

Control de sistema buffer para plantas híbridas

Mariano De Paula^{1,3}, Sergio Gallina² y Carlos Sanchez Reinoso^{2,3}

(1) CIFICEN – CONICET, Facultad de Ingeniería, Universidad Nacional del Centro de la Provincia de Buenos Aires.

(2) Centro de Investigación y Desarrollo en Modelado, Optimización y Simulación de Sistemas Electrónicos (CIDMOS), Departamento de Electrónica, Facultad de Tecnología y Ciencias Aplicadas, Universidad Nacional de Catamarca (UNCa).

(3) Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET).
csanchezreinoso@santafe-conicet.gov.ar

Fecha de recepción del trabajo: 05/10/2015

Fecha de aceptación del trabajo: 11/12/2015

RESUMEN: El uso de técnicas de control multimodal en sistemas dinámicos de producción por lotes (sistemas *batch*) propone una promisoriosa alternativa para realizar exitosamente tareas de supervisión y control en procesos industriales. Estas técnicas persiguen integrar distintas estrategias de control para objetivos parciales o "comportamientos" usando autómatas de Lebesgue con vista a alcanzar objetivos de operación. Estos autómatas permiten identificar secuencias óptimas de modos, también denominados programas de control, usando simulaciones del sistema. Los programas de control multimodal consisten en una secuencia de modos π , cada uno de los cuales comprende una ley de control por retroalimentación $\kappa(x)$ y condiciones relevantes de terminación $\xi(x, T)$. En este trabajo se describe el empleo de un algoritmo de aprendizaje por refuerzos para encontrar vía simulación un programa óptimo de control alineado con el objetivo de maximizar la productividad en un sistema buffer compuesto de dos tanques.

PALABRAS CLAVES: sistemas batch, aprendizaje por refuerzo, control multi-modal, muestreo de Lebesgue.

CONTROLLING BUFFER SYSTEMS FOR HYBRID PLANTS

ABSTRACT: The use of multimodal control techniques for batch dynamic systems offers a promising alternative to successfully perform tasks of supervision and control in industrial processes. These techniques seek to integrate different control strategies with partial objectives or "behaviors" using Lebesgue automata overlooking achieve certain operational objectives. These automata can identify optimal sequences of modes, also called control programs, using system simulations. Multimodal control programs consist of a sequence of modes π , each of which comprises a feedback control law $\kappa(x)$ and relevant termination conditions $\xi(x, T)$. In this paper the use of a reinforcement learning algorithm is described via to find, by simulations, optimal control program aligned to maximize productivity in a buffer system composed of two tanks.

KEY WORDS: batch systems, reinforcement learning, multimodal control, Lebesgue Sampling.

1 INTRODUCCIÓN

En muchos de los sistemas de producción en las plantas químicas existen sistemas con dinámicas híbridas (Engell et al. 2000; Barton, Lee, y Yunt 2006). Estos aparecen en los sectores donde es necesario acoplar operaciones por lotes como reactores o cristalizadores con otra continua como los trenes de separación u operaciones de secado (Peirce y Crisafulli 1999). La función de integración entre estas distintas formas de operación se realiza por medio inventarios intermedios o tanques *buffer*. Una problemática importante radica en la utilización de la capacidad de estos tanques de tal suerte que no se limite innecesariamente la productividad del proceso en conjunto. Otro objetivo relevante es aprovechar la capacidad disponible para suavizar el flujo de salida.

Como se muestra en la Fig. 1, un sistema dinámico multi-modal es un sistema controlado cuya dinámica alterna entre un conjunto finito de posibilidades con vista a desplegar un dado comportamiento o alcanzar un

objetivo de interés. Estos cambios del comportamiento pueden ser el resultado de un evento específico o una decisión planificada. La estrategia de control se resume en implementar un programa óptimo de modos que permita alcanzar un determinado objetivo derivado del estado deseado para un sistema o proceso a pesar de las perturbaciones que alteran el curso y resultado de cada modo aplicado. Uno cualquiera de estos programas de control (π) consiste en una dada secuencia finita de modos (σ_i), donde cada uno de estos modos está compuesto de una ley de control $\kappa^i(x)$ y sus condiciones relevantes de terminación $\xi^i(x, T)$. Ver referencias (T. R. Mehta y Egerstedt, 2008); (T. Mehta y Egerstedt 2005) para más detalles.

En este trabajo se presenta un algoritmo de aprendizaje por refuerzos (Sutton y Barto, 1998) que permite identificar la secuencia óptima de modos usando simulaciones del sistema estudiado. Se aborda un caso de estudio relacionado con la interfaz entre un conjunto de reactores discontinuos que abastecen un tren de

separación del producto. El sistema bajo estudio está compuesto por dos tanques, mientras que el objetivo de control es maximizar la productividad del proceso químico híbrido en cada campaña de producción. Las leyes de control, de cada modo, son diseñadas para alcanzar una determinada meta parcial de acumulación o drenaje del inventario intermedio.

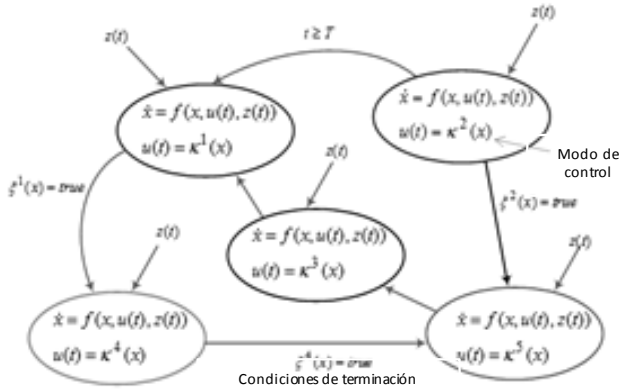


Figura. 1. Autómata multimodal

2 PROGRAMAS DE CONTROL MULTIMODAL

3

Supóngase que la dinámica del estado x responde a:

$$\frac{dx}{dt} = f(x, u(t), z(t)), x \in X = R^n, u \in U = R^m \quad (1)$$

de donde $z(t)$ es una perturbación medible que evoluciona en el tiempo según:

$$\frac{dz}{dt} = g(z, t), z \in Z = R^d \quad (2)$$

Si en un determinado momento τ_0 , en el que el estado del sistema es $x(\tau_0)$ y la perturbación es $z(\tau_0)$, el sistema recibe una secuencia de modos $\pi = \{(\kappa_1, \xi_1), \dots, (\kappa_q, \xi_q)\}$ se desencadena la transición de estados:

$$\delta(\sigma, x(\tau_0), z(\tau_0)) = x(\tau_0) + \int_{\tau_0}^{\tau_1} f(x(t), u(t), z(t)) dt + \dots + \int_{\tau_{q-1}}^{\tau_q} f(x(t), u(t), z(t)) dt \quad (3)$$

Si la secuencia de modos π posee una longitud acotada, sólo será posible alcanzar un conjunto finito de estados. Por tanto la aplicación de programas de control con una longitud máxima N , resulta en una cuantización de los estados del sistema. De acuerdo con esto se obtiene una discretización finita del espacio de estados, conocido como "Lebesgue-sampled state machine" ($X_N^Q, \Sigma, \tilde{\delta}, \tilde{x}_0, \tilde{z}_0$) (T. R. Mehta y Egerstedt, 2008); (T. Mehta y Egerstedt, 2005); (Astrom y Bernhardsson,

2002). El superíndice Q significa que estos estados pertenecen al espacio de función valor o utilidad (Sutton and Barto, 1998), mientras que la función de transición de estados $\tilde{\delta}$ es:

$$\tilde{x}_{k+1} = \tilde{\delta}(\tilde{x}_k, \tilde{z}_k, \sigma_k) = \delta(\sigma, x(\tau_0), z(\tau_0)), k = 0, 1, 2, \dots, x_0 = x(\tau_0), z_0 = z(\tau_0), \quad (4)$$

El espacio de estados discreto X_N^Q está dado por el conjunto de todos los estados que pueden alcanzarse desde $\chi_0 = (x_0, z_0)$ y para una dada evolución del vector de perturbaciones $z(t)$ cuando se implementa una secuencia de modos $\sigma \in \Sigma$ de longitud menor o igual que N . El objetivo de este trabajo es encontrar una secuencia de modos tal que maximice la acumulación de *rewards* obtenidos en las transiciones de estado del autómata híbrido de Lebesgue, el cual se esboza su idea en la Fig. 2. De acuerdo con la discretización multimodal X_N^Q del espacio de estados y la dinámica de transición del autómata híbrido de Lebesgue, es posible utilizar aprendizaje por refuerzos ó *reinforcement learning* para estimar los *Q-values* correspondientes a la función de *premios (castigos)* relacionada con el objetivo de control (Sutton y Barto, 1998). Es ventajoso que los estados explorados y los escenarios de perturbación sean utilizados para descubrir cuál es el mejor modo σ^* para cada par $\chi \in X_N^Q$.

En el algoritmo representado en la Fig.3, inicialmente la discretización del espacio estado-perturbación X_N^Q se asume desconocida. El proceso de aprendizaje consiste en, partiendo desde un dado par estado-perturbación $\tilde{\chi}_0 = (\tilde{x}_0, \tilde{z}_0)$, simular las posibles transiciones hacia todos los estados alcanzables usando los distintos modos que son factibles de aplicar en el estado inicial. En cada iteración del proceso de aprendizaje un par estado-perturbación se elige aleatoriamente del conjunto de estados-perturbaciones \aleph visitados. Luego se aplica uno de los modos de control del conjunto de modos posibles Σ , lo cual genera la transición al siguiente estado \tilde{x}' . En dicha transición se obtiene un premio o *reward* $r(\tilde{\chi}', \sigma_i)$ que se consigue una vez finalizada la ejecución del modo σ_i , momento en el cual $\xi_i = 1$.

En el algoritmo, la función $step(\tilde{x})$ representa la longitud del programa de control más corto, necesario para alcanzar un estado \tilde{x}' a partir de un estado inicial \tilde{x}_0 . De esta forma, únicamente son explorados los estados resultantes de aplicar una secuencia de modos de longitud menor o igual que N , esto garantiza que $\tilde{x}' \in X_N^Q$. En cada transición a un nuevo estado \tilde{x}' , es necesario determinar si este estado pertenece o no al

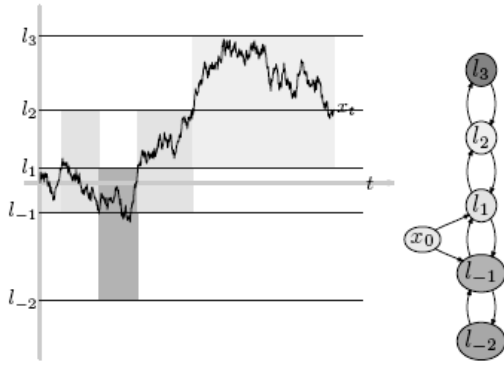


Figura. 2. Autómata híbrido con muestreo de Lebesgue

conjunto de estados visitados previamente. En el caso de que $\tilde{\chi}'$ no pertenezca al espacio de estados debe incorporarse al mismo, incrementando $step(\tilde{x})$ en 1; una nueva entrada se agrega a la tabla Q . En las situaciones que $\tilde{\chi}'$ pertenece al entorno de un estado visitado previamente, es actualizado el Q -value del estado que define el entorno en cuestión. La exploración de estado-perturbación continúa de esta forma hasta que se estabilicen las entradas de la Q -table y no aparecen nuevos estados.

Las condiciones de stop del bucle principal (línea 13) se imponen de tal suerte que las combinaciones de estados-perturbaciones \aleph sean visitados una suficiente cantidad de veces, y además que todos los modos $\sigma \in \Sigma$ sean ensayados repetidas veces para lograr una adecuada convergencia de las entradas en tabla Q .

4 CASO DE ESTUDIO

3.1 Descripción general

En diversos procesos de la industria química tales como manufactura de PVC o la industria azucarera existen dispositivos de almacenamiento temporario *obuffers* que se emplean con el fin de acoplar sin pérdida de productividad operaciones discontinuas o por lotes como reactores o cristalizadores con operaciones de naturaleza continua como secaderos, trenes de destilación, etc. (Simeonova 2008; Geist, Gromov, y Raisch 2008).

A modo de ejemplo sencillo consideremos un conjunto de n reactores, descargando en paralelo a un tanque *buffer* cuya salida alimenta el proceso aguas abajo (Fig.(4)). La gestión adecuada de la capacidad de estos tanques no es un problema de fácil solución, sujeto a las restricciones operativas de cada proceso en particular y de la variabilidad del *scheduling* de descarga desde los reactores.

Siendo que el objetivo que se persigue es el de maximizar la productividad del proceso en conjunto, es razonable pensar que una buena gestión de la capacidad del inventario intermedio en el tanque *buffer* consiste

```

1.-  $\aleph := \{\tilde{\chi}_0, \delta(\tilde{\chi}_0, \sigma)\}; step(\tilde{\chi}_0) := 0;$ 
2.-  $step \delta(\tilde{\chi}_0, \sigma) := 1; \forall \sigma \in \Sigma$ 
3.-  $k := 1;$  índice para el recuento de visitas a pares estado de perturbación  $\chi \in \aleph$ 
4.-  $Q_k(\tilde{\chi}, \sigma) := const, \forall \chi \in \aleph, \sigma \in \Sigma$ 

repeat
5.-  $k = k + 1$ 
6.-  $(\tilde{\chi}) := rand(\chi \in \aleph | step(\chi) < N)$ 
7.-  $\sigma := rand(\Sigma)$ 
8.-  $\tilde{\chi}' := \delta(\tilde{\chi}, \sigma)$ 

9.- if  $\tilde{\chi}' \notin \aleph$  then
10.-  $step(\tilde{\chi}') = step(\tilde{\chi}) + 1$ 
11.-  $\aleph := \aleph \cup \tilde{\chi}'$ 
12.-  $Q_k(\tilde{\chi}', \sigma) := const, \forall \chi \in \aleph, \sigma \in \Sigma$ 
end if
12.-  $Q_{k+1}(\tilde{\chi}', \sigma) := Q_k(\tilde{\chi}', \sigma) + \alpha_k [\rho(\tilde{\chi}', \sigma) + \gamma \max_{\sigma' \in \Sigma} [Q_{k-1}(\tilde{\chi}', \sigma') - Q_{k-1}(\tilde{\chi}', \sigma)]]$ 
13.- until  $mod(k, L) = 0$  and  $|Q_k(\tilde{\chi}, \sigma) - Q_{k-L}(\tilde{\chi}, \sigma)| < \epsilon, \forall \chi \in \aleph, \sigma \in \Sigma$ 

 $X_N^Q = \aleph$ 

```

Figura 3. Multi-modal Q -learning control

en brindar un flujo aguas abajo tal que el caudal volumétrico enviado hacia la sección continua sea el máximo posible en todo momento, a la vez que se evita rebalsar o secar el tanque *buffer*.

Pensando el problema desde el punto de vista del control clásico, la variable manipulada sería, por ejemplo, el flujo de salida del tanque *buffer* ($F_{out}(t)$). En este sentido, resulta necesario definir una variable de referencia o *set point*, para lo cual se podría tomar un determinado nivel del tanque como una referencia a seguir, por caso la altura media del tanque. Operado de esta manera, es muy posible que la variable manipulada ($F_{out}(t)$) deba experimentar cambios abruptos teniendo en cuenta la discontinuidad de la descarga de los reactores. A efectos prácticos, esta situación no es deseable debido a que atenta con la productividad y continuidad operativa del conjunto.

En la situación expuesta en este trabajo no se recurrirá a una referencia o *set point* determinado para ninguna de las variables de estado, sino que se enfatizará en la productividad del conjunto evitando eventos inadmisibles como que el tanque *buffer* rebalse o se seque. Concomitante con lo anterior se aspira a variar suavemente el flujo de descarga ($F_{out}(t)$) durante períodos de tiempo considerables y sólo admitiendo

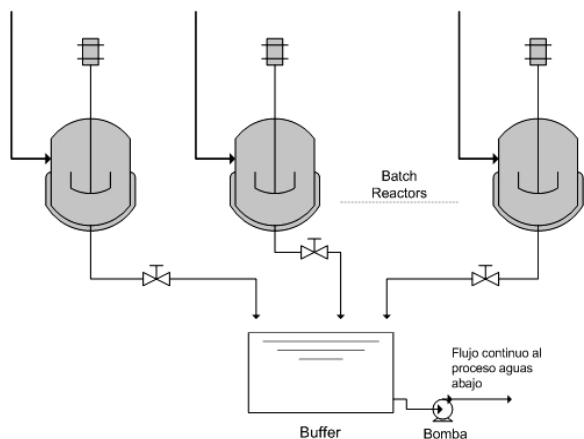


Fig. 4. Buffer tank: interfaz entre las secciones discontinuas y continuas de una planta híbrida

unas pocas variaciones sensibles, de forma de obtener la mayor descarga posible.

En la situación expuesta en este trabajo no se recurrirá a una referencia o *set point* determinado para ninguna de las variables de estado, sino que se enfatizará en la productividad del conjunto evitando eventos inadmisibles como que el tanque buffer rebalse o se seque. Concomitante con lo anterior se aspira a variar suavemente el flujo de descarga ($F_{out}(t)$) durante períodos de tiempo considerables y sólo admitiendo unas pocas variaciones sensibles, de forma de obtener la mayor descarga posible.

La variable manipulada para el control multi-modal será entonces el flujo de salida del buffer tanque ($F_{out}(t)$), cuya magnitud y variación se controla mediante leyes de retroalimentación que deben estar en función de las variables de estado disponibles en el sistema para cada modo de control.

Hasta aquí, con el problema así definido, no se identifican en el sistema variables de estado para los flujos de entrada, que cumplan con la condición de Markov (Sutton y Barto 1998), de tal forma que sea posible aplicar las técnicas de *Q-Learning* antes descriptas.

Con el fin de conseguir variables de estado Markovianas para el flujo total de entrada, se propone una modificación de las condiciones de diseño del sistema buffer (veáse Fig. 5). Esto es, en lugar de utilizar un solo tanque buffer, es posible usar dos tanques en serie, dispuestos de forma que los n reactores descarguen directamente al primero de ellos (de aquí en adelante se llamará como “*tanque suavizador*”) y este descargue directamente al segundo (“*tanque controlado*”), según la ley de Torricelli. De esta manera, se tiene un sistema abierto en el que el que el tanque superior se comporta como un filtro de baja frecuencia generando una salida continua que alimenta al tanque *buffer* inferior. Con esta configuración se consiguen dos variables de estado genuinas que

resumen la información del estado del sistema en todo momento.

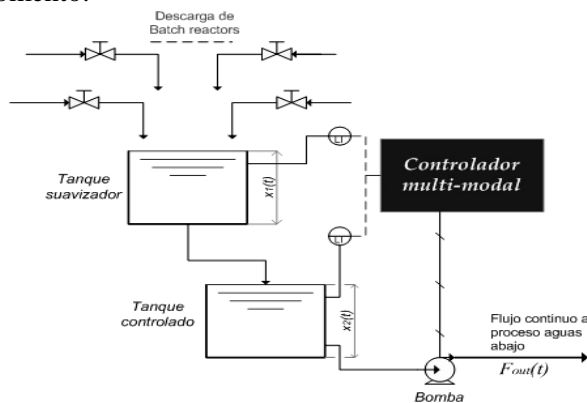


Fig.5. Sistema con dos tanques

La primera de ellas es la altura del tanque suavizador ($x_1(t)$) y la segunda es la altura del tanque controlado ($x_2(t)$). Las variables $x_1(t)$ y $x_2(t)$ son variables de estados markovianas, dado que en su valor presente refleja toda la historia previa reciente. Por otra parte, el estado del tanque suavizador depende sólo del patrón de descarga de los reactores, con lo cual constituyen una adecuada representación del cronograma (*schedule*) de producción. Lógicamente sí el patrón de variación de los flujos cambia, el patrón de variación de $x_1(t)$ también va a cambiar y, consecuentemente, deberá cambiar el control de $x_2(t)$.

En los procesos de producción por lotes (procesos *batch*) los n reactores trabajan respetando un determinado programa de producción (*schedule*), con lo cual el patrón de descarga del conjunto de reactores, está directamente vinculado con la estructura de dicho programa de producción. Así, el flujo de salida del tanque suavizador está directamente relacionado con el patrón de variación del *schedule* de las descargas. Este flujo pasa directamente al tanque controlado, cuya salida ($F_{out}(t)$) será manipulada en función de las variables de estado del sistema para conseguir los objetivos propuestos anteriormente.

La idea de aplicar las técnicas de control multimodal en este caso de estudio, consiste en encontrar una secuencia de modos (π) que permitan cumplir los objetivos mencionados para toda la campaña de producción. Como se explicó anteriormente, los modos se definen mediante una serie de leyes de control (σ_i) y sus respectivas condiciones de terminación (ξ_i). Estas leyes y condiciones de terminación actúan directamente sobre las variables de estado del sistema para manipular la variable de control $F_{out}(t)$.

3.2 Caso particular

Como caso particular para ilustrar cuantitativamente el enfoque propuesto, se considera un sistema constituido por cuatro reactores, los cuales descargan en paralelo a

un suavizador y este al tanque controlado, o *buffer* propiamente dicho.

De esta configuración se pueden tener innumerables patrones de producción. En este caso se analizará uno en particular, pero el mismo análisis puede realizarse de forma similar para otros programas de producción.

Algunas consideraciones a tener en cuenta, antes de aplicar la técnica para obtener el programa de control, son las relacionadas con aspectos técnicos de diseños de los equipos. El tanque al que descargan los reactores debe estar diseñado para drenar según la ley de Torricelli, en donde el flujo de descarga (f) es:

$$f = \gamma\sqrt{h} \quad (3)$$

además dicho tanque deberá tener un volumen suficiente para soportar el patrón de descarga de los reactores, de manera de que no se produzcan desbordes en el suavizador. Para simplificar el problema se asume que los todos los reactores durante su correspondiente fase de descarga, drenan el mismo caudal de forma intermitente según dicta el schedule. En las siguientes sub-secciones se detallarán las características del sistema de dos tanques y seguidamente se proporcionaran detalles de la implementación de la técnica de control multimodal para el schedule de variación de los flujos desde los reactores.

3.2.1 Especificaciones

El tanque suavizador es un recipiente cilíndrico de $1.5m^3$ de volumen y con $1.5m$ de altura útil, que descarga según (3) con $\gamma=1$; en tanto el tanque controlado posee un volumen de $1m^3$ con una altura máxima de $1.0m$.

Las leyes de control en los distintos modos se definen con las metas parciales de aumentar (acumular) o disminuir (drenar) la altura promedio del tanque controlado. Las condiciones de parada comunes a todos los modos consisten en detenerlos cuando se exceda el nivel máximo del tanque controlado (H_2) o cuando se llegue a un nivel cercano a cero, es decir cuando se rebalsa o se seca el buffer. Para el caso de los modos cuya meta parcial sea lograr una tendencia creciente de la evolución de la altura promedio, la condición de parada del modo se corresponde en detener cuando la imposibilidad práctica de incrementar o disminuir la altura promedio indica la futilidad de continuar la ejecución. A modo de ejemplo, para los modos cuyo objetivo es lograr un decrecimiento en la tendencia de evolución de la altura del tanque, los mismos se detendrán cuando la tendencia de dicha evolución sea creciente. Para lograr un comportamiento suave de $F_{out}(t)$, las leyes de control actúan sobre un valor suavizado de la altura instantánea del tanque controlado, de acuerdo al conocido criterio de ajuste exponencial, con un coeficiente de ajuste $\alpha=0.01$.

3.2.2 Aplicación del algoritmo

En primer lugar se define un estado inicial x_0 a un tiempo t_0 , en el cual se empiezan a aplicar las acciones de control. Dicho estado se puede establecer arbitrariamente como el par $(x_1(t_0), x_2(t_0))$, para el cual $x_2(t_0)$ alcanza un cierto porcentaje de la altura máxima del tanque inferior, en este ejemplo se establece en un 20% de H_2 . Tanto para los modos cuya meta es lograr una tendencia positiva en la evolución de la altura como para los que tienen como meta una evolución con tendencia decreciente, las leyes de control siguen la forma indicada en la Fig. 6.

Los modos 1 y 3 se comportan según la ley de la recta sólida, en tanto que los modos 2 y 4 lo hacen según la recta de trazos. En todos los casos los modos se detienen cuando se seca el tanque controlado o cuando el nivel de líquido excede su altura máxima posible (H_2), esto es $\xi_i=0 \Rightarrow \xi_i=1$ sí $h_2(t) \leq \epsilon$ ó $h_2(t) \geq H_2$. Por otra parte los modos 1 y 2 tienen el objetivo de generar un incremento en la altura del tanque controlado. Para simplificar el ejemplo, dicha tendencia se vincula directamente con la pendiente de la recta de ajuste lineal de los últimos cinco valores de altura suavizada, interrumpiendo la ejecución del modo cuando la misma es negativa. Análogamente, los modos 2 y 4 se detienen cuando el valor de la pendiente de la recta de ajuste sea positivo.

Las formas de las leyes han sido definidas para responder a rangos de especificación del proceso por un lado, y por el otro variar suavemente el flujo de salida del tanque inferior.

En línea con el objetivo planteado, la función de *rewards* se define como el volumen descargado durante la aplicación del modo, siempre y cuando no se seque ni rebalse el tanque. En este último caso al *reward* se le asigna un valor negativo de -5 . De esta forma resulta:

$$r = \int_t^{t+\tau} F_{out}(t) dt \Leftrightarrow x_2(t) < H_2 \wedge x_2(t) > 0$$

$$r = -5 \Leftrightarrow x_2(t) \geq H_2 \vee x_2(t) \leq \epsilon \quad (6)$$




Figura 6. Leyes de retroalimentación

Otra cuestión a definir respecto al punto 9 del algoritmo definido en la sección 2, es el criterio de “similitud” entre los estados visitados, para determinar si un estado pertenece o no al espacio de estados explorado hasta el momento cuando se utiliza el algoritmo de la Fig. 3. En este trabajo se acepta que un estado s_t pertenece al espacio de estados previamente visitados (\mathcal{N}) si se cumple que con referencia a uno cualquiera s_i de los estados previamente visitados el estado s_t dista menos de una cierta fracción (ρ) de la altura total del tanque controlado H_2 , esto es cuando se satisface:

$$s_t \in \mathcal{N} \Leftrightarrow \exists s_i / \|s_t - s_i\| \leq \rho \cdot \|H_2\| \tag{7}$$

En el estudio realizado, la fracción ρ se fijó en un valor de 0.05.

3.3 Resultados

El ejemplo analizado es de un programa de producción intermitente, para diez batches consecutivos de cada uno de los cuatro reactores. Se analizarán los resultados de controlar el sistema durante los primeros tres mil minutos aproximadamente, dado que constituye la parte más representativa en relación con el schedule de producción. El patrón del flujo de descarga del tanque suavizador, resultante de un dado schedule de producción, es el que se representa en la Fig.7.

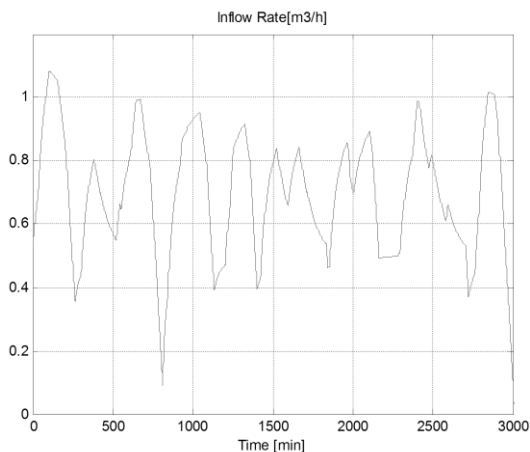


Figura 7. Flujo de carga al tanque controlado

El programa de control π resultante, genera una variación de la altura del tanque como el que se indica en la Fig.8. La descarga aguas abajo del tanque controlado sigue la evolución indicada en la Fig.9, la cual está directamente vinculada con la secuencia de modos (Fig. 10) y la variación de la altura $x_2(t)$ indicada en la Fig.8. Finalmente la secuencia de modos encontrada sigue el comportamiento representado en la Fig.10. Es para destacar que, según se observa en Fig.8, el sistema trata en todo momento de elegir los modos que generan una mayor salida aguas abajo del proceso.

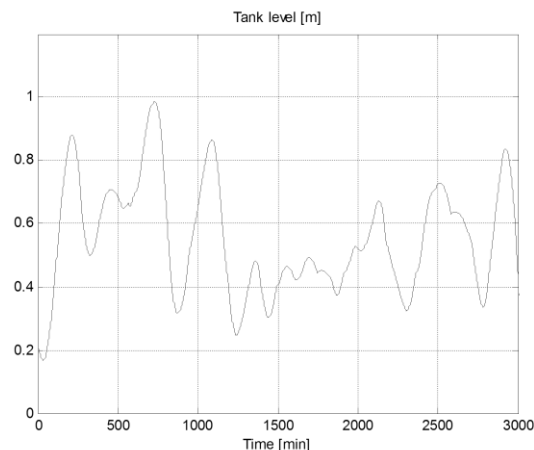


Figura 8. Evolución de la altura en el tanque controlado




Figura 9. Flujo de descarga aguas abajo




Figura 10. Secuencia óptima de modos

5 CONCLUSIONES

Como puede observarse en las gráficas anteriores, la cuestión más importante a resaltar de la aplicación del control multimodal surge al comparar la variación del flujo de entrada al tanque controlado (Fig.7.) con la variación en la descarga del mismo (Fig.9.). Se puede apreciar que uno de los objetivos planteados se cumple satisfactoriamente: la salida promedio se mantiene

elevada a la par que se evitan que los cambios bruscos a la entrada del tanque controlado se trasladen directamente a la salida del mismo. Si bien se observan variaciones en el caudal de descarga, ésta se comporta de manera suave durante períodos prolongados de tiempo y la frecuencia y magnitud de los cambios de caudal de descarga es baja.

6 REFERENCIAS

- Astrom, K J, y B M Bernhardsson. 2002. «Comparison of Riemann and Lebesgue sampling for first order stochastic systems» 2: 2011–2016.
- Barton, Paul I., Cha Kun Lee, y Mehmet Yunt. 2006. «Optimization of hybrid systems». *Computers & Chemical Engineering* 30 (10–12) (septiembre 12): 1576-1589. doi:10.1016/j.compchemeng.2006.05.024.
- Engell, S., S. Kowalewski, C. Schulz, y O. Stursberg. 2000. «Continuous-discrete Interactions in Chemical Processing Plants». *Proceedings of the IEEE* 88 (7) (julio): 1050-1068. doi:10.1109/5.871308.
- Geist, Stephanie, Dmitry Gromov, y Jörg Raisch. 2008. «Timed discrete event control of parallel production lines with continuous outputs». *Discrete Event Dynamic Systems* 18 (2) (junio): 241–262. doi:10.1007/s10626-007-0023-2.
- Mehta, Tejas, y Magnus Egerstedt. 2005. «Learning multi-modal control programs». En *Hybrid Systems: Computation and Control*, editado por Manfred Morari y Lothar Thiele, 3414:466-479. *Lecture Notes in Computer Science*. Springer Berlin / Heidelberg. <http://www.springerlink.com/content/0cyrb83baea182kj/abstract/>.
- Mehta, Tejas R., y Magnus Egerstedt. 2008. «Multi-modal control using adaptive motion description languages». *Automatica* 44 (7) (julio): 1912-1917. doi:10.1016/j.automatica.2007.11.024.
- Peirce, R, y S Crisafulli. 1999. «Surge tank control in a cane raw sugar factory». *Journal of Process Control* (9): 33-39.
- Simeonova, Ilyana. 2008. «On-line periodic scheduling of hybrid chemical plants with parallel production lines and shared resources». Belgium: Université catholique de Louvain.
- Sutton, Richard S., y Andrew G. Barto. 1998. *Reinforcement learning: An introduction*. MIT Press.