

2. CONTROL PREDICTIVO.

2.1 Introducción al control predictivo.

La aparición del control predictivo surge como consecuencia de la necesidad conjunta de gestionar situaciones complejas (donde se precisa una mejora del control tradicional), y de optimizar los procesos. En los últimos años este tipo de controladores han alcanzado un nivel sustancial de aceptación, aportando soluciones a las exigencias crecientes de calidad, seguridad y gestión económica de la planta.

Así, el Control Predictivo Basado en Modelo (MPC) ha alcanzado un nivel muy significativo de aceptabilidad industrial en aplicaciones prácticas de control de procesos. Es una estrategia de control que se basa en la utilización de forma explícita de un modelo del proceso para predecir el valor de las variables controladas a lo largo de un horizonte temporal especificado por el usuario, calculándose el valor de las variables manipuladas para hacer que en ese horizonte las variables controladas estén en sus valores de referencia. Existen muchos métodos de control predictivo que han sido aplicados con éxito: GPC, IDCOM, DMC, etc. En este proyecto se va a aplicar concretamente un controlador predictivo tipo DMC.

Es un hecho bien conocido que la mayoría de los problemas de control del nivel inferior se pueden resolver mediante simples reguladores PID. Sin embargo, existe una serie de lazos de control económicamente muy significativos que, debido a su dificultad (procesos con múltiples variables que interaccionan, retardos, dinámica compleja, etc.) o a la calidad del control exigida, requieren técnicas de control más avanzadas. Estas aplicaciones tienden a aumentar debido a una serie de factores: exigencias crecientes de calidad, ahorro de energía, seguridad, flexibilidad en la producción, necesidad de integrar decisiones económicas y sistemas de control, etc.

Desde el punto de vista de las aplicaciones industriales, el control predictivo tiene algunas ventajas importantes sobre otras técnicas de control, estas ventajas son:

- La incorporación de un modelo explícito del proceso en los cálculos permite al controlador tratar con todas las características importantes de la dinámica del sistema.
- Permite tratar de forma sencilla sistemas multivariables con distinto número de entradas y salidas.

- Incorpora de forma natural la compensación *feedforward*, proporciona varianza mínima en las variables controladas y puede utilizarse en sistemas de dinámica difícil, con retardos, respuesta inversa, etc.
- Es posible la introducción de restricciones en las variables de entrada y salida.
- Es conceptualmente simple de comprender y ajustar por el personal técnico.
- Existen controladores comerciales en el mercado con adecuado soporte técnico como es el caso del software empleado en este proyecto, el DMCplus.

Lógicamente el control MPC también presenta inconvenientes entre los que cabe destacar la elevada carga computacional para la resolución de algunos algoritmos y la necesidad de un modelo preciso del sistema.

El resultado proporcionado por este control dependerá en gran medida de lo que se ajuste el modelo al proceso real.

2.2 Elementos del control predictivo.

El Control Predictivo no es una estrategia de control específica, sino que se trata más bien de un campo muy amplio de métodos de control desarrollados en torno a ciertas ideas comunes. Es por ello que todos los controladores predictivos presentan una serie de elementos comunes, éstos son:

- El uso de un modelo matemático del proceso que se utiliza para predecir la evolución futura de las variables controladas sobre un horizonte de predicción.
- La imposición de una estructura en las variables manipuladas futuras.
- El establecimiento de una trayectoria deseada futura, o referencia, para las variables controladas.
- El cálculo de las variables manipuladas optimizando una cierta función de coste.
- La aplicación del control siguiendo una política de horizonte deslizante.

A continuación se explica brevemente como funciona esta técnica de control, para ello ver la figura 2.1.




Figura 2.1

En el instante de tiempo t , utilizando un modelo e información pasada de entrada y salida, pueden calcularse las predicciones de la variable controlada $y(t + j)$, $j = 0, \dots, N2$, en función de los valores futuros de la variable manipulada $u(t + j)$, a la cual en la figura se la obliga a permanecer constante después del instante $t + Nu - 1$. Se ha establecido una trayectoria deseada $r(t + j)$ para ir desde el valor actual $y(t)$ de la variable controlada, a la referencia $w(t)$, y se trata de determinar la secuencia $u(t + j)$ de valores de la señal de control que llevan las predicciones $y(t + j)$ tan cerca como sea posible de la trayectoria $r(t + j)$.

Una vez calculada toda la secuencia $u(t + j)$ se aplica el valor $u(t)$ en el instante t , y en el período de muestreo siguiente, $t + 1$, se repiten otra vez todos los cálculos en lugar de utilizar los obtenidos en t , de acuerdo a la política de horizonte deslizante antes mencionada.

Un esquema de esta estrategia se puede ver en la figura 2.2.




Figura 2.2.

2.3 Algoritmos de identificación de los modelos.

Existen varios algoritmos de identificación de los modelos que se utilizan para realizar las predicciones necesarias.

- Finite Impulse Response (FIR):

Son modelos que tienen la forma $y(t) = \sum_{i=1}^{\infty} h_i \cdot \Delta u(t-i)$, en donde los coeficientes

h_i se obtienen tras aplicar un impulso como entrada al proceso. Sin embargo estos modelos suelen truncarse de forma que nos quedamos con un modelo de la forma:

$$y(t) = \sum_{i=1}^N h_i \cdot \Delta u(t-i).$$

Este algoritmo de identificación es muy simple y no necesita ningún conocimiento previo del proceso sobre el que se esté trabajando, y además no le afectan los retardos. Sin embargo no es posible su aplicación sobre procesos inestables y presenta el inconveniente de la complejidad de generar señales de tipo impulsional.

- Modelo de respuesta ante escalón:

Es parecido al anterior, presentando las mismas ventajas e inconvenientes, solo que en vez de utilizar señales de tipo impulsional utilizamos señales en escalón. Entonces tenemos un modelo del tipo:

$$y(t) = \sum_{i=1}^N g_i \cdot \Delta u(t-i)$$

- Subspace Identification:

Se trata de una nueva tecnología de identificación paramétrica introducida por DMCplus, que ofrece las siguientes ventajas:

- Utiliza un modelo en el espacio de estados para representar relaciones internas entre variables.
- Con este algoritmo de identificación se captan dinámicas de alta y baja frecuencia por lo que puede modelar gran cantidad de procesos dinámicos como el comportamiento de fase no mínima, tiempos muertos desconocidos, etc.
- Es una técnica especialmente indicada para procesos MIMO, pudiendo obtener la mínima parametrización y aumentando por tanto su eficiencia.
- Es un proceso no iterativo que usa álgebra lineal por lo que no presenta problemas de convergencia.

Su mayor inconveniente es su poca implantación hasta el momento en la industria, por lo que no está demasiado depurado su funcionamiento.

Otros tipos de modelos son los modelos de función de transferencia y los modelos de espacio de estados, sin embargo no se van a detallar por no ser utilizados para la realización del proyecto.

2.3.1 Comparación entre el método FIR y Subspace Identification en DMCplus.

Cuando se realiza la identificación del sistema se puede comprobar que Subspace Identification requiere una mayor carga computacional que el método FIR sobre todo en modelos con un elevado número de variables dependientes e independientes. Esto ocurre porque el método de Subspace Identification realmente hace la identificación de un sistema multivariable (MIMO) y no como en el caso de FIR que lo que hace es un sistema MISO. El beneficio es que un verdadero modelo MIMO tiene menos

incertidumbre y es estadísticamente más preciso. En la figura 2.3 se puede ver la relación entre el tamaño del modelo y el aumento de la carga computacional que sufre el proceso de identificación.




Figura 2.3.

Estas curvas muestran que el tiempo que tarda el método Subspace Identification en identificar el sistema aumenta cúbicamente con el tamaño del modelo.

Uno de los parámetros que hay que especificar cuando se quiere identificar el modelo del sistema empleando este algoritmo es el Orden Máximo del sistema. Este parámetro especifica el tiempo en el cual el algoritmo de identificación va a buscar el orden óptimo del sistema. Para asegurar que el orden óptimo del sistema se puede encontrar con este algoritmo de identificación, el parámetro "Maximum Order" debe ser lo suficientemente grande. En la figura 2.4 se muestra la relación entre el Orden Máximo y la carga computacional.




Figura 2.4.

En la figura 2.4 se puede observar también como la relación entre carga computacional y orden máximo es cúbica.

Para evitar cargas computacionales elevadas se recomienda seguir las siguientes instrucciones:

- Evitar identificar modelos demasiados grandes con este algoritmo de identificación, y para una primera aproximación identificar con el algoritmo FIR.
- No dar un valor demasiado elevado a Maximum Order, usar en primer lugar el valor por defecto. Una vez que se ha completado el proceso de Subspace Identification el orden óptimo del sistema se muestra en el interface. Si el orden seleccionado es menor que el orden máximo entonces no hay que aumentar el valor de este parámetro.

El valor por defecto del parámetro Maximun Order es 20 y el valor mínimo con que se puede ajustar es 10.

Si se compara el resultado obtenido entre ambos algoritmos de identificación en ocasiones se puede comprobar que la ganancia en el régimen permanente es menor cuando se emplea Subspace Identification, la principal causa de esto es el preprocesamiento que sufren los datos antes de la identificación. Existen varios métodos de preprocesamiento. Por defecto los datos son filtrados internamente y las señales de baja frecuencia son eliminadas como perturbaciones. El Time to Steady State se emplea

como referencia para el filtro si el valor del Time to Steady State es muy bajo entonces el preprocesamiento de las señales de baja frecuencia no será muy bueno.

A continuación se describen brevemente cada uno de los métodos de preprocesamiento:

- ❖ Differencing: usa las derivadas de las de las variables dependientes e independientes para identificar el sistema.
- ❖ Detrending: usa el filtrado de datos para la identificación y se emplea cuando las variables dependientes no están marcadas como tipo Ramp.
- ❖ ZeroMean: es el preprocesamiento por defecto, elimina los valores medios de las variables dependientes e independientes.
- ❖ DoubleDiff: usa la derivada de las variables dependientes y las variables manipulables sin su media. Se emplea para identificar modelos en los que las variables dependientes no son de tipo Ramp para obtener un modelo tipo rampa.

2.4 Modelo del DMC.

Como ya se ha comentado anteriormente, los distintos tipos de control predictivo se diferencian entre otras cosas en el modelo que utilizan para realizar las predicciones de las señales de salida del proceso. El DMC utiliza la respuesta ante escalón para modelar el proceso considerando sólo los N primeros términos y asumiendo por tanto que el proceso es estable.

Así, en el caso de tener un sistema monovariable se tiene:

$$y(t) = \sum_{i=1}^N g_i \cdot \Delta u(t-i)$$

$t \rightarrow$ es el tiempo en el que nos encontremos
 $u \rightarrow$ es la señal de entrada al sistema
 $g \rightarrow$ son los coeficientes del modelo
 $N \rightarrow$ número máximo de coeficientes utilizados en el modelo
 $y \rightarrow$ es la señal de salida del proceso.

Tras una serie de operaciones matemáticas se llega a que las predicciones generadas por DMC son de la forma:

$$\hat{y}(t) = G \cdot u + f$$

$$G = \begin{bmatrix} g_1 & 0 & \dots & 0 \\ g_2 & g_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_m & g_{m-1} & \dots & g_1 \\ \vdots & \vdots & \ddots & \vdots \\ g_p & g_{p-1} & \dots & g_{p-m+1} \end{bmatrix}$$

G es la matriz dinámica del ensayo en escalón y contiene los coeficientes del modelo para todas las variables formada por m (horizonte de control) columnas, f es la respuesta libre del sistema, u son las señales de control e $\hat{y}$ son las predicciones de la salida (vector de dimensión p, número de variables del sistema).

2.5 Perturbaciones en DMC.

El efecto de las perturbaciones medibles se puede añadir de una manera simple a la ecuación anterior de predicción tratando a las perturbaciones medibles como señales de entrada al sistema. El resultado sería la siguiente expresión:

$$\hat{y}_d = D \cdot d + f_d$$

donde $\hat{y}_d$ es la contribución de las perturbaciones medibles a la salida del sistema, D es una matriz similar a G que contiene los coeficientes de la respuesta del sistema a un escalón en la perturbación, d es el vector de perturbaciones y f_d es la parte de la respuesta que no depende de la perturbación.

Si se tuviese en cuenta el caso más general con perturbaciones medibles y no medibles, entonces se podría suponer la respuesta libre del sistema como una suma de cuatro efectos: respuesta a la entrada u(t), a la perturbación medible d(t), a la perturbación no medible y al estado actual del proceso: $f = f_u + D \cdot d + f_d + f_n$, pudiendo usar la expresión que teníamos en un principio: $\hat{y}(t) = G \cdot u + f$

2.6 Función objetivo y algoritmo de control de DMC.

Una de las principales causas del éxito del DMC es que utiliza una función objetivo a la cual se le pueden añadir restricciones.

En general, la función objetivo que se intenta minimizar para obtener el punto de operación más adecuado para el proceso es, incluyendo sólo los errores futuros,

$$J = \sum_{j=1}^p \left[\hat{y}(t+j/t) - w(t+j) \right]^2$$

En caso de incluir el esfuerzo de control se obtendría la expresión

$$J = \sum_{j=1}^p \left[\hat{y}(t+j/t) - w(t+j) \right]^2 + \sum_{j=1}^p \lambda \cdot [\Delta u(t+j-1)]^2$$

utilizándose λ como parámetro para incrementar o disminuir la importancia de la acción de control en la función objetivo.

Sin considerar restricciones en el sistema, la minimización de la función objetivo anterior da como solución de la acción de control

$$u = (G^T G + \lambda I)^{-1} G^T (w - f)$$

siendo ésta la acción de control a lo largo de todo el horizonte de control, pero hay que recordar que sólo ha de aplicarse la primera de las acciones.

Si se añaden restricciones se tendría un problema matricial como el que sigue

$$R \cdot u \leq c$$

Por último resaltar que las expresiones anteriores son fácilmente extensibles a sistemas multivariables sin más que convertir las variables en vectores de forma que recojan todas las señales de entrada y salida que toman parte en el proceso. La matriz G en el caso multivariable quedaría como:

$$G = \begin{bmatrix} G_{11} & G_{12} & \dots & G_{1nu} \\ G_{21} & G_{22} & \dots & G_{2nu} \\ \vdots & \vdots & \ddots & \vdots \\ G_{ny1} & G_{ny2} & \dots & G_{nynu} \end{bmatrix}$$

Donde cada submatriz G_{ij} contiene los coeficientes de la respuesta ante escalón i -ésima correspondiente a la entrada j -ésima.