control lineal (Bjarne A. Foss and Sorensen, 1995; Megías *et al.*, 1999; El Ghoumari, 1998).

☛ **Otros métodos de modelado**

Existen otros métodos de modelización que usan el método de descomposición del modelo no-lineal a una parte dinámica lineal y otra constituida por un polinomio no lineal estático. Dentro de esta familia citamos los más importantes:

- Representaciones de Volterra
- Modelos Hammerstein
- Modelos Weiner

A continuación se describe brevemente estos modelos:

– **Representaciones de Voltera:**

Las series de Voltera pueden ser interpretados como una extensión natural de los modelos **FIR** (respuesta impulso finita), a los modelos **FIR** no-lineales introduciendo los productos cruzados y polinomios en las entradas. Las series Voltera son una extensión temporal de las series de Taylor. Los modelos Voltera pueden ser obtenidos como una aproximación a otros modelos, o bien directamente identificados a partir de los datos experimentales. Los modelos Voltera pueden entonces ser obtenidos a partir de (Doyle, 1995):

- * Modelos no lineales en ecuaciones diferenciales.
- * Modelos NARMAX.
- * Una red neuronal artificial que usa una función sigma.
- * Datos experimentales entrada/salida.

– **Modelos Hammerstein:**

Estos modelos tienen la estructura especial de facilitar el análisis no-lineal de los procesos, con un enfoque especial para el diseño de controladores. Los modelos Hammerstein generalizan el concepto de *gain-scheduling* en el caso del control no lineal, y lo convierte en un método riguroso de identificación (Fruzzetti, 1997). Los modelos Hammerstein están compuestos de elementos no lineales estáticos en la entrada, seguidos por un elemento dinámico lineal (figura 2.4). Los parámetros del modelo son determinados usando datos de entrada/salida del proceso real. La parte estática no lineal del sistema se puede modelar por una serie N_m (ecuación 2.6):

$$N_m = \sum_{i=1}^{\rho} \gamma_i u^i \quad (2.6)$$

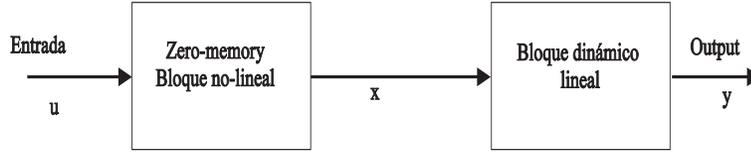


Figura 2.4: Modelo de Hammerstein

Donde ρ es la longitud de la serie y γ es el coeficiente a determinar. El segundo bloque está representado por una función de transferencia lineal clásica (ecuación 2.7)

$$G_m(q^{-1}) = q^{-nk} \frac{B(q^{-1})}{A(q^{-1})} \quad (2.7)$$

Finalmente la relación de entrada salida del sistema es:

$$y_m(k) = q^{-nk} \frac{B(q^{-1})}{A(q^{-1})} \sum_{i=1}^{\rho} \gamma_i u^i(k) \quad (2.8)$$

– **Modelos Wiener:**

Los modelos de Wiener representados por la figura 2.5, tienen un bloque lineal y un bloque que presenta una parte no lineal estática.

La señal de salida del modelo de Wiener se obtiene por el mapeo de una señal intermedia x , a través de una función f (bloque no lineal) tal como:

$$y(k) = f(x(k)). \quad (2.9)$$

Como la señal intermedia $x(k)$ no esta disponible, se puede estimar a través de la función f (o por la función $g = f^{-1}$)

$$x(k) = g(y(k)) \quad (2.10)$$

La función f deberá ser inversible para que un modelo de Wiener podrá ser estimado.

El bloque dinámico lineal esta representado por un modelo ARX, la salida $x(k)$ se calcula por la ecuación 2.10:

$$x(k) = \sum_j \theta_j x(k-j) + \sum_i \sigma_i u(k-i) \quad (2.11)$$

donde:

θ es un parámetro relacionado con la salida del modelo ARX.

σ es un parámetro relacionado con la entrada del modelo ARX
sustituyendo la ecuación 2.9 en la ecuación 2.11 obtendremos:

$$y(k) = f\left(\sum_j \theta_j x(k-j) + \sum_i \sigma_i u(k-i)\right) \quad (2.12)$$

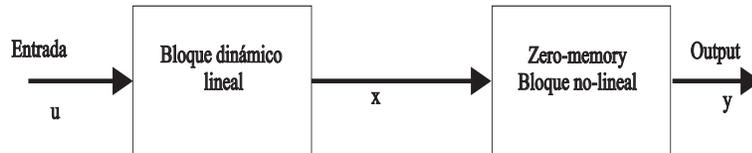


Figura 2.5: Modelo de Wiener

de la ecuación 2.10 podemos deducir que:

$$x(k-j) = g(y(k-j)) \quad (2.13)$$

Sustituyendo la relación 2.13 en la ecuación 2.12, la forma polinomial de un modelo de Wiener se obtiene como relación de entrada salida del sistema $u(k)$ y $y(k)$ y se calcula como:

$$y(k) = f\left(\sum_j \theta_j g(y(k-j)) + \sum_i \sigma_i u(k-i)\right) \quad (2.14)$$

2.2.2 Cálculo de las predicciones

Las predicciones se calculan en base a un tipo de modelo. Vamos a ver a continuación como se haría en el caso de un modelo CARIMA

Las predicciones se pueden calcular a partir del modelo de la ecuación 2.1 en el instante $t + j$

$$A.y(t + j) = B.u(t + j) + D.v(t + j) + \frac{T}{\Delta}\zeta(t + j) \quad (2.15)$$

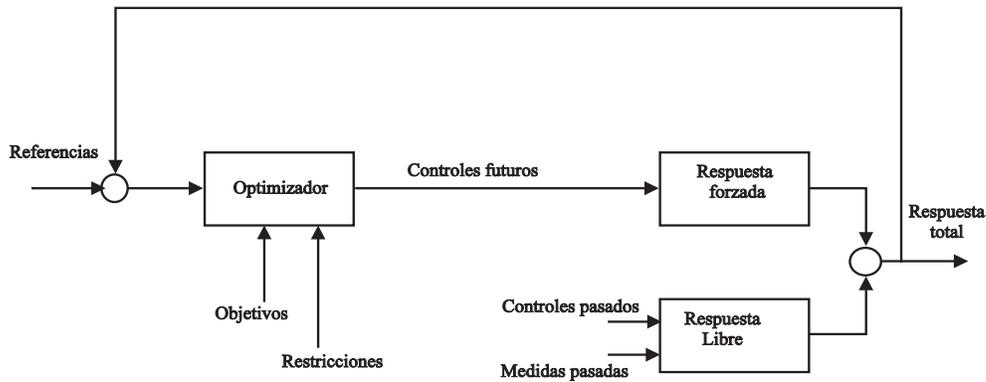


Figura 2.6: Cálculo interno de las predicciones

En el caso de sistemas lineales, la respuesta se puede dividir en dos partes diferentes: respuesta forzada y respuesta libre (figura 2.6). La respuesta libre representa el comportamiento predicho de la salida $y(t + j)$, considerando una acción de control constante. La respuesta forzada o controlada representa la parte de la salida que corresponde a las acciones de control futuras. El principio de superposición se puede usar en el caso de los sistemas lineales. La predicción es la suma de los dos términos (ecuación 2.16), respuesta libre y forzada (De Keyser, 1998; Serrano, 1994a).

$$y(t + j) = y_{libre}(t + j) + y_{forzada}(t + j) \quad (2.16)$$

La respuesta libre se puede calcular suponiendo que los incrementos de control son nulos $\Delta u(t) = 0$ para $j \geq 0$. La respuesta forzada se calcula mediante la ecuación siguiente:

$$y_{forzada} = g_i \Delta u(t) + g_{i-1} \Delta u(t-1) + \dots + g_1 \Delta u(t+j-1) \quad (2.17)$$

donde g_i son los elementos de la respuesta escalón del sistema $G(q^{-1})$.

2.2.3 Función de coste y optimización

La señal de control óptima se calcula minimizando una función de coste a lo largo de un horizonte de predicción.

La formulación de la función de coste se puede hacer de muchas maneras, pero generalmente se define un índice cuadrático. El objetivo es minimizar el error entre la salida actual $y(t)$ y la trayectoria de referencia $w(t)$ durante un horizonte de predicción. La formulación general de esta función de coste (ecuación 2.18) se basa sobre la distancia entre la trayectoria de referencia futura y la salida predicha del proceso.

$$J = \sum_{N_1}^{N_2} [w(t+j) - y(t+j)]^2 + \beta \sum_i^{N_u} [\Delta u(t+j)]^2 \quad (2.18)$$

Donde:

N_1, N_2 son los límites inferior y superior del horizonte de predicción.

N_u es el horizonte de control.

β es factor de peso de la señal de control.

En el caso donde no hay restricciones este método proporciona una solución explícita. El CPBM, en el caso lineal, es matemáticamente equivalente a un problema LQG (*Linear Quadratic Gaussian*). Sin embargo, es la inclusión de las restricciones dentro del algoritmo lo que ha llevado esta técnica a la industria (Bitmead *et al.*, 1990).

Una vez encontrada la señal de control óptima, y usando la técnica del horizonte móvil, el CPBM se convierte en una estrategia de control en lazo cerrado. Ello implica que sólo la primera señal de control $u(t)$ se aplica a la planta y todo el procedimiento se repite en cada instante de muestreo (Pike, n.d.).

2.2.4 Sintonía del controlador

Los métodos para sintonizar un controlador predictivo son muy variados. Antes de empezar a sintonizar un controlador, es importante fijar los objetivos de control: Tiempo de respuesta, porcentaje de sobrepico integral del error cuadrático, etc.

El objetivo principal de una buena sintonía del controlador predictivo, es naturalmente el seguimiento de la consigna cuando hay un cambio en esta última, rechazo de perturbaciones y reducción de sobrepico. A veces conseguir todos estos objetivos es imposible, siempre hay que privilegiar uno sobre los otros, y intentar tener un buen compromiso entre todos ellos.

En (Serrano, 1994a) hay un estudio de como influye cada uno de los parámetros de sintonía sobre la estabilidad, robustez y rendimiento del sistema en lazo cerrado.

2.2.5 Generación de la trayectoria interna

Una de las ventajas importantes del control predictivo es su habilidad de incorporar la referencia futura en su formulación cuando se conoce a priori. De esta forma el sistema puede reaccionar frente a un cambio eventual de la consigna superando los posibles tiempos muertos de la planta. La trayectoria interna $w(t + j)$ es la respuesta deseada en el lazo cerrado del sistema, y tiene que ser considerada en la sintonía del controlador.

La construcción de la trayectoria interna es normalmente una aproximación suave de la salida actual del proceso $y(t)$ hacia la consigna deseada $r(t + j)$, por medio de un polinomio de orden variable según los objetivos de control.

2.3 Control predictivo no lineal

Muchos procesos presentan un comportamiento no lineal, porque operan en puntos de operación muy variados debido a las perturbaciones que les pueden afectar o a cambios en la consigna. Los controladores lineales no pueden resolver el problema de control para estos sistemas en la mayoría de los casos.

El control predictivo no lineal es una buena alternativa para los procesos con dinámicas difíciles, y altamente no lineales. Esta familia de controladores predictivos incorpora más información del sistema a controlar, por lo tanto el resultado de control en general es mucho mejor.

Muchas técnicas de control predictivo son lineales, basadas en modelos lineales del sistema a controlar. Esto se explica porque un modelo lineal es siempre suficientemente válido alrededor del punto de operación, también

por las técnicas avanzadas de identificación y por que muchas plantas operan siempre en el mismo punto y no hay perturbaciones graves. No obstante hay casos donde las no linealidades son muy fuertes, lo que justifica el uso de técnicas de control predictivo no lineal.

El mayor reto para el control predictivo no lineal es la obtención del modelo no lineal. También es de una gran dificultad encontrar soluciones para un problema no-convexo de control óptimo. La elaboración de métodos robustos es de una gran utilidad para evitar inestabilidades frente a errores inevitables de modelado (Megías, 2000).

2.3.1 Consideraciones computacionales

El control predictivo no lineal depende de la manera como encontrar la solución al problema de programación no-lineal en cada instante de muestreo.

Para resolver un problema de control predictivo, es necesario resolver ambos problemas de optimización y integración del modelo del sistema. El control predictivo no lineal puede ser implementado por medio de algoritmos de optimización numérica y de álgebra numérica lineal. Naturalmente el método usado para la optimización es la programación cuadrática secuencial (SQP). Es un algoritmo iterativo que calcula una aproximación del problema general en cada paso de integración.

2.3.2 Estado del arte del Control Predictivo no lineal

En los últimos años la investigación en el área del control predictivo basado en modelos se ha centrado principalmente en el desarrollo de métodos que garantizan la estabilidad. También se han hecho muchos esfuerzos para de-

sarrollar métodos nuevos de modelado adecuados para este tipo de control. Al final de este apartado se expone los últimos avances en la industria de paquetes de CPBM.

2.3.2.a Estabilidad

La estabilidad en el control predictivo no lineal ha sido objetivo de la investigación durante los últimos años. El primer resultado que se ha demostrado para la estabilidad de sistemas no lineales fue el método de forzar el estado de ser en el origen, propuesto por Keerthi y Gilbert (Keerthi, 1988). Este trabajo fue el detonante de muchos importantes trabajos como el método del modo dual (Michalska and Mayne, 1993), el método de restricciones contractivas (Yan, 1993) y más tarde el método que se propone en los trabajos siguientes: (Chen and Allgöwer, 1998b; DeNicolao *et al.*, 1998; Jadbabaie, 1999), que consiste en usar un coste apropiado al estado final en los problemas del control óptimo. Este método fue anteriormente propuesto por Rawlings en (Rawlings and Muske, 1993) para sistemas lineales.

Estos métodos vienen desarrollados a continuación:

- **Restricciones terminales de igualdad**

Consiste en forzar a que el estado sea nulo en el final del horizonte de predicción.

$$\bar{x}(t + T_p) = 0 \quad (2.19)$$

Este Método es muy intuitivo en la teoría del control LQ, porque es equivalente a poner condiciones iniciales infinitas en la ecuación de Riccati (Kleinman, 1974). La explicación es, si el sistema está en el origen al final del horizonte con una entrada nula y sin perturbaciones, seguirá siempre en el origen. La formulación del problema de optimización se resuelve mediante las ecuaciones 2.20 y 2.21

$$\min \sum_{j=0}^{T_2} f(x(k+j), u(k, j)) \quad (2.20)$$

sujeta a :

$$\left\{ \begin{array}{l} \bar{x}(k+j+1) = f(\bar{x}(k+j), \bar{u}(k+j)), \bar{x}(k) = x(k) \\ \bar{u}(k+j) \in U, j \in [0, N_2] \\ x(k+N_2) = 0 \end{array} \right. \quad (2.21)$$

Donde $T_2 = \frac{N_2}{p_m}$ y

N_2 es el horizonte de predicción

p_m es el periodo de muestreo

f es una función no lineal

$x(k+j)$ es el estado del sistema en el instante $k+j$

$u(k+j)$ es la señal de control en el instante $k+j$

- **Horizonte variable en modo dual**

La solución exacta del problema de estabilidad con el método anterior necesita un número de iteraciones infinito en el caso no-lineal. (Michalska and Mayne, 1993) ha propuesto una aproximación de poner restricciones terminales de desigualdad, es decir, que el estado terminal este dentro de una región reducida al final del horizonte de predicción, y realimentado por un estado linealizado localmente.

Al contrario de las restricciones terminales de igualdad (ecuación 2.20), las restricciones terminales de desigualdad se expresan por la ecuación 2.22

$$x(t + N_2) \in \Omega \quad (2.22)$$

Donde Ω es la región terminal

Las ventajas de este método son su eficiencia durante la optimización, y que presenta menos problemas de factibilidad.

Los inconvenientes de este método son su difícil implementación ya que requiere un cambio de estrategia de control si el estado esta dentro de la región terminal. Además necesita determinar un estado lineal estable para la realimentación y por fin una formulación adecuada de la región terminal Ω .

- **Control predictivo contractivo**

Este método propuesto por (Yan, 1993; Oliveira *et al.*, 1995), se resume en imponer al vector de estados una contracción con un factor predeterminado, llamada *restricciones de contracción*. El problema de optimización se formula entonces por las ecuaciones 2.23 y 2.24

$$\min J(x(t), u(t), T_c) \quad (2.23)$$

$$\left\{ \begin{array}{l} \text{sujeta a} \\ \|x(t + N_2)\|^2 \leq \alpha^2 \|x(t)\|^2 \\ \dot{\bar{x}} = f(\bar{x}, u), \quad \bar{x}(t) = x(t) \\ \bar{u}(\tau) \in U, \tau \in [t, t + T_p] \\ T_c \in [t + N_1, t + N_2] \\ \|x(t + N_2)\|^2 \leq \alpha^2 \|x(t)\|^2 \\ \max_{\tau \in [t, t + T_c]} \|x(\tau)\|^2 \leq \beta^2 \|x(t)\|^2 \end{array} \right. \quad (2.24)$$

Este método tiene la ventaja por sus propiedades de estabilidad exponencial. Sin embargo su mayor inconveniente es su difícil implementación en la práctica, y que no hay garantía de factibilidad en cada instante de muestreo.

- **CPBM lineal con una linealización de realimentación**

Este método combina la linealización feedback y las propiedades de estabilidad del control predictivo lineal con restricciones. Este método fue propuesto por (Oliveira and Morari, 1995). El problema de este método es la complejidad que puede generar la linealización feedback.

- **CPBM con horizonte Casi-infinito**

Este método introduce un término de penalidad terminal $E(x(t + T_p))$ en la función de coste. Este término se determina *a priori*.

$$\left\{ \begin{array}{ll} \text{Minimizar} & \int_t^{t+N_2} f(x(\tau), u(\tau))d\tau + E(x(t + N_2)) \\ \text{sujeta a} & \bar{x}(\tau) \in X, \tau \in [t, t + T_p] \\ & \dot{\bar{x}} = f(\bar{x}, u), \bar{x}(t) = x(t) \\ & \bar{u}(\tau) \in U, \tau \in [t, t + T_p] \\ & x(t + T_c) \in \Omega \end{array} \right. \quad (2.25)$$

En resumen, para sistemas no-lineales, la formulación del problema de estabilidad en el control predictivo, se pone restricciones al estado terminal en el lazo abierto. Este método no garantiza la estabilidad y su aplicación en tiempo real es muy difícil. Por otra parte, en la práctica para determinados sistemas se puede conseguir la estabilidad sin imponer restricciones artificiales escogiendo los valores adecuados de los parámetros de la función de coste. Sin embargo, estos métodos prácticos no tienen ninguna base teórica.

Otro método que garantiza la estabilidad sin poner restricciones del estado terminal fue propuesto por Jadbabaie en (Jadbabaie, 1999) usando la función de Liyapunov como estado terminal. Este método no contempla el caso de restricciones en las entradas.

En 1998 De Nicolau (DeÑicolao *et al.*, 1998) propuso un método que establece la estabilidad exponencial para sistemas no-lineales discretos. Este método propone un coste terminal en el infinito si el estado terminal es fuera de una región predeterminada, elección que no garantiza la factibilidad del problema de control óptimo.

Finalmente el último trabajo citado es el de Fontes (Fontes, 2001) que propone una solución con un libre estado terminal (sin restricciones artificiales). Calcula la señal de control resolviendo la secuencia del problema de control óptimo usando el estado del sistema actual como estado inicial. Este método demuestra la eficiencia del algoritmo de optimización, y sobre todo puede demostrar la existencia o no a priori de la estabilidad.

2.3.2.b Desarrollo de modelos

Tres preguntas fundamentales se imponen a la hora de escoger una estrategia de modelado o otra siempre con fines de control:

- ¿Que información explícita es necesaria para lograr un nivel determinado de rendimiento?
- ¿Que limitación fundamental tiene el rendimiento del controlador independientemente del grado de fiabilidad del modelo?
- ¿Que compromiso hay entre la fiabilidad del modelado, el rendimiento del control y la estabilidad?

En este apartado se contesta a estas preguntas exponiendo los métodos de modelado utilizados y analizando que ventaja tiene una o otra. Dentro de muchos métodos, citamos los más importantes:

- **Modelado usando principios fundamentales** : La tendencia de la investigación en este campo se dirige hacia la reducción del orden del modelo. La mayoría de los modelos son muy complejos y el hecho de describirlos con detalle puede conducir a cientos de ecuaciones. En el caso del control predictivo la complejidad de las ecuaciones puede resultar innecesaria, y se puede describir las dinámicas más relevantes del proceso con un número mucho más reducido de ecuaciones. El objetivo de esta técnica de reducción del orden del modelo es obtener un modelo con un orden reducido con una capacidad predictiva del comportamiento del sistema.

Un método de un gran interés, que se utiliza sobre todo en los sistemas fluidos, es el método de generación de un largo rango de datos y hacer una proyección ortogonal sobre los datos. (Sirovich, 1991). Esta técnica no ha tenido mucho éxito en el mundo del control, probablemente porque el caso lineal se puede resolver sin necesidad de datos. Sin embargo esta técnica puede ser una buena solución para el problema de la reducción del orden del modelo.

- **Modelado empírico**: La investigación en este campo se dirige hacia la generación de los datos. En este sentido es fundamental saber que la fiabilidad de cualquier modelo empírico está intrínsecamente relacionada con los datos usados para la construcción del modelo. Es importante destacar que en el caso de los sistemas no-lineales es muy difícil saber que tipo de entradas hay que aplicar al sistema para obtener los datos, incluso si se pudiera hacer cualquier tipo de experimentos y para un tiempo bastante grande el único resultado es aplicar un modelo de Volterra de segundo orden.

Es de una gran importancia estudiar la eficiencia de los experimentos de identificación para generar los datos que tienen suficiente información del sistema a controlar. Es evidente que cuando se trabaja en el lazo cerrado un buen experimento de identificación tiene que llevar a un buen resultado de control, sin embargo esta condición depende del controlador que a su vez depende del modelo. Es un gran dilema en el caso de diseñar controladores basados en la identificación de modelos, y la única solución posible parece ser un diseño iterativo donde el modelo es continuamente mejorado por los nuevos datos obtenidos de la identificación.

En general, cualquier modelo empírico es una aproximación de la dinámica del sistema, por esta razón el problema de incertidumbre del modelo no puede ignorarse o tratarse heurísticamente. Ambas incertidumbres, paramétricas y estructurales, son significantes. Estas incertidumbres están principalmente determinadas por la cantidad y densidad de los datos, de aquí el problema es directamente relacionado con el diseño del experimento de identificación. Desde el punto de vista de diseño de la estrategia de control podemos diseñar un controlador o restringir el cálculo de la señal de control para que la parte incierta del modelo no afecta al rendimiento y evitar un comportamiento oscilatorio o inestable. Este problema se clasifica dentro de la técnica de control robusto. Para aplicar esta técnica hay que aplicar un método para capturar la incertidumbre en un base cuantitativa (B. Cooley, 1997; Gevers, 1991).

Otro método para reducir la cantidad de incertidumbres es continuar de mejorar el modelo en-línea basando se sobre los nuevos datos. Esto nos conduce a la técnica del control adaptativo.

- **Modelado integrado**

Esta técnica consiste en usar las dos técnicas de modelado, empírica y basada en principios fundamentales. Tiene un gran interés porque

en la práctica se necesitan ambas cosas. El conocimiento fundamental y los datos, y que cada una de las técnicas es necesaria para obtener un buen modelo. En este caso, el éxito de la operación de modelado depende de la habilidad de combinar entre las informaciones sacadas a partir de la dos técnicas.

La integración se puede hacer de varias maneras:

- Un modelo basado en principios fundamentales tiene que ser usado solamente para fines de simulaciones con el objetivo de tener una visión sobre el diseño de los experimentos y la selección de la estructura de los modelos. Virtualmente los simuladores no imponen ninguna restricción en el sentido de la cantidad y tipo de los datos que pueden ser recogidos. Es ideal para diseñar experimentos de identificación viables que dan una visión clara del sistema sin preocuparse de problemas de inestabilidad. Además pueden ofrecer indicaciones de cuantos datos se necesitan y que rendimiento en el lazo cerrado se tiene que esperar finalmente. Incluso en el caso de que si tengamos un modelo fundamental muy fiable, un modelo empírico puede ofrecer una manera de obtener un modelo más simple que es más fácil y "dócil" a la hora de usarlo en-línea.
- La situación típica sería primero escribir las ecuaciones básicas representando los balances másicos y energéticos, pero se da poco interés a algunas informaciones críticas cómo la relaciones cinéticas y termodinámicas. En este caso hay que incluir una caja negra dentro de modelo fundamental (basado en modelos fundamentales). La pregunta clave es cómo hay que incluir esta caja negra o estimar los parámetros más relevantes en base de los datos de entrada-salida de la planta. El modelo resultante todavía puede tener solamente una capacidad predictiva de extrapolación y conducir nos a problemas en lazo cerrado. Si

embargo, es probable que el problema sea menos severo.

- Otro método es incluir dentro de modelo empírico algunas restricciones que surgen del entendimiento del proceso a partir de modelo fundamental. Este método se conoce como Caja de identificación gris (*grey box identification*) en la literatura de la identificación de sistemas (Tulleken, 1993). Cómo es imposible encontrar restricciones que puedan ser universalmente aplicables a todos los procesos, sería seguramente más interesante examinar que tipo de restricciones son más relevantes para cada tipo de procesos.
- En algunos casos, modelos de orden reducido, se pueden elaborar en base a los conocimientos que tenemos sobre las características intrínsecas de los sistemas dinámicos. El modelo "traveling wave" de las columnas de destilación de alta pureza es un buen ejemplo de ello (Marquart, 1987).
- En el caso que se pueda encontrar un sistema de ecuaciones diferenciales que describan bien el comportamiento de un sistema, el diseño de un controlador predictivo puede resultar difícil por culpa de la imposibilidad de modelar las perturbaciones y sus características estadísticas. En este caso, los residuos (errores de predicción del modelo fundamental), pueden representarse por un modelo empírico. Es particularmente atractivo desde el punto de vista de que en el lazo cerrado sólo se afectarán las variables manipuladas cuya influencia se predice por medio del modelo fundamental. La parte del modelo combinado que tiene una buena capacidad de predicción. Los residuos que representan los efectos de las perturbaciones no medibles y los ruidos se pueden modelar usando los datos históricos.

2.3.2.c Aplicaciones en la industria

En la mayoría de los paquetes del control predictivo se han adoptado una serie de técnicas para resolver el problema de control:

- Utilización de modelos en el espacio de estados obtenidos de la identificación o principios fundamentales. (**DMC / Aspen Target**)
- Simplificación de los modelos. (**MVC y Process Perfecter**)
- Utilización de los modelos basados en principios fundamentales con un filtro de Kalman. (**NOVA-NLC**)
- Considerar las perturbaciones constantes e integradas como estrategias feedback. (**NOVA-NLC**)
- Las acciones de control son penalizadas por diferentes estrategias: trayectoria de referencia, factor de peso sobre la salida. (**MVC y Process Perfecter**)
- Consideración de las restricciones en el espacio de estados. (**NOVA-NLC**)
- Muchos paquetes aplican restricciones blandas en las VC y restricciones duras en las VM. (**Aspen Target, MVC, NOVA-NLC, etc.**)

El número total de las aplicaciones es más de 4600 ¹, cabe destacar que hasta 1995 este número era sólo de 2200. La mayoría de las aplicaciones se han usado primeramente en la industria petroquímica y de refinería. Después esta técnica fue adoptada POR las industrias de papel y química. Hoy en día varias industrias tienen implementadas aplicaciones (automóvil,

¹El número no incluye las aplicaciones patentadas o implementadas internamente en la industria

microelectrónica, aeroespacial, etc.) *Aspentch* es la compañía con más aplicaciones (1850) tiene en el mercado y el mayor número de variables (603 VC x 283 VM) (Lee, 2001).

Los cambios recientes en la tecnología del CPBM se centran en los aspectos siguientes:

- Técnicas de identificación: en el CPBM sólo se usaba el método de los mínimos cuadrados. Ahora en la industria se puede encontrar técnicas nuevas como el método del error de predicción, subespacio, y mínimos cuadrados recursivos.
- Utilización de filtros: Muchos paquetes incluyen filtros de Kalman
- Estabilidad nominal: En este aspecto no se ha hecho muchos esfuerzos. Sintonizar bien el controlador es la única manera para garantizar la estabilidad de estos paquetes industriales.
- Modelos: Varios tipos de modelos han sido introducidos en los paquetes industriales como: modelos en función de transferencia, en el espacio de estados, modelos adaptativos y multimodelos (Connoisseur donde se han usado 12 modelos distintos para una sola aplicación).

Los aspectos anteriores han aportado a los paquetes industriales más robustez, rapidez de cálculo y fiabilidad en control. Sin embargo los obstáculos que se encuentran son:

- Desarrollo de modelos no lineales
- Estimación de estado
- Velocidad de cálculo en tiempo real

2.4 Resumen

Este capítulo presenta un estudio sobre la estrategia de control predictivo basado en modelos en general. Se analiza la evolución de este controlador desde las ideas básicas de este control (Lee y Markus (1967) y Fleming y Rishel (1975)) hasta llegar a las diferentes técnicas de CPBM modernas (GPC, DMC, etc.). También se analizan los aspectos de implementación de este controlador, dependiendo de la elección del modelo, la función de coste y los parámetros de sintonía.

Al final de este capítulo se presenta un estudio sobre el estado de arte del CPBM en los aspectos siguientes:

- Estabilidad
- Desarrollo de modelos
- Aplicaciones en la industria

Capítulo 3

Modelado del invernadero

Para aplicar el control predictivo es necesario disponer de un modelo del proceso que se quiere controlar. En este capítulo se describe con detalle un sistema agrícola como es el invernadero y su interacción con su entorno. Es importante destacar que este sistema se puede modelar de dos maneras diferentes. La primera es sin considerar el cultivo. De esta forma se estudian sólo las variables climáticas dentro del invernadero, despreciando el efecto de las plantas sobre el clima interno de este. La segunda forma, es incorporar el modelo del cultivo. Así, podemos estudiar el crecimiento de las plantas bajo un cierto clima creado por el invernadero. En este capítulo se van a estudiar las dos formas de modelar el invernadero, ya que en una primera fase se estudia el control predictivo sobre un invernadero vacío de plantas. Una vez este controlador este implantado lo aplicaremos a un invernadero con plantas.

Este trabajo de modelización tiene una doble finalidad. El primer objetivo es obtener un modelo para aplicar el Control predictivo. El segundo objetivo es obtener un modelo validado para fines de simulación y estudio del clima interior, y del comportamiento de las plantas. Este modelo tiene la

característica de ser lo suficientemente general para representar los sistemas industriales de producción en invernaderos, que al mismo tiempo sirve como planta piloto de los experimentos presentados en esta tesis.

En la primera parte de este capítulo se describen los fenómenos que influyen sobre el clima del invernadero. Principalmente la ventilación, radiación solar y los procesos de intercambio por convección, conducción y radiación térmica.

En la segunda parte se desarrolla un modelo del clima que describe la evolución de la temperatura interna, la humedad interna y la concentración de CO₂.

El desarrollo de un modelo de crecimiento de la planta estudiada se hace en la tercera parte. Esta planta se caracteriza por su interés económico, y también por no tener muchas variables de estado que puedan dificultar la optimización en-línea del proceso de producción.

3.1 Descripción del proceso

El invernadero es un recinto cerrado donde la diferencia entre el clima interior y exterior se crea principalmente por la cubierta, mediante la radiación solar y los mecanismos del estancamiento de aire. La radiación se constituye de dos componentes, la onda corta que proviene directamente del sol, y la onda larga que proviene por emisión del suelo, el sistema de calefacción, las plantas y la transmisión por la cubierta (figura 3.1).

El estancamiento de aire se debe al poco cambio de aire que hay entre dentro y fuera del invernadero. Los fenómenos que influyen sobre el clima dentro del invernadero son :

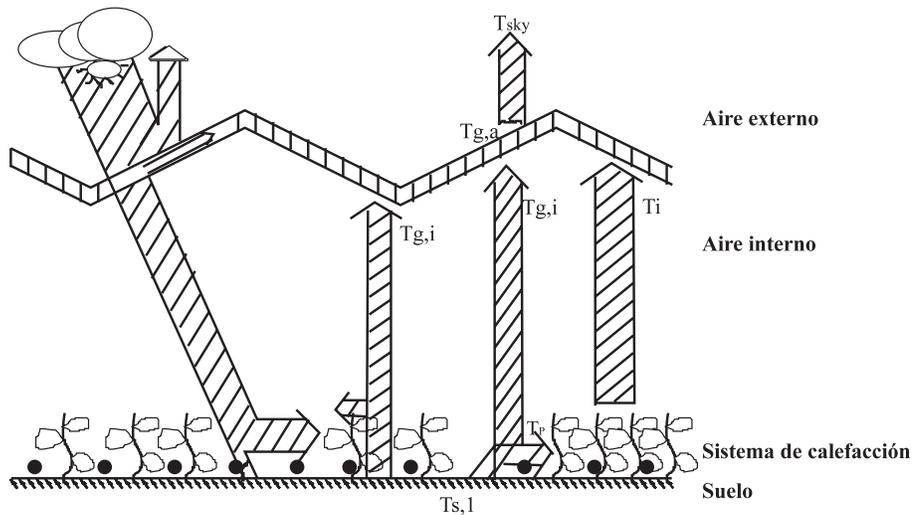


Figura 3.1: Cambios energéticos en un invernadero

- **La ventilación** : es un factor determinante en la totalidad del clima interno. Su influencia se extiende sobre la temperatura, la humedad y sobre la concentración de CO_2 .
- **La radiación solar**: La radiación solar influye mucho sobre la temperatura interior por medio de la cantidad de energía que proporciona. Es una radiación de onda corta, con una longitud de onda de entre 0.2 y $5 \mu m$.
- **Los procesos de intercambio por convección**:

Los intercambios por convección se manifiestan con todas las estructuras existentes dentro del invernadero. Su influencia es principalmente sobre la temperatura interna. En la mayoría de los invernaderos estos procesos se pueden resumir en:

- Intercambios del aire interior a la cara interna del material de la cubierta.

- Intercambios de la cara exterior de la cubierta al aire exterior.
- Intercambios a nivel de la cubierta.

A continuación se describe con más detalle cada uno de estos fenómenos que influyen sobre el ambiente dentro del invernadero.

3.1.1 Ventilación

La ventilación es un fenómeno que tiene un papel muy importante en la determinación del clima del invernadero. Su influencia es determinante sobre la temperatura, la humedad, y el nivel de CO_2 dentro del invernadero. Muchos estudios se han hecho para determinar la influencia de la ventilación sobre la temperatura, y su relación con la velocidad del viento y el grado de apertura de las ventanas. Brown y Solvason en 1962 realizaron el primer estudio teórico sobre la ventilación y su relación con la diferencia de temperatura entre dentro y fuera del invernadero. Kozai y Sase en 1978 fueron los primeros en presentar un modelo de ventilación de un invernadero. Este modelo relaciona la ventilación, la apertura de las ventanas y la velocidad del viento en un invernadero de apertura simple (una sola ventana) en el techo. Es un modelo cuantitativo de la ventilación en un invernadero.

3.1.1.a Características de flujo de aire en una ventana

La apertura de una ventana causa una diferencia de presión Δp entre el interior y el exterior del invernadero, un flujo de aire Φ_v se produce hacia la zona con menor presión. Este flujo Φ_v se puede modelar como el producto de la velocidad del aire \bar{v} y la superficie de la apertura A_0 :

$$\Phi_v = \bar{v} A_0 \quad (3.1)$$

La diferencia de presión se puede deducir del número de Euler E_u , definido como la división de la diferencia de presión Δp por la energía cinética por unidad de volumen.

$$E_u = \frac{\Delta p}{\frac{1}{2}\rho\bar{v}^2} \quad (3.2)$$

De las ecuaciones 3.1 y 3.2 podemos calcular la diferencia de presión:

$$\Delta p = \frac{E_u}{2}\rho\left(\frac{\Phi_v}{A_0}\right)^2 \quad (3.3)$$

Donde:

E_u Número de Euler llamado también factor de aspecto y depende de la forma geométrica de la ventana

ρ es la densidad del aire [Kgm^{-3}]

Φ_v es el flujo de aire [m^3s^{-1}]

A_0 es la superficie básica de apertura de la ventana [m^2] (Área ABCD) (figura 3.2)

La apertura real A_w se puede expresar en función de la apertura básica A_0 de la forma siguiente: $A_w = A_0f(\zeta)$, ζ es el ángulo de apertura y f es una función que varía según el tipo de apertura (figura 3.2).

3.1.1.b Fuerzas Involucradas en la ventilación

La ventilación natural se debe a dos factores, el efecto del viento y el efecto de la diferencia de temperatura entre el interior y el exterior del invernadero. A continuación se describen con más detalle estos dos factores responsables de la ventilación.

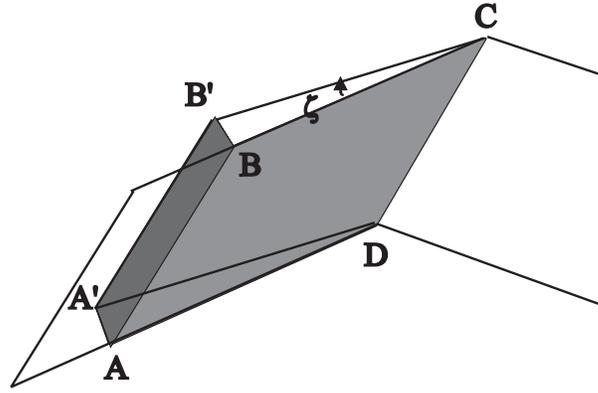


Figura 3.2: Ventana de ventilación

Efecto del viento La presión estática debida al efecto del viento es proporcional a la energía cinética media del viento ($\frac{\rho_a \bar{u}_1^2}{2}$) y se define con la siguiente ecuación:

$$p_u = K_p \frac{\rho_a \bar{u}_1^2}{2} \quad (3.4)$$

ρ_a es la densidad del aire externo. K_p es el coeficiente de presión. A partir de la ecuación 3.4, se puede deducir que el flujo de aire es entrante o saliente, dependiendo de que el valor K_p sea negativo o positivo.

El flujo de aire debido al efecto de viento es el producto de la velocidad del aire por toda la superficie de la apertura de la ventana. Se calcula mediante la ecuación siguiente:

$$Q_v = \int \bar{u} \cdot dA_0 \quad (3.5)$$

donde A_0 es la superficie básica de la ventana (Superficie ABCD , figura 3.2).

Efecto de la temperatura Bajo la suposición de que la temperatura es uniforme dentro del invernadero. La diferencia de presión vertical se puede

expresar en función de la diferencia de temperatura entre dentro y fuera del invernadero:

$$\Delta P(y) = \Delta P_0 - \rho g \left(\frac{\Delta T}{T} \right) y \quad (3.6)$$

donde:

$\Delta P(y)$ es la diferencia de presión vertical [kPa].

ΔP_0 es la diferencia de presión a nivel del suelo [kPa].

ρ es la densidad del aire en el exterior [Kgm^{-3}].

g es la aceleración gravitacional [ms^{-2}].

ΔT es la diferencia de temperatura entre dentro y fuera [$^{\circ}C$].

T es la temperatura del aire exterior [$^{\circ}C$].

A partir de la ecuación 3.3, la velocidad del aire en la apertura se puede deducir como:

$$\bar{u} = \left(\frac{2\Delta P}{\rho E_u} \right)^{\frac{1}{2}} \quad (3.7)$$

Sustituyendo ΔP en la ecuación 3.7 obtendremos la ecuación siguiente:

$$\bar{u} = \left(\frac{2}{\rho E_u} \right)^{\frac{1}{2}} \left(\Delta P_0 - \rho g \left(\frac{\Delta T}{T} \right) y \right)^{\frac{1}{2}} \quad (3.8)$$

El flujo de aire debido a la temperatura Φ_t se define como la integral de la velocidad del aire a lo largo de toda la altura H de la ventana:

$$\Phi_t = L \int_0^H \bar{u}(y) dy \quad (3.9)$$

Donde L es la longitud de la ventana.

Debido a que la resolución de esta integral es muy difícil de calcular (P. Muñoz, 1998), se hace una aproximación de segundo orden. Finalmente se obtiene el flujo de aire térmico por la ecuación siguiente:

$$\Phi_t = \frac{LC_d}{3\left(\frac{\Delta T}{T}\right)g} \left[\left(2g \frac{\Delta T}{T} \right) \left(\frac{H}{2} \right) \right]^{\frac{3}{2}} \quad (3.10)$$

Donde:

C_d es el coeficiente de descarga de la ventana (P. Muñoz, 1998; Jong, 1990).

H es la altura de la ventana.

L es la longitud de la ventana.

3.1.1.c Ventilación resultante

Aplicando el principio de conservación de la masa al aire del invernadero, la cantidad de aire entrante es igual a la cantidad de aire saliente del invernadero, por tanto:

$$Q_v + \Phi_t = 0 \quad (3.11)$$

A partir de la ecuación 3.11 se puede deducir si la ventilación se debe al efecto de viento o al efecto de temperatura, en un invernadero de tipo *Venlo* (invernadero estudiado en este trabajo) los efectos eólicos dominan sobre los efectos térmicos cuando (Matallana G.A, 1995):

$$3V > (\Delta T)^{\frac{1}{2}} \quad (3.12)$$

V es la velocidad de viento fuera del invernadero [ms^{-1}].

ΔT es la diferencia entre las temperaturas interna y externa[°C].

Como se puede deducir de la ecuación 3.12 el efecto térmico predomina solamente a bajas velocidades de viento. Así en el caso de una velocidad de 1 m/s el efecto térmico predominará a partir de una diferencia térmica de 9 °C. En condiciones meteorológicas mediterráneas casi siempre predominará el efecto eólico.

3.1.2 Radiación solar

La radiación solar es una radiación de onda corta con una longitud de onda entre 0.2 y 5 μm . Esta radiación es la principal responsable de la fotosíntesis, y también es la principal fuente de energía en el invernadero.

Tanto la producción, como el clima en los invernaderos, depende mucho de la interacción de la radiación de onda corta con la cubierta. El factor de transmisión determina que cantidad de radiación entrante está disponible para el crecimiento del cultivo. La misma cantidad también contribuye directamente al equilibrio de energía de las plantas. La radiación absorbida por la cubierta del invernadero contribuye directamente al equilibrio de energía de la cubierta.

La cubierta de vidrio es opaca a la radiación de onda larga (superior que 3 μm). La cubierta entonces actúa como una barrera entre el invernadero y este tipo de radiaciones. Así la interacción de la radiación de onda larga con la cubierta contribuye sólo en el balance energético de esta última. Este fenómeno es el llamado efecto invernadero.

La radiación de onda corta proviene directamente del sol como radiación directa o del cielo como radiación difusa. Los dos tipos de radiaciones tienen diferentes características espectrales y geométricas.

La geometría de la radiación directa se caracteriza a partir de la posición del sol, que naturalmente depende del tiempo y del día. La transmisión de la cubierta del invernadero se puede calcular a partir de la posición del sol y de las características geométricas del invernadero si las propiedades ópticas de la cubierta son conocidas.

En su impacto con la cubierta, la radiación de onda corta se divide en tres partes:

- Reflejada: I_R
- Absorbida: I_A
- Transmitida: I_T

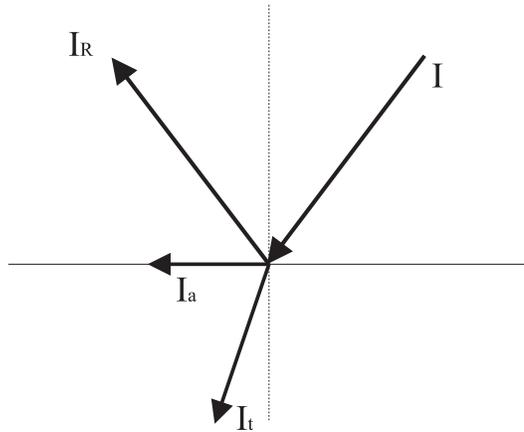


Figura 3.3: Reflexión I_R , Absorción I_a , y transmisión I_t de una radiación incidente I

El flujo de energía radiante que incide sobre una superficie 2 proveniente de otra superficie 1 se calcula a partir del balance térmico aplicando las leyes de termodinámica:

$$E_1 = q_1 A_1 F_{12} \quad (3.13)$$

donde:

F es el factor de forma que depende de la cantidad de energía emitida por la superficie 1

A es la superficie

De la misma manera, el flujo de energía radiante que incide sobre una superficie 1 proveniente de otra superficie 2 es:

$$E_2 = q_2 A_2 F_{21} \quad (3.14)$$

La transferencia neta se puede calcular por la relación siguiente:

$$Q_{12} = q_1 A_1 F_{12} - q_2 A_2 F_{21} \quad (3.15)$$

3.1.3 Procesos de intercambio por convección-conducción

A continuación se describe los diferentes intercambios de energía por convección. Se pueden resumir en tres grupos:

- ☛ Intercambios entre el aire interior y la cara interna del material de cobertura es proporcional a la diferencia de temperatura entre las dos temperaturas. Se pueden calcular mediante la ecuación siguiente:

$$Q_{ii} = h_i (t_i - t_{pi}) \quad [W m^{-2}] \quad (3.16)$$

donde h_i [$\frac{W}{m^2 \cdot ^\circ C}$] es el coeficiente superficial de convección, t_i y t_{pi} son las temperaturas interna del invernadero y de la cara interior de la cubierta respectivamente.

- ☛ Intercambios entre la cara exterior de la cubierta y el aire exterior es proporcional a la diferencia de temperatura entre las dos temperaturas, y se definen por la siguiente ecuación:

$$Q_{ce} = h_e(t_{pe} - t_e) \quad [W m^{-2}] \quad (3.17)$$

donde h_e es el factor de convección exterior [$W m^{-2} \text{ } ^\circ C^{-1}$], t_e es la temperatura exterior [$^\circ C$], t_{pe} es la temperatura de la cara externa de la cubierta.

- ☛ Intercambios a nivel de la cubierta También es proporcional a la diferencia de temperatura entre las dos temperaturas. Vienen definidos por la expresión siguiente:

$$Q_{ci} = \frac{\lambda}{e}(t_{pi} - t_{pe}) \quad [W.m^{-2}] \quad (3.18)$$

donde λ es la conductibilidad térmica [$W m^{-1} \text{ } ^\circ C^{-1}$], e es el espesor de la cubierta, t_{pi} y t_{pe} son las temperaturas de la cara interna y externa de la cubierta respectivamente.

- ☛ Radiación térmica La cubierta en el invernadero estudiado en este trabajo es totalmente opaca, por esta razón la radiación térmica es despreciable y no se tiene en cuenta, ya que su influencia es muy pequeña sobre los balances energéticos del invernadero.

3.2 Modelo dinámico del invernadero

En la literatura se puede encontrar muchos modelos de invernaderos, dependiendo de los fines de los estudios, se da más o menos importancia a algunos fenómenos. En este apartado se desarrolla un modelo no lineal incluyendo todas las dinámicas importantes para la aplicación del control predictivo

no lineal. Las dinámicas incluidas en este modelo son la temperatura, la humedad y el nivel de CO_2 . También se integra el modelo de crecimiento de las plantas. La planta escogida para el modelado es la lechuga.

Se ha elegido el modelo de la lechuga por las razones siguientes:

- Modelo suficientemente desarrollado y validado por varios estudios.
- Modelo no demasiado complejo. Así a la hora de integrarlo en el proceso de optimización no conlleva muchas variables adicionales.
- Planta bastante solicitada en los mercados europeos, por lo tanto su producción es de gran interés económico.

El modelo propuesto en este trabajo es general y se puede aplicar a todos los tipos de invernaderos sin introducir grandes cambios. Las dos grandes familias de invernaderos son los de plástico (abundantes en países del mediterráneo), y los de vidrio (que se usan más en los países del norte de Europa). La gran diferencia entonces es la cubierta y hay que modificar las características de esta última según el tipo de invernadero que se quiere modelar.

El invernadero modelado aquí es un invernadero construido en el *Institute for Horticultural and Agricultural Engineering (ITG)* de la Universidad de Hannover (Alemania). Es un invernadero general y se puede encontrar en cualquier sistema de producción agrícola.

3.2.1 Temperatura interna

La evolución de temperatura interna depende de los siguientes factores:

- La calefacción
- La radiación solar
- La ventilación
- La influencia del suelo

A continuación se describe con más detalle cada punto de estos factores determinantes de la temperatura interna del invernadero.

3.2.1.a Calefacción

Generalmente existen dos tipos de sistemas de calefacción que se usan en los invernaderos:

- Sistemas por agua caliente: consiste en tuberías de hierro distribuidas a lo largo de las paredes del invernadero, donde circula agua caliente proveniente de una caldera dispuesta fuera del invernadero.
- Generador de aire caliente: consiste en un ventilador que proporciona aire caliente al invernadero.

En el invernadero estudiado en este trabajo el sistema de calefacción usado es del primer tipo, que usa agua caliente.

El sistema de calefacción tiene mucha importancia en la determinación de la temperatura interna del invernadero, su influencia Q_{cal} . Es proporcional a la diferencia entre la temperatura interior del invernadero y la del sistema de calefacción. Se puede describir por la ecuación siguiente:

$$Q_{cal} = k_c(T_p - T_i) \quad (3.19)$$

donde:

k_c es el coeficiente de transmisión térmica [$W m^{-2} °C^{-1}$]

T_p es la temperatura del agua dentro del sistema de calefacción [$°C$]

T_i es la temperatura interior del invernadero [$°C$]

La temperatura del agua dentro de los conductos de calefacción es la **variable de control**.

3.2.1.b Radiación solar

La cantidad de radiación solar que entra al invernadero, es proporcional al factor de transmisión de la cubierta. Esta descrita por la ecuación siguiente:

$$Q_{rad} = k_{rad}G \quad (3.20)$$

donde:

k_{rad} es el factor de conversión de la radiación por la cubierta [-].

G es la radiación de onda corta [$W m^{-2}$].

3.2.1.c Ventilación

Una de las consecuencias de la ventilación es la reducción de la temperatura del invernadero. Depende de la diferencia de temperatura que hay entre dentro y fuera del invernadero. Es la suma de dos factores, el primer factor

es por ventilación y el segundo por transmisión a través la cubierta. Su acción se puede calcular por la ecuación siguiente:

$$Q_{vent} = (k_v \Phi_{vent} + k_r)(T_i - T_o) \quad (3.21)$$

donde:

k_v es la capacidad calorífica por unidad volumétrica de aire.

k_r es el coeficiente de transmisión de energía a través de la cubierta.

T_i es la temperatura interior del invernadero.

T_o es la temperatura exterior.

Φ_{vent} es el flujo de aire causado por la ventilación

El flujo de aire causado por ventilación a través de las ventanas Φ_{vent} , se calcula a partir de la velocidad del viento y de la apertura de las ventanas de ventilación. Este flujo depende principalmente del grado de apertura de las ventanas A y de los escapes que pueda tener el invernadero c_{esc} . Se puede calcular por la ecuación siguiente (Jong, 1990):

$$\Phi_{vent} = A \left(\frac{a_1 U_{ls}}{1 + a_2 U_{ls}} + a_3 + a_4 U_{ws} \right) W + c_{esc} \quad (3.22)$$

donde:

A es la apertura de las ventanas por m^2 [%]

a_1 , a_2 , a_3 y a_4 son factores de parametrización de la función de ventilación [-].

U_{ls} y U_{ws} son los grados de apertura de las ventanas [%]

W es la velocidad del viento [ms^{-1}]

c_{esc} es el término de escape de aire a través de las grietas del invernadero [ms^{-1}]

3.2.1.d Influencia del suelo

La temperatura del suelo influye mucho sobre la temperatura del invernadero. La cantidad de energía aportada por el suelo es proporcional a la diferencia entre la temperatura del suelo T_s y la del interior del invernadero T_i . Su contribución se describe por la ecuación siguiente:

$$Q_{suelo} = k_s(T_s - T_i) \quad (3.23)$$

donde:

k_s es el coeficiente de transmisión de calor a través del suelo [$W\ ^\circ C^{-1}\ m^{-2}$]

T_s es la temperatura del suelo [$^\circ C$]

T_i es la temperatura interior [$^\circ C$]

3.2.1.e Submodelo de temperatura

Aplicando un balance energético al aire interior del invernadero se obtiene la siguiente ecuación diferencial:

$$\frac{dT_i}{dt} = \frac{1}{c_{cap,q}}(Q_{rad} + Q_{cal} + Q_{suelo} - Q_{vent}) \quad (3.24)$$

donde:

$c_{cap,q}$ es la capacidad térmica del aire del invernadero [$Wm^{-2}\ ^\circ C^{-1}$]

Q_{rad} es el flujo de energía que proviene del sol [Wm^{-2}]

Q_{cal} es el flujo de energía que proviene del sistema de calefacción [Wm^{-2}]

Q_{suelo} es el flujo de energía que proviene del suelo [Wm^{-2}]

Q_{vent} es el flujo de energía perdida por ventilación, infiltración, conducción y conducción [Wm^{-2}]

3.2.2 Humedad interna

La humedad interna está relacionada con la transpiración de la vegetación $\Phi_{hum,transp}$ [$Kgm^{-2}s^{-1}$], la ventilación $\Phi_{hum,vent}$ [$Kgm^{-2}s^{-1}$] y el aporte de los humidificadores $\Phi_{hum,fog}$ (*fog systems*) [$Kgm^{-2}s^{-1}$] en el caso de los invernaderos que usan este tipo de controles.

3.2.2.a Ventilación

El intercambio del vapor de agua $\Phi_{hum,vent}$ [$Kgm^{-2}s^{-1}$] a través de la ventilación se puede modelar como el producto del flujo de aire Φ_{vent} y la diferencia entre la humedad exterior y interior. Se puede describir por la ecuación siguiente:

$$\Phi_{hum,vent} = \Phi_{vent}(V_i - V_o) \quad (3.25)$$

donde:

Φ_{vent} es el flujo de aire a través de las ventanas [ms^{-1}]

V_i es la humedad absoluta dentro del invernadero [Kgm^{-3}]

V_o es la humedad absoluta fuera del invernadero [Kgm^{-3}]

3.2.2.b Transpiración

La transpiración de la vegetación actúa como una fuente de vapor de agua al aire interior del invernadero. El motor de este fenómeno es la diferencia entre la presión del aire del invernadero y la cavidad sub-estomatal. La presión de saturación está determinada por la temperatura del cultivo (equivalente a la temperatura del aire en este modelo)(Henten, 1994). La transpiración del cultivo se describe por:

$$\Phi_{hum,transp} = (1 - e^{-a_t P_s}) a_{t,m} \left(\frac{c_1 c_2 a_{H_2O}}{a_R (T_i + t_{abs})} e^{\frac{c_3 T_i}{T_i + c_4}} - V_i \right) \quad (3.26)$$

donde:

$a_1[-]$, $a_2[Jm^{-3}]$, $a_3[-]$, $a_4[^\circ C]$ son parámetros de saturación de presión del vapor de agua.

a_t es un factor de parametrización de la función de reducción de la transpiración [$m^2 K g^{-1}$].

P_s es el peso seco estructural [$K g m^{-2}$].

$a_{t,m}$ es el coeficiente de transmisión de masa [$m s^{-1}$].

a_{H_2O} es la masa molecular del agua [$K g k mol^{-1}$].

a_R es la constante de gases perfectos [$J K^{-1} k mol^{-1}$].

T_i es la temperatura interior [$^\circ C$].

t_{abs} es la temperatura absoluta [K].

V_i es la humedad absoluta dentro del invernadero [$K g m^{-3}$].

c_1 es el parámetro de saturación de presión del vapor de agua.

c_2 es el parámetro de saturación de presión del vapor de agua.

c_3 es el parámetro de saturación de presión del vapor de agua.

c_4 es el parámetro de saturación de presión del vapor de agua.

La ecuación 3.26 describe la transpiración de la vegetación para una superficie de 1 m^2 de suelo.

3.2.2.c Humidificación (*fogging*)

Los sistemas de humidificación contribuyen directamente con una cantidad $\Phi_{hum,fog}$ de humedad en el aire interior del invernadero. Su acción consiste en aportar gotas de agua al aire muy finas que se evaporan antes de llegar a las plantas.

3.2.2.d Submodelo de humedad

Aplicando un balance másico de la humedad, se obtiene la ecuación diferencial que explica la evolución de la humedad interna del invernadero. Las cantidades de vapor de agua que se ganan son las que provienen de la transpiración $\Phi_{hum,transp}$ y del sistema de *fogging* $\Phi_{hum,fog}$. Por otra parte, las cantidades que se pierdan son las que salen por causa de la ventilación $\Phi_{hum,vent}$:

$$\frac{dV_i}{dt} = \frac{1}{a_{hum,mas}} (\Phi_{hum,transp} + \Phi_{hum,fog} - \Phi_{hum,vent}) \quad (3.27)$$

donde $a_{hum,mas}$ es la capacidad másica del aire del invernadero para la humedad [m].

3.2.3 Concentración de CO₂

La concentración de CO₂ está condicionada por los siguientes factores:

- El consumo/aporte de la vegetación: durante el día las plantas consumen el CO₂ por fotosíntesis, y por la noche aportan CO₂, por la noche notaremos una subida del nivel de CO₂.
- La Ventilación: El nivel de CO₂ baja o sube por ventilación, según si la concentración de CO₂ interior es más o menos grande que la concentración exterior.
- El aporte de CO₂: en el caso de los invernaderos que disponen de un sistema de aporte de CO₂.

En el siguiente apartado se describe con más detalle todos estos factores que influyen sobre la concentración de CO₂:

3.2.3.a Consumo de la vegetación

El consumo neto de la vegetación Φ_{resp,CO_2} [$Kgm^{-1}s^{-1}$] debido a la fotosíntesis, la respiración de la vegetación y el mantenimiento de la respiración, se puede calcular a partir de la ecuación siguiente:

$$\Phi_{resp,CO_2} = \Phi_{phot} - \frac{1}{c_\alpha} \Phi_{resp} - \frac{1 - c_\beta}{c_\alpha c_\beta} r_{gr} P_s \quad (3.28)$$

donde:

Φ_{phot} es el ratio bruto de la fotosíntesis [$Kgm^{-2}s^{-1}$]

c_α es un factor de conversión [-]

Φ_{resp} es el ratio de mantenimiento de respiración [$Kgm^{-2}s^{-1}$]

c_β es el factor de producción [-]

r_{gr} es el ratio específico de crecimiento [s^{-1}]

Ps es el peso seco estructural. [Kgm^{-2}]

El primer elemento Φ_{phot} de la ecuación 3.28 representa la fotosíntesis bruta, el segundo elemento $\frac{1}{c_\alpha}\Phi_{resp}$ representa el factor de mantenimiento de la respiración y por último el tercer elemento $\frac{1-c_\beta}{c_\alpha c_\beta}r_{gr}C_i$ es la producción de CO_2 por causa de la respiración de la vegetación.

3.2.3.b Ventilación

El intercambio de CO_2 por ventilación es proporcional a la diferencia entre las concentraciones de CO_2 interior C_i y exterior C_o . Se puede calcular por la ecuación siguiente:

$$\Phi_{vent,CO_2} = \Phi_{vent}(C_i - C_o) \quad (3.29)$$

donde:

Φ_{vent} es el flujo de aire causado por la ventilación [ms^{-1}]

C_i es la concentración de CO_2 dentro del invernadero [Kgm^{-3}]

C_o es la concentración de CO_2 fuera del invernadero [Kgm^{-3}]

3.2.3.c Aporte de CO₂

En el caso de los invernaderos que disponen de sistemas de enriquecimiento de CO₂ para alcanzar la concentración de CO₂ deseada dentro del invernadero. El balance másico está afectado por una cantidad aditiva de CO₂ U_{aport} .

3.2.3.d Submodelo de CO₂

Aplicando un balance másico al CO₂ se obtiene la ecuación diferencial siguiente:

$$\frac{dX_c}{dt} = \frac{1}{c_{cap,c}} (U_{aport} - \Phi_{vent,CO_2} - \Phi_{resp,CO_2}) \quad (3.30)$$

3.3 Modelo de crecimiento

El modelo de crecimiento de las plantas escogido en este trabajo es el caso de la lechuga, esta planta se caracteriza por no tener un modelo con muchas variables de estado. Las variables que describen la evolución son:

- Peso no-estructural seco: se constituye por la glucosa, la sucrosa y el almidón de la planta.
- Peso estructural seco: es el resto de los componentes del total del peso seco del cultivo.

En general el peso estructural se obtiene secando el cultivo a temperatura altas (según el tipo de cultivo) y por lo tanto, es un método destructivo. El peso seco total es la suma de estos dos pesos.

El crecimiento del peso seco no-estructural lo determinan los siguientes factores:

- La fotosíntesis bruta Φ_{phot} que contribuye en el aumento del peso seco no estructural.
- La proporción según la cual el material no-estructural se usa en el crecimiento del peso seco no-estructural ($-r_{gr}P_n$).
- Las pérdidas respiratorias asociados con el crecimiento ($\frac{1-c_\beta}{c_\beta}r_{gr}P_s$).

Estos dos factores reflejan cómo los pesos, estructural y no-estructural son inversamente proporcionales. Una aumento del peso estructural por crecimiento o por causa de los efectos respiratorios, se traduce por una disminución del peso seco no-estructural.

- El ratio de mantenimiento de la respiración Φ_{resp} . Este factor proporcióna la energía necesaria para el mantenimiento de las células.

Por otra parte el crecimiento del peso seco estructural depende del ratio, según el cual la materia no-estructural se transforma en materia estructural.

El modelo que describe la evolución de estos dos estados en un m^2 de cultivo, está determinado por las ecuaciones diferenciales siguientes:

$$\begin{aligned}\frac{dP_{ns}}{dt} &= c_\alpha \Phi_{phot} - r_{gr}P_s - \Phi_{resp} - \frac{1-c_\beta}{c_\beta}r_{gr}P_s \\ \frac{dP_s}{dt} &= r_{gr}P_s\end{aligned}\quad (3.31)$$

donde:

P_{ns} es el peso no estructural seco [Kgm^{-2}].

c_α es el factor de conversión de CO_2 a su equivalente en azúcar [-].

Φ_{phot} es el consumo bruto de CO_2 por el mecanismo de fotosíntesis [$\text{K gm}^{-2} \text{s}^{-1}$].

r_{gr} es el ratio específico de crecimiento [-].

Φ_{resp} es el mantenimiento de la respiración [$\text{K gm}^{-2} \text{s}^{-1}$].

c_β es un factor de producción [-].

P_s es el peso estructural [K gm^{-2}].

La fotosíntesis neta se puede modelar como el producto de la fotosíntesis bruta por un factor que determina las propiedades geométricas y ópticas de la vegetación. Se puede calcular por la siguiente ecuación (J. Goudriaan, 1978):

$$\Phi_{phot} = \Phi_{phot,max} \left(1 - e^{-c_k c_{lar,s} (1 - c_\tau) P_s} \right) \quad (3.32)$$

donde:

$\Phi_{phot,max}$ está definida como la asimilación bruta de CO_2 [$\text{K gm}^{-2} \text{s}^{-1}$].

El factor $\left(1 - e^{-c_k c_{lar,s} (1 - c_\tau) P_s} \right)$ representa las propiedades geométricas y ópticas de la vegetación respecto a la radiación solar incidente.

3.4 Modelo Integral del invernadero

Las ecuaciones que rigen las dinámicas de interés en este estudio se describen mediante el conjunto de ecuaciones (3.24, 3.27, 3.30 y 3.31) encontradas en las secciones 3.2.1, 3.2.2 y 3.2.3 y 3.3.

El sistema de ecuaciones diferenciales se escribe en la ecuación siguiente:

$$\left\{ \begin{array}{l} \frac{dT_i}{dt} = \frac{1}{c_{cap,q}} (Q_{rad} + Q_{cal} + Q_{suelo} - Q_{vent}) \\ \frac{dV_i}{dt} = \frac{1}{a_{hum,mas}} (\Phi_{hum,transp} + \Phi_{hum,fog} - \Phi_{hum,vent}) \\ \frac{dX_c}{dt} = \frac{1}{c_{cap,c}} (U_{aport} - \Phi_{vent,CO_2} - \Phi_{resp,CO_2}) \\ \frac{dP_{ns}}{dt} = c_\alpha \Phi_{phot} - r_{gr} P_n - \Phi_{resp} - \frac{1 - c_\beta}{c_\beta} r_{gr} P_s \\ \frac{dP_s}{dt} = r_{gr} P_s \end{array} \right. \quad (3.33)$$

Las tres primeras ecuaciones, representan el modelo del clima del invernadero, mientras que las dos últimas, representan al modelo de crecimiento del cultivo.

La validación de este modelo se obtiene siguiendo las tres etapas siguientes:

- ➡ Estimación
- ➡ Calibración
- ➡ Validación

Esta metodología asegura la buena elección de los parámetros a calibrar y, por lo tanto, la obtención de un modelo válido que reproduce el comportamiento del sistema real. Este estudio se detalla más en detalle en el capítulo 5.

3.5 Resumen

En este capítulo se presenta el proceso de modelado del invernadero. Se trata de un invernadero construido en el *Institute for Horticultural and Agricultural Engineering (ITG)* de la Universidad de Hannover (Alemania). Es un invernadero general y se puede encontrar en cualquier sistema de producción agrícola.

Las variables de estado de este sistema son:

- Temperatura interna: es la temperatura dentro del invernadero. En la elaboración del modelo de temperatura se considera todos los fenómenos que determinan la dinámica de esta variable. Son principalmente la calefacción, la radiación solar, la ventilación y la influencia del suelo.
- Humedad interna: es la humedad en el invernadero y su dinámica esta condicionada por la ventilación, transpiración del cultivo y aporte del sistema de humidificación.
- Concentración de CO₂: Esta variable tiene relación con el consumo de la vegetación en CO₂, la ventilación y el aporte de CO₂ al invernadero.

También se presenta el modelo de crecimiento del cultivo que es la lechuga porque es un modelo sencillo con pocas variables de estado y que son:

- Peso no-estructural seco: se constituye por la glucosa, la sucrosa y el almidón de la planta.
- Peso estructural seco: es el resto de los componentes del total del peso seco del cultivo.

Por último se presenta un estudio sobre la validación de este modelo.

Capítulo 4

Control predictivo no lineal

Varias metodologías han sido seguidas para la formulación del control predictivo. Una de las principales diferencias entre ellas es la elección del modelo. Dos grandes familias de CPBM pueden ser destacadas:

- ☛ **Control Predictivo Lineal**, si el modelo es lineal
- ☛ **Control Predictivo No Lineal**, si el modelo es no lineal

Los algoritmos de control predictivo no lineal propuestos en esta tesis combinan las ventajas de ambos enfoques. Están basados en una linealización en línea, en cada instante de muestreo. A continuación se hace un estudio sobre una serie de controladores basados en esta técnica (ELPC, MELPC, EPSAC). También se incluyen los controladores lineal y no-lineal, ya que el primero es la base de desarrollo y el segundo es la referencia a la que siempre hay que referirse en cuanto a todos los criterios de comparación.

4.1 Control predictivo lineal

La formulación del control predictivo lineal se hace en base a la elección del modelo, varios modelos pueden ser usados: modelos de convolución, modelos en función de transferencia o modelos en variables de estado.

4.1.1 Modelos en el espacio de estados

La formulación del CPBM en el espacio de estados es una metodología unificada para entender y generalizar los algoritmos de CPBM. Esta formulación permite hacer un estudio sistemático de las propiedades de los sistemas en el lazo cerrado desde el punto de vista del control óptimo. Además, el CPBM formulado en el espacio de estados se puede extender al caso no lineal Basta con cambiar a modelos no lineales en el espacio de estados(Chen and Allgöwer, 1998*b*).

4.1.2 Descripción de la planta en el espacio de estados

Dado un sistema multivariable con l entradas y m salidas descrito por el modelo siguiente:

$$\begin{aligned}\mathbf{x}(t+1) &= \mathbf{A}\mathbf{x}(t) + \mathbf{B}\Delta\mathbf{u}(t) + P\mathbf{v}(t) \\ \mathbf{y}(t) &= \mathbf{C}\mathbf{x}(t) + \mathbf{w}(t)\end{aligned}\tag{4.1}$$

donde $\mathbf{x}(t)$ es un vector de n estados, $\mathbf{y}(t)$ es la salida del proceso, $\mathbf{v}(t)$ y $\mathbf{w}(t)$ son ruidos blancos que afectan respectivamente el proceso y la salida,

y tienen las características siguientes:

$$\begin{aligned} E[v(t)] &= 0 \\ E[w(t)] &= 0 \\ E[v(t) v(t)^\top] &= \Gamma_v \\ E[w(t) w(t)^\top] &= \Gamma_w \\ E[v(t) w(t)^\top] &= \Gamma_{vw}. \end{aligned}$$

donde E denota la covarianza.

4.1.3 El algoritmo de control

La salida del modelo en el instante $t + j$ se puede deducir recursivamente de la ecuación (4.1):

$$\begin{aligned} \mathbf{y}(t + j) &= \mathbf{CA}^j \mathbf{x}(t) + \sum_{i=0}^{j-1} \mathbf{CA}^{j-i-1} \mathbf{B} \Delta \mathbf{u}(t + j) + \\ &\quad \sum_{i=0}^{j-1} \mathbf{CA}^{j-i-1} \mathbf{P} \mathbf{v}(t + j) + \mathbf{w}(k + 1) \end{aligned} \quad (4.2)$$

la estimación de la salida viene dada por (Camacho and Bordóns, 1995; P. Alberto, 1989; S. Li, 1989):

$$\begin{aligned} \hat{\mathbf{y}}(t + j) &= E(\mathbf{y}(t + j)) \\ &= \mathbf{CA}^j E(\mathbf{x}(t)) + \sum_{i=0}^{j-1} \mathbf{CA}^{j-i-1} \mathbf{B} \Delta \mathbf{u}(t + j) + \\ &\quad \sum_{i=0}^{j-1} \mathbf{CA}^{j-i-1} \mathbf{P} E(\mathbf{v}(t + j)) + E(\mathbf{w}(k + 1)) \end{aligned} \quad (4.3)$$

considerando que $E[\mathbf{v}(t + j)] = 0$, $E[\mathbf{w}(t + j)] = 0$.

La predicción óptima de orden j es :

$$\hat{\mathbf{y}}(t+j) = \mathbf{C} \mathbf{A}^j E(\mathbf{x}(t)) + \sum_{i=0}^{j-1} \mathbf{C} \mathbf{A}^{j-i-1} \mathbf{B} \Delta \mathbf{u}(t) \quad (4.4)$$

donde:

$\mathbf{C} \mathbf{A}^j E(\mathbf{x}(t))$ es la respuesta libre

$\sum_{i=0}^{j-1} \mathbf{C} \mathbf{A}^{j-i-1} \mathbf{B} \Delta \mathbf{u}(t)$ es la respuesta forzada

Para un horizonte de predicción N_2 , el vector de predicciones viene dado por la ecuación siguiente:

$$\mathbf{y} = \begin{bmatrix} \hat{\mathbf{y}}(t+1|t) \\ \hat{\mathbf{y}}(t+2|t) \\ \vdots \\ \hat{\mathbf{y}}(t+N_2|t) \end{bmatrix} = \begin{bmatrix} \mathbf{C} \mathbf{A} E(\mathbf{x}(t)) + \mathbf{C} \mathbf{B} \Delta \mathbf{u}(t) \\ \mathbf{C} \mathbf{A}^2 E(\mathbf{x}(t)) + \sum_{i=0}^{i=1} \mathbf{C} \mathbf{A}^{j-i-1} \mathbf{B} \Delta \mathbf{u}(t+i) \\ \vdots \\ \mathbf{C} \mathbf{A}^{N_2} E(\mathbf{x}(t)) + \sum_{i=0}^{i=N_2-1} \mathbf{C} \mathbf{A}^{j-i-1} \mathbf{B} \Delta \mathbf{u}(t+i) \end{bmatrix} \quad (4.5)$$

Esta ecuación que se puede expresar de la forma siguiente:

$$\mathbf{y} = \mathbf{F} \hat{\mathbf{x}}(t) + \mathbf{H} \mathbf{u} \quad (4.6)$$

donde:

$$\hat{\mathbf{x}}(t) = E[\mathbf{x}(t)]$$

\mathbf{H} es la matriz triangular inferior donde los elementos no nulos son definidos por:

$$(\mathbf{H})_{ij} = \mathbf{C} \mathbf{A}^{j-i} \mathbf{B} \quad (4.7)$$

y la matriz F está definida por:

$$\mathbf{F} = \begin{bmatrix} \mathbf{C} \mathbf{A} \\ \mathbf{C} \mathbf{A}^2 \\ \vdots \\ \mathbf{C} \mathbf{A}^{N_2} \end{bmatrix} \quad (4.8)$$

por un horizonte de predicción de N_1 hasta N_2 y un horizonte de control N_u , el vector de predicciones es:

$$\mathbf{y}_{N_2} = [\hat{\mathbf{y}}(t + N_1 | t)^\top \quad \dots \quad \hat{\mathbf{y}}(t + N_2 | t)^\top]^\top \quad (4.9)$$

y el vector de las señales de control es:

$$\mathbf{U}_{N_u} = [\Delta \mathbf{u}(t)^\top \quad \dots \quad \Delta \mathbf{u}(t + N_u - 1)^\top]^\top \quad (4.10)$$

resultado que nos conduce a la expresión siguiente de la predicción de la salida:

$$\mathbf{y}_{N_2} = \mathbf{F}_{N_2} \hat{\mathbf{x}}(t) + \mathbf{H}_{N_2} \mathbf{U}_{N_u} \quad (4.11)$$

donde:

$$\mathbf{F}_{N_2} = \begin{bmatrix} \mathbf{C} \mathbf{A}^{N_1} \\ \mathbf{C} \mathbf{A}^{N_1+1} \\ \vdots \\ \mathbf{C} \mathbf{A}^{N_2} \end{bmatrix} \quad (4.12)$$

y

$$\mathbf{H}_{N_{123}} = \begin{bmatrix} \mathbf{C} \mathbf{A}^{N_1} \mathbf{B} & 0 & 0 & \dots & 0 \\ \cdot & \mathbf{C} \mathbf{A}^{N_1} \mathbf{B} & 0 & \dots & 0 \\ \cdot & \cdot & \mathbf{C} \mathbf{A}^{N_1} \mathbf{B} & \dots & 0 \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \mathbf{C} \mathbf{A}^{N_2} \mathbf{B} & \mathbf{C} \mathbf{A}^{N_2-1} \mathbf{B} & \mathbf{C} \mathbf{A}^{N_2-2} \mathbf{B} & \dots & \mathbf{C} \mathbf{A}^{N_2-N_u} \mathbf{B} \end{bmatrix} \quad (4.13)$$

La función de coste de la ecuación 2.18 se puede reescribir de la forma siguiente:

$$\mathbf{J} = (\mathbf{H}_{N_{123}} \mathbf{U}_{N_2} + \mathbf{F}_{N_2} \hat{\mathbf{x}}(t) - \mathbf{w})^\top \bar{\mathbf{R}} (\mathbf{H}_{N_{123}} \mathbf{U}_{N_2} + \mathbf{F}_{N_2} \hat{\mathbf{x}}(t) - \mathbf{w}) + \mathbf{U}_{N_u}^\top \bar{\mathbf{Q}} \mathbf{U}_{N_u} \quad (4.14)$$

Derivando esta última expresión de la función de coste respecto a \mathbf{u}

$$\frac{\partial \mathbf{J}}{\partial \Delta \mathbf{u}} = 0 \quad (4.15)$$

$$(\mathbf{H}_{N_{123}} \mathbf{U}_{opt} + \mathbf{F}_{N_2} \hat{\mathbf{x}}(t) - \mathbf{w})^\top \bar{\mathbf{R}} \mathbf{H}_{N_{123}} + \mathbf{U}_{opt}^\top \bar{\mathbf{Q}} = 0 \quad (4.16)$$

finalmente la expresión de la señal de control óptima viene dada por:

$$\mathbf{U}_{opt} = (\mathbf{H}_{N_{123}}^\top \bar{\mathbf{R}} \mathbf{H}_{N_{123}} + \bar{\mathbf{Q}})^{-1} \mathbf{H}_{N_{123}}^\top \bar{\mathbf{R}} (\mathbf{w} - \mathbf{F}_{N_2} \hat{\mathbf{x}}(t)) \quad (4.17)$$

4.2 El control predictivo no lineal mediante optimización global

Si disponemos de un conjunto de ecuaciones diferenciales no lineales, u otros modelos no lineales de otro tipo (Redes neuronales, Modelos paramétricos,

Modelos cualitativos), el control predictivo se puede plantear como un problema no lineal. Cuando no hay restricciones ese problema se convierte en un problema clásico de control óptimo y la solución se encuentra mediante el cálculo de variaciones o mediante programación dinámica, que también sirve en el caso del control predictivo con restricciones (Serrano, 1994b).

Este método, en resumen, es un problema de programación no lineal. Estamos utilizando una discretización respecto al tiempo del vector de controles y usando como modelo de simulación las ecuaciones diferenciales para el cálculo de las predicciones y de los gradientes necesarios para el algoritmo numérico de optimización.

4.2.1 Aspectos de implementación

Consideramos un sistema no lineal descrito por la siguiente ecuación diferencial:

$$\dot{\mathbf{x}}(t) = f(\mathbf{x}(t), \mathbf{u}(t)), \quad \mathbf{x}(0) = \mathbf{x}_0 \quad (4.18)$$

$$\mathbf{y} = g(\mathbf{x}) \quad (4.19)$$

donde $\mathbf{x}(t)$ y $\mathbf{u}(t)$ denotan los vectores de estados y de control respectivamente.

El problema de optimización en lazo abierto descrito anteriormente se formula matemáticamente de la forma siguiente:

Encontrar el mínimo de una función objetivo predeterminada:

$$\mathbf{U}_{opt} = \min_u J(\mathbf{y}(t), \Delta\mathbf{u}(t), N_1, N_2, N_u) \quad (4.20)$$

donde J es la función de coste de la forma siguiente:

$$J(\mathbf{y}(t), \mathbf{u}(t), N_1, N_2, N_u) = \int_0^{t+N_2} (\mathbf{y} - \mathbf{w})^\top \mathbf{Q} (\mathbf{y} - \mathbf{w}) + \Delta \mathbf{u}(t)^\top \mathbf{R} \Delta \mathbf{u}(t) \quad (4.21)$$

donde \mathbf{y} es la salida deseada, \mathbf{w} es la referencia, \mathbf{Q} y \mathbf{R} son las matrices de peso.

Este procedimiento se repite en cada instante de muestreo, actualizando las informaciones del sistema.

4.2.2 Ventajas e inconvenientes

La ventaja que presenta este método es la precisión máxima de las predicciones, porque es un problema completamente general. En contrapartida el inconveniente principal de este método es su coste computacional muy grande, porque dentro de todo el proceso de optimización se integran las ecuaciones diferenciales en cada evaluación de la función de coste.

4.3 Control predictivo no lineal mediante linealización *on-line*

En este apartado se presentan las cuatro técnicas de control predictivo con linealización *on-line*, los controladores ELPC, MELPC, MELPC con restricciones, EPSAC. Al final se hace un estudio comparativo de todos estos métodos sobre un reactor químico encamisado CSTR con una reacción de Van der Vusse.

4.3.1 El *Extended Linearised Predictive Controller* ELPC

El **ELPC** es un controlador predictivo que se basa principalmente en linealizar el modelo no lineal en cada instante de muestreo. Esta técnica garantiza que el control presente una menor sensibilidad a los cambios de punto de trabajo. Un razonamiento similar (basado en LQG) se ha hecho en (Friedland, 1996). La formulación del **ELPC** en cada instante de muestreo se hace como en el caso de un controlador lineal, la única diferencia es que la linealización se hace en un punto no estacionario lo que implica la aparición de unos vectores constantes en la formulación del modelo lineal en el espacio de estados.

4.3.1.a Linealización en un punto no estacionario

El modelo lineal en el espacio de estados se puede expresar como:

$$\begin{aligned} \mathbf{x}(t+1) &= \bar{\mathbf{x}} + \bar{\mathbf{A}}_t \mathbf{x}(t) + \bar{\mathbf{B}}_t \Delta \mathbf{u}(t) \\ \mathbf{y}(t) &= \bar{\mathbf{y}} + \bar{\mathbf{C}}_t \mathbf{x}(t) \end{aligned} \quad (4.22)$$

donde $\bar{\mathbf{x}}$ y $\bar{\mathbf{y}}$ son vectores constantes.

Las matrices $\bar{\mathbf{A}}_t$, $\bar{\mathbf{B}}_t$ y $\bar{\mathbf{C}}_t$ son matrices que se recalculan en cada instante de muestreo.

El modelo lineal en continuo se debe discretizar. Para evitar problemas de errores en estado estacionario se ha añadido un integrador en la formulación del modelo.

Los vectores constantes se pueden obtener según la naturaleza de la matriz $\bar{\mathbf{A}}_t$. A continuación se describe como se calculan los vectores $\bar{\mathbf{x}}$ y $\bar{\mathbf{y}}$:

- **Caso 1:** $\bar{\mathbf{A}}_t$ es diagonalizable

Dado el sistema de ecuaciones siguiente:

$$\dot{\mathbf{x}}(t) = \bar{\mathbf{x}} + \bar{\mathbf{A}}_t \mathbf{x}(t) \quad (4.23)$$

Si $\bar{\mathbf{A}}_t$ es diagonalizable, siempre se puede encontrar una matriz \mathbf{D} diagonal que se escribe como: $\mathbf{D} = \mathbf{P}^{-1} \bar{\mathbf{A}}_t \mathbf{P}$ y haciendo un cambio de variable $\mathbf{z} = \mathbf{P}^{-1} \mathbf{x}$. La ecuación (4.23) se puede escribir de la forma siguiente:

$$\dot{\mathbf{z}}(t) = \mathbf{D} \mathbf{z}(t) + \varphi \quad (4.24)$$

donde $\varphi = \mathbf{P}^{-1} \bar{\mathbf{x}}$

La componente de orden i del vector z se puede escribir como:

$$\dot{\mathbf{z}}_i = \lambda_i \mathbf{z}_i + \varphi_i \quad (4.25)$$

donde λ_i es el elemento de la diagonal de la matriz \mathbf{D} de orden i .

La discretización de la ecuación (4.25) con un período de muestreo h , se obtiene según los valores de los elementos de la diagonal de la matriz \mathbf{D}

Si $\lambda_i \neq 0$

$$\mathbf{z}_i(k+1) = e^{\lambda_i h} \mathbf{z}_i(k) + (e^{\lambda_i h} - 1) \frac{a_i}{\lambda_i} \quad (4.26)$$

donde a_i es el elemento de orden i del vector φ , así el vector constante se puede expresar en discreto como:

$$\bar{\theta}_i = (e^{\lambda_i h} - 1) \frac{a_i}{\lambda_i} \quad (4.27)$$

Si $\lambda_i = 0$

$$\mathbf{z}_i(k+1) = \mathbf{z}_i(k) + \varphi_i h \quad (4.28)$$

En este caso el vector constante se expresa como:

$$\bar{\theta}_i = \varphi_i h \quad (4.29)$$

la expresión de la ecuación (4.27) converge hacia la expresión de la ecuación (4.29) cuando λ_i tiende hacia cero.

- **Caso 2:** $\bar{\mathbf{A}}_t$ no es diagonalizable En este caso se busca la forma canónica de Jordan de la matriz $\bar{\mathbf{A}}_t$, así: se hace el mismo procedimiento que en el caso 1

$$\Lambda = \mathbf{P}^{-1} \bar{\mathbf{A}}_t \mathbf{P} \quad (4.30)$$

donde Λ tiene la forma canónica de Jordan y \mathbf{P} es la matriz de cambio de base.

$$\Lambda = \begin{bmatrix} [J_1] & & 0 & & \\ & \ddots & & \cdot & 0 \\ & & [J_i] & & \\ & & & \lambda_1 & 0 \\ 0 & & & & \lambda_i \\ & & & 0 & \lambda_i \end{bmatrix} \quad (4.31)$$

Las componentes J_i son la matrices de Jordan definidas por la expresión siguiente:

$$J_i = \begin{matrix} i_1 \rightarrow \\ \\ i_2 \rightarrow \end{matrix} \begin{bmatrix} \lambda_i & 1 & & 0 \\ 0 & \lambda_i & 1 & 0 \\ & & & \cdot \\ & & & 1 \\ 0 & & & & \lambda_i \end{bmatrix} \quad (4.32)$$

La ecuación (4.23) se puede escribir de la forma siguiente:

$$\dot{\mathbf{z}}(t) = \Lambda \mathbf{z}(t) + \varphi \quad (4.33)$$

donde $\varphi = \mathbf{P}^{-1} \bar{\mathbf{x}}$

Como en el caso anterior, la componente de orden i del vector z viene dada por la expresión siguiente:

$$\dot{\mathbf{z}}_i = \mathbf{J}_i \mathbf{z}_i + \varphi_i \quad (4.34)$$

donde $\mathbf{z}_i = [\mathbf{z}_{i1} \dots \mathbf{z}_{i2}]^\top$, y $\varphi_i = [\varphi_{i1} \dots \varphi_{i2}]$

La discretización de la ecuación (4.34) con un período de muestreo h se calcula según la naturaleza de los valores propios λ_i (nulas o no): $\lambda_i \neq 0$

$$\begin{aligned} z_i(k+1) &= e^{J_i h} z_i(k) + (e^{J_i h} - I) J_i^{-1} \varphi_i \\ &= e^{J_i h} z_i(k) + \theta_i \end{aligned} \quad (4.35)$$

donde $\theta_i = (e^{J_i h} - I) J_i^{-1} \varphi_i$ es un vector constante. $\lambda_i = 0$

En este caso las matrices de Jordan se convierten en la forma siguiente:

$$J_1 = \begin{matrix} i_1 \rightarrow & \begin{bmatrix} 0 & 1 & \dots & 0 \\ 0 & 0 & 1 & \dots \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & 1 \\ i_2 \rightarrow & 0 & \dots & 0 \end{bmatrix} \end{matrix} \quad (4.36)$$

La ecuación (4.23) se escribe ahora como lo siguiente:

$$\begin{aligned} \dot{z}_{i_1} &= z_{i_1+1} + \varphi_{i_1} \\ \dot{z}_{i_1+1} &= z_{i_1+2} + \varphi_{i_1+1} \\ &\vdots \\ &\vdots \\ &\vdots \\ \dot{z}_{i_2-1} &= z_{i_2} + \varphi_{i_2-1} \\ \dot{z}_{i_2} &= \varphi_{i_2} \end{aligned}$$

La discretización con un período de muestreo viene dada por la ecuación siguiente:

$$z_i(k+1) = e^{J_i h} z_i(k) + \theta_i \quad (4.37)$$

donde

$$e^{J_i h} = \begin{bmatrix} 1 & h & \frac{h^2}{2} & \frac{h^3}{3!} & \cdot & \cdot & \frac{h^{n-1}}{(n-1)!} \\ 0 & 1 & h & \frac{h^2}{2} & \cdot & \cdot & \frac{h^{n-2}}{(n-2)!} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \cdot & \cdot & \cdot & 1 \end{bmatrix} \quad (4.38)$$

y

$$\theta_i = \begin{bmatrix} h & \frac{h^2}{2} & \frac{h^3}{3} & \cdot & \cdot & \cdot & \frac{h^n}{n!} \\ 0 & h & \frac{h^2}{2} & \cdot & \cdot & \cdot & \frac{h^{n-1}}{(n-1)!} \\ \cdot & \cdot & h & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \cdot & \cdot & \cdot & h \end{bmatrix} \varphi_i \quad (4.39)$$

Finalmente la discretización viene dada por la ecuación siguiente:

$$\mathbf{z}(k+1) = e^{\Lambda h} \mathbf{z}(k) + \theta \quad (4.40)$$

Este caso se puede considerar como el caso general, por que cualquier matriz se puede descomponer en matrices que tienen la forma canónica de Jordan. La generalización puede tener el inconveniente de hacer que los cálculos sean más costosos calculando la serie de potencias del vector constante θ_i y de la matriz $e^{J_i h}$, por esta razón a la hora de diseñar el controlador hay que estudiar si en algún instante de muestreo la linealización puede dar matrices no diagonalizables.

4.3.1.b Implementación del ELPC

El **ELPC** se implementa como un controlador predictivo lineal formulado en el espacio de estados (ecuación 4.11) en cada **instante de muestreo**.

La predicción óptima de orden j es :

$$\hat{\mathbf{y}}(t+j) = \bar{\mathbf{y}} + \bar{\mathbf{C}}_t \sum_{i=0}^{j-1} \bar{\mathbf{A}}_t^j \bar{\mathbf{x}}(t) + \sum_{i=0}^{\min(N_u, j)-1} \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{j-1-i} \bar{\mathbf{B}}_t \Delta \mathbf{u}(t+i) \quad (4.41)$$

En un horizonte de predicción N_2 , el vector de predicciones viene dado por la ecuación siguiente:

$$\mathbf{y} = \begin{bmatrix} \hat{\mathbf{y}}(t+1|t) \\ \hat{\mathbf{y}}(t+2|t) \\ \vdots \\ \hat{\mathbf{y}}(t+N_2|t) \end{bmatrix} \quad (4.42)$$

$$= \begin{bmatrix} \bar{\mathbf{y}} + \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t \bar{\mathbf{x}}(t) + \bar{\mathbf{C}}_t \bar{\mathbf{B}}_t \Delta \mathbf{u}(t) \\ \bar{\mathbf{y}} + \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^2 \bar{\mathbf{x}}(t) + \sum_{i=0}^{i=1} \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{j-i-1} \bar{\mathbf{B}}_t \Delta \mathbf{u}(t+i) \\ \vdots \\ \bar{\mathbf{y}} + \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_2} \bar{\mathbf{x}}(t) + \sum_{i=0}^{i=N_2-1} \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{j-i-1} \bar{\mathbf{B}}_t \Delta \mathbf{u}(t+i) \end{bmatrix} \quad (4.43)$$

Por unos horizontes de predicción N_2 y de control N_u la ecuación (4.43) se puede expresar de la forma siguiente:

$$\mathbf{y}_{N_2} = \bar{\boldsymbol{\varphi}} + \mathbf{F}_{N_2} \bar{\mathbf{x}}(t) + \mathbf{H}_{N_2} \mathbf{U}_{N_u} \quad (4.44)$$

donde:

$$\bar{\varphi} = [\bar{\mathbf{y}}^\top \quad \bar{\mathbf{y}}^\top \quad \dots \quad \bar{\mathbf{y}}^\top]^\top \quad (4.45)$$

$$\mathbf{F}_{N_{12}} = \begin{bmatrix} \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_1} \\ \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_1+1} \\ \vdots \\ \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_2} \end{bmatrix} \quad (4.46)$$

y

$$\mathbf{H}_{N_{123}} = \begin{bmatrix} \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_1} \bar{\mathbf{B}}_t & 0 & 0 & \dots & 0 \\ \cdot & \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_1} \bar{\mathbf{B}}_t & 0 & \dots & 0 \\ \cdot & \cdot & \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_1} \bar{\mathbf{B}}_t & \dots & 0 \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_2} \bar{\mathbf{B}}_t & \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_2-1} \bar{\mathbf{B}}_t & \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_2-2} \bar{\mathbf{B}}_t & \dots & \bar{\mathbf{C}}_t \bar{\mathbf{A}}_t^{N_2-N_u} \bar{\mathbf{B}}_t \end{bmatrix} \quad (4.47)$$

La función de coste se puede reescribir de la forma siguiente:

$$J = (\mathbf{H}_{N_{123}} \mathbf{U}_{N_2} + \mathbf{F}_{N_u} \bar{\mathbf{x}}(t) + \bar{\varphi} - \mathbf{w})^\top \bar{\mathbf{R}} (\mathbf{H}_{N_{123}} \mathbf{U}_{N_u} + \mathbf{F}_{N_{12}} \bar{\mathbf{x}}(t) + \bar{\varphi} - \mathbf{w}) + \mathbf{U}_{N_u}^\top \bar{\mathbf{Q}} \mathbf{U}_{N_u} \quad (4.48)$$

Derivando esta última expresión de la función de coste respecto a \mathbf{u} , obtendremos la expresión del control óptimo:

$$\mathbf{U}_{opt} = (\mathbf{H}_{N_{123}}^\top \bar{\mathbf{R}} \mathbf{H}_{N_{123}} + \bar{\mathbf{Q}})^{-1} \mathbf{H}_{N_{123}}^\top \bar{\mathbf{R}} (\mathbf{w} - \mathbf{F}_{N_{12}} \bar{\mathbf{x}}(t) - \bar{\varphi}) \quad (4.49)$$

El procedimiento de obtener la señal de control óptima en el caso lineal se repite en cada instante de muestreo, teniendo como condiciones iniciales la señal de control pasada y la salida actual del sistema.

Claramente este controlador no usa el modelo no lineal directamente sino, a través de una linealización en cada instante de muestreo. De esta deficiencia nace la idea de usar un controlador que usa directamente el modelo no lineal del sistema para el cálculo de la respuesta libre. Esta versión modificada de este controlador se desarrolla en la sección siguiente.

4.3.2 El *Modified Extended Linearised Predictive Controller*

La idea general de este controlador se resume por lo siguiente: para el cálculo de la respuesta forzada se hace una linealización del modelo no lineal en cada instante de muestreo, y para el cálculo de la respuesta libre se resuelve las ecuaciones diferenciales del modelo no lineal manteniendo como entrada la señal de control calculada en el instante anterior, tal como se ha descrito en el caso del controlador lineal.

Como todos los controladores predictivos el *Modified Extended Linearised Predictive Controller* (**MELPC**) necesita un modelo de predicción, que es un modelo no lineal de la planta; es decir, el conjunto de ecuaciones diferenciales que describen la dinámica del sistema.

4.3.2.a Integración de las ecuaciones diferenciales

Como se ha descrito anteriormente se necesita integrar las ecuaciones diferenciales en cada instante de muestreo, operación que exige una gran precisión para el cálculo de la respuesta libre. La elección de un método de integración u otro es crucial para la obtención de buenos resultados que pueden compaginar entre precisión de predicción y tiempo de cálculo (Ayyub, 1996).

4.3.2.b Aspectos de implementación del MELPC

Como todos los controladores predictivos, para la implementación del MELPC se precisa el cálculo de la respuesta libre y de la respuesta forzada del sistema

Cálculo de las predicciones

Bajo la suposición de que el principio de separación se puede aplicar a sistemas no lineales cuando se opera en puntos muy cercanos, esta aproximación nos conduce al resultado de que la respuesta del sistema se puede dividir en dos partes, una respuesta libre (sin acciones de control futuras) y una respuesta forzada:

$$\mathbf{y}(t+j) = f(\mathbf{x}(t+j), \mathbf{u}_f(t+j), \mathbf{u}_c(t+j)) \quad (4.50)$$

\mathbf{u}_f : la señal de control suponiendo que no hay acciones de control futuras

$$\mathbf{u}_f(t+j) = \mathbf{u}(t-1), \quad j \geq 0.$$

\mathbf{u}_c : la señal de control futura que hay que determinar

$$\mathbf{u}_c(t-j) = 0, \quad j < 0 \text{ y } \Delta \mathbf{u}_c(t+j) = \Delta \mathbf{u}(t+j), \quad j \geq 0.$$

Si hacemos un desarrollo de Taylor a la ecuación (4.50) obtendremos:

$$\begin{aligned} \mathbf{y}(t+j) &= f(\mathbf{x}(t+j), \mathbf{u}_f(t+j)) + \mathbf{H}_j \Delta \mathbf{u}_c(t+j) + e = \mathbf{y}_f + \mathbf{y}_c \quad (4.51) \\ \mathbf{H}_j &= \frac{\partial f}{\partial \mathbf{x}} \frac{\partial \mathbf{x}}{\partial \mathbf{u}} + \frac{\partial f}{\partial \mathbf{u}} \end{aligned}$$

Haciendo una aproximación de primer orden:

$$\begin{aligned} \mathbf{y}_f &= f(\mathbf{x}(t+j), \mathbf{u}_f(t+j)) \\ \mathbf{y}_c &= \mathbf{H}_j(q^{-1}) \Delta \mathbf{u}_c(t+j) \end{aligned} \quad (4.52)$$

Respuesta libre La respuesta libre se puede calcular simplemente resolviendo la ecuaciones diferenciales del sistema manteniendo los valores de

entrada salida y usándolos como condiciones iniciales mediante el modelo no lineal de predicción.

$$\begin{aligned} \mathbf{y}_f(t+j) &= f(\mathbf{x}(t+j), \mathbf{u}_f(t+j)) \\ \widehat{\mathbf{y}}_f(t+j) &= f(\mathbf{x}(t+j), \mathbf{u}_f(t+j)) \end{aligned} \quad (4.53)$$

Respuesta forzada Encontrar una solución analítica de la función \mathbf{H}_j (ecuación 4.53) es una operación muy complicada. Linealizando el modelo en cada punto de operación del modelo la respuesta forzada se obtiene y se formula como el producto de una matriz ganancia por la señal de control.

El modelo lineal se describe en el espacio de estados como:

$$\begin{aligned} \mathbf{z}(t) &= \bar{\mathbf{z}} + \mathbf{A}_t \mathbf{z}(t) + \mathbf{B}_t \Delta \mathbf{u}(t) \\ \mathbf{y}(t) &= \bar{\mathbf{y}} + \mathbf{C}_t \mathbf{z}(t) \end{aligned} \quad (4.54)$$

Para un sistema de n estados, m entradas y l salidas, \mathbf{A}_t es una matriz ($n \times n$), \mathbf{B}_t una matriz ($n \times m$), \mathbf{C}_t una matriz ($l \times n$), estas matrices se recalculan en cada instante de muestreo. $\bar{\mathbf{z}}$ y $\bar{\mathbf{y}}$ son vectores constantes.

La respuesta forzada viene dada por la siguiente expresión:

$$\mathbf{y}_c = \mathbf{H}_{N_{123}} \mathbf{U}_{N_u} \quad (4.55)$$

donde $\mathbf{H}_{N_{123}}$ es:

$$\mathbf{H}_{N_{123}} = \begin{bmatrix} \mathbf{C}_t \mathbf{A}_t^{N_1} \mathbf{B}_t & 0 & 0 & \dots & 0 \\ \cdot & \mathbf{C}_t \mathbf{A}_t^{N_1} \mathbf{B}_t & 0 & \dots & 0 \\ \cdot & \cdot & \mathbf{C}_t \mathbf{A}_t^{N_1} \mathbf{B}_t & \dots & 0 \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \mathbf{C}_t \mathbf{A}_t^{N_2} \mathbf{B}_t & \mathbf{C}_t \mathbf{A}_t^{N_2-1} \mathbf{B}_t & \mathbf{C}_t \mathbf{A}_t^{N_2-2} \mathbf{B}_t & \dots & \mathbf{C}_t \mathbf{A}_t^{N_2-N_u} \mathbf{B}_t \end{bmatrix} \quad (4.56)$$

y donde N_1 , N_2 y N_u representan los horizontes de predicción y de control respectivamente.

En resumen, el **MELPC** es un controlador predictivo no lineal que utiliza un modelo no lineal de predicción y que trata de reducir al máximo la complejidad del algoritmo e intenta llegar a una solución analítica del problema. La respuesta libre se calcula simplemente integrando las ecuaciones diferenciales del modelo no lineal manteniendo una señal de control constante. La respuesta forzada se calcula mediante una linealización en-línea en cada punto de operación a cada instante de muestreo. El cálculo de la respuesta forzada se puede calcular de dos formas diferentes, linealizar el modelo analíticamente o calcular la respuesta impulso del sistema, porque la matriz **H** contiene los elementos de la respuesta impulso del sistema.

4.3.3 MELPC con restricciones

Sea un proceso descrito por el siguiente sistema de ecuaciones diferenciales:

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{u}), \\ \mathbf{y} = \mathbf{g}(\mathbf{x}), \end{cases} \quad (4.57)$$

con n estados, m entradas y p salidas.

Las predicciones de la salida se calculan usando el principio de separación, dado que las predicciones se hacen en horizontes relativamente cortos, este principio se puede usar en el caso no lineal como aproximación al caso lineal (El Ghoumari, 1998; Megías *et al.*, 1999).

El vector de predicciones está dado por:

$$\mathbf{Y} = \begin{bmatrix} \mathbf{y}_f(t_s + N_1) + \mathbf{y}_u(t_s + N_1) \\ \mathbf{y}_f(t_s + N_1 + 1) + \mathbf{y}_u(t_s + N_1 + 1) \\ \vdots \\ \mathbf{y}_f(t_s + N_2) + \mathbf{y}_u(t_s + N_2) \end{bmatrix},$$

donde $y_f(t_s + j)$ son las respuestas libres y $y_u(t_s + j)$ son las respuestas forzadas, que dependen de $\Delta v(t_s + j)$ por $j = 1, \dots, N_u$. Además, N_1 y N_2 son respectivamente los límites inferior y superior del horizonte de predicción, N_u es el horizonte de control. Como es usual, la estrategia de control de horizonte móvil está aplicada, y sólo se usa la primera señal de control $\Delta v(t_s)$, y se descarta el resto.

La respuesta libre $y_f(t_s + j)$ se calcula integrando el modelo no lineal de la ecuación 4.57 en cada periodo de muestreo. La salida se calcula entonces como la suma de la respuesta libre y la respuesta forzada: $\mathbf{Y} = \tilde{\mathbf{Y}} + \tilde{\mathbf{H}}\Delta\mathbf{V}$, donde $\tilde{\mathbf{H}}$ es la matriz formada por los coeficientes de la respuesta escalón. Δ es el operador diferencial $1 - q^{-1}$ y por último $\Delta\mathbf{V}$ es el vector de los futuros controles definido como:

$$\Delta\mathbf{V} = [\Delta\mathbf{v}(t_s)^\top \dots \Delta\mathbf{v}(t_s + N_u - 1)^\top]^\top \quad (4.58)$$

La función de coste cuadrada está definida por:

$$J(t_s) = (\mathbf{W} - \mathbf{Y})^\top \mathbf{Q}(\mathbf{W} - \mathbf{Y}) + \Delta\mathbf{V}^\top \mathbf{R}\Delta\mathbf{V}, \quad (4.59)$$

Donde \mathbf{Q} y \mathbf{R} las matrices de peso de control y de salida respectivamente, \mathbf{W} es el vector de referencias, finalmente, el vector de control óptimo se obtiene resolviendo el problema:

$$\Delta\mathbf{V}^{\text{opt}} = \arg \min_{\Delta\mathbf{V}} J(t_s) \text{ sujeta a } \mathbf{P}\Delta\mathbf{V} \leq \mathbf{r}, \quad (4.60)$$

donde la matriz \mathbf{P} y el vector \mathbf{r} definen la restricciones de entrada. Este problema se puede resolver usando una herramienta de optimización estándar,

como la programación cuadrática (*Quadratic Programming* QP). El método de implementar \mathbf{P} y \mathbf{r} (Kuznetsov and Clarke, 1996) se describe a continuación.

4.3.3.a Formulación de las restricciones

Las restricciones se utilizan para dar una mejor representación de los sistemas físicos, teniendo en cuenta las limitaciones que aparecen en todas las aplicaciones. También son herramientas para mejorar el rendimiento de la planta, según las preferencias del ingeniero de control. A la hora formular la restricciones se tienen en cuenta varias consideraciones.

- Consideraciones según las necesidades prácticas
 - Restricciones físicas: nunca pueden ser violadas y son determinadas por las características físicas del sistema.
 - Restricciones de operación: determinan un rango dentro del cual hay que encontrar una variable para el funcionamiento normal del proceso. Esta categoría de restricciones puede ser violada.
 - Restricciones reales o de trabajo: se tienen en cuenta en el cálculo de los controles futuros.
 - Restricciones de optimización: se usan en los procedimientos especiales de gestión de la no factibilidad y por garantías de estabilidad.
- Consideraciones de gestión:
 - Restricciones blandas: sólo penalizan las violaciones, la función de coste aumenta con los términos de penalización, de forma que el problema se reduce en un caso de optimización sin restricciones.

- Restricciones duras: fuerzan que la acción de control sea de tal manera que la restricción se satisfaga a cualquier coste. Determinan un conjunto (podría ser vacío), denominado región factible, en el cual hay que encontrar la solución a un problema de optimización con restricciones.
- Consideraciones matemáticas
 - Restricciones de igualdad
 - Restricciones de desigualdad

4.3.3.b Incorporación de las restricciones en el controlador MELPC

En el controlador **MELPC**, las restricciones se han introducido de forma explícita. En este caso las restricciones definen la región donde se optimiza una función de coste cuadrática sujeta al conjunto de restricciones que se imponen en las variables manipuladas y controladas. Este problema se plantea como un problema de programación cuadrática (*Quadratic Programming*,QP), para lo cual existen los algoritmos adecuados. La utilización de este método puede llevarnos al caso de una posible aparición de situaciones no factibles en los cuales el controlador no puede operar.

La función de coste cuadrática La función de coste (ecuación 4.61) pesa la diferencia entre la salida y la referencia, y también los esfuerzos de control.

$$J(t_s) = (\mathbf{W} - \mathbf{H}\Delta\mathbf{u} - \mathbf{f})^T \mathbf{Q} (\mathbf{W} - \mathbf{H}\Delta\mathbf{u} - \mathbf{f}) + \Delta\mathbf{V}^T \mathbf{R} \Delta\mathbf{V}, \quad (4.61)$$

Donde \mathbf{Q} y \mathbf{R} son las matrices de peso control de salida respectivamente, \mathbf{W} es el vector de referencias y la matriz \mathbf{H} (ecuación 4.13) es la matriz ganancia que contiene los valores de la respuesta escalón del sistema.

El índice J se puede expresar de forma cuadrática estándar

$$J = \frac{1}{2} \Delta \mathbf{u}^T \mathbf{A} \Delta \mathbf{u} + \mathbf{b}^T \Delta \mathbf{u} + c \quad (4.62)$$

donde:

$$\mathbf{A} = 2(\mathbf{H}^T \mathbf{Q} \mathbf{H} + \mathbf{R}), \quad (4.63)$$

$$\mathbf{b} = 2\mathbf{H}^T \mathbf{Q}(\mathbf{w} - \mathbf{f}), \quad (4.64)$$

$$c = (\mathbf{w} - \mathbf{f})^T \mathbf{Q}(\mathbf{w} - \mathbf{f}). \quad (4.65)$$

La solución del problema se hace mediante programación cuadrática. Existen varias librerías de uso público como las librerías **NAG** y otras que se pueden encontrar por Internet, que sirven para encontrar la solución a este problema.

La herramienta usada en este trabajo es, la *toolbox* de MATLAB que proporciona una herramienta para resolver problemas QP, en concreto es la función `qp`. La llamada a esta función se hace de la manera siguiente:

$$X = qp(M, f, C, b) \quad (4.66)$$

En el caso de controladores predictivos hay que resolver el problema de tipo:

$$\Delta \mathbf{u}^* = \arg \min_{\Delta \mathbf{v}} \frac{1}{2} \Delta \mathbf{u}^T \mathbf{A} \Delta \mathbf{u} + \mathbf{b}^T \Delta \mathbf{u} + c, \quad (4.67)$$

sujeta a un conjunto de restricciones:

$$\mathbf{P} \Delta \mathbf{u} \leq \mathbf{r}, \quad (4.68)$$

El problema se resuelve mediante la función `qp` y las equivalencias $X = \Delta \mathbf{u}^*$, $x = \Delta \mathbf{u}$, $H = \mathbf{A}$, $f = \mathbf{b}$, $C = \mathbf{P}$ y $b = \mathbf{r}$.

En el caso concreto del **MELPC** se ha usado tres tipos de restricciones:

- Restricciones duras en la amplitud de la salida

- Restricciones duras en la amplitud del control
- Restricciones duras en la variación del control

La formulación de este problema se ha hecho de la manera global siguiente:

$$\begin{cases} \text{Minimizar} & \frac{1}{2}\Delta\mathbf{u}^T \mathbf{A}\Delta\mathbf{u} + \mathbf{b}^T \Delta\mathbf{u} + c \\ \text{sujeta a} & \mathbf{P}\Delta\mathbf{V} \leq \mathbf{r} \end{cases} \quad (4.69)$$

donde:

$$\mathbf{A} = 2(\mathbf{H}\mathbf{Q}\mathbf{H} + \mathbf{R}), \quad (4.70)$$

$$\mathbf{b} = 2\mathbf{H}\mathbf{Q}(\mathbf{f} - \mathbf{w}), \quad (4.70)$$

$$c = (\mathbf{f} - \mathbf{w})^T \mathbf{Q}(\mathbf{f} - \mathbf{w}), \quad (4.71)$$

$$\mathbf{P} = [\mathbf{P}_y^T \quad -\mathbf{P}_y^T \quad \mathbf{P}_u^T \quad -\mathbf{P}_u^T \quad \mathbf{P}_{\Delta u}^T \quad -\mathbf{P}_{\Delta u}^T]^T \quad (4.72)$$

$$\mathbf{r} = [\mathbf{y}_{max}^T \quad -\mathbf{y}_{min}^T \quad \mathbf{u}_{max}^T \quad -\mathbf{u}_{min}^T \quad \Delta\mathbf{u}_{max}^T \quad -\Delta\mathbf{u}_{min}^T]^T \quad (4.73)$$

La Matriz \mathbf{P} cambia de forma según el tipo de restricciones:

- Restricción en la amplitud de la salida:

$$\mathbf{P}_y = \begin{bmatrix} h_1 & 0 & \dots & 0 \\ h_2 & h_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ h_{N_{y2}} & h_{N_{y2}-1} & \dots & h_{N_{y2}-N_u+1} \end{bmatrix} \quad (4.74)$$

- Restricción en la señal de control

$$\mathbf{P}_u = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 1 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 1 \end{bmatrix} \quad (4.75)$$

- Restricción en el cambio de Control

$$\mathbf{P}_{\Delta u} = \mathbf{I} \quad (4.76)$$

4.3.4 EPSAC

En la misma línea de utilizar el principio de separación, el controlador EPSAC propone otro método de utilizar este principio. La inclusión de este controlador en este estudio, viene en la perspectiva de comparar entre los dos controladores MELPC y EPSAC.

El Extended Prediction Self-Adaptive Controller es un controlador propuesto por *De Keyser* (De Keyser, 1998; De Keyser and Cauwenberghe, 1985).

La idea general del EPSAC es aplicar el principio de separación, realizando una predicción "base" con el modelo no lineal mientras que se efectúa una predicción "optimizante", calculada a partir de una linealización local en cada instante de muestreo. Este procedimiento se realiza dentro de un esquema iterativo hasta que la predicción "optimizante" es casi nula para encontrar una solución "exacta" del esquema de optimización.

Este controlador se basa en dividir la respuesta predicha en dos partes:

- Respuesta Base y_{base} debida a los efectos de:
 - Las señales de control pasadas $\{u(t-1), u(t-2), \dots\}$
 - Las señales de control futuras *básicas*, denominadas $u_{base}(t+k|t)$, $k \geq 0$, que se definen a priori.
 - Las perturbaciones futuras $n(t+k|t)$

Esta componente $y_{base}(t+k|k)$ se puede calcular usando el modelo no lineal del sistema a controlar.

- Respuesta Optimizada $y_{optimize}$ debida a las acciones de control futuras *optimizantes* $\{\delta(t|t), \delta(t+1|t), \dots, \delta(t+N_u|t)\}$, con $\delta(t+k|t) =$

$u(t+k|t) - u_{base}(t+k|t)$. La figura 4.1 ilustra como se obtiene $\delta u(t+k|k)$ y $y_{optimize}$ es la suma de los tres siguientes componentes:

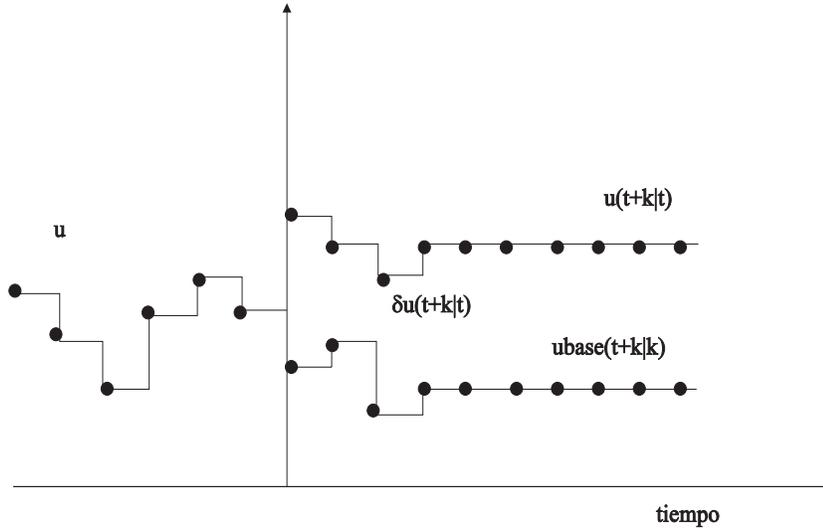


Figura 4.1: señales de control usadas por el EPSAC

- $h_k \delta u(t|t)$ producida en el instante $t+k$ (k periodos de muestreo después), por un impulso con amplitud $\delta u(t|t)$ aplicado en el instante t ,
- $h_{k-1} \delta u(t+1|t)$ producida en el instante $t+k$ ($k-1$ periodos de muestreo después), por un impulso con amplitud $\delta u(t+1|t)$ aplicado en el instante $t+1$.
- $g_{k-N_u+1} \delta u(t+N_u-1)$ producida en el instante $t+k$ ($k-N_u+1$ periodos de muestreo después), por un escalón con amplitud $\delta u(t+N_u-1-t)$

Finalmente $y_{optimize}$ en el instante $t+k$ se puede calcular por la ecuación

4.77:

$$y_{optimize}(t+k|t) = h_k \delta u(t|t) + h_{k-1} \delta(t+1|t) + \dots + g_{k-N_u+1} \delta u(t+N_u-1|t) \quad (4.77)$$

Los parámetros $h_1, h_2, \dots, h_k, \dots, h_{N_2}$ son los coeficientes de la respuesta impulso del sistema, que se pueden calcular mediante la respuesta escalón con la relación siguiente:

$$h_k = g_k - g_{k-1}$$

La selección de u_{base} es muy importante para que la respuesta $u_{optimize}$ sea nula. El objetivo en el caso no lineal es encontrar (de forma iterativa) una señal de control que sea lo más cercana posible a la señal óptima $u(t+k-t)$ (por lo tanto las acciones de control $\delta u(t+k|t)$ y $y_{optimize}$ son prácticamente nulos). El numero de iteraciones depende de los siguientes factores:

- "Grado" de las no linealidades del sistema a controlar.
- Elección del valor inicial de $u_{base}(t+k|t)$. Una elección simple y efectiva es comenzar con $u_{base}(t+k|t) = u(t+k|t-1)$ (última señal de control óptima).

Las predicciones se pueden escribir de forma matricial por la ecuación 4.78:

$$\mathbf{Y} = \bar{\mathbf{Y}} + \mathbf{GU} \quad (4.78)$$

donde:

$$\bar{\mathbf{Y}} = [y_{base}(t+N_1|t) \dots y_{base}(t+N_2|t)]^T$$

$$\mathbf{U} = [\delta u(t|t) \dots \delta u(t+N_u-1|t)]^T$$

$$\mathbf{G} = \begin{bmatrix} h_{N1} & h_{N1-1} & h_{N1-2} & \cdots & g_{N1-N_u+1} \\ h_{N1+1} & h_{N1} & h_{N1-1} & \cdots & g_{N1-N_u+2} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ h_{N2} & h_{N2-1} & h_{N2-2} & \cdots & g_{N2-N_u+1} \end{bmatrix}$$

Sustituyendo el valor de $\Delta \mathbf{V} = (\mathbf{A}\mathbf{U} + \mathbf{b})$ y $\mathbf{Y} = \bar{\mathbf{Y}} + \mathbf{G}\mathbf{U}$ en la ecuación 4.59, la función de coste se puede reescribir por la ecuación siguiente:

$$J = [\mathbf{W} - \bar{\mathbf{Y}} + \mathbf{G}\mathbf{U}]^T \mathbf{Q} [\mathbf{W} - \bar{\mathbf{Y}} + \mathbf{G}\mathbf{U}] + (\mathbf{A}\mathbf{U} + \mathbf{b})^T \mathbf{R} (\mathbf{A}\mathbf{U} + \mathbf{b}) \quad (4.79)$$

donde:

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ -1 & 1 & 0 & \cdots & 0 \\ \vdots & \cdots & \cdots & \cdots & \vdots \\ 0 & 0 & \cdots & -1 & 1 \end{bmatrix}$$

$$\mathbf{b} = \begin{bmatrix} u_{base}(t|t) - u(t-1) \\ u_{base}(t+1|t) - u_{base}(t|t) \\ \vdots \\ u_{base}(t+N_u-1|t) - u_{base}(t+N_u-2|t) \end{bmatrix}$$

Las condiciones de convergencia del algoritmo son muy difíciles de obtener ((Camacho and Bordóns, 1995)) y dependen principalmente de:

- La severidad de las no-linealidades del proceso.
- Las entradas y salidas pasadas.
- Las referencias.
- Las perturbaciones.

4.3.5 EPSAC con modelo de predicción lineal variante en el tiempo

Nevistić (1997) propuso como alternativa al CPN estándar, un algoritmo de control predictivo que usa un modelo de predicción lineal variante en el tiempo (MPC+LTV), obtenido aplicando una linealización local a lo largo de una trayectoria de estados nominal predefinida y de la trayectoria de entrada correspondiente, con lo cual consigue una aproximación más exacta a aquella obtenida usando una linealización local y se alcanza un rendimiento más cercano al de control predictivo no lineal estándar, especialmente en el caso de sistemas con dinámicas rápidas.

En (Declercq, 1999) se propone una linealización alrededor de una trayectoria que es la respuesta libre predicha del proceso, en un método iterativo que utiliza una optimización no lineal con restricciones basada en gradientes.

4.3.6 Estudio comparativo de los diferentes controladores

En este apartado se hace un estudio comparativo entre los diferentes controladores arriba descritos. El sistema elegido para tal fin, es un reactor químico encamisado CSTR con una reacción de Van de Vusse. Este sistema se caracteriza por:

- No-linealidades muy fuertes.
- La ganancia en el estado estacionario cambia de signo.
- El comportamiento cualitativo del CSTR cambia para diferentes referencias y perturbaciones.

Estas características hacen que el control de este sistema sea muy difícil, por lo tanto es una buena prueba para las diferentes técnicas de control.

4.3.6.a Descripción del sistema

Reactor de Van de Vusse

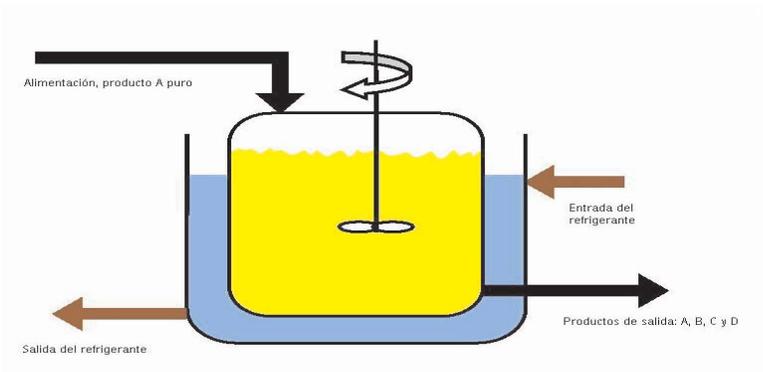
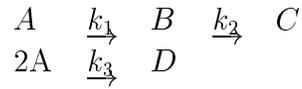


Figura 4.2: Reactor de van der vusse

Este sistema es un reactor continuo encamisado (*Continuous Stirred Tank Reactor*). Su funcionamiento principal es producir ciclopentanol a partir de ciclopentadieno. La reacción que describe la transformación se deduce de las propiedades químico-físicas del sistema (figura 4.2).

La principal reacción es la transformación de la sustancia A (ciclopentadieno) a la sustancia B (ciclopentanol). El reactante inicial A reacciona en una reacción paralela indeseada, produciendo dicitlopentadieno (sustancia D). Además, se forma ciclopentanediol (sustancia C) en una reacción consecutiva no deseada a partir del producto ciclopentanol. Todo el procedimiento se describe por la reacción siguiente, también llamada reacción de Van de Vusse:



El flujo \dot{V} alimenta el reactor y contiene sólo ciclopentadieno (sustancia A) con concentración c_{A0} y temperatura ϑ_0 . El calor removido \dot{Q}_K puede extraerse de la camisa por un intercambiador de calor externo.

Modelo del sistema La dinámica de este sistema puede describirse por las siguientes ecuaciones diferenciales no lineales que se derivan de los balances másicos de los diferentes componentes, y de los balances de energía del reactor y de la camisa refrigerante:

$$\dot{c}_A = \frac{\dot{V}}{V_R}(c_{A0} - c_A) - k_1(\vartheta)c_A - k_3(\vartheta)c_A^2 \quad (4.80)$$

$$\dot{c}_B = -\frac{\dot{V}}{V_R}c_B + k_1(\vartheta)c_A - k_2(\vartheta)c_B \quad (4.81)$$

$$\begin{aligned} \dot{\vartheta} = & \frac{\dot{V}}{V_R}(\vartheta_0 - \vartheta) - \frac{1}{\rho C_p} (k_1(\vartheta)c_A \Delta H_{RAB} \\ & + k_2(\vartheta)c_B \Delta H_{RBC} + k_3(\vartheta)c_A^2 \Delta H_{RAD}) \\ & + \frac{k_w A_R}{\rho C_p V_R} (\vartheta_K - \vartheta) \end{aligned} \quad (4.82)$$

$$\dot{\vartheta}_K = \frac{1}{m_k C_{PK}} (\dot{Q}_K + k_w A_R (\vartheta - \vartheta_K)), \quad (4.83)$$

$$c_A \geq 0, c_B \geq 0$$

Las concentraciones de las sustancias A y B son c_A y c_B , respectivamente. La temperatura en el reactor se llama ϑ , mientras que la temperatura en

la camisa refrigerante ϑ_K . Las velocidades de reacción k_i se suponen que dependen de la temperatura a través de la ley de Arrhenius

$$k_i(\vartheta) = k_{i0} \exp\left(\frac{E_i}{\vartheta + 273.15}\right), i = 1, 2, 3.$$

Los valores de los parámetros físicos y químicos en las ecuaciones 4.80, 4.81, 4.82 y 4.83 se muestran en la tabla 5.1. Casi todos los parámetros se conocen dentro de determinados límites.

Parámetro	Símbolo	Valor	dimensión
Factor de colisión para la reacción k_1	k_{10}	$(1.287 \pm 0.04) \cdot 10^{12}$	h^{-1}
Factor de colisión para la reacción k_2	k_{20}	$(1.287 \pm 0.04) \cdot 10^{12}$	h^{-1}
Factor de colisión para la reacción k_3	k_{30}	$(9.043 \pm 0.27) \cdot 10^9$	h^{-1}
Energía de activación para la reacción k_1	E_1	-9758.3	K
Energía de activación para la reacción k_1	E_1	-9758.3	K
Energía de activación para la reacción k_2	E_2	-9758.3	K
Energía de activación para la reacción k_3	E_3	-8560	K
Entalpía de la reacción k_1	$\Delta H_{R_{AB}}$	4.2 ± 2.36	$\frac{\text{kJ}}{\text{mol A}}$
Entalpía de la reacción k_2	$\Delta H_{R_{BC}}$	$-(11.0 \pm 1.92)$	$\frac{\text{kJ}}{\text{mol A}}$
Entalpía de la reacción k_3	$\Delta H_{R_{AD}}$	$-(41.85 \pm 1.41)$	$\frac{\text{kJ}}{\text{mol A}}$
Densidad	ρ	$0.9342 \pm 4.0 \cdot 10^{-4}$	$\frac{\text{kg}}{\text{l}}$
Capacidad calorífica	C_p	3.01 ± 0.04	$\frac{\text{kJ}}{\text{kg} \cdot \text{K}}$
Coefficiente de transferencia de calor de la camisa refrigerante	k_w	4032 ± 120	$\frac{\text{kJ}}{\text{h} \cdot \text{m}^2 \cdot \text{K}}$

Superficie de la camisa refrigerante	A_R	0.215	m^2
Volumen del reactor	V_R	0.01	m^3
Masa del refrigerante	m_K	5.0	kg
Capacidad calorífica del refrigerante	C_{PK}	2.0 ± 0.05	$\frac{kJ}{kg \cdot K}$

Tabla 4.1: Parámetros físico-químicos del Reactor de Van de Vusse

4.3.6.b Descripción de las simulaciones

En este experimento se analiza la respuesta del sistema de Van de Vusse frente a los cambios en la consigna de la concentración del producto c_B , la consigna cambia desde un valor inicial de 0.9 a 0.7 en el instante 720 segundos. En el instante 1800 segundos vuelve a cambiar de valor hasta 0.95 que se mantiene hasta el final de la simulación.

Los valores iniciales de control y de los estados son :

$$u = [18.83 \quad -4495.7]^\top \quad (4.84)$$

$$x_k = [1.235 \quad 0.9 \quad 134.14 \quad 128.95]^\top, \quad (4.85)$$

Los valores de sintonía del controlador fueron elegidos para conseguir un buen compromiso entre rendimiento y estabilidad, por esto se han usados los siguientes valores:

$$N_2 = 20 \quad (4.86)$$

$$N_u = 1 \quad (4.87)$$

$$\mathbf{Q} = [0.1 \quad 10^{-6}] \mathbf{I} \quad (4.88)$$

$$R = 5 \mathbf{I} \quad (4.89)$$

El objetivo de control para este reactor, es conseguir que la concentración de la sustancia B siga un valor determinado de la consigna, las variables de control son la velocidad del flujo normalizada respecto al volumen del reactor $\frac{\dot{V}}{V_R}$ y el calor extraído \dot{Q}_K .

4.3.6.c Control EPSAC: Resultados de simulación

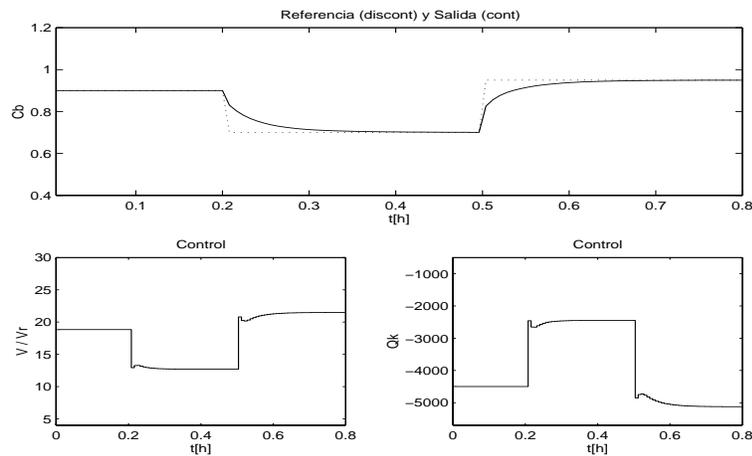


Figura 4.3: Reactor de Van de Vusse controlado por el EPSAC

Los resultados de simulación obtenidos con este controlador, se ilustran en la figura 4.3. El sistema consigue seguir la consigna, cuando hay un cambio en el valor de esta última. En el instante 720 segundos, la concentración de la sustancia B baja hacia el valor indicado por la consigna, para llegar a establecerse en este valor. En el instante 1800 segundos la concentración vuelve a subir cuando hay un cambio en la consigna al valor $0.95 h^{-1}$. La respuesta del sistema es bastante rápida y no hay sobre pico. La primera variable de control, (flujo normalizado del producto A $\frac{\dot{V}}{V_R}$) varía entre $18.83 h^{-1}$ y $13.2 h^{-1}$, en cuanto a la segunda variable de control (Calor extraído Q_k) su valor varía entre $-4495.7 \frac{kJ}{h}$ y $-2400 \frac{kJ}{h}$, estos valores serán objeto

de una comparación más adelante, con los resultados obtenidos de las otras técnicas de control.

4.3.6.d Control MELPC: Resultados de simulación

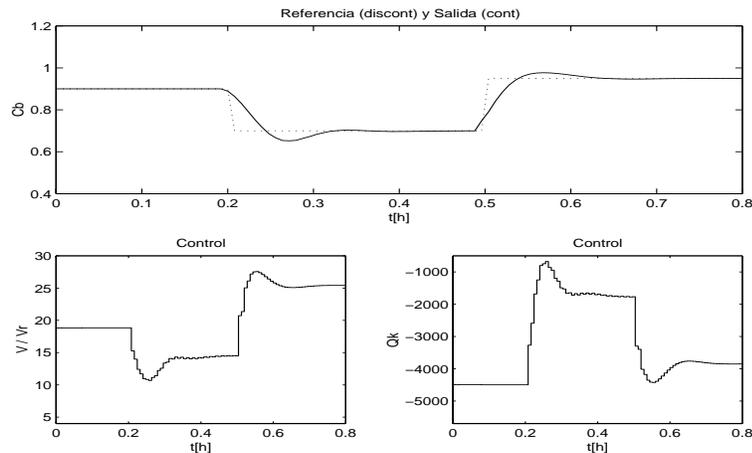


Figura 4.4: Reactor de Van der Vusse controlado por el MELPC

Los resultados se ilustran en la figura 4.4 donde se puede observar el seguimiento de la referencia. Durante los primeros 720 segundos el sistema parte de un estado estacionario y sigue la referencia perfectamente. A la hora de cambiar la consigna el sistema responde rápidamente hasta llegar al nuevo valor de consigna pero con un sobrepico. En otros experimentos (no presentados aquí) se consigue que el sistema llegue sin sobre pico, pero más lentamente a la consigna cambiando los valores de peso.

4.3.6.e Control ELPC: Resultados de simulación

Los resultados de la figura 4.5, ilustran el comportamiento del sistema, controlado por el ELPC. La respuesta del sistema es muy rápida y con un

gran sobrepico. Este resultado se puede mejorar, si se elige otros valores de los factores de peso y de los horizontes. Pero para poder hacer una comparación entre los diferentes controladores, los experimentos se hacen bajo las mismas condiciones que en los otros controladores .

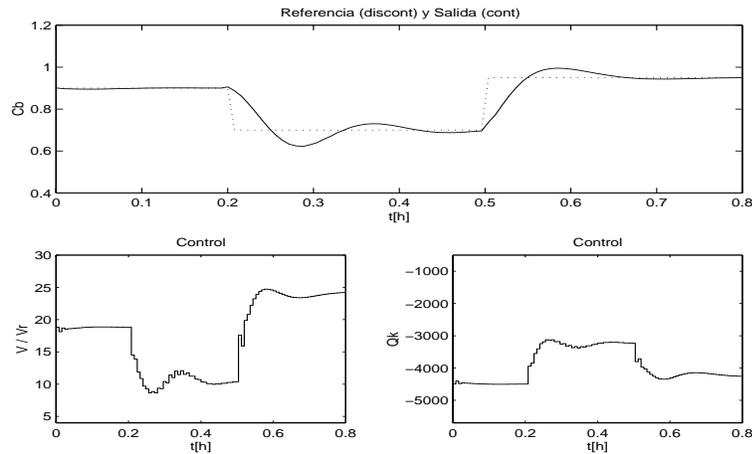


Figura 4.5: Reactor de Van der Vusse controlado por el ELPC

4.3.6.f Control lineal: Resultados de simulación

Los resultados conseguidos por este controlador son claramente peores que los anteriores. La respuesta del sistema es muy oscilatoria y con un tiempo de establecimiento muy grande. Este resultado se explica por la poca información que dispone el controlador del sistema en cada periodo de muestreo.

4.3.6.g Control no-lineal: Resultados de simulación

La figura 4.7 ilustra los resultados obtenidos con el controlador no-lineal. El sistema sigue bien el cambio en las referencias. Esta respuesta debe ser la referencia de cualquier análisis de los otros controladores ya que el modelo

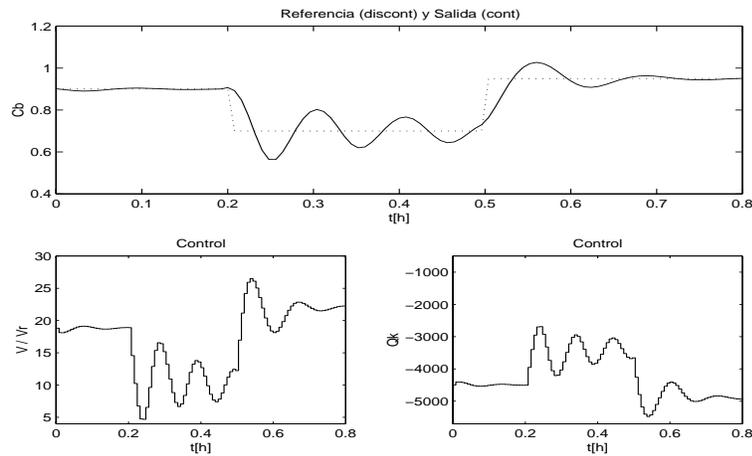


Figura 4.6: Reactor de Van der Vusse controlado por el controlador lineal

usado para este controlador es un modelo no-lineal. El único inconveniente de este controlador es su gran carga computacional en cada periodo de muestreo.

4.3.6.h Análisis y comparación de los resultados

Para analizar estos resultados cabe destacar las particularidades de este sistema que son:

- Sistema con no-linealidades muy fuertes.
- La ganancia en el estado estacionario cambia de signo en un punto de operación.
- El comportamiento cualitativo del CSTR cambia para diferentes referencias y perturbaciones.

La comparación se centra en los aspectos siguientes:

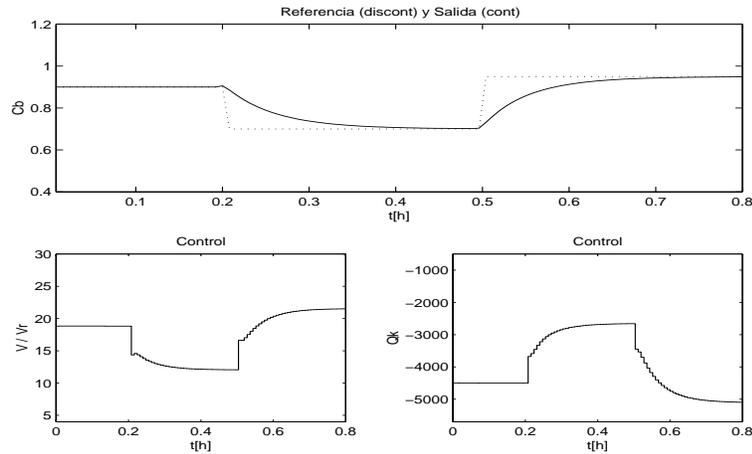


Figura 4.7: Reactor de Van der Vusse controlado por el controlador no-lineal

➔ **Rendimiento:** Los resultados de las figuras 4.3, 4.4, 4.5, 4.6 y 4.7, ilustran el rendimiento de cada controlador. Claramente la respuesta de los controladores no-lineal y EPSAC son las mejores. El seguimiento de las referencias se consigue sin sobrepico. Las señales de controles son suaves, con un intervalo de variación de $[13.2h^{-1} \ 21.8h^{-1}]$ respecto al flujo del producto A, y de $[-5095 \frac{kJ}{h} \ -3253 \frac{kJ}{h}]$ respecto a la segunda variable de control Q_k . Estos intervalos de variación son prácticamente iguales para los dos controladores y EPSAC y el no-lineal. El rendimiento muy alto del EPSAC es debido a su capacidad de anular la respuesta $y_{optimize}$ (descrita más arriba) de forma iterativa. El rendimiento baja tanto como baja la cantidad de la información usada por cada controlador. El Controlador lineal que usa la más mínima información del sistema en cada instante de muestreo, no consigue un buen rendimiento y el sistema se ve muy inestable. El ELPC cómo usa más información del sistema, linealizando el modelo en cada instante de muestreo, consigue un resultado mejor que con el controlador lineal y la respuesta es más estable. En el caso del controlador MELPC se consigue un buen rendimiento. El sistema sigue bien

las consignas aunque con un pequeño sobrepico. Cabe destacar que el tiempo de establecimiento con este controlador es más o menos igual que el de los dos controladores EPSAC y el no-lineal. Este resultado se debe al hecho de que este controlador además de linealizar el modelo en cada instante, sólo lo usa para el cálculo de la respuesta forzado, en cuanto a la respuesta libre usa el modelo no-lineal, manteniendo una señal de control constante.

- **Rechazo de las perturbaciones.** Para ilustrar la robustez de los controladores frente a las perturbaciones, se aplica en el instante 2880 segundos una perturbación de $0.2 \frac{mol}{l}$. La figura 4.13 ilustra el rechazo de las perturbaciones de los diferentes controladores. Aparte del controlador no-lineal, en general todos los controladores rechazan las perturbaciones de la misma manera como responden frente a un cambio de consigna. Este resultado se debe a su formulación en el espacio de estados, que tiene en cuenta el error entre la respuesta actual y la respuesta predicha en la función de coste, en cada instante de muestreo. En el caso del controlador no-lineal, este controlador está programado con un error de offset cero, eso se puede explicar por el hecho de que la optimización ha llegado a su límite de iteraciones sin llegar a un óptimo, y el controlador sigue buscando el valor óptimo que encontrará con un tiempo de simulación más largo (Chen and Allgöwer, 1998a).
- **Tiempo computacional.** Además del criterio de rendimiento, este factor es determinante a la hora de escoger un algoritmo u otro. La elección depende principalmente de los factores siguientes:
 - Tipo del sistema a controlar: fuerte no-linealidad o no.
 - Tiempo disponible para calcular la señal de control: sistema rápido o no.
 - Entorno de operación: naturaleza de las perturbaciones.

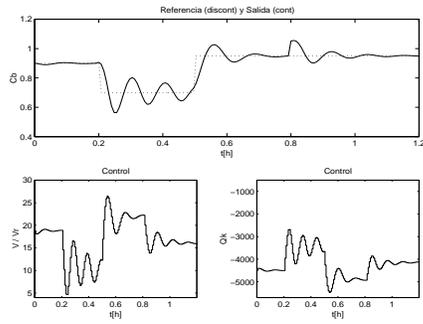


Figura 4.8: Lineal

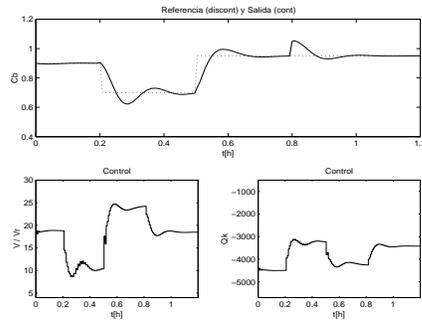


Figura 4.9: ELPC

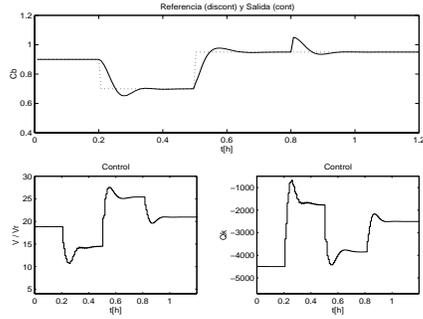


Figura 4.10: MELPC

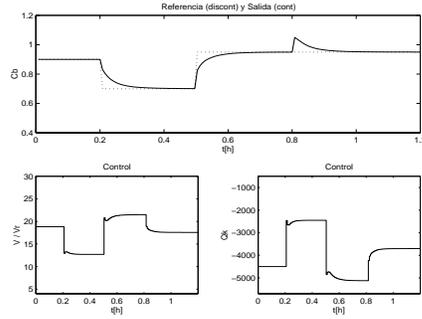


Figura 4.11: EPSAC

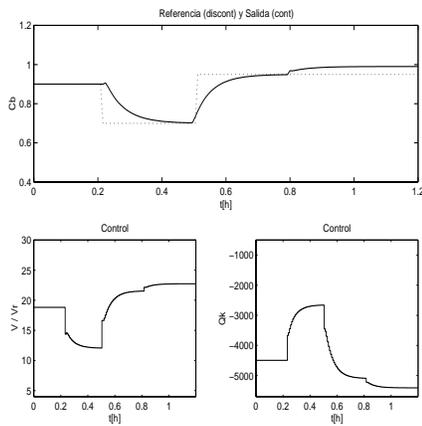


Figura 4.12: No Lineal

Figura 4.13: Rechazo de la perturbaciones de cada controlador

A continuación se hace una comparación de los tres controladores con mayor rendimiento: MELPC, EPSAC y el controlador no lineal, teniendo en cuenta todos estos factores.

Como estos tres controladores tienen un rendimiento similar o comparable, rechazan de la misma forma las perturbaciones. El único factor determinante es el coste computacional.

Cuando no hay perturbaciones ni cambios en la consigna los tres controladores tienen un tiempo de cálculo de la señal de control menor que el periodo de muestreo. A la hora de cambiar la consigna los dos controladores no-lineal y el EPSAC tienen un tiempo de cálculo muy grande depende de la magnitud del cambio en la consigna y también de la tolerancia relativa soportada para cada algoritmo de control. Esta tolerancia es el factor que determina si hay convergencia en el resultado y se ajusta por el programador. Valores muy pequeños puede implicar cálculos adicionales innecesarios, por otra parte valores grandes conducen generalmente a que los algoritmos no converjan. La ausencia de esta variable en el controlador MELPC le da una gran capacidad de poder planificar exactamente el problema de control, según cuanto tiempo disponemos para hacer los cálculos de la señal de control óptima. Además de su gran rendimiento el MELPC puede considerarse muy útil y muy viable en casi todos los casos, porque obtiene una gran compromiso entre los controladores no-lineales y los controladores lineales. Combina los puntos fuertes de las dos familias (lineal y no-lineal), rapidez y rendimiento. El controlador **MELPC** es un caso particular del **EPSAC** con una sola iteración a la hora de calcular la respuesta forzada. El método usado por el **EPSAC** es general pero con un gran riesgo de no convergencia en el caso de sistemas muy no-lineales o sujetos a fuertes perturbaciones.

4.4 Ejemplos de aplicación del MELPC

En este apartado, se analiza el comportamiento de este controlador, controlando varios tipos de sistemas. Los sistemas escogidos son totalmente diferentes y su campo de aplicación varía desde la robótica hasta la química. Así podemos probar que este algoritmo tiene un rango de aplicación muy grande y se puede aplicar a la mayoría de los sistemas usados en la industria.

4.4.1 Sistemas rápidos: Robot de tres grados de libertad

Un robot de tres grados de libertad es un sistema mecánico multisólidos articulado. Está constituido por tres elementos rígidos ensamblados por enlaces simples de tipo rotacional (un grado de libertad de rotación) o de tipo prismáticos (un grado de libertad de translación).

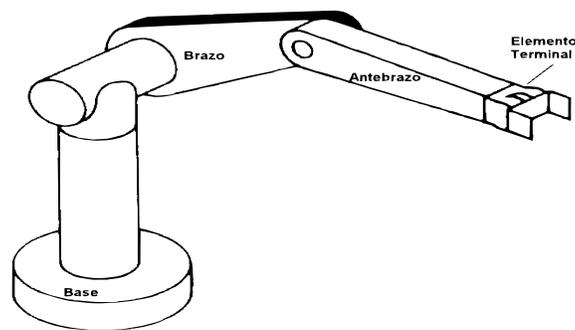


Figura 4.14: Robot de 3 grados de libertad

El sistema está constituido por los elementos (o subsistemas) siguientes (figura 4.14):

- La base: que es un disco de radio R y masa m_0 y situada en el centro de la referencia absoluta.
- Dos brazos: de masas m_1 y m_2 y longitudes l_1 y l_2 respectivamente, articulados entre ellos mediante un enlace rotacional y de otra parte el primer brazo está articulado con la base de la misma manera.
- Un elemento terminal: de masa m_3 y modelado como un punto material situado en el extremo del segundo brazo.

Este último submodelo puede tener tres grados de libertad, en este caso el robot se considerará como un robot de seis grados de libertad.

En la industria hay varios robots modelados como se ha descrito anteriormente, notemos las versiones 500 y 700 del robot PUMA , el robot CRS-A255 y por último el robot MA2000.

Las articulaciones están animadas por sistemas de motorización constituidos por accionadores y transmisores. A lo largo de este estudio se supone que los motores tienen una dinámica mas rápida que la del robot y la podemos despreciar en el planteamiento del problema de modelado.

El modelo dinámico del sistema se ha obtenido aplicando el formalismo de Lagrange.

Modelo del sistema

Las ecuaciones dinámicas se pueden escribir de una forma matricial:

$$\tau = \mathbf{M}(\mathbf{q}) \ddot{\mathbf{q}} + \mathbf{V}(\mathbf{q}, \dot{\mathbf{q}}) + \mathbf{G}(\mathbf{q}) \quad (4.90)$$

donde $\mathbf{M}(\mathbf{q})$ es la matriz $n \times n$ denominada Matriz masa del manipulador, $\mathbf{V}(\mathbf{q}, \dot{\mathbf{q}})$ es el vector $n \times 1$ del término centrífugo y de Coriolis. Por último, $\mathbf{G}(\mathbf{q})$ es el vector $n \times 1$ del término gravitacional (Angulo J.M., 1986).

Cada elemento de $\mathbf{M}(\mathbf{q})$ y $\mathbf{G}(\mathbf{q})$ es una función de la posición \mathbf{q} de todos los elementos del manipulador. Cada elemento de $\mathbf{V}(\mathbf{q}, \dot{\mathbf{q}})$ es una función de \mathbf{q} y $\dot{\mathbf{q}}$

La separación de la ecuación dinámica nos conduce a las matrices \mathbf{M} , \mathbf{V} , y \mathbf{G} que vienen dadas por las siguientes expresiones:

$$\begin{bmatrix} M_{11} & M_{12} & M_{13} \\ M_{21} & M_{22} & M_{23} \\ M_{31} & M_{32} & M_{33} \end{bmatrix} \begin{bmatrix} \ddot{\phi} \\ \ddot{\theta}_1 \\ \ddot{\theta}_2 \end{bmatrix} + \begin{bmatrix} V_{11} & V_{12} & V_{13} \\ V_{21} & V_{22} & V_{23} \\ V_{31} & V_{32} & V_{33} \end{bmatrix} \begin{bmatrix} \dot{\phi} \\ \dot{\theta}_1 \\ \dot{\theta}_2 \end{bmatrix} + \begin{bmatrix} G_1 \\ G_2 \\ G_3 \end{bmatrix} = \begin{bmatrix} \tau_1 \\ \tau_2 \\ \tau_3 \end{bmatrix}$$

donde los componentes de la Matriz masa son:

$$\begin{aligned} M_{12} &= 0, & M_{13} &= 0, & M_{21} &= 0, & M_{31} &= 0. \\ M_{11} &= 1/2 m_0 R^2 + m_1 l_1^2 \cos^2(\theta_1) + m_2 (l_1 \cos(\theta_1) + \frac{l_2}{2} \cos(\theta_2))^2 + \\ & \quad m_3 (l_1 \cos(\theta_1) + l_2 \cos(\theta_2))^2 \\ M_{22} &= (\frac{11m_1}{12} + m_2 + m_3) l_2^2 \\ M_{23} &= (\frac{m_2}{4} + m_3) l_1 l_2 \cos(\theta_2 - \theta_1) + \frac{1}{2} m_2 l_1^2 \\ M_{32} &= (\frac{m_2}{4} + m_3) l_1 l_2 \cos(\theta_2 - \theta_1) + \frac{1}{2} m_2 l_1^2 \\ M_{33} &= (\frac{5m_2}{8} + m_3) l_2^2 \end{aligned}$$

y los elementos del vector centrífugal y de Coriolis son:

$$\begin{aligned}
V_{11} &= -\frac{m_1}{2} l_1^2 \dot{\theta}_1 \cos(\theta_1) \sin(\theta_1) & (4.91) \\
V_{12} &= -2 m_2 \dot{\varphi} (l_1 \cos(\theta_1) + \frac{l_2}{2} \cos(\theta_2)) l_1 \sin(\theta_1) - \\
&\quad 2 m_3 \dot{\varphi} (l_1 \cos(\theta_1) + l_2 \cos(\theta_2)) l_1 \sin(\theta_1) \\
V_{13} &= -m_2 l_2 \dot{\varphi} (l_1 \cos(\theta_1) + \frac{l_2}{2} \cos(\theta_2)) \sin(\theta_2) - \\
&\quad 2 m_3 l_2 \dot{\varphi} \sin(\theta_2) (l_1 \cos(\theta_1) + l_2 \cos(\theta_2)) \\
V_{21} &= m_2 l_1 \dot{\varphi} \sin(\theta_1) (l_1 \cos(\theta_1) + \frac{l_2}{2} \cos(\theta_2)) + \\
&\quad m_3 l_1 \dot{\varphi} \sin(\theta_1) (l_1 \cos(\theta_1) + l_2 \cos(\theta_2)) + \\
&\quad \frac{m_1}{4} l_1^2 \dot{\varphi} \cos(\theta_1) \sin(\theta_1) \\
V_{22} &= -(\frac{m_2}{2} + m_3) l_1 l_2 \dot{\theta}_2 \sin(\theta_2 - \theta_1) \\
V_{23} &= -(\frac{m_2}{2} + m_3) l_1 l_2 (\dot{\theta}_2 - \dot{\theta}_1) \sin(\theta_2 - \theta_1) \\
V_{31} &= m_2 \frac{l_2}{2} \dot{\varphi} (l_1 \cos(\theta_1) + \frac{l_2}{2} \cos(\theta_2)) \sin(\theta_2) + \\
&\quad m_3 l_2 \dot{\varphi} \sin(\theta_2) (l_1 \cos(\theta_1) + l_2 \cos(\theta_2)) \\
V_{32} &= -(\frac{3m_2}{4} + m_3) l_1 l_2 (\dot{\theta}_2 - \dot{\theta}_1) \sin(\theta_2 - \theta_1) \\
V_{33} &= (\frac{m_2}{2} + m_3) l_1 l_2 \dot{\theta}_1 \sin(\theta_2 - \theta_1) + \frac{m_2}{4} l_1 l_2 \dot{\theta}_2 \sin(\theta_2 - \theta_1)
\end{aligned}$$

Finalmente los elementos del vector gravitacional son:

$$\begin{aligned}
G_1 &= 0 & (4.92) \\
G_2 &= (\frac{m_1}{2} + m_2 + m_3) g l_1 \cos(\theta_1) \\
G_3 &= (\frac{m_2}{2} + m_3) l_2 g \cos(\theta_2)
\end{aligned}$$

descripción del experimento Todos los controladores se ha probado con los siguientes parámetros:

- **Período de muestreo:** $T_s=0.01s$.
- **Sintonía:** $N_1=1, N_2=30, N_u=5$.
- **Matrices de peso:** $\mathbf{R}=10^{-10}\mathbf{I}, \mathbf{Q}= 300\mathbf{I}$
- **Referencias** Las consignas en el caso de los robots industriales no suelen ser saltos. Por esta razón se ha escogido un polinomio de orden tres entre los puntos inicial y final de cambio de la consigna.
- **Trayectoria de referencia** La trayectoria de referencia es un elemento muy importante en el CPBM. Influye sobre la robustez y la estabilidad de una forma decisiva. Se ha usado un filtro de orden tres.

Se ha elegido esta sintonía por razones de estabilidad y de asentamiento rápido hacia las referencias.

Los experimentos sobre el robot de tres grados de libertad se han realizado bajo los siguientes cambios de consigna:

Tiempo (segundos)	0	0.21	2	4	6	8	10	12
Base (radianes)	π	$(2 - \frac{1}{20})\pi$	*	*	*	*	*	*
Brazo (radianes)	$\frac{\pi}{3}$	*	$\frac{2}{3}\pi$	$\frac{3}{2}\pi$	*	$\frac{2}{3}\pi$	*	*
Antebrazo (radianes)	$\frac{\pi}{4}$	*	*	*	$-\frac{\pi}{4}$	*	$\frac{\pi}{4}$	*

Tabla 4.2: Cambio de consignas

El objetivo de control es el seguimiento de la referencia (Tabla, 4.2) por parte de las tres partes del robot (base, brazo y antebrazo).

En la figura 4.15, se observa el buen seguimiento a las referencias de cada una de las posiciones, también se nota una ligera influencia entre las articulaciones cambiando la referencia de cada una.

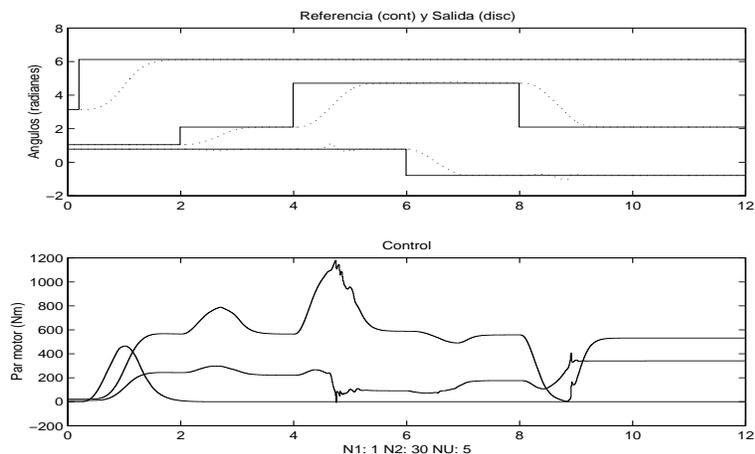


Figura 4.15: Control MELPC de las posiciones del robot

El **MELPC** usa más información del sistema, como estamos usando directamente el modelo no lineal del sistema para el cálculo de la respuesta libre. También se nota las pocas oscilaciones cuando la consigna cambia de valor.

Se ha hecho un estudio de las operaciones en punto flotante **FLOPS** necesarias para cada uno de los controladores en un período de muestreo y los valores encontrados se recogen en la tabla siguiente:

	Megaflops
Respuesta forzada	1.188
Respuesta libre	0.227
Linealizar el modelo	0.004
discretización	0.026
Total	1.241

Tabla 4.3: Tabla de FOLPS

Cómo se ilustra en la tabla 4.3, el cálculo de la respuesta forzada es la

operación que lleva más coste computacional. Esto se explica por la cantidad de operaciones en punto flotante que conlleva el cálculo del producto matricial de la ecuación 4.55.

4.4.2 Sistemas con respuesta inversa: Reactor químico

El sistema en cuestión es un reactor químico exotérmico encamisado (figura 4.16). Está constituido por un tanque de reacción donde entra un flujo de líquido que contiene una sustancia A con una determinada concentración inicial. Esta sustancia reacciona transformándose una parte en una nueva sustancia B. Esta reacción es exotérmica, por tanto es necesario enfriar el reactor. Esto se hace mediante un líquido refrigerante que se introduce en la camisa que envuelve el tanque.

El flujo del líquido F_l entra con una concentración inicial C_{a0} de la sustancia A. El volumen del reactor V es fijo, por eso el flujo del líquido que entra es igual al que sale. A la salida las concentraciones de las sustancias A y B son C_a y C_b . A la cámara de refrigeración entra un flujo del líquido refrigerante F_r a una temperatura T_{r0} . Por último la temperatura en el interior del tanque es T_l .

Modelo del sistema Aplicando el balance másico y energético al sistema se obtienen las ecuaciones diferenciales que describen las dinámicas de las variables involucradas.

$$V \frac{C_a}{dt} = F_l C_{a0} - V k C_a - F_l C_a \quad (4.93)$$

$$C \frac{C_b}{dt} = V k C_a - F_l C_b \quad (4.94)$$

$$V \rho C e_1 \frac{T_l}{dt} = F_l \rho C e_1 (T_{l0} - T_l) - U S (T_l - T_r) + V k C_a H \quad (4.95)$$

$$V \rho_r C e_r \frac{T_r}{dt} = F_r \rho_r C e_r (T_{r0} - T_r) + U S (T_l - T_r). \quad (4.96)$$

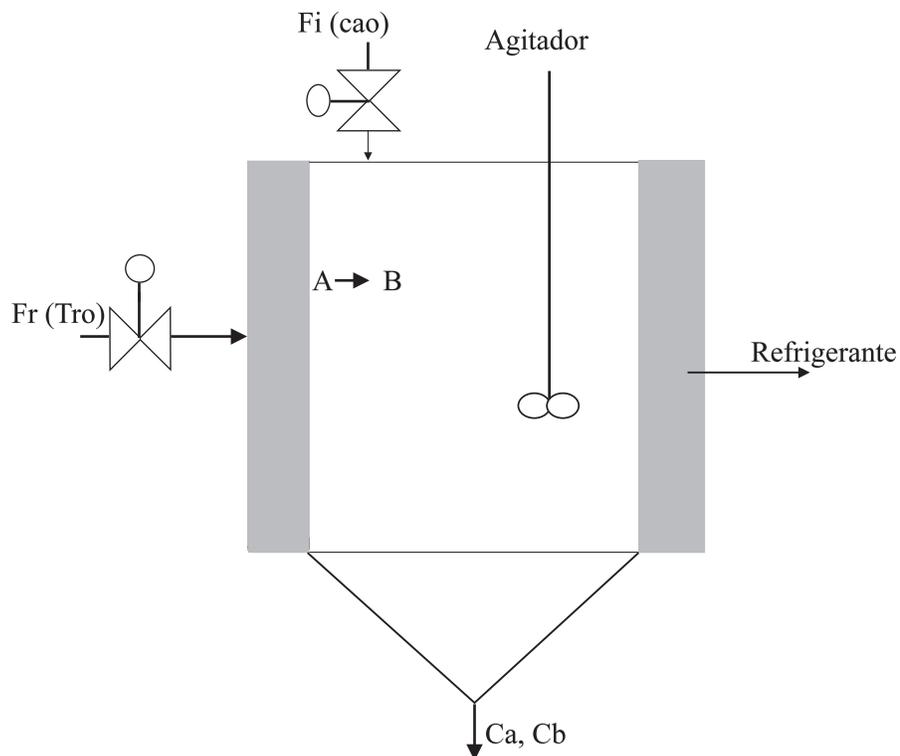


Figura 4.16: Reactor químico exotérmico encamisado

Los valores y significados de las constantes se ilustran en la tabla 4.4.

Parámetro	Símbolo	Valor	dimensión
Flujo (volumétrico) de entrada al tanque	F_1	-	m^3/h
Concentración de A en el tanque	C_a	8	$Kgmol/m^3$
Concentración de B en el tanque	C_b	-	$Kgmol/m^3$
Volumen del tanque	V	-	m^3
Velocidad de reacción	k	-	$1/h$
Concentración de A en el flujo de entrada al tanque	C_{a0}	-	$Kgmol/m^3$

Energía de activación de la reacción	E_a	-	kJ/Kgmol
Constante de los gases perfectos	R	-	$\text{kJ/Kgmol}^\circ\text{K}$
Densidad del líquido del tanque	ρ_l	800	Kg/m^3
Densidad del refrigerante	ρ_r	1000	Kg/m^3
Calor específico del líquido del tanque	C_{e_l}	3	$\text{kJ/Kg } ^\circ\text{C}$
Calor específico del refrigerante	C_{e_r}	4.1868	$\text{kJ/Kg } ^\circ\text{C}$
Temperatura del líquido a la entrada del tanque	T_{l0}	30	$^\circ\text{C}$
Coefficiente de transmisión de calor global	U	4300	$\text{kJ/h m}^2 \text{ } ^\circ\text{C}$
Superficie de intercambio de calor	S	25	m^2
Temperatura del refrigerante a la entrada de la cámara	T_{r0}	20	$^\circ\text{C}$
Temperatura del refrigerante en la cámara	T_r	-	$^\circ\text{C}$
Calor de reacción	H	20000	kJ/Kgmol
Flujo de refrigerante	F_r	-	m^3/h

Tabla 4.4: Parámetros físico-químicos del reactor en-camisado

Resultados de simulación Los objetivos de control en este caso son dos. Uno es mantener la temperatura constante en el interior del reactor para que se produzca la reacción de una sustancia A transformándose en una sustancia B. El segundo objetivo es mantener la concentración de sustancia B a un determinado valor de la consigna.

Las variables de control también son dos. La primera es el flujo del líquido de entrada al reactor conteniendo la sustancia A. La segunda variable

de control es el flujo del refrigerante que entra a la camisa de refrigeración.

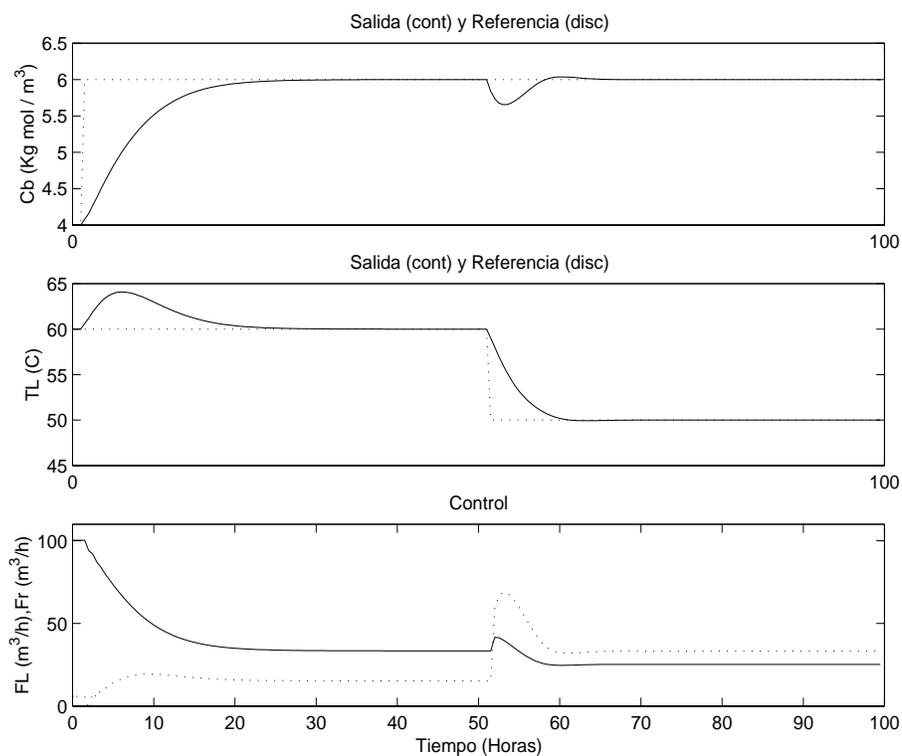


Figura 4.17: Respuesta del reactor encamisado

El experimento consiste en cambiar en el instante $t = 2h$ la consigna de la concentración de B en el tanque de 4 a 6 $Kgmol/m^3$, y en el $t = 52h$ se modifica la consigna de la temperatura de 60 a 50 °C.

Los parámetros de sintonía del controlador son, $N_1=1$, $N_2=10$, $N_u=4$, las matrices de peso $\mathbf{Q}=[0.05 \ 0.01] \mathbf{I}$ y $\mathbf{R}=[0.4 \ 0.1] \mathbf{I}$.

La respuesta del sistema frente a los cambios de las consignas se ilustran en la figura 4.17. Este sistema se caracteriza por su respuesta inversa frente a las acciones de control. A la hora de cambiar la consigna de la

concentración, el sistema responde lentamente hasta alcanzar el valor de la referencia, este cambio afecta también a la temperatura con una perturbación de 4°C. Cuando se cambia la consigna de la temperatura, el sistema sigue la referencia sin embargo, se ve un poco afectado el lazo de concentración C_b .

4.4.3 Sistema en un entorno muy hostil: Control del clima dentro de un invernadero

El sistema a controlar en este caso es el invernadero descrito en el capítulo 3. Este sistema se caracteriza por las fuertes perturbaciones que le afecta, también se caracteriza por sus fuertes no-linealidades. El objetivo de control es mantener la temperatura en un valor constante de 18 °C por la noche y otro valor de 22°C por el día. El valor de consigna de CO₂ es de un valor constante durante las 24 horas.

En la sintonía del controlador se ha dado más importancia a controlar la temperatura, porque es un factor muy crítico para el crecimiento de las plantas, así que se ha dado un valor muy alto al factor de peso de esta variable del orden de 300. El factor de peso de la humedad es de 0, porque esta variable no tiene mucha importancia para controlarla. El factor de peso de la concentración de CO₂ es de 100, tres veces más pequeño que el factor de peso de la temperatura, porque tiene menos importancia.

Las variables de control son: la temperatura del sistema de calefacción, la apertura de las ventanas y el aporte de CO₂. La influencia de cada una de estas variables viene con detalle en la siguiente tabla:

donde:

y_1 es la temperatura Interior (°C)

	y_1	y_2	y_3
u_1	✓		✓
u_2	✓	✓	✓
u_3		✓	

Tabla 4.5: Interacción entre los diferentes lazos de control

y_2 es la concentración de CO_2 (g/m^2)

y_3 es la humedad relativa interior (%)

u_1 es la temperatura del sistema de calefacción ($^\circ\text{C}$)

u_2 es el grado de apertura de las ventanas (%)

u_3 es el aporte de CO_2 ($\text{g s}^{-1} \text{ m}^{-2}$)

Los resultados de simulación de control de este sistema, son ilustrados en las figuras 4.18 y 4.19

La consigna de la temperatura interna se ha elegido dos valores, una por la noche de 18°C y otra por el día de 22°C . La respuesta del sistema frente a estos cambios en la consigna es bastante buena y el seguimiento se hace sin ninguna influencia de las condiciones externas ni por las otras variables, debido a que el factor de peso de esta variable es muy grande 4.18. Las variables de control que actúan sobre esta variable son la apertura de las ventanas r_w y la temperatura del sistema de calefacción T_p 4.19. Las restricciones para estas dos variables de control son entre 0 y 40 para T_p .

La formulación de la restricción para la apertura de las ventanas r_w se ha hecho para preservar la energía proveniente del sistema de calefacción. Las ventanas sólo se pueden abrir si el sistema de calefacción esta apagado. Así se aprovecha al máximo la energía proveniente del sol y que no cuesta nada.

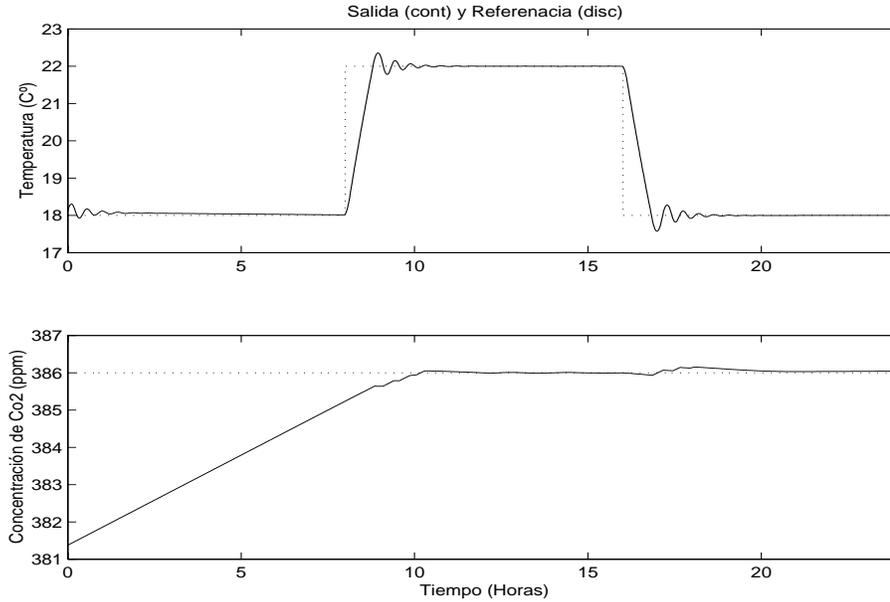


Figura 4.18: Temperatura interior y concentración de CO₂

La cantidad de energía que se pierde por ventilación en el invernadero Q_{vent} (ecuación 3.21) depende de la diferencia entre la temperatura interior y exterior ($T_i - T_o$), y de una función $f(r_w)$ que depende grado de apertura de las ventanas r_w .

$$Q_{vent} = f(r_w)(T_i - T_o) \quad (4.97)$$

Para escoger un grado límite $r_{w_{limit}}$ de r_w , teniendo en cuenta que la cantidad de energía perdida Q_{vent} no proviene del sistema de calefacción se ha formulado de la manera siguiente:

de la ecuación 4.97 podemos escribir

$$r_w = g\left(\frac{Q_{vent}}{(T_i - T_g)}\right) \Rightarrow r_{w_{limit}} = g\left(\frac{Q_{vent_{limit}}}{(T_i - T_g)}\right) \quad (4.98)$$

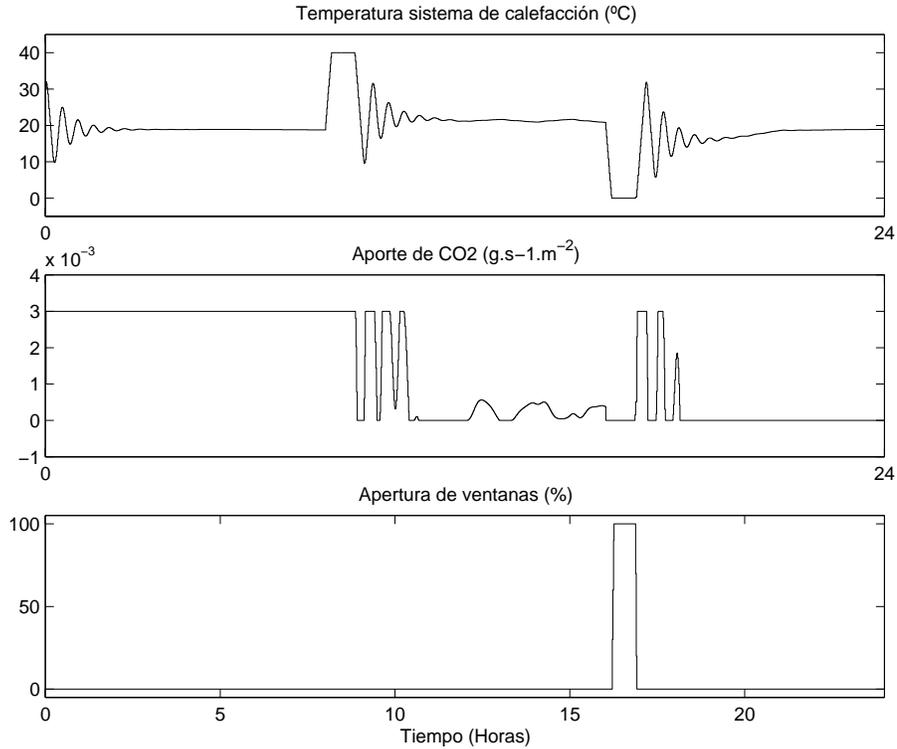


Figura 4.19: Variables de control

entonces la formulación de la restricción de esta variable r_w es la siguiente:

$$r_{w_{limit}} = \begin{cases} g\left(\frac{Q_{vent_{limit}}}{(T_i - T_g)}\right) & \text{si la calefacción funciona.} \\ 100 & \text{si la calefacción no funciona.} \end{cases}$$

$Q_{vent_{limit}}$ es la cantidad máxima que debemos decidir de perder a fin de controlar el sistema. En muchos casos se opta por no perder nada, pero esto influye sobre el rendimiento en la humedad. En los casos donde se persigue un control de humedad interna se deja perder una cantidad de energía, dejando que la ventanas se abran hasta un 10%, mientras el sistema de calefacción esté funcionando. En nuestro caso se ha usado un valor de

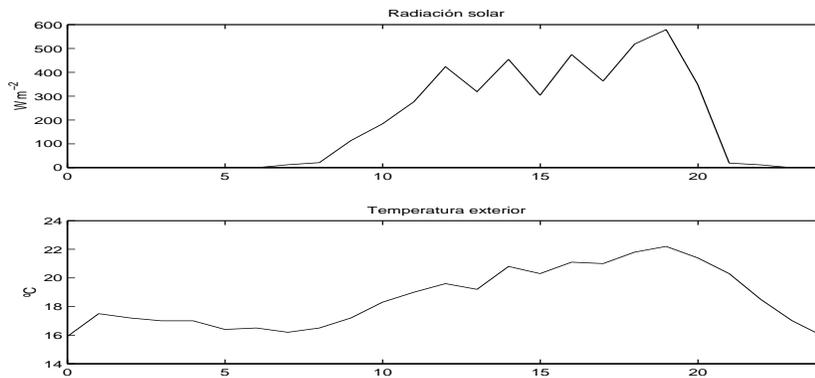


Figura 4.20: Condiciones externas (radiación solar y temperatura exterior)

$Q_{ventilimit} = 0$. Las condiciones externas, (figuras 4.20 y 4.21) son de un día de verano (30/06/2001) del clima de ciudad de Hannover en el Oeste de Alemania.

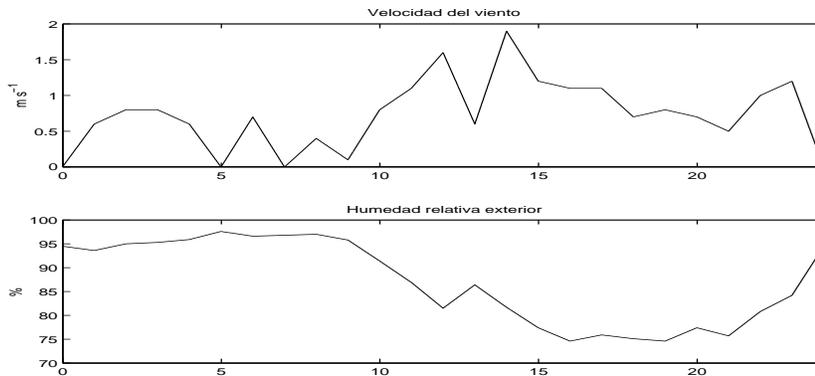


Figura 4.21: Condiciones externas (velocidad del viento y humedad exterior)

4.4.4 Conclusión

El estudio presentado ilustra los diferentes casos donde se pueden usar los algoritmos no-lineales basados la linealización en lineal. La tabla 4.6 resume

la conclusiones sacadas de este estudio.

	Lineal	ELPC	MELPC	EPSAC	no-lineal
Sistemas rápidos	T,RP	T,RP	T,R,RP	R,RP	R
Sistemas con perturbaciones	T,RP	T,RP	T,R,RP	R,RP	R
Sistemas con respuesta inversa	T,RP	T,RP	T,R,RP	R,RP	R
sistemas muy no lineales	T,RP	T,RP	T,R,RP	R,RP	R

Tabla 4.6: Comparación entre los controladores en Tiempo (T), rendimiento (R) y rechazo de perturbaciones (RP)

En la tabla 4.6 se ilustra que en los controladores lineal y ELPC sólo se pueden usar en sistema simples que no presentan fuertes no-linealidades ni operen en puntos de operación muy lejanos. Su rendimiento es muy bajo en contra del reducido coste computacional. Los controladores no-lineal y EPSAC tienen un muy buen rendimiento, en cambio su tiempo de cálculo es muy grande, lo que implica en algunos casos su imposible implantación. El controlador MELPC presenta un muy buen compromiso entre los diferentes controladores. Combina entre las dos ventajas de cada controlador, tiempo cálculo, rendimiento y rechazo de perturbaciones.

4.5 Resumen

En este capítulo se han analizado las diferentes estrategias de control predictivo no lineal basadas en la linealización *on-line*. Se han estudio los aspectos de implementación de los controladores propuestos en este trabajo el ELPC y el MELPC. También se han estudiado los controladores lineal, no-lineal mediante optimización global, el controlador propuesto por Nevistić con el

objetivo de hacer una comparación entre ellos en los aspectos de rendimiento, tiempo de cálculo y rechazo de perturbaciones. En estos experimentos se ha demostrado que los controladores MELPC y EPSAC son los controladores que mejor compaginan entre el rendimiento y el tiempo de cálculo, sin embargo el MELPC queda el mejor controlador aplicable en tiempo real porque su tiempo de cálculo es muy reducido en comparación con el EPSAC.

Al final de este capítulo se ha expuesto una serie de experimentos en simulaciones para probar el MELPC controlador propuesto en esta tesis. Los experimentos consisten en aplicar este controlador sobre una amplia gama de sistemas con dinámicas diferentes. Los resultados demuestran que efectivamente el controlador MELPC puede controlar una amplia gama de sistemas con dinámicas muy diferentes, con un rendimiento muy grande y un tiempo de cálculo que le permite ser implementado en tiempo real.

Capítulo 5

Resultados experimentales

En este capítulo se presentan los resultados experimentales que se han llevado a cabo en esta tesis. El objetivo de estos experimentos es la aplicación del controlador MELPC en tiempo real sobre un invernadero construido en el *Institute for Horticultural and Agricultural Engineering (ITG)* de la Universidad de Hannover (Alemania). Este invernadero es similar a cualquier sistema de producción en la industria agrícola.

Dos tipos de experimentos se hacen con el fin de controlar las variables climáticas dentro del invernadero y que son:

- ☛ Validación del modelo
- ☛ Control en tiempo real del clima

A continuación se da el detalle de estos experimentos.

5.1 Validación del modelo

La validación implica la prueba de las capacidades predictivas del modelo. Un modelo de invernadero necesita ser capaz de reproducir los resultados en similares condiciones que el sistema real atendiendo a los objetivos perseguidos por este modelo, antes de ser utilizado. La fiabilidad del modelo dependerá en gran parte de la capacidad de análisis de los procedimientos y las dinámicas involucradas.

Para poder validar un modelo, hay que definir un conjunto de procedimientos que se resumen en la figura 5.1 por orden cronológico. En la

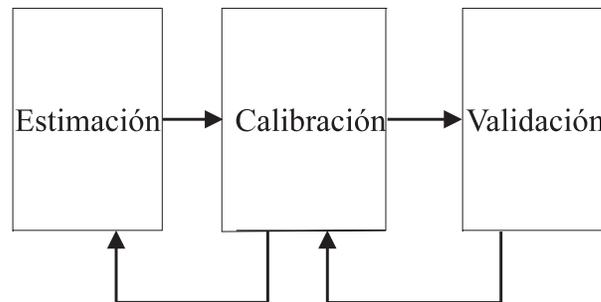


Figura 5.1: Etapas de validación

práctica, la validación de un modelo implica generalmente los tres siguientes pasos:

- **Estimación:** es la elección de los parámetros de calibración. Esta elección se puede hacer por simple razonamiento sobre la importancia que pueda tener un parámetro u otro, o por un método formal haciendo un análisis de sensibilidad.
- **Calibración:** Es la segunda etapa, después de haber definido los parámetros a calibrar, sirve para ajustar los valores de estos últimos

generalmente mediante la optimización de una función de coste que minimiza la diferencia entre los valores experimentales y simulados.

- **Validación:** Para probar si el modelo tiene una capacidad de predecir el comportamiento del proceso en cuestión, se hace una comparación de los resultados en distintas condiciones de simulación.

5.1.1 Descripción del invernadero real

Los experimentos se han realizado sobre un invernadero situado en el *Institute for Horticultural and Agricultural Engineering (ITG)* de la Universidad de Hannover (Alemania) (figura 5.2).



Figura 5.2: Invernadero real

Este invernadero tiene una estructura metálica de aluminio. el vidrio está sostenido por esta estructura en la cubierta y en las paredes laterales. Tiene una superficie de 200 m² y dispone de dos ventanas longitudinales, este y oeste la ventanas que representan el 30% del área del techo. La apertura de cada una de ellas es independiente de la otra.

El sistema de calefacción es de tipo de agua caliente, donde las tuberías de agua están dispuestas a lo largo de las paredes del invernadero.

El entorno meteorológico de este sistema se resume en los siguientes factores:

	Min	Max
Temperatura [°C]	-7	29
Humedad relativa	51%	100%
Radiación solar a las 14 horas [W/m ²]	14.6	1008

Tabla 5.1: Características del invernadero

Las medidas de la tabla 5.1, son cogidas de la estación meteorológica del **ITG**, del año 2000-2001.

Las características de este invernadero vienen detalladas en la tabla 5.2

Altura	3 m
Superficie	200 m ²
Tipo	Vidrio
Tipo de calefacción	Aérea
Tipo de ventilación	Natural

Tabla 5.2: Características del invernadero

5.1.2 Estimación

Formalmente la elección de los parámetros que tienen influencia sobre el modelo se hace usando un análisis de sensibilidad. En la mayoría de los estudios (Tap, 2000; Henten, 1994) se opta por calibrar los tres parámetros que tienen más influencia en el modelo del invernadero, y que son:

- $c_{cap,q}$: Capacidad térmica del aire del invernadero.
- k_c : Coeficiente de transmisión térmica.
- k_r : Coeficiente de transmisión de la energía a través de la cubierta.

Siguiendo esta metodología, en este trabajo se calibran estos tres parámetros por una optimización **SQP**.

5.1.3 Calibración

Una vez los parámetros de calibración están seleccionados se procede a una optimización para minimizar la diferencia entre los valores calculados y experimentales. En este trabajo se ha elegido una optimización usando el método **SQP** (Sequential Quadratic programming) con restricciones durante el periodo de 14 días, del 16 de Junio al 29 de Junio de 2001.

La función de coste a minimizar es la diferencia entre la temperatura interna calculada y medida durante este periodo.

$$coste = \sum_{t_i}^{t_f} (T_c - T_m) \quad (5.1)$$

donde:

T_c y T_m son las temperaturas calculada y medida.

t_f y t_i son los tiempos inicial y final de la optimización.

El algoritmo de optimización escoge dentro de los rangos $[c_{cap,q_{min}} \ c_{cap,q_{max}}]$, $[k_{c_{min}} \ k_{c_{max}}]$ y $[k_{r_{min}} \ k_{r_{max}}]$, los valores de $c_{cap,q}$, k_c y k_r que minimiza la distancia entre T_c y T_m . Los valores mínimos y máximos son unos valores fijados en la bibliografía (Tap, 2000; Henten, 1994).

La media de los valores óptimos encontrados después de la optimización de varios días son:

$$\begin{aligned} c_{cap,q} &= 20000[\text{J m}^{-2}\text{°C}^{-1}] , \\ k_c &= 9[\text{W m}^{-2} \text{°C}^{-1}] , \\ k_r &= 50[\text{W m}^{-2} \text{°C}^{-1}] . \end{aligned} \tag{5.2}$$

5.1.4 Validación

Para validar el modelo encontrado se hace una comparación entre los resultados calculados y experimentales en los días donde se hizo la optimización (del 16/06/2001 al 29/06/2001). Las condiciones externas del invernadero en esta época se ilustran en las figuras 5.3 y 5.5, donde se representan las dos variables radiación solar G y temperatura exterior T_0 por una parte, y las variables velocidad del viento V y la humedad exterior V_o por otra parte.

En la figura que representa la radiación solar se puede observar que en esta época del año, casi todos los días son soleados y con una cantidad de radiación mínima de 530 W/m^2 al medio día y como valor máximo de 1000 W/m^2 .

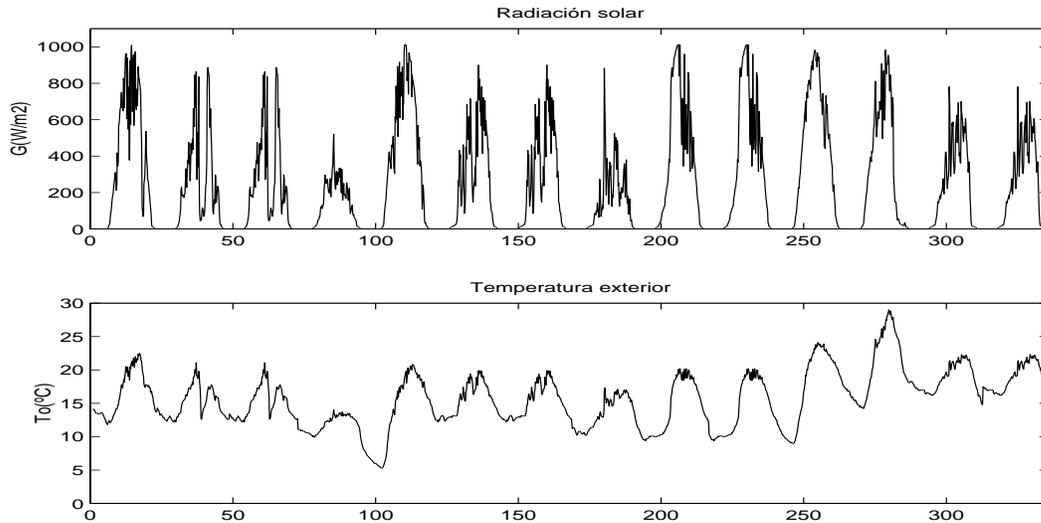


Figura 5.3: Condiciones externas: Radiación solar y Temperatura exterior

Las temperaturas son relativamente elevadas, la temperatura máxima al medio día de casi unos 30 °C, mientras que la temperatura mínima que se alcanzó durante los días de prueba, es de 5°C grados por la noche.

La velocidad del viento no supera los 4 m/s, excepto en el primer día donde la velocidad del viento alcanzó un valor de 6,9 m/s.

Finalmente la humedad relativa exterior está comprendida en el rango [60%-100%]. Hay que notar que la humedad exterior y la temperatura son inversamente proporcionales. La humedad disminuye cuando la temperatura sube. Los resultados encontrados por simulación (figura 5.4) demuestran un buen ajuste a los valores experimentales. Por la noche la diferencia es del orden de 3°C, la causa puede ser el error en la estimación del coeficiente de transmisión de calor a través el suelo k_s .

El error por la noche no influye mucho sobre los resultados de control porque no hay perturbaciones. Durante el día la diferencia es muy pequeña

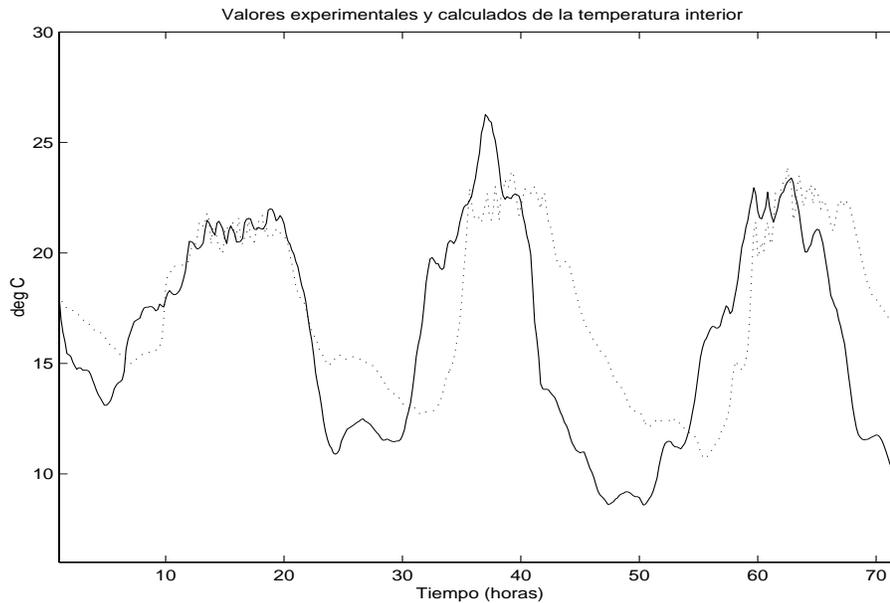


Figura 5.4: Resultados experimentales y de simulación

debido a la buena estimación de los parámetros de calibración por parte del programa de optimización.

5.1.5 Parámetros del modelo del clima

Los parámetros del modelo de clima del invernadero (ecuación 3.33) son listados en la tabla 5.3. Muchos parámetros son extraídos de la bibliografía o basados en leyes físicas de los fenómenos involucrados en el invernadero.

Parámetro	Valor	Dimensión	Descripción
k_c	9	$\text{W m}^{-2} \text{ } ^\circ\text{C}^{-1}$	Coficiente de transmisión térmica
T_i	VarContr	$^\circ\text{C}$	Temperatura interna

¹Variable controlada

T_p	VarManip ²	$^{\circ}\text{C}$	Temperatura del sistema de calefacción
K_{rad}	0,3	SD ³	Factor de conversión de la radiación por la cubierta
G	Entrada	W m^{-2}	Radiación solar
k_v	1290	$\text{J m}^{-3} \text{ } ^{\circ}\text{C}^{-1}$	Capacidad calorífica por unidad volumétrica de aire
k_r	6	$\text{W } ^{\circ}\text{C}^{-1} \text{ m}^{-2}$	Coefficiente de transmisión de la energía a través de la cubierta
T_0	Entrada	$^{\circ}\text{C}$	Temperatura exterior
Φ_{vent}	-	m s^{-1}	Flujo de ventilación
A	VarManip	m^2	Apertura de las ventanas por m^2
a_1	$5.5 \cdot 10^{-4}$	SD	Factor de parametrización de la función de ventilación
a_2	1.56	SD	Factor de parametrización de la función de ventilación
a_3	10^{-2}	SD	Factor de parametrización de la función de ventilación
a_4	2.46	SD	Factor de parametrización de la función de ventilación
a_5	10^{-4}	SD	Factor de parametrización de la función de ventilación
a_6	4.85	SD	Factor de parametrización de la función de ventilación
a_7	10^{-4}	SD	Factor de parametrización de la función de ventilación
c_{esc}	0.75	m s^{-1}	Término de escape de aire a través de la grietas de las ventanas
a_8	10^{-4}	SD	Factor de parametrización de la función de ventilación
U_{ls}	[0-100] VarManip	%	Grado de apertura de la ventana este (Variable manipulada)
U_{ws}	[0-100] VarManip	%	Grado de apertura de la ventana oeste (Variable manipulada)
W	Entrada	m s^{-1}	Velocidad del viento

²Variable manipulada³Sin dimensión

k_s	5.75	$W\ ^\circ C^{-1}\ m^{-2}$	Coefficiente de transmisión de calor a través el suelo
T_s	Entrada	$^\circ C$	Temperatura del suelo
$c_{cap,q}$	20000	$W\ m^{-2}\ ^\circ C^{-1}$	Capacidad térmica del aire del invernadero
V_i	VarContr	$Kg\ m^{-3}$	Humedad absoluta dentro del invernadero
V_0	Entrada	$Kg\ m^{-3}$	Humedad absoluta fuera del invernadero
a_t	62.8	$m^2\ Kg^{-1}$	Factor de parametrización de la función de reducción de la transpiración
P_s	VarContr	$Kg\ m^{-2}$	Peso seco estructural
$a_{t,m}$	$3.6\ 10^{-3}$	$m\ s^{-1}$	Coefficiente de transmisión de masa
a_{H_2O}	18	$Kg\ kmol^{-1}$	Masa molecular del agua
Φ_{phot}	-	$Kg\ m^{-2}\ s^{-1}$	Fotosíntesis bruta
c_α	0.68	SD	Factor de conversión de CO_2 a su equivalente en azúcar
Φ_{resp}	-	$Kg\ m^{-2}\ s^{-1}$	Mantenimiento de la respiración
c_β	0.8	SD	Factor de producción
r_{gr}	-	s^{-1}	Ratio específico de crecimiento
C_i	VarContr	$Kg\ m^{-3}$	Concentración de CO_2 dentro del invernadero
V_c	Entrada	$Kg\ m^{-3}$	Concentración de CO_2 fuera del invernadero
P_{ns}	VarContr	$Kg\ m^{-2}$	Peso no estructural seco
Φ_{phot}	-	$Kg\ m^{-2}\ s^{-1}$	Consumo bruto de CO_2 por fotosíntesis
c_1	0.85	SD	Parámetro de saturación de presión del vapor de agua
c_2	611	$J\ m^{-3}$	Parámetro de saturación de presión del vapor de agua

c_3	17.4	SD	Parámetro de saturación de presión del vapor de agua
c_4	239	$^{\circ}\text{C}$	Parámetro de saturación de presión del vapor de agua

Tabla 5.3: Parámetros del modelo del invernadero

5.2 Control en tiempo real del clima

El invernadero en cuestión es un invernadero controlado por un algoritmo de control PI adaptativo. Tiene la instrumentación necesaria para poder controlar las variables que queremos regular. Debido al poco tiempo disponible y el coste elevado para hacer este trabajo de control en tiempo real, habría que adaptar el sistema de control ya implantado y aprovecharlo al máximo. La idea es sustituir el controlador maestro (*Master Controller*) que es el PI adaptativo, por el controlador predictivo basado en modelos.

5.2.1 Estructura del controlador

La estructura del sistema de control, está descrita por la figura 5.6. El controlador predictivo está implementado como un controlador maestro que proporciona los valores óptimos de las variables de control (apertura de las ventanas, temperatura del sistema de calefacción) al controlador esclavo, que a su vez, proporciona las secuencias de control a los actuadores implementados en el sistema real. La comunicación entre estos controladores se hace por medio del protocolo ActiveX.

El controlador maestro espera cada minuto los valores del último valor de la señal de control, las variables climática externas, y el valor actual de

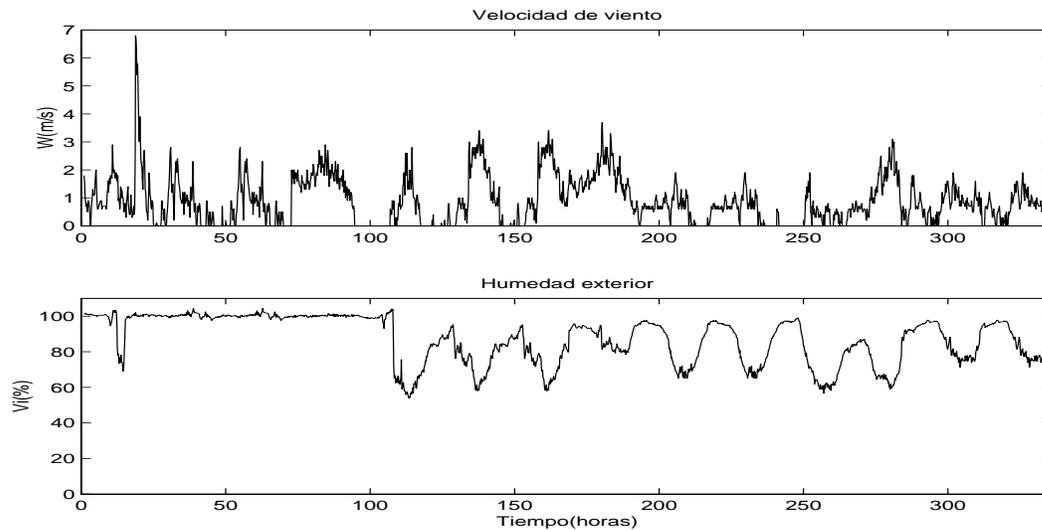


Figura 5.5: Condiciones externas: Velocidad del viento y Humedad relativa

la temperatura interna del sistema de adquisición de datos, entonces calcula el valor óptimo de la señal de control para el controlador esclavo que a su vez la proporciona al sistema real. Esta operación se repite cada minuto (periodo de muestreo) durante todo el experimento.

5.2.2 Resultados experimentales

El objetivo de este experimento es el control de la temperatura interna del invernadero descrito en la sección 5.1, las referencias se eligen de manera que por la noche la temperatura interna sea 18°C y de día 23°C hasta las 20 horas. La elección de los valores de estas temperaturas de referencia fue propuesta por los agricultores (Ingenieros agrónomos de la ITG), debido a su experiencia en este tipo de invernaderos y por el tipo de cultivo que se planta normalmente.

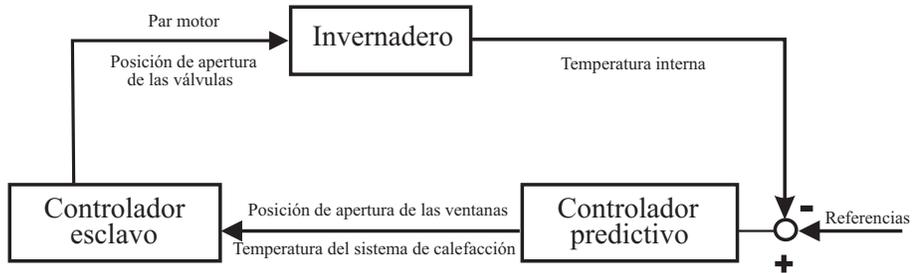


Figura 5.6: Estructura del controlador: Controladores maestro y esclavo

Los parámetros del controlador se eligen como lo siguiente:

- $N_2=15$: Horizonte de predicción.
- $\mathbf{R} = [10^{-8} \ 10^{-2}] \mathbf{I}$: Matriz de peso de las señales control del sistema de calefacción y de la apertura de las ventanas respectivamente.
- $\mathbf{Q} = 30 \mathbf{I}$ Matriz de peso de la salida.
- $p_m=1$ min: Periodo de muestreo.

Estos valores se han escogido para obtener un compromiso entre el seguimiento de las referencias y los esfuerzos de control.

La trayectoria de referencia se calcula en base de un polinomio de orden 3 para conseguir acciones de control suaves.

La figura 5.7 ilustra los resultados obtenidos con el controlador MELPC. Por la noche el sistema es capaz de seguir las referencias perfectamente, porque no hay perturbaciones provenientes del sol. Sin embargo, el efecto de la radiación solar se puede observar por el día, y se notan algunas oscilaciones alrededor de la referencia.

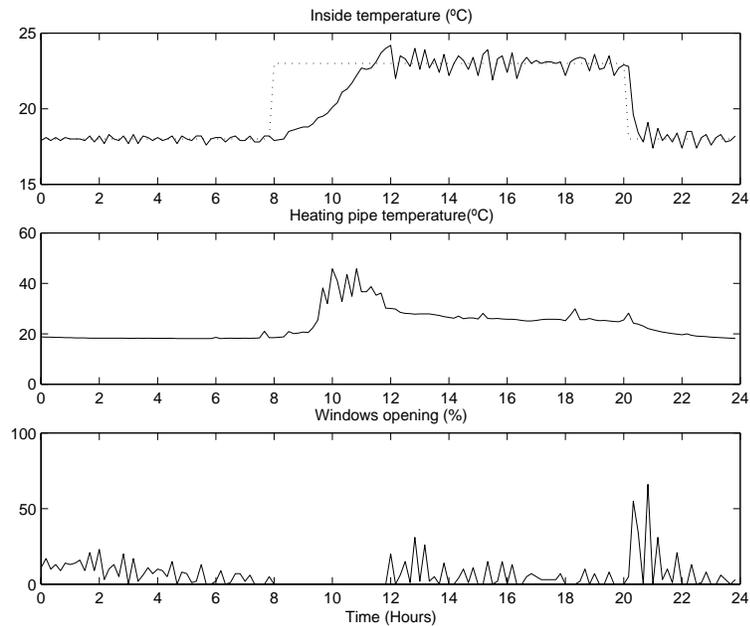


Figura 5.7: Controlador predictivo: respuesta en lazo cerrado

El resultado más importante de este experimento es el hecho de que con el controlador predictivo no hay pérdidas de energía, cuando las ventanas están abiertas el sistema de calefacción siempre está cerrado. En la figura 5.7 se puede observar que la temperatura del sistema de calefacción aumenta entre las 9 y 12 horas, ello implica que el sistema de calefacción está abierto, en este mismo intervalo de tiempo las ventanas están totalmente cerradas. Fuera de este intervalo las válvulas del sistema de calefacción están cerradas porque la temperatura del sistema de calefacción es muy baja.

La formulación del controlador MELPC incluye las restricciones sobre los límites de la temperatura del sistema de calefacción, y también sobre los límites del valor de la pérdida de energía (W/s^2). Esto se puede describir por la fórmula 5.3:

La pérdida de energía debido al ventilación es una función de la apertura de ventanas A :

$$Q = f(A)(T_i - T_{out}) \Rightarrow Q_{limit} = f(A_{limit})(T_i - T_{out}) \Rightarrow A_{limit} = g\left(\frac{Q_{limit}}{T_i - T_{out}}\right) \quad (5.3)$$

Donde:

A : Grado de apertura de las ventanas

f : función no lineal de A

T_i y T_{out} : son las temperaturas interna y externa del invernadero respectivamente.

Q_{limit} : es el valor límite de energía (objetivo de control)

g : función inversa de f (f^{-1})

El controlador predictivo MELPC está comparado con el sistema de control del el *Institute for Horticultural and Agricultural Engineering (ITG)* (controlador PI adaptativo) en un invernadero similar ⁴. La figura 5.8 ilustra el seguimiento de la temperatura interna y las acciones control.

El rendimiento es realmente pobre en comparación con el obtenido con el controlador predictivo. Durante la noche donde no hay perturbaciones de la radiación solar y las ventanas esta totalmente cerradas, el sistema es incapaz de seguir la referencia. También durante el periodo entre las 2:00 p.m. y 6:00 p.m. se puede observar que el sistema de calefacción está abierto

⁴la referencia por el día es 22°C

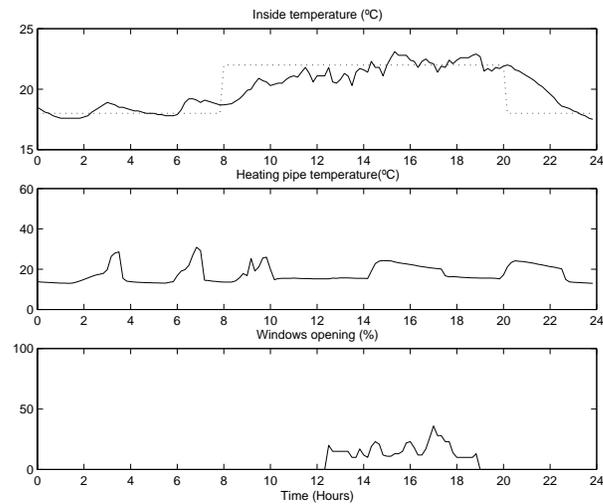


Figura 5.8: Controlador PI adaptativo: respuesta en el lazo cerrado

cuando las ventanas están abiertas, también se puede observar oscilaciones al rededor de la referencia por el día, y por último el sistema responde muy lentamente cuando hay un cambio en la referencia.

Las principales ventajas del controlador predictivo se pueden resumir en los siguientes puntos:

- El rendimiento con el controlador predictivo es mucho mejor.
- La formulación exacta de las restricciones (ecuación 5.3).
- Es multivariable y fácil de implementar.

5.3 Resumen

En este capítulo se presentan los resultados experimentales que se han llevado a cabo en esta tesis. Los experimentos se hacen en dos etapas:

- Validación del modelo: La validación del modelo se hace comparando los resultados de simulación con los datos obtenidos del invernadero real. Es un problema de optimización cuadrática de una función coste que depende de la diferencia entre los valores teóricos y experimentales. El objetivo de la validación es encontrar los valores óptimos de las variables de calibración de este modelo.
- Control en tiempo real del clima: Los experimentos de control en tiempo real se hacen en un día de verano (25/05/2001) de la ciudad de Hannover en Alemania.

Capítulo 6

Control jerárquico

Una aproximación global de un sistema de producción bajo invernaderos permite separar este sistema en varios subsistemas. La mayor parte de los estudios (Udink Ten Cate, 1985; Tantau, 1993) proponen la siguiente división:

- subsistema invernadero/microclima instantáneo
- subsistema cultivo/invernadero a corto plazo
- subsistema cultivo/invernadero a largo plazo

A cada uno de estos subsistemas corresponde:

- una escala de tiempo, liada a la constante de tiempo de los procesos involucrados.
- un nivel de control de decisión.

6.1 Control Jerárquico

Un orden jerárquico está asignado a cada uno de los subsistemas. El nivel superior está definido por el objetivo económico a largo plazo. El nivel intermedio es la determinación de las consignas climáticas a corto plazo (escala de unas horas o de un día). Por último el nivel inferior es el control del microclima deseado dentro del invernadero.

Esta descripción jerárquica (figura 6.1), necesaria para un sistema tan complejo, implica un cierto número de suposiciones (Udink Ten Cate, 1984; Tantau, 1993):

- Cada subsistema tiene que ser descrito de manera explícita.
- Las entradas y salidas de los subsistemas tienen que ser observables.
- Las interacciones entre los diferentes niveles son o despreciables o perfectamente conocidos.

Los tres niveles de este sistema de producción intercambian continuamente un flujo de informaciones y decisiones. Estos intercambios son muy fuertes y tienen que ser perfectamente conocidos; por ejemplo, la importancia del conocimiento de la relación entre cultivo y clima para una gestión óptima del sistema de producción, tanto a corto plazo como a largo plazo.

Son de una gran importancia los puntos siguientes:

- Disponer de las informaciones más pertinentes posibles del nivel en cuestión.
- Definir bien los criterios.

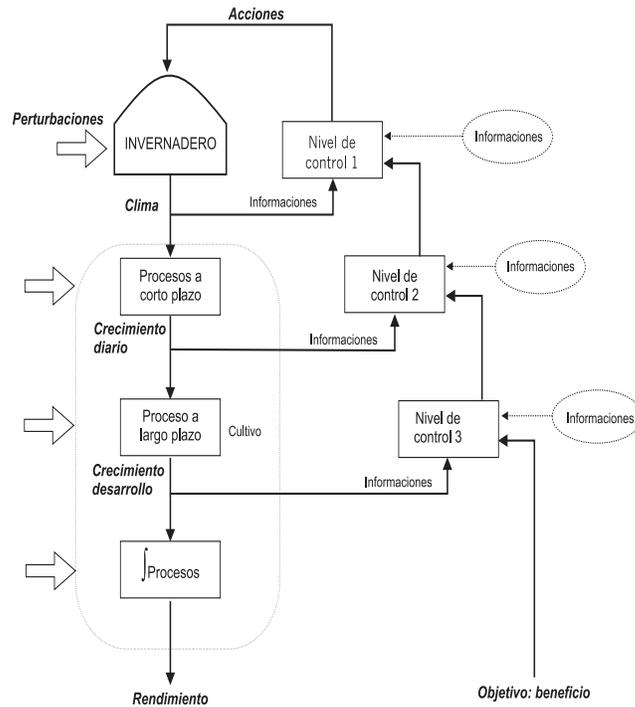


Figura 6.1: Los tres niveles del proceso de producción bajo invernadero

6.1.1 Nivel 1: Control del micro-clima interior

En este nivel más bajo se trata principalmente de:

- Adquirir las informaciones por medio de los sensores. Estas informaciones casi siempre son de tipo físico (clima interior y exterior), raramente de tipo biológico (fisiología, crecimiento, morfología, etc.) adquiridas en tiempo real son usadas por algoritmos de control, que aseguran el seguimiento de las consignas.

- Proporcionar las informaciones necesarias al nivel inmediatamente superior donde serán analizadas, y que serán traducidas a nuevas consignas que el primer nivel debe seguir.
- Evitar las situaciones de conflicto entre diferentes funciones de climatización (por ejemplo no hay que ventilar si la calefacción está encendida)
- Disparar las alarmas cuando un parámetro sobrepasa los valores límites fijados con antelación.

Generalmente la escala de tiempo correspondiente a estas tareas es muy corta, del orden de un minuto. Este primer nivel realiza las tareas de control de clima usando las diferentes variables de control como:

- Calefacción
- Ventilación
- Enriquecimiento en CO₂
- Humidificación (*fogging*)
- Pantallas térmicas
- Sistemas de alumbrado artificial

En este estudio el nivel I, es la etapa que se ha desarrollado completamente desde el estudio teórico (Capítulo 3), en simulación (Sección 4.4) y por fin hasta la aplicación en un invernadero real (Capítulo 5).

6.1.2 Nivel 2: Crecimiento de desarrollo del cultivo a corto plazo

Es un nivel intermediario, donde se hace el cálculo de la consignas, que el primer nivel debe seguir. La escala de tiempo puede variar de una hora hasta un día. Los procesos involucrados en este nivel, son los que varían de manera significativa durante esta escala de tiempo, por ejemplo la fotosíntesis, la respiración, la transpiración, etc. El resultado de todos estos procesos es el crecimiento diario de las plantas. Las salidas de este nivel serán utilizadas para calcular las consignas del primer nivel, y también sirve para el nivel superior, donde serán integrados todos los datos diarios. Las salidas de este nivel son difícilmente medibles. La utilización de modelos de crecimiento es muy importante en este nivel; sin embargo, la obtención de estos últimos, aún es muy difícil visto la implicación de muchos procesos difíciles de medir, sobre todo, los de tipo fisiológico.

6.1.3 Nivel 3: Crecimiento del cultivo a largo plazo

Este nivel incluye todos los objetivos a largo plazo de la producción impuestos por los imperativos de la infraestructura existente, la situación del mercado, o bien el calendario cultural, etc. Las variables de salida a controlar (fecha de floración o rendimiento) pueden integrarse en modelos económicos con el objetivo final de evaluar los beneficios del cultivo en función de las estrategias cultural y climática adoptadas y de la situación en el mercado.

6.2 Ejemplo de simulación

El control jerárquico consiste en la optimización de todo el proceso de producción dentro de un invernadero. Hay tres elementos muy importantes:

- Modelo del invernadero: este modelo servirá principalmente para el control del primer nivel. el objetivo de control en este nivel es el seguimiento de las referencias calculadas en el segundo nivel.
- Modelo de crecimiento del cultivo: necesario para el cálculo de las referencias óptimas de las diferentes variables a controlar. Esto se hace optimizando una función de coste económica.
- Función de coste económica: Esta función de coste puede tener muchas formas según el objetivo de control. La forma común de esta función es la diferencia entre los gastos y los beneficios, pero hay una posibilidad de incluir el tiempo en el proceso de optimización, que se explica por el hecho de tener un cierto beneficio bajo la condición de producir cierta cantidad en un tiempo determinado.

El objetivo de control es la maximización del rendimiento neto (*i.e.* rendimiento bruto menos los gastos). El rendimiento bruto es el precio unitario por todo el peso seco de la cosecha, y los gastos incluyen el precio de la energía gastada durante toda la temporada, y del abono de CO₂.

El esquema de control que se ha planteado está ilustrado en la figura 6.2, donde el proceso está dividido en 2 niveles, (realmente son tres, como el segundo nivel incluye los dos niveles superiores 2 y 3 arriba descritos). El segundo nivel minimiza una función de coste económica, calculando la combinación de las consignas óptimas que debe proporcionar al primer nivel. El lazo de control se realimenta con las variables de estado provenientes del primer nivel actualizadas en cada periodo de muestreo.

La aplicación del control jerárquico en un experimento real es muy difícil por la razones siguientes:

- Obtención de modelos de crecimiento fiables: el modelado del crecimiento es una tarea muy difícil de cumplir. Esto limita la aplicación de este tipo de control a algunas especies de cultivos con modelos relativamente "sencillos" y con "pocas" variables de estado.
- Lentitud de los experimentos: Los experimentos pueden durar hasta 6 meses según el tipo de cultivo. En estas condiciones los experimentos deben estar bien estudiados con antelación, contemplando todas las posibilidades y los problemas que pueden ocurrir, falta de esto todo el experimento se hecha a perder y hay que esperar otra temporada.
- Repetibilidad de los experimentos: A la hora de repetir cualquier experimento, hay que asegurar que las condiciones de todos los experimentos son idénticas. Esto es extremadamente difícil porque las condiciones climáticas varían de una temporada a otra.

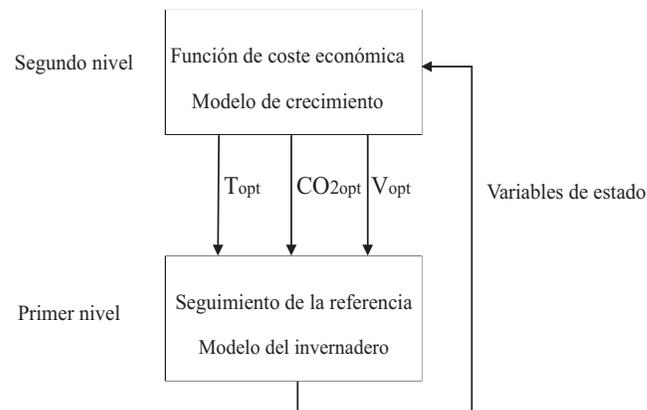


Figura 6.2: Optimización de producción: esquema de control

6.2.1 Descripción del experimento de simulación

El ejemplo de simulación consiste en simular la optimización de producción de un invernadero. Los aspectos más importantes a tener en cuenta son:

- Modelo del invernadero+crecimiento: Son los modelos encontrados en el capítulo 3.
- Horizonte de predicción: Este parámetro debe ser comparable con una evolución normal de la variable a optimizar (peso de la cosecha), en este experimento se ha elegido un valor de 3 meses, porque en este periodo podemos tener una variación significativa de este cultivo (lechuga).
- Periodo de muestreo: Este factor es muy importante, porque los datos actualizados en cada instante de muestreo deben ser los suficientemente representativos del estado del sistema sin despreciar ningún dato que pueda ser de interés para el sistema. El valor escogido en este experimento es de 12 horas, en este intervalo de tiempo se incluyen todas las dinámicas (clima exterior, clima interior, fotosíntesis, respiración, etc.).
- Modelo de perturbaciones (Condiciones meteorológicas): Las predicciones se pueden hacer considerando un modelo de perturbaciones (usar un predictor) o considerados constantes (igual como el año anterior). En este estudio se elige la segunda opción, por razones computacionales. Los cálculos pueden ser muy costosos aún más si se usa un predictor para la perturbaciones, porque con perturbaciones constantes sólo se hace una suma a las predicciones, y o hay un gran incremento de los cálculos. Con un predictor las predicciones se hacen dos veces, las de la salida y las de las perturbaciones y esto aumenta más el tiempo computacional.

- Función de coste económica:

La función de coste está en función del beneficio neto que es la diferencia entre el beneficio bruto y el precio de los gastos y tiene la forma siguiente:

$$B_n = B_b - G_s \quad (6.1)$$

$$B_b = P_c \cdot Pr_c \quad (6.2)$$

$$G_s = P_{CO_2} \cdot C_i + P_{enrg} \cdot W \quad (6.3)$$

donde:

B_n es el beneficio neto.

B_p es el beneficio bruto.

G_s representa los gastos.

P_c es el peso de la cosecha en Kg.

P_{r_c} es el precio del un Kg de cosecha.

El objetivo de optimización es obtener los valores óptimos de las referencias (temperatura interna, concentración de CO_2 y humedad relativa interna) para toda una semana, con un horizonte de predicción de tres meses teniendo en cuenta que las condiciones climatológicas son iguales que el año anterior en la misma época.

El sistema a optimizar es el mismo que el descrito en el capítulo 3, con la misma condiciones climatológicas de la ciudad de Hannover en Alemania.

6.2.2 Resultados de simulación

Las simulaciones consisten en obtener los valores óptimos de las consignas de la temperatura de día y de noche, con el fin de obtener la producción

óptima.

El experimento se resume en maximizar una función de coste que calcula el beneficio neto durante todo el periodo de cosecha.

El problema de optimización consiste en encontrar el valor óptimo de las consignas de las temperaturas nocturna y diaria, que maximiza el valor del peso neto durante todo el periodo de cosecha (6 meses en este caso). Durante la optimización, se ha escogido un intervalo de variación de la temperatura nocturna que varía entre 10°C y 19°C , en cuanto a la temperatura de día varía entre 20°C y 29°C . Estos valores nacen de los posibles valores que puedan tener las consignas nocturna y de diaria en el clima de la ciudad de Hannover en Alemania.

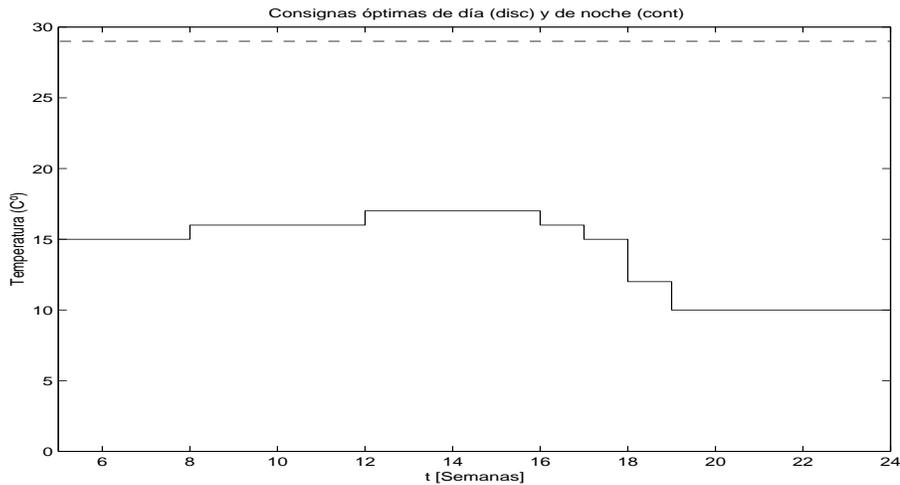


Figura 6.3: Consignas óptimas de día (discontinuo) y de noche (continuo)

Los valores óptimos de las dos temperaturas se ilustran en la figura 6.3. Durante todo el periodo de cosecha el valor óptimo para la temperatura de día es de 29°C , en cuanto a la temperatura óptima de noche varía entre 15°C , 18°C y 10°C .

El peso óptimo durante el periodo de cosecha se ilustra en la figura 6.4 y se observa el crecimiento de este último hasta llegar a un valor máximo de 84 g/m^2 al final del periodo de cosecha.

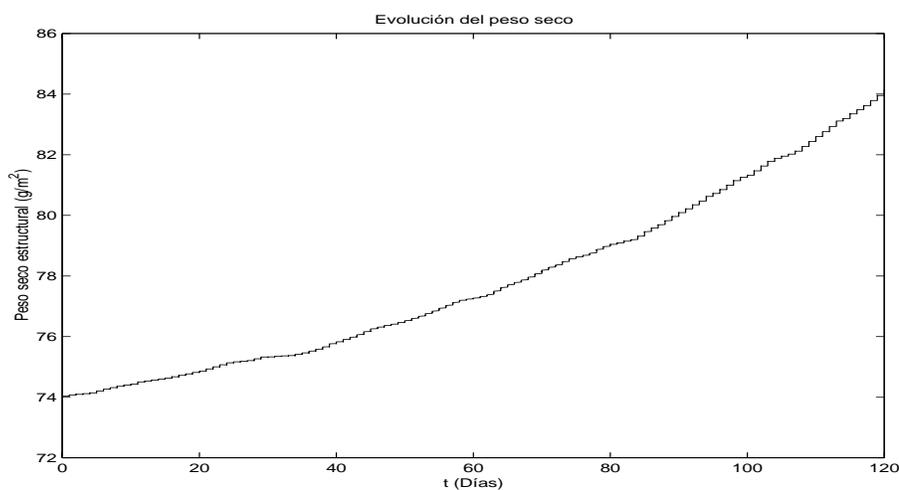


Figura 6.4: Peso óptimo

6.2.3 Análisis de los resultados

El control jerárquico conlleva una serie de problemas, sobre todo los relativos a la optimización, porque la división del sistema en tres niveles de decisión y de control tiene una desventaja: que estos niveles están fuertemente relacionados entre ellos, y los lazos de control y de interacción tienen que ser definidos y coherentes entre ellos. Aunque en el caso de dominar todas estas relaciones, la optimización en estas condiciones es muy difícil por el gran número de variables y el largo tiempo del periodo de optimización (varios meses). Una manera de hacer esta tarea posible es reducir el número de variables, y escoger las variables más representativas como el peso bruto total o el número de frutas. Esta reducción puede conducirnos a un resulta-

do no óptimo. Hay que utilizar entonces una estrategia subóptima al lugar de una estrategia óptima.

Otro tipo de problemas es de tipo práctico, y se puede dividir en dos partes:

- **Antes de la plantación:** Es un problema de planificación donde hay que determinar la estrategia climática la más adaptada al tipo del invernadero y a los equipos de climatización, al clima local, a la especie plantada, y a las condiciones de mercado que tenemos como objetivo.

La elección del " *planning*" del clima y del cultivo es una optimización estática, porque está basada en un cierto número de datos considerados fijos y que no evolucionan. Los programas de *planning* pueden ser construidos a partir de modelos fisiológicos, biológicos y económicos presentados más arriba. Sirven para poder juzgar un cierto número de estrategias definidas antes de la implantación, y escoger dentro de ellas la más adaptada a los objetivos económicos del agricultor.

- **A lo largo de la plantación:** Se trata de determinar las modificaciones a aportar al *planning* inicial cuando las condiciones reales se descartan demasiado de las condiciones medias como datos de entrada a la hora de escoger el *planning*. Al contrario del primer tipo de optimización, es un proceso de optimización dinámico, porque usa datos pasados del clima y del estado de las plantas, registradas desde el principio del ciclo de cultivo. La comparación entre los datos actualizados y los objetivos previstos nos da entonces los elementos de decisión para modificar o no la estrategia climática contenida en el *planning* inicial.

6.2.4 Conclusión

La gestión óptima del clima y de la producción en invernaderos está sujeta a los avances en el conocimiento de los fenómenos implicados en los niveles 2 y 3 y las interacciones que existen entre ellos.

En el nivel 2, las perspectivas son muy prometedoras debido a los avances en la tecnología de los sensores especializados en este campo (variación de diámetro, temperatura en la superficie de las plantas, etc.).

En el nivel 3 un conocimiento más profundo en la fisiología de las plantas es indispensable para el desarrollo de modelos biológicos más fiables.

Sin embargo, un modelo heurístico puede ser muy útil (i.e. sistema experto), sobre todo para tener en cuenta fenómenos difíciles de modelar (i.e. ataque de parásitos) o para tener en cuenta las observaciones cualitativas hechas por el productor.

La aplicación práctica de este tipo de control puede ser viable si los avances en el modelado de los procesos usados en los niveles 2 y 3 son considerables.

Capítulo 7

Conclusiones

En la presente tesis se presenta una aplicación práctica del control predictivo sobre un invernadero real. Por esta razón se desarrolla un algoritmo de control predictivo MELPC, no lineal, multivariable, basado en la linealización en línea y que no requiere un gran esfuerzo computacional.

La investigación se ha centrado en el comportamiento de este controlador tanto en rendimiento como en aspectos computacionales. Se ha incluido, además, el análisis de un amplio rango de problemas relacionados al control de sistemas con restricciones, tales como: estabilidad, factibilidad, optimización, implementación y cálculo, e influencia de las perturbaciones. Este estudio se ha complementado por una comparación entre los diferentes algoritmos que usan la misma técnica de linealización *on-line* ELPC, EP-SAC y también con los algoritmos de control predictivo lineal y no lineal. También se ha expuesto una serie de experimentos en simulaciones para probar el MELPC, controlador elaborado en esta tesis. Los experimentos consisten en aplicar este controlador sobre una amplia gama de sistemas con dinámicas diferentes. Finalmente se ha aplicado este controlador sobre un invernadero real construido en el *Institute for Horticultural and Agricul-*

tural Engineering (ITG) de la Universidad de Hannover (Alemania) para el control de las variables climáticas en tiempo real.

Se ha desarrollado un modelo de un invernadero real similar a los sistemas de producción en la industria agrícola, considerando las variables de estado: temperatura interna, humedad interna y concentración de CO₂.

La validación de este modelo se ha hecho mediante optimización de los parámetros de calibración:

- $c_{cap,q}$: Capacidad térmica del aire del invernadero.
- k_c : Coeficiente de transmisión térmica.
- k_r : Coeficiente de transmisión de la energía a través de la cubierta.

También se ha presentado el modelo de crecimiento del cultivo que es la lechuga porque es un modelo sencillo con pocas variables de estado y que son: el peso seco no-estructural y el peso seco estructural.

La gestión óptima del clima y de la producción en invernaderos está sujeta a los avances en el conocimiento de los fenómenos implicados en los niveles 2 y 3 y las interacciones que existen entre ellos.

En el nivel 2, las perspectivas son muy prometedoras debido a los avances en la tecnología de los sensores especializados en este campo (variación de diámetro, temperatura en la superficie de las plantas, etc.).

En el nivel 3 un conocimiento más profundo en la fisiología de las plantas es indispensable para el desarrollo de modelos biológicos más fiables.

Sin embargo, un modelo heurístico puede ser muy útil (i.e. sistema experto), sobre todo para tener en cuenta fenómenos difíciles de modelar (i.e.

ataque de parásitos) o para tener en cuenta las observaciones cualitativas hechas por el productor.

La aplicación práctica de este tipo de control puede ser viable si los avances en el modelado de los procesos usados en los niveles 2 y 3 son considerables.

Trabajos futuros

Las líneas de investigación futuras en este tema del control jerárquico y optimización de la producción en invernaderos, son muy diversas y pueden resumirse en los siguientes puntos:

- **Métodos de optimización:** La elección de un método de integración adecuado es de una gran importancia para resolver el problema de optimización en línea durante toda una temporada de 6 meses. La utilización de un algoritmo de optimización que usa valores enteros es obligatoria, porque el uso de un algoritmo que no usa esta técnica implica una gran carga computacional sin necesidad; por ejemplo, la búsqueda de un punto óptima dentro de un sub-intervalo de $[10,1^{\circ}\text{C} \ 10,5^{\circ}\text{C}]$ no tiene ningún interés porque en el caso del invernadero todo este intervalo se puede reducir en un solo valor de 10°C .

La técnica adecuada en este caso es la llamada **programación entera**

- **Optimización multiobjetivo:** En este trabajo se ha usado una optimización "*mono-objetivo*" porque se ha usado un solo criterio, es la maximización del peso neto. Otra posibilidad es plantear el problema de optimización con el mismo objetivo pero en una determinada fecha. La variable tiempo entra como una variable más de optimización. Esto por supuesto, sumará esfuerzos de cálculo, pero es de una gran

importancia considerar el tiempo en un sistema de producción bajo invernaderos, donde la producción de algunos productos debe estar disponible en el mercado en una fecha precisa y con gran cantidad. El ejemplo más representativo es la fiesta de SAN JORDI en Catalunya, donde hay que tener la producción del invernadero (en este caso con un cultivo de flores) disponible ese día para poder maximizar el beneficio. El problema que pueda tener esta técnica es obviamente el tiempo de cálculo muy grande. La aplicación en práctica implica un gran conocimiento por parte del programador de la situación económica de los mercados y del estado de la oferta y la demanda.

- **Aplicación práctica:** Hoy en día muy pocos paquetes proponen una solución para una gestión integrada de todo el sistema de producción. Un esfuerzo en este sentido puede ser de gran utilidad para la producción en invernaderos. Uno de los objetivos a conseguir es lograr una aplicación del control jerárquico en un paquete industrial usando control predictivo. Uno de los problemas que se pueden encontrar es la lentitud de obtener resultados. La repetibilidad de las condiciones de algún experimento es imposible o la difícil comparación entre dos experimentos dificulta el poder analizar los resultados y evaluarlas.

Bibliografía

- Allwright, J. C. (1994). On min-max mode-based predictive control. In: *Advances in model-based predictive control* (D. W. Clarke, Ed.). Oxford University Press. Oxford, UK.
- Angulo J.M., Avile R. (1986). *Curso de robótica*. Paraninfo. Madrid, España.
- Ayyub, Bilal M. (1996). *Numerical Methods for engineers*. Prentice Hal cop. Upper Saddle River, New Jersey, EEUU.
- B. Cooley, J.H. Lee (1997). Integrated identification and robust control. In: *IFAC ADCHEM Conference*. Bannf Canada.
- Babuska, R., Verbrugeen H.B. (1996). An overview of fuzzy modelling for control. *Control Engineering Practice* 4(11), 1593–1606.
- Bitmead, R., M. Gevers and V. Wertz (1990). *Adaptive Optimal Control. The Thinking Man's GPC*. Prentice Hall. Sydney, Australia.
- Bjarne A. Foss, Tor A. Johansen and Aage V. Sorensen (1995). Nonlinear predictive control using local models - applied to a batch fermentation process. *Control Engineering Practice*.
- Camacho, E. F. and C. Bordóns (1995). *Model Predictive Control in the Process Industry*. Springer-Verlag. London, UK.

- Chen, H. and F. Allgöwer (1998*a*). Nonlinear model predictive control schemes with guaranteed stability. In: *Nonlinear Model Based Process Control* (R. Berber and C. Kravaris, Eds.). pp. 465–494. Kluwer academic publishers. Dordrecht, Germany.
- Chen, H. and F. Allgöwer (1998*b*). A quasi-infinite horizon nonlinear model predictive control scheme with guaranteed stability. *Automatica* **34**(10), 1205–1217.
- Cutler, C. R. and R. B. Hawkins (1987). Constrained multivariable control of a hydrocracker reactor. In: *Proc. of the American Control Conference*. Minneapolis, MN, USA. pp. 1014–1020.
- De Keyser, R. M. C. (1998). A gentle introduction to model based predictive control. Plenary paper.. In: *EC-PADI2 International Conference on Control Engineering and Signal Processing*.. Peru.
- De Keyser, R. M. C. and A. R. Van Cauwenberghe (1985). Extended prediction self-adaptive control. In: *IFAC Symposium on Identification and System Parameter Estimation*. York, UK.
- DeÑicolao, G., L. Magni and R. Scattolini (1998). Stabilizing receding-horizon control of nonlinear time-varying systems. *IEEE Trans. on Automatic Control* **43**(7), 1030–1036.
- Declercq, F. R.M.C. De Keyser (1999). Suboptimal nonlinear predictive controllers. *Int. J. Appl. Math. and Comp. Sci* **9**(1), 129–148.
- Doyle, F.J., et al (1995). Nonlinear model-based control using second-order volterra models.. In: *Automatica*. Vol. 31. pp. 697–714.
- El Ghoumari, M. Y. (1998). Control predictivo no lineal de un robot de tres grados de libertad. Master's thesis. Departament d'Informàtica. Universitat Autònoma de Barcelona. (In Spanish).

- Fontes, F.A.C.C., Richard B.V. (2001). A general framework to design stabilizing nonlinear model predictive controllers. *Systems and Control Letters* **42**, 127–143.
- Friedland, B. (1996). *Advanced Control System Desing*. Prentice Hall. Englewood cliffs, New Jersey, EEUU.
- Fruzzetti, K.p., Palazoglu A. Mcdonald K.A. (1997). Nonlinear predictive control using hammerstein models. *Journal of Process Control* **7**(1), 31–41.
- Gevers, M. (1991). Connecting identification and robust control: a new challenge. In: *9th IFAC Symposium on Identification and SystemParameter Estimation*. Budapest.
- Henten, E.J. Van (1994). Greenhouse Climate Management: An Optimal Control Approach.. PhD thesis. Institute of Agricultural and Environmental Engineering, Wageningen Agricultural University, The netherlands.
- J. Goudriaan, H.H. van Laar (1978). Calculation of daily totals of the gross CO_2 assimilation of leaf canopies. In: *Netherlands Journal of Agriculture Science*. Vol. 26. pp. 373–382.
- Jadbabaie, A., Yu J. Hause H. (1999). Stabilizing receding horizon control of nonlinear systems. In: *American Control Conference*. San Diego, USA.
- JM Zamarreno, P Vega (1999). Neural predictive control. application to a highly non-linear system. *COMPUTERS and STRUCTURES* **71**(2), 149–158.
- Jong, T. (1990). Natural ventilation of large multi-span greenhouses.. PhD thesis. Wageningen Agricultural University, The netherlands.

- Keerthi, S., E. Gilbert (1988). Optimal infinite-horizon laws for a general class of constrained discrete-time systems: Stability and moving-horizon approximations.. *Journal of Optimization Theory and Applications* **57**, 265–293.
- Kleinman, D. L. (1974). Stabilizing a discrete, constant, linear system with application to iterative methods for solving the Riccati equation. *IEEE Trans. on Automatic Control* **19**(3), 252–254.
- Kuznetsov, A. G. and D. W. Clarke (1996). The performance of generalised predictive control with interval constraints. *European J. Control* **2**, 260–277.
- Lee, Jay H. (2001). Industrial model predictive control. In: *Lecture Notes*. Georgia Institut of Technology- School of Chemical Engineering.
- Marquart, W. (1987). Wave propagation in counter-current separation processes and its significance to model reduction. *Automatisierungstechnik* **35**(4), 156–162.
- Matallana G.A, Montero J.I. (1995). Invernaderos diseño, construcción y climaización.
- Megías, D., M. Y. El Ghoumari and J. Serrano (1999). Extended linearised predictive control: Practical control algorithms for non-linear systems. In: *Proc. of the European Control Conference*. Karlsruhe, Germany.
- Megías, J. D. (2000). Robustness aspects of Model Predictive Control. PhD thesis. Universidad Autónoma de Barcelona.
- Michalska, H. and D. Q. Mayne (1993). Robust receding horizon control of nonlinear systems without differentiability of the optimal value function. *IEEE Trans. on Automatic Control* **38**(11), 1623–1633.

- M.R. Arahál, M. Berenguel y E.F. Camacho (1997). Nonlinear neural model-based predictive control of a solar plant. In: *European Control Conference ECC'97*. Bruselas, Bélgica.
- Oliveira, S. L. De and V.Ñevistić and M. Morari (1995). Model predictive control for nonlinear systems subject to input constraints. Technical report. Automatic Control Laboratory, Swiss Federal Institute of Technology (ETH).
- Oliveira, S. L., V.Ñevistić and M. Morari (1995). Model predictive control for nonlinear systems subject to input constraints. Technical report. Automatic Control Laboratory, Swiss Federal Institute of Technology (ETH).
- P. Alberto, R. Ortega (1989). On generalized predictive control: two alternative formulations. In: *Automatica*. Vol. 25(5). pp. 753–755.
- P. Muñoz, J.I. Montero, A. Antón (1998). Ventilación natural de invernaderos. In: *Tecnología de Invernaderos II* (I. M. C. Gómez J.J. Perez Parra, Ed.). Chap. 6, pp. 267–311. Caja Rural de Almeria. Plaza Careaga, 2 Almeria, España.
- Pike, A.W. et al. (n.d.). *Predictive Control*. The Control Handbook CRC Press.
- Prada, C. (1990). Modelado y simulación en procesos de control. In: *Apuntes Internos*. Universidad Autónoma de Barcelona.
- Qin, S. J. and T. A. Badgwell (1996). An overview of industrial model predictive control technology. In: *5th International Conference on Chemical Process Control - CPC V*.
- Rawlings, J. B. and K. R. Muske (1993). The stability of constrained receding horizon control. *IEEE Trans. on Automatic Control* **38**(10), 1512–1516.

- S. Li, K. Lim, D.G. Fisher (1989). A state space formulation for model predictive control. In: *AIChE Journal*. Vol. 35. pp. 241–249.
- Serrano, J. (1994a). Aspectos de implementación y técnicas de robustez en CPBM. PhD thesis. Departament d'Informàtica. Universitat Autònoma de Barcelona. (In Spanish).
- Serrano, J. (1994b). Control predictivo basado en modelos. una visión general. In: *Apuntes Internos*. Universidad Autónoma de Barcelona.
- Sirovich, L. (1991). Empirical eigenfunctions and low-dimensional systems. In: *New Perspective in Turbulence* (L. Sirovich, Ed.). Springer - Verlag.
- Tantau, H.-J. (1993). Optimal control for plant production in greenhouses. In: *The computerized Greenhouse* (Inc. Academic Press, Ed.). Chap. 6, pp. 139–152. 1250 sixth Avenue, San Diego, California 92101-4311.
- Tap, F. (2000). Economics-based Optimal Control of Greenhouse Tomato Crop Production.. PhD thesis. Institute of Agricultural and Environmental Engineering, Wageningen Agricultural University, The Netherlands.
- Tulleken, H.J.A. (1993). Grey-box modeling and identification using physical knowledge and Bayesian techniques. *Automatica* **29(2)**, 285–308.
- Udink Ten Cate, A.J. (1984). On optimal computer control of the crop growth system. *Acta Horticulturæ* (148), 267–276.
- Udink Ten Cate, A.J. (1985). Advances in greenhouse climate control. *Acta Horticulturæ* (106), 43–48.
- Yan, T.H. E. Polak (1993). Moving horizon control of nonlinear systems with input saturation, disturbances and plant uncertainty. *International Journal of Control*. **58(4)**, 875–903.