

Estimación no lineal adaptativa con tolerancia a fallos: aplicación a la destilación por lotes

Fault tolerant adaptive estimation of nonlinear processes: a case study of batch distillation

Miranda, Moira^{1*}; Edelmayer, Andrés²

¹ Departamento de Operaciones Unitarias, Escuela de Ingeniería Química,
Facultad de Ingeniería, Universidad de Los Andes.
Mérida 5101, Venezuela.

² Systems and Control Laboratory, Computer and Automation Research Institute
Hungarian Academy of Sciences, H-1111, Budapest, XI, Kende u. 13-17. Hungary.

*moira@ula.ve

Resumen

En este trabajo se presenta un enfoque robusto para la estimación de estado de un proceso no lineal mediante una combinación del filtro de Kalman extendido y detección de fallos con reconfiguración del filtro. Por un lado, el filtro es diseñado robusto de cara a la incertidumbre de la medida usando filtrado adaptativo. Con este fin, el filtro identifica la covarianza del ruido de medición por medio de la estimación recursiva, suprimiendo el efecto de variaciones esporádicas en la calidad de las mediciones así como compensando fallos incipientes en los sensores. Por otro lado, la supervisión de fallos se aplica continuamente a la innovación del filtro, en un intento de re-iniciar la configuración del filtro cuando el mecanismo de adaptación no sea capaz por sí solo de superar la situación de fallo. La discusión de los resultados se enmarcan en la estimación de estado de un proceso de destilación por lotes.

Palabras clave: Filtro de Kalman adaptativo, tolerancia a fallos, destilación por lote.

Abstract

This paper presents a dual layer approach for robust fault tolerant estimation of nonlinear processes using a combined adaptive extended Kalman filter and fault detection and filter reconfiguration. From the one hand, the filter is made robust in face of environment uncertainty using adaptive filtering. To this end, the filter identifies the measurement covariance by means of recursive estimation, upon which the adaptation relies, to suppress the effect of sporadic variations in the quality of measurements as well as compensates for incipient sensor faults. From the other hand, fault monitoring is continuously applied to the filter's innovation in an attempt to initiate filter reconfiguration when the adaptation mechanism alone is not able to overcome the failure situation. The discussion of the results is embedded in the application framework of state estimation of a batch distillation process.

Key words: Adaptive Kalman filter, sensor fault tolerance, batch distillation.

1 Introducción

En las últimas décadas, un gran número de trabajos se han dedicado a las técnicas de estimación de estado y parámetros en sistemas dinámicos lineales y no lineales. Cuando se selecciona un método de estimación, para la solución de un problema específico, es necesario considerar al menos dos características del sistema dinámico: a) la incertidumbre del modelado y b) la naturaleza de las perturbaciones a la

cual el sistema será sometido. En la mayoría de los casos estas características pueden determinar si la formulación del problema de estimación será lineal o no-lineal, determinístico o estocástico. El filtro lineal de Kalman (KF) es un método ampliamente utilizado en sistemas lineales, cuando la incertidumbre de la modelización pueda ser omitida y las perturbaciones del sistema puedan ser modeladas como un proceso aleatorio gaussiano. Cuando el sistema no es lineal, el filtro correspondiente se obtiene de la extensión de la solución lineal del filtro de Kalman, resultando en la formula-

ción del filtro de Kalman extendido (EKF) (Gelb y col., 1974, Maybeck 1982). A pesar de su rendimiento variable, el EKF es considerado el estándar de facto en la teoría de la estimación de estado no lineal. Entre sus áreas de aplicación se encuentran el control de procesos, robótica, sistemas de navegación y GPS (Sorenson 1985, Julier y col., 2001, Edelmayer y col., 2010). Sin embargo, en algunos casos la solución del EKF no es aceptable. Una de las limitaciones conocidas del tradicional EKF es la linealización del modelo de manera que el tradicional KF pueda ser aplicado. La linealización se realiza aplicando desarrollos en serie de Taylor en los estimados previamente obtenidos en cada etapa. Este enfoque es problemático, no sólo porque las aproximaciones pueden introducir grandes errores e incluso causar la inestabilidad del filtro, sino que además, el filtro no considera que potencialmente los problemas de estabilidad pueden ocurrir cuando las covarianzas del ruido se incrementan o cambian comparadas con la dinámica del sistema.

En la última década han habido algunas innovaciones del EKF. El filtro de partículas (SLP) puede manejar distribuciones multimodales y no linealidades reportando en general mejor rendimiento que el EKF, pero su implementación es mucho más compleja, y como tal, no existe la posibilidad de ser utilizados en aplicaciones con sistemas embebidos. El filtro de Kalman Unscented (UKF) se basa en la idea de un muestreo determinista, proporcionando un equilibrio entre el esfuerzo computacional bajo del EKF y el rendimiento alto del SLP. (Julier y col., 1995).

En Miranda y col. (2010) se comparan los rendimientos del EKF y el UKF. Los experimentos demostraron convincentemente que el UKF puede tener éxito en deshacerse de la degradación del rendimiento causado por la linealización y, como tal, puede ser un método prometedor para resolver los problemas de estabilidad atribuibles al cómputo de las derivadas y a la variación de la medición. Por el contrario, la robustez del filtro UKF con respecto al EKF por cambios en las condiciones iniciales y variación del ruido no pudo ser justificada.

En la búsqueda de soluciones a este último problema, un filtro EKF es desarrollado basándose en una política de adaptación, de manera de obtener robustez en los cambios estadísticos del ruido y ocasionalmente a las interrupciones de las señales de medición. La idea del enfoque adaptativo es evaluado en un proceso de destilación por lotes, con data experimental de una planta piloto. Se ve como la instrumentación específica de la columna, como múltiples sensores de medición de temperaturas, junto con la aplicación de filtrado adaptativo, permite más allá de mejorar el rendimiento y precisión de la estimación, mejorar potencialmente la tolerancia a fallos.

La idea básica del enfoque adoptado es la de estimar de forma adaptativa la covarianza de ruido de medición a partir de los residuos del filtro y usar la innovación para la detección de fallo de sensores. Entonces, basado en la decisión de la existencia de un fallo, la reconfiguración del filtro es iniciada en un intento de restablecer las condiciones norma-

les de funcionamiento del filtro. De hecho, el desarrollo de este enfoque operacional con tolerancia a fallos de dos niveles, es la principal contribución de este trabajo.

2 Estimador de estado

El control de una columna de destilación por lotes requiere del conocimiento de las composiciones de los productos durante toda la duración del proceso (Kim y col., 1999). Algunos de estos sistemas, por ejemplo, son controlados utilizando modelos de control predictivo que requieren de la disponibilidad de datos precisos obtenidos de la estimación de estado. Una forma de obtener la información de las composiciones es por medio del uso de analizadores en línea, aunque son muy exactos, son instrumentos costosos, muy lentos e inclusive inexistentes en el mercado. La alternativa más popular para controlar la composición es la utilización de controladores de temperatura estándar de retroalimentación. Sin embargo, las mediciones de temperatura no son indicadores precisos de la variación de la composición (Mejdell y col., 1991). Otra alternativa es el uso de un algoritmo de estimador de estado el cual utiliza algunas variables del proceso, conjuntamente con un modelo simplificado del mismo, para estimar las variables que directamente no son observables o el estado completo del proceso (Oisiovi y col., 2000, Venkateswarlu y col., 2001).

2.1 Filtro de Kalman Extendido

El filtro de Kalman extendido es uno de los algoritmos más usados para determinar el estado de un sistema dinámico no lineal. La teoría detrás del EKF ha sido bien establecida y sus aplicaciones en la industria han aumentado significativamente (Oisiovi y col., 2001), por lo tanto, únicamente un resumen de las ecuaciones más relevante serán provistas en este trabajo. El estimador de estado es formulado como:

$$\dot{x}_{i+1} = g_i(x_i, u_i) + w_i \quad (1)$$

$$\varphi_i = h(x_i) + v_i, \quad (2)$$

donde $x \in \mathbb{R}^n$, $u \in \mathbb{R}^m$, $\varphi \in \mathbb{R}^p$, denotan los vectores de estado, entrada y salida del sistema, $w(t)$ y $v(t)$, son ruidos que afectan al sistema y a la medición, y se asumen que tienen una distribución gaussiana con media cero y matriz de covarianza Q y R , respectivamente.

El EKF predice el siguiente estado del sistema (\hat{x}), basándose en la información disponible del modelo dinámico y la matriz de covarianza esperada P . El filtro es inicializado con $x_{o/o} = x_o$ y $P_{o/o} = P_o$ y opera recursivamente entre un proceso de predicción y corrección. En el proceso de predicción se genera un pronóstico del estado hacia adelante en el tiempo, tomando en cuenta toda la información disponible en ese momento. En el proceso de corrección el estado

estimado es mejorado, de manera de minimizar el error estadísticamente de acuerdo a las ecuaciones (3) y (4),

$$\hat{x}_{k/k} = \hat{x}_{k/k-1} + K_k [\varphi_k - h(\hat{x}_{k/k-1})] \quad (3)$$

$$K_k = P_{k/k-1} \bar{H}_k^T (\bar{H}_k P_{k/k-1} \bar{H}_k^T + R_k)^{-1} \quad (4)$$

donde \bar{H}_k^T es la matrix Jacobiana de las derivadas parciales de $h(x)$ con respecto a x y K es la matrix de ganancia de Kalman. La matrix de covarianza es actualizada de acuerdo a la ecuación 5,

$$P_{k/k} = (I - K_k \bar{H}) P_{k/k-1} \quad (5)$$

2.2 Modelo de la columna y validación

El proceso bajo consideración es una columna de destilación por lotes experimental, modelo CE600 de la compañía alemana GUNT, para mayor detalle (Miranda y col. 2011), que consta de 10 etapas de equilibrio, es decir, 8 platos, un condensador total y un hervidor, donde se lleva a cabo una separación de una mezcla de 30% en peso de etanol y agua. La columna tiene sensores que permiten registrar las temperaturas en cada etapa a diferentes intervalos de tiempo.

En la literatura se han reportado muchos modelos rigurosos para columnas de destilación por lotes (Mujtaba 2004). Estos modelos consisten básicamente en un gran número de ecuaciones diferenciales y algebraicas no lineales, que describen la variación de la composición a lo largo de las etapas individuales de la columna, basados en el balance de materia y energía, termodinámica, hidráulica del plato, etc. Los modelos rigurosos son herramientas indispensables para el análisis, sin embargo, son demasiados complicados para el controlador y filtro debido a la complejidad y costo computacional de la implementación. Por lo tanto, el diseño del filtro requiere una representación más simple, que todavía capture las partes esenciales de la dinámica del proceso. Aunque un modelo riguroso similar al publicado en (Mujtaba 2004), fue utilizado para fines de validación, una simple representación de (1) de la mezcla binaria fue desarrollado para el filtro bajo los supuestos de: a) flujo equimolar de líquido y vapor ($L_j = L$ para $i \leq j \leq n$ y $V = V_j$ para $2 \leq j \leq n$) b) etapas teóricas c) presión constante y d) retención de vapor despreciable.

Las variables de estado son las fracciones molares del líquido en cada etapa x_i . Para un sistema de n_c componentes la $\sum_i^{n_c} x_i = 1$, por lo tanto, es suficiente considerar $n_c - 1$ variables de estado en cada etapa, porque la fracción molar del n_c^{th} componentes puede ser obtenida por simple substracción.

El proceso está controlado por la razón de reflujo interna, la cual está definida como se muestra en la ecuación (6).

$$u = R = \left[\frac{L}{V} \right], \quad (6)$$

El reflujo (u) es mantenido constante en una relación de 3. Entonces, el modelo no lineal de la columna de destilación por lotes en su representación en espacio de estado con $x \in R^n$ y $n_c = 2$, sujeto a ruido, es como se indica en la ecuación (7)

$$\begin{bmatrix} \dot{x}_1 \\ \vdots \\ \dot{x}_j \\ \vdots \\ \dot{x}_n \end{bmatrix} = \begin{bmatrix} \frac{V}{M_1}(y_2 - x_1) \\ \vdots \\ \frac{V}{M_j}(y_{j+1} - y_j) + \frac{RV}{M_j}(x_{j-1} - x_j) \\ \vdots \\ \frac{RV}{M_n}(x_{n-1} - x_n) + \frac{V}{M_n}(y_n - x_n) \end{bmatrix} + \begin{bmatrix} w_1 \\ \vdots \\ w_j \\ \vdots \\ w_n \end{bmatrix}, \quad (7)$$

donde, x_i y y_i , denotan la fracción molar del componente c_i , en los flujos de líquido y vapor, respectivamente, que abandonan la etapa j . La etapa 1, corresponde al producto destilado que se obtiene de la columna. El sistema no es directamente observable. Las variables observables del proceso son las temperaturas en cada etapa ($\varphi_j = T_i$). El sistema de mediciones es modelado como una función del vector de estado $h(x)$ corrompida por ruido, representado por la ecuación (8)

$$T = h(x) + v \quad (8)$$

La relación no lineal $h(x)$ entre la temperatura y la fracción molar puede ser obtenida de las ecuaciones del equilibrio líquido-vapor (Perry 1997). Puesto que la presión del sistema y las estimaciones de las fracciones molares son conocidas, para cada etapa se calcula la temperatura de burbuja (temperatura a la cual la suma de las composiciones de la fase vapor es igual a la unidad). La fracción de vapor y_i es calculada a través de la ley de Raoult modificada según la ecuación (9)

$$y_j = \gamma_j x_j p_j^v / p, \quad (9)$$

donde γ_j es el coeficiente de actividad calculado por la ecuación de Wilson, y p es la presión de la columna. La presión de vapor p_i^v es modelada por la ecuación de Antoine (Perry 1997). La precisión del modelo simplificado del proceso (7) fue validado contra un modelo riguroso, el cual a su vez fue validado con datos obtenidos de la columna de destilación experimental (Miranda 2011). La figura 1 muestra la variación de las fracciones molares del flujo de líquido en las diferentes etapas de la columna, para el modelo

riguroso y el modelo simplificado.

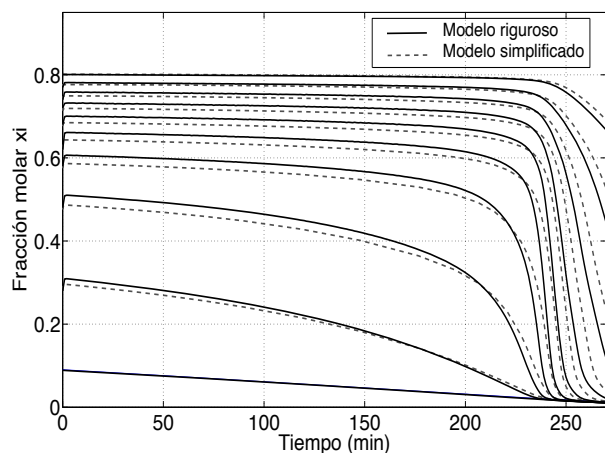


Fig. 1. Composición molar en las diferentes etapas de la columna.

Con el fin de diseñar el filtro es necesario que el sistema sea observable. Se sabe que un proceso de destilación con n componentes es considerado observable si al menos n mediciones de temperatura a lo largo de la columna están disponibles para la síntesis del filtro (Yu y col., 1987). En este trabajo se utilizan dos mediciones de las diez mediciones de temperatura disponibles para el desarrollo del filtro.

3 Propuesta de un filtro con tolerancia a fallos

El filtro con tolerancia a fallos de este trabajo se aproxima a un enfoque de dos niveles, lo que significa que a) se desarrolló un filtro robusto capaz de compensar las excesivas variaciones de las señales de entrada, por medio de la estimación recursiva de la covarianza del ruido. Para este efecto en tiempo real la ganancia del filtro es corregida, basada en las características actuales del ruido, suprimiendo el efecto de las variaciones esporádicas en la calidad de las mediciones, como también compensando fallas incipientes de los sensores. b) La supervisión de fallos se aplica continuamente a la innovación del filtro, en un intento de iniciar una acción de reconfiguración del filtro cuando la adaptación por sí sola no sea capaz de superar la situación de fallo.

3.1 Estimación de la covarianza del ruido

La idea de utilizar un filtro de Kalman extendido adaptativo (AEKF), para aumentar la precisión de la estimación, la robustez frente a los errores de modelado del sistema y manejar las variaciones del ruido a través de la estimación en tiempo real de la covarianza no es nueva. En últimos años diferentes esquemas de adaptación han sido desarrollados. Un enfoque clásico lo presentó (Mehra 1970) conocido como la estimación máxima de la probabilidad (MLE) y se ha utilizado en diversas aplicaciones.

El método adoptado en este trabajo se basa en la evaluación secuencial de residuos $r_k = \varphi_k - h_k(\hat{x}_{k/k-1})$ que pueden ser obtenidos en forma directa de la ecuación 3. Una de las dificultades del enfoque residual es que la matriz R debe ser definida positiva. Un método para garantizar esto es mediante la aplicación de la condición presentada en (Wang 2000), donde el valor estimado de la covarianza en tiempo real es calculado como $\hat{R}_k = \hat{C}_v + H_k \hat{P}_k H_k^T$ y la varianza estimada de la covarianza residual en un horizonte deslizante de longitud m es calculada con la ecuación 10.

$$\hat{C}_v = \frac{1}{m} \sum_{k=1}^m r_{k-i} r_{k-i}^T \quad (10)$$

Entonces, el valor estimado de R es usado en la actualización de la medición, al tiempo $k + 1$, adaptando la ganancia del filtro K de acuerdo a las variaciones del ruido.

3.2 Detección de fallo y reconfiguración del filtro

La idea de la tolerancia a fallo se fundamenta en la detección de un comportamiento anormal de una señal y la selección adecuada de las señales de medición. En el caso particular que una medición sea defectuosa y el fallo sea detectado, la señal del sensor defectuoso se sustituye en tiempo real por una nueva señal de otro sensor, en un intento de restablecer instantáneamente la operación del filtro todavía no afectada.

La detección de fallos se realiza a partir de la innovación del filtro de Kalman definida por la ecuación (11)

$$\rho_k = \varphi_k - h(\hat{x}_{k/k-1}). \quad (11)$$

La innovación debe tener un comportamiento gaussiano si la condición de ruido blanco de la medición es razonablemente cierta. Para la detección de un comportamiento anormal, se utiliza la innovación cuadrática normalizada (NIS) definida a partir de la innovación como

$$\psi = \rho_k^T S_k^{-1} \rho_k. \quad (12)$$

En la ecuación (12) la matriz de covarianza de la innovación es calculada usando la ecuación (13)

$$S_k = H_k P_{k/k-1} K_k^T + R \quad (13)$$

La NIS sigue una distribución chi-cuadrado χ^2 . Por lo tanto, si ψ se encuentra fuera del umbral de aceptación que el test χ^2 proporciona, es una indicación que existe una falla en el sistema de medición. Con el fin de minimizar la detección de falsas alarmas, a causa de un simple valor extremo en los datos de medición, el test es realizado a lo lar-

go de un horizonte deslizante a los valores calculados por la ecuación (12), resultando en

$$J_k = \sum_{i=k-l}^k \frac{\psi_i}{\omega}, \text{ con } l = \omega - 1, \quad (14)$$

donde ω es la longitud del horizonte deslizante. Entonces, el índice estadístico J_k se utiliza como un recurso para activar la reconfiguración del filtro, es decir, decidir si la configuración del filtro actual aplicada durante el po k debe ser usada posteriormente por el tiempo $k + 1$ o una configuración alternativa del filtro debe ser obtenida a través de la sustitución de la medición errónea.

Durante la sustitución de la medición, la información del filtro del estado actual y la covarianza del tiempo anterior es remitida a la nueva configuración del filtro, como se muestra en la figura 2. Para el reemplazo de la medición, un algoritmo de selección de 2 de N mediciones es aplicado, como es comprensible, es preferible optar por la señal vecina del conjunto de medidas disponibles.




Fig. 2. Esquema de dos niveles de tolerancia a fallos basado en (i) ajuste de adaptación de la ganancia del filtro y (ii) la detección de fallos del sensor y reconfiguración del filtro

4 Resultados y discusión

Con el fin de simular el comportamiento del proceso el modelo riguroso de la columna por lotes fue empleado. En cada periodo de tiempo, las temperaturas de las etapas 5 y 7, fueron utilizadas como entradas al filtro. Todas las simulaciones fueran hechas en el ambiente de programación MATLAB. En este trabajo los resultados de tres soluciones diferentes de filtrado son reportadas: i) el EKF, ii) el AEKF iii) el filtro de Kalman extendido adaptativo con tolerancia a fallos (AREKF), en respuesta a dos escenarios típicos con fallos en el sensor de temperatura de la etapa 5. En el primer escenario se estudia, el efecto del aumento del ruido en el sensor e incipiente fallo. Para este fin, un aumento moderado de la covarianza del ruido fue aplicado a la señal de entrada del filtro en el momento que la simulación alcanzaba el minuto 120 (figura 3a). En el segundo escenario otro fallo típico en los sensores representado por la figura 3b, se estudio, afectando la señal del sensor por una función escalón a

partir del minuto 170 de la simulación, permaneciendo constante con ruido gaussiano (figura 3b).





Fig.3. Mediciones de temperatura del filtro sujetas a ruido y fallos: a) Con falla en el sensor 5 a partir del minuto 120 b) Con falla tipo escalón en el sensor 5, a partir del minuto 170.

Líneas de trazos temperaturas de referencia

En la figura 4a y 4b se muestra el índice estadístico J , para las tres configuraciones del filtro en ambos escenarios. Se puede ver como el índice J aumenta para todas las configuraciones una vez ocurrida la falla (minuto 120 y minuto 170). El filtro AREKF detecta el fallo del sensor 5 y se reconfigura cambiando la señal del sensor utilizada al sensor 4, volviendo el índice al umbral de aceptación. (Índice J menor a 5). En la figura 5 se presentan los resultados de las simulaciones que comparan las características de funcionamiento de las tres soluciones de filtrado para la estimación de las fracciones molares de tres etapas de la columna, siendo el producto destilado la etapa 1. Se puede ver como la precisión de la estimación varía de acuerdo al enfoque de filtrado para cada escenario. Mientras que la esti-

mación con el EKF, casi inmediatamente después del momento del fallo del filtro, no puede seguir el estado real, el AEKF es capaz de compensar el efecto relativamente bien y el AREKF permanece casi invariante a las alteraciones introducidas.

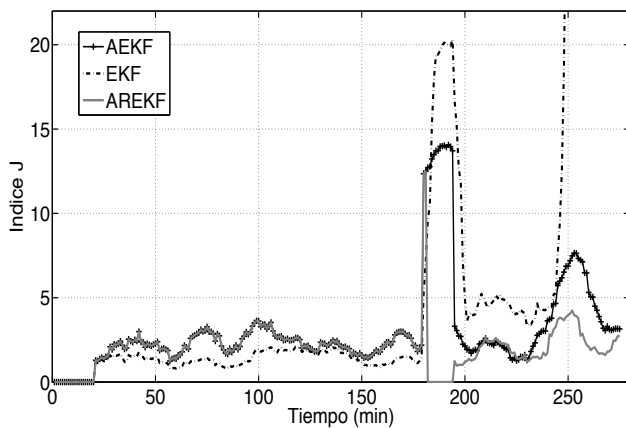
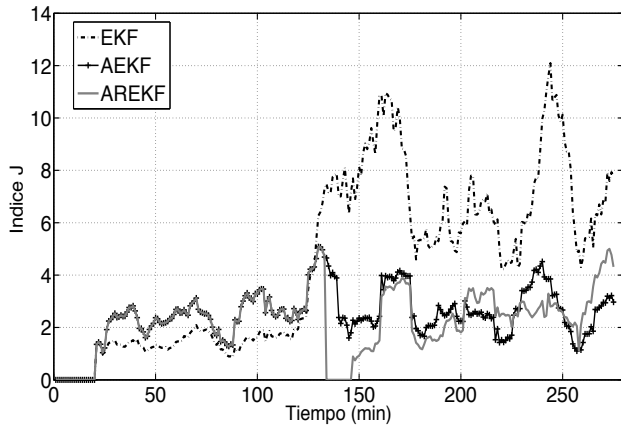


Fig.4. Índice estadístico J para las tres configuraciones del filtro a) Falla al minuto 120 b) Falla al minuto 170

La tabla 1 reporta el error porcentual medio absoluto (EPMA) de las pruebas realizadas para los diferentes escenarios, de manera de cuantificar el desempeño de los estimadores, corroborando los resultados de la figura 5.

Tabla 1. EPMA en la estimación de la composición

Escenario 1			
Etapa	EKF	AEKF	AREKF
1	0.593	0.301	0.153
2	1.756	1.003	0.590
3	4.620	2.860	1.186
Escenario 2			
Etapa	EKF	AEKF	AREKF
1	0.458	0.330	0.165
2	1.330	1.007	0.594
3	2.427	1.923	1.223

En la tabla 1 se observa que el error de estimación de la fracción molar utilizando el AREKF, para el producto de destilado (etapa 1), es aproximadamente 70% menor que el error reportado por el EKF para el escenario 1 y 60% menor para el escenario 2.

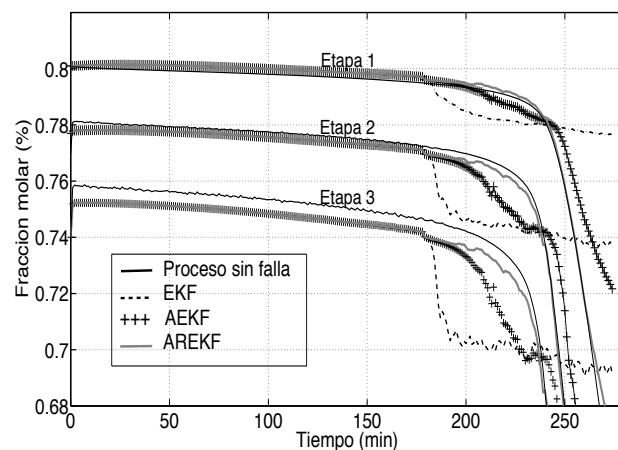
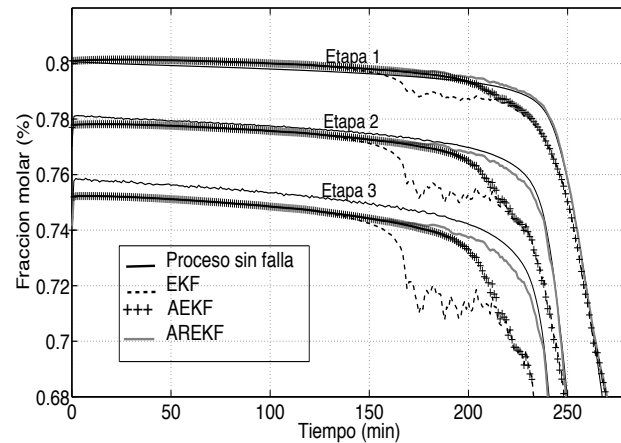


Fig.5. Estimación de las fracciones molares para las tres configuraciones del filtro a) Falla aumento de la varianza del ruido b) Falla escalón

5 Conclusiones

En este trabajo se ha presentado un enfoque de dos niveles de estimación robusta tolerante a fallos para procesos no lineales. La implementación y rendimiento de la solución estándar de EKF en comparación con el EKF adaptativo y con el EKF adaptativo con mecanismo de tolerancia a fallos fueron comparados. Los algoritmos de filtrado fueron usados para la estimación de estado de una columna de destilación por lotes a partir de datos reales de la columna. Los resultados confirman que el EKF adaptativo es capaz de incrementar la robustez del filtro contra variaciones en la señal de medición y el AREKF ampliado con el mecanismo de reconfiguración a fallo, mejorar de manera significativa la precisión de la estimación.

Referencias

Edelmayer A, Miranda M, Nebehaj V, 2010, A cooperative federated filtering approach for enhanced position estimation and sensor fault tolerance in ad-hoc vehicle networks, *IET Intell. Transp. Syst*, Vol 4(1) pp. 82–92.

Gelb A, Kasper J, Nash R, Price F, Sutherland A, 1974, *Applied optimal estimation*. MIT Press, MA.

Julier S, Uhlmann J, Durrant-Whyte H, 1995, A new approach for filtering nonlinear systems, In: *Proc. IEEE American Control Conference, ACC'95*, pp. 1628–1632.

Julier S, Uhlmann J, 2001, A counter example for the theory of simultaneous localization and map building, In: *Proc. of the IEEE Conf. on Robotics and Automation*, pp. 4238–4243.

Kim J, Ju D, 1999, Shortcut procedure for multicomponent batch distillation with distillate receiver, *Industrial & Engineering Chemistry Research*, 38, pp. 1024–1031.

Maybeck, 1982, *Stochastic Models, Estimation and Control*, Vol. 2, Academic Press, New York.

Mehra R, 1970, On the identification of variance and adaptive Kalman filtering, *IEEE Trans. Aut. Cont.*, 15(2) pp. 175–184.

Mejdell T, Skogestad S, 1991, Estimation of distillation compositions from multiple temperature measurements using partial-least-squares regression, *Industrial & Engineering Chemistry Research*, 30(12) pp. 2543–2555

Miranda M, Edelmayer A, Encinoza A, 2011, Case study of unscented state estimation for batch distillation processes, in *Proc. IEEE Int. Conf. Cont., ICCA'11*, pp. 919–924.

Mujtaba I, 2004, *Batch Distillation: Design and Operation*, Series on Chemical Engineering, Vol. 3, Imperial College Press, London, pp 57-73.

Oisiović R, Cruz S, 2000, State estimation of batch distillation columns using an extended Kalman filter, *Chemical Engineering Science*, 55 pp. 4667–4680.

Oisiović R, Cruz S, 2001, Inferential control of high-purity multi-component batch distillation columns using an extended Kalman filter, *Industrial & Engineering Chemistry Research*, 40, pp. 2628–2639.

Sorenson H, 1985, *Kalman Filtering: Theory and Application*, IEEE Press, NY.

Venkateswarlu C, Avantika S, 2001, Optimal state estimation of multicomponent batch distillation. *Chemical Engineering Science*, 56, pp. 5771–5786.

Perry R, Green D, 1997, *Perry's Chemical Engineer's Handbook*, Ed. McGraw-Hill, United State of America, pp. 2-345

Wang J, 2000, Stochastic modeling for real-time kinematic GPS/GLONASS positioning, *Navigation*, 46(4) pp. 297–305.

Yu C, Luyben W, 1987, Control of multicomponent distillation columns using rigorous composition estimators, *Int. Chem. Eng. Symp. Series*, 104, pp. 29-69.

Recibido: 17 de diciembre de 2013

Revisado: 15 de marzo de 2014

Miranda, Moira: *Profesor Asociado de la Escuela de Ingeniería Química (ULA). Ingeniero Químico (ULA, 1998). Magister Scientiae en Ingeniería de Control y Automatización". (ULA, 2001). Doctor en Ingeniería de Procesos de la Universidad de Pau (Francia, 2005).*

Edelmayer, András: *Investigador del MTA SZTAKI (Hungria), Profesor de la Universidad de Széchenyi, (Győr, Hungria). PhD. Ingeniería Eléctrica (1994), Doctor de la Academia de Ciencias de Hungria (2007). Correo electrónico: edelmayer@sztaki.hu*

