

# Filtro de Kalman Federado con fusión adaptativa: Aplicación a la destilación por lotes

Moira Miranda, Darlene Echeverria  
Universidad de Los Andes. Facultad de Ingeniería.  
Mérida, 5101. Venezuela.  
[moira@ula.ve](mailto:moira@ula.ve)  
Telef: (58)2742402961

**Resumen**— Este artículo discute la aplicación de la idea de Filtro Federado con factor de intercambio de información adaptativo para la estimación de estado de una columna de destilación por lotes, su impacto en la tolerancia a fallos y rendimiento en el filtrado. En concreto, el desempeño de las tradicionales soluciones centralizadas es comparado con la estructura del filtro Federado, y su equilibrio entre la capacidad de tolerancia a fallas y la precisión en la estimación. El artículo muestra como el filtro extendido de Kalman adaptativo en una estructura de Filtro Federado es exitoso en la estimación de estado de una columna de destilación por lotes.

**Palabras clave:** Filtro Federado, filtro de Kalman, tolerancia a fallas, destilación por lotes.

## I. INTRODUCCIÓN

La destilación por lotes es un método de separación ampliamente usado para la obtención de productos con alto valor comercial, tales como productos farmacéuticos, polímeros, u otros productos de química fina.

La demanda de la calidad de los productos, el aumento de la seguridad y la minimización del impacto en el medio ambiente, acompañado por la reducción de los costos de fabricación, han evidenciado la importancia de la utilización de tecnología de control avanzada en estos últimos años.

La garantía de una operación continua y segura a largo plazo se han convertido en un requisito primordial de la industria. El reconocimiento oportuno del mal funcionamiento de un equipo, junto con las acciones de control, aplicadas correctamente, puede tener un impacto considerable en la integridad, estabilidad y objetivo del sistema, que también puede influir en la seguridad de los operadores. Un problema fundamental del control de sistemas es la detección y estimación de datos fiables para el controlador. En muchos procesos químicos, la calidad del producto u otras variables no pueden ser medidas directamente, ésta puede ser estimada o inferida en tiempo real a partir de un conjunto de mediciones disponibles, permitiendo al control inferir la calidad del producto.

La composición en una columna de destilación por lotes puede ser medida directamente a través de analizadores en línea. Aunque hay un gran desarrollo en la tecnología de analizadores de composición, estos generan grandes retrasos en la medición y altos costos de inversión y mantenimiento. Al-Arfaj y Luyben (2000) sugieren que un estimador de

estado puede ser una alternativa al costoso e inclusive inexistente analizador en línea

Oisiović y Cruz (2000), desarrollaron un estimador de estado utilizando el filtro extendido de Kalman (EKF, del inglés *Extended Kalman Filter*) para inferir el perfil de composiciones de la columna de destilación por lote a partir de las temperaturas de las diferentes etapas. Venkateswarlu y col. (2001, 2006) han aplicado el filtro EKF para la estimación de la composición de una columna de destilación reactiva por lote, mostraron que incluso en la presencia de ruido en la medición y grandes cambios en los parámetros del modelo, EKF tiene un buen desempeño en la estimación del estado. Recientemente, Miranda y col. (2010) compararon el desempeño e implementación del filtro de Kalman ‘*Unscented*’ (UKF), basado en un enfoque de muestreo determinístico con el EKF en la estimación de la composición de una columna de destilación por lote, demostrando que el UKF puede ser un método prometedor para resolver problemas de estabilidad atribuibles al cómputo de las derivadas y a la variación de la medición. En contra, la robustez del filtro UKF con respecto al EKF a cambios en las condiciones iniciales y variación del ruido no pudo ser justificada.

A pesar de que el EKF ha demostrado en la literatura ser robusto a las variaciones del ruido este requiere un gran esfuerzo computacional debido a la dimensión del problema de estimación. Su solución centralizada no pueden dar respuestas a los requerimientos de seguridad y fiabilidad, debido a su falta de capacidad en la tolerancia a fallas cuando ocurren por ejemplo, fallas de operación en algún sensor.

Se ha reconocido que la partición de un problema de estimación global en pequeños problemas locales distribuyendo la carga computacional a lo largo de los filtros locales, tiene ventajas obvias en sistemas de gran escala. Esfuerzos previos basados en los trabajos de Hassan y col. (1978); Speyer (1979), se han concentrado ya sea en filtros descentralizados con topología jerárquica o esencialmente en filtros centralizados con descentralizada topología.

La necesidad de transmisión de data entre los procesadores locales es una propiedad intrínseca de tales aplicaciones. En una aplicación de filtros distribuidos, la cantidad de información que debe ser transmitida puede ser muy grande. Una estructura particular de filtro que ha tratado este problema es el filtro de Kalman Federado (FKF) desarrollado por Carlson (1988, 1993), el cual se basa en el principio de intercambio de la información a través de los filtros. La estructura consiste en varios filtros locales (LF) y

un filtro maestro o de fusión (MF), cada subsistema tiene asignado un filtro local. Los filtros locales trabajan en paralelo y su solución es periódicamente fusionada por el filtro maestro.

Aunque, las estructuras descentralizadas han sido extensamente estudiadas para reducir la alta carga computacional, su potencial para la tolerancia y detección de fallas no ha sido completamente desarrollado. De cualquier forma, mientras la teoría de filtros Federados ha sido bien desarrollada para sistemas lineales, experiencias con aplicaciones de sistemas no lineales son muy pocas. Una de ellas puede ser encontrada en el artículo de Ali y col. (2005). En este artículo, se combinarán dos estrategias, de manera de mejorar considerablemente la robustez y exactitud de la estimación del FKF aplicado a una columna de destilación por lotes. Primero, el filtro maestro del FKF, usará el enfoque propuesto por Zhang, (2002), de adaptación de los factores de intercambio de información, basado en la descomposición del valor propio de la matriz de covarianza del error estimado y segundo los filtros locales usarán el filtro extendido de Kalman adaptativo (AEKF) como estimador de estado. El filtro extendido de Kalman ha sido la técnica estándar para la estimación en sistemas no lineales pero generalmente funciones diferenciables.

En este trabajo, se muestra, cómo las soluciones de los Filtros Federados Adaptativos aprovechan el principio de redundancia en la estimación, para mejorar simultáneamente la precisión de la misma y su tolerancia a fallas.

El artículo esta estructurado de la siguiente manera, en la sección II, se detallan los fundamentos básicos y la estructura del Filtro Federado de Kalman, enfocándose en el algoritmo de fusión adaptativo. En la sección II.1, se presenta el modelo de la columna de destilación por lotes, que utilizarán los diferentes algoritmos de filtrado. Por último se muestran los resultados obtenidos de las simulaciones de los filtros para estimar el estado de la columna de destilación bajo diferentes escenario de operación.

## II. FILTRO DE KALMAN FEDERADO

En un sistema con múltiples sensores existen varios esquemas para incorporar la información de los sensores al estimador (Gao,1993). Uno de los más usados es el Filtro de Kalman centralizado (FKC). En este esquema de estimación, la información de todos los sensores es alimentada a un bloque de procesamiento llamado filtro de Kalman, obteniéndose la estimación óptima del estado a la salida. Por lo tanto el Filtro de Kalman procesa todas las mediciones en paralelo. Por supuesto tiene una estructura relativamente simple y su aplicación no es complicada. Pero por otro lado, si el número de sensores aumenta o de manera equivalente, si el vector de medición asociado con el filtro de Kalman centralizado se hace más grande, la carga de cálculo en el sistema aumenta. Además, el FKC carece de robustez frente a datos de un sensor defectuoso, ya que toda la información del sistema se ve afectada por estos datos defectuosos dentro del filtro y es difícil aislar datos erróneos una vez mezclados.

Una posible solución a éste problema es utilizar un esquema de filtrado descentralizado (Gao,1993). En dicho esquema se dividen las mediciones en pequeños subgrupos. Cada grupo de medición se procesa en filtros locales (FL) individuales, generando una estimación local del estado. Los filtros trabajan en paralelo y sus soluciones son periódicamente fusionadas en un filtro maestro (FM), generando una solución global. Como resultado de esto la carga computacional puede ser significativamente reducida. Un caso especial del filtro descentralizado es el Filtro del Kalman Federado (FKF) introducido por Carlson, (1988) cuya estructura es mostrada en la figura 1, el filtro utiliza el principio de intercambio de información a través de los filtros locales para mejorar el rendimiento de la tolerancia a fallos del sistema.

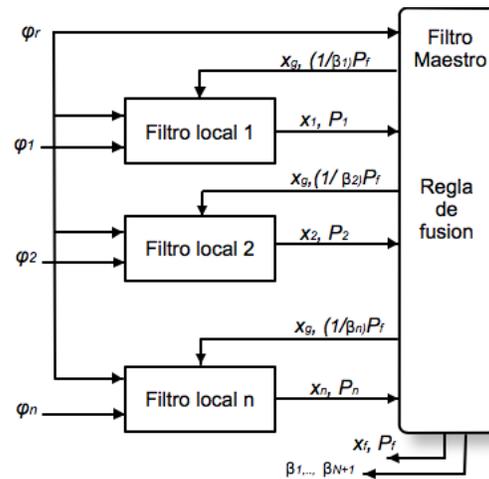


Figura 1. Arquitectura del Filtro de Kalman Federado

En la estructura del FKF, existe un sensor de referencia, que actúa como sensor fundamental en el sistema y sus datos son entrada al filtro maestro. Este sensor por lo general es más fiable y sus datos son utilizados a menudo en los filtros locales. Cada filtro local tiene sus propios sensores, además del sensor de referencia. Para la actualización, el filtro local utiliza la información de sus mediciones. Por el contrario, el filtro maestro utiliza las salidas de los filtros locales como mediciones para actualizar el vector de estado. A continuación se detalla el algoritmo de los filtros locales y el filtro maestro.

Considere el sistema dinámico no lineal y su sistema de medición descrito en espacio de estado como:

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

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

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, de covarianza  $Q$  y  $R$ , respectivamente. Asuma que cada sensor mide una señal  $\varphi_i$  la cual es corrompida por un ruido  $v_i$  que tienen una distribución gaussiana con media cero. El estimado local y su covarianza del filtro  $i$  serán representados por  $\hat{x}_i$  y

$P_i$  ( $i = 1, 2, \dots, n$ ). El algoritmo del filtro es considerado como una extensión del filtro lineal de Kalman.

El filtro de Kalman Extendido (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 cada instante  $k \geq 1$ , se calcula el predictor  $\hat{x}_{k/k-1}$ , y la correspondiente matriz de covarianzas del error  $P_{k/k-1}$ , mediante las siguientes expresiones

$$\hat{x}_{k/k-1} = f_{k-1}(\hat{x}_{k/k-1}, u_{k-1}) \quad (3)$$

$$P_{k/k-1} = F_{k-1}P_{k-1/k-1}F_{k-1}^T + Q_{k-1} \quad (4)$$

donde  $F_{k-1}$  es la matriz Jacobiana de las derivadas parciales de  $f_i(x_i, u_i)$  con respecto a  $x$ .

Seguidamente se actualiza la estimación de la señal  $\hat{x}_{k/k-1}$  incorporando la nueva información aportada por la observación  $\varphi_k$ , obteniéndose de este modo el estado  $\hat{x}_{k/k}$  y a matriz de covarianza del error  $P_{k/k}$

$$\hat{x}_{k/k} = \hat{x}_{k/k-1} + K_k[\varphi_k - h(\hat{x}_{k/k-1})] \quad (5)$$

$$P_{k/k} = (I - K_k\bar{H})P_{k/k-1} \quad (6)$$

$$K_k = P_{k/k-1}\bar{H}_k^T(\bar{H}_kP_{k/k-1}\bar{H}_k^T + R_k)^{-1} \quad (7)$$

donde  $\bar{H}_k^T$  es la matrix Jacobiana de las derivadas parciales de  $h(x)$  con respecto a  $x$  y  $K$  es la matriz de ganancia de Kalman. Cada filtro local usa sus propias mediciones correspondientes a sus sensores. Debido a que cada FL es estadísticamente independiente, los ruidos de medición no están correlacionados y la solución global esta representada por la matriz de covarianza  $P_f$  y el vector de estado  $\hat{x}_f$ , calculados en el FM de acuerdo a las ecuaciones

$$P_f^{-1} = P_1^{-1} + P_2^{-1} + \dots + P_N^{-1} + P_{N+1}^{-1} \quad (8)$$

$$\hat{x}_f = P_f[P_1^{-1}\hat{x}_1 + P_2^{-1}\hat{x}_2 + \dots + P_N^{-1}\hat{x}_N + P_{N+1}^{-1}\hat{x}_{N+1}] \quad (9)$$

Ahora la información de la matriz de covarianza del proceso y el ruido del proceso son compartidos entre los filtros locales y el filtro maestro según el esquema

$$Q_i = (1/\beta_i)Q, \quad P_i = (1/\beta_i)P_f, \quad (10)$$

donde  $\beta_i \geq 0$ , es el factor de intercambio de información y satisface la regla

$$\beta_1 + \beta_2 + \dots + \beta_{N+1} = 1 \quad (11)$$

El factor de intercambio de información juega un importante rol en determinar el rendimiento del FKF. Carlson (1988) presentó diferentes enfoques para especificar el factor de intercambio de información, las ventajas y desventajas de cada modo son discutidas en su artículo. Cuando los factores de intercambio de información son fijados como  $\beta_1 + \beta_2 + \dots + \beta_{N+1} = 1/(N+1)$ , se ha observado de los resultados

de simulaciones que la estimación global ofrece la mejor precisión cuando no hay cambios en las perturbaciones de los sistemas locales. En las aplicaciones prácticas, las condiciones de los subsistemas pueden verse alteradas en gran medida con el tiempo. Estos cambios no pueden ser reflejados si los factores de intercambio de información están fijos resultando en el deterioro del rendimiento de los filtros de Kalman asociados. Cuanto mayor sea el factor de intercambio de información mayor será la influencia del subsistema en la estimación global. La idea es cambiar el factor de intercambio de información de acuerdo al rendimiento de cada filtro local y por lo tanto cambiar la proporción de la información de la estimación del filtro local al filtro maestro usando los autovalores de la matriz de covarianza  $P_i$ , idea presentada por Zhang y col. (2002). Con este fin se utilizará la información de los autovalores de las matrices de covarianza  $P_i$  de cada filtro local, ya que ellos representan las covarianzas de sus correspondientes vectores de estado. Cuanto mayor es el autovalor de  $P_i$ , mayor es la covarianza de la estimación del estado correspondiente y por lo tanto peor es su rendimiento. La matriz de la covarianza del filtro local  $i$ , puede ser descompuesta en

$$P_i = L\Lambda_iL^T \quad (12)$$

donde  $\Lambda_i = \text{diag}\{\lambda_{i1}, \lambda_{i2}, \dots, \lambda_{im}\}$ ;  $\lambda_i \sim \lambda_{im}$  son los autovalores de  $P_i$  y  $L$  es su correspondiente autovector. Como los autovalores pueden ser positivos o negativos se utilizará  $P_i^T P_i$  en vez de  $P_i$  en la descomposición. Entonces el factor de intercambio de información será definido como:

$$\beta_i = \text{tr}\Lambda'_i / \sum_{i=1}^{N+1} \Lambda'_i \quad (13)$$

donde  $\text{tr}\Lambda'_i$  es la traza de la matriz  $\Lambda'_i$ .

De manera de aumentar la precisión de la estimación y manejar las variaciones del ruido a través de la estimación en tiempo real cada filtro local, utilizará un filtro de Kalman extendido adaptativo (AEKF). Han habido diferentes esquemas de adaptación desarrollados en los últimos años. La idea de un enfoque clásico se presentó en (Mehra, 1970) el cual es conocido como la estimación máxima de la probabilidad y se ha utilizado en diversas aplicaciones.

El método adoptado en este trabajo se basa en la evaluación secuencial de residuos

$$r_k = \varphi_k - h_k(\hat{x}_{k/k-1}) \quad (14)$$

que pueden ser obtenidos de (5) en forma directa. 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  $\hat{R}_k = \hat{C}_v + H_k\hat{P}_kH_k^T$  y la varianza estimada de la covarianza residual en un horizonte deslizante de longitud  $m$  es calculada como

$$\hat{C}_v = \frac{1}{m} \sum_{k=1}^m r_{k-i} r_{k-i}^T \quad (15)$$

Entonces el valor estimado de  $\hat{R}$  es usado en la actualización de la medición de (7) al tiempo  $k + 1$  adaptando la ganancia  $K$ , de cada filtro de acuerdo a las variaciones del ruido.

### II.1. 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 vea (Miranda, 2011) que consta de 10 etapas de equilibrio, es decir, 8 platos, un condensador total y un rehervidor, 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, vea (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) para 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,  $\sum_{i=1}^{n_c} x_i = 1$ , 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 obtenido por simple substracción.

El proceso esta controlado por la razón de reflujo interna, la cual esta definida como

$$u = R = \left[ \frac{L}{V} \right], \quad (16)$$

y es mantenida 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 :

$$\begin{bmatrix} \dot{x}_1 \\ \vdots \\ \dot{x}_j \\ \vdots \\ \dot{x}_n \end{bmatrix} = \begin{bmatrix} \frac{V}{M_1}(y_2 - x_1) \\ \vdots \\ \frac{V}{M_j}(y_{j+1} - y_j) + \frac{RV}{M_j}(x_{j-1} - x_j) \\ \vdots \\ \frac{RV}{M_n}(x_{n-1} - x_n) + \frac{V}{M_n}(y_n - x_n) \end{bmatrix} + \begin{bmatrix} w_1 \\ \vdots \\ w_j \\ \vdots \\ w_n \end{bmatrix}, \quad (17)$$

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. ( $\varphi_j = T_j$ ). El sistema de mediciones es modelado como una función del vector de estado  $g(x)$  corrompida por ruido

$$T = g(x) + v \quad (18)$$

La relación no lineal  $g(x)$ , entre la temperatura y la fracción molar puede ser obtenida de las ecuaciones del equilibrio liquido-vapor (VLE) (Perry, 1967). 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

$$y_j = \gamma_j x_j \left( \frac{p_j^v}{p} \right), \quad (19)$$

donde  $\gamma_j$  es el coeficiente de actividad calculado por la ecuación de Wilson, y  $p$  es la presión de la columna. presión de vapor  $p_i^v$  es modelada por la ecuación de Antoine (Perry, 1967). 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 (vea Miranda, 2011). La figura 2, 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.

Con el fin de diseñar el filtro, es necesario que el sistema sea observable. Se sabe por la literatura 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 trabajara con 5 mediciones de las temperatura disponibles para el desarrollo de los filtros.

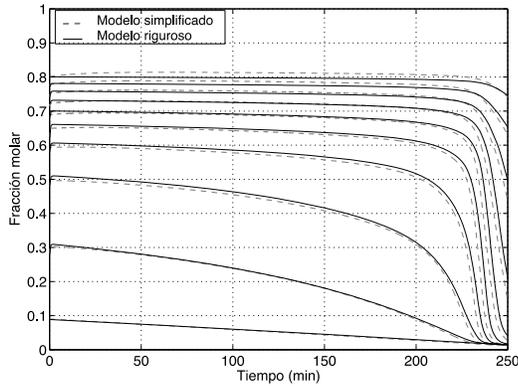


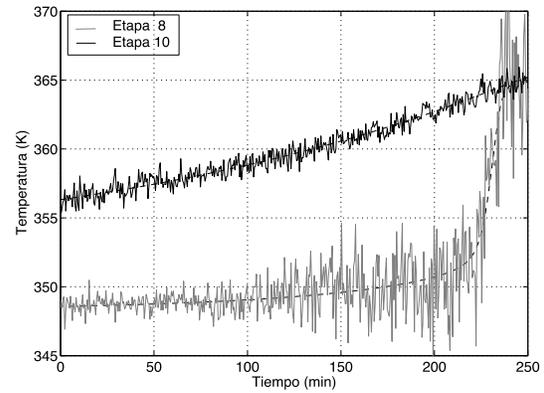
Figura. 2. Composición molar en las diferentes etapas de la columna.

### III. RESULTADOS Y DISCUSION

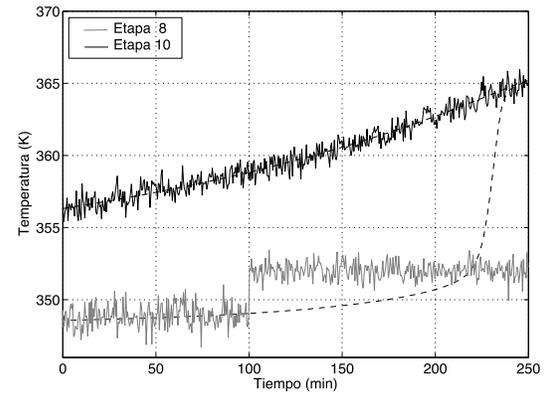
Con el fin de simular el comportamiento del proceso, el modelo riguroso de la columna fue empleado. En cada período de tiempo, las temperaturas de las etapas 3,4,5,8 y 10, fueron utilizadas como entradas al filtro. Todas las simulaciones fueran hechas en el ambiente de programación MATLAB. En el EKF y AEKF, las señales de los 5 sensores son alimentadas al filtro. En el FKF, las señales de los sensores son alimentadas por pares a cada filtro individual o filtro local (3;10), (4;10), (5;10) y (8;10) de acuerdo a la arquitectura de la figura 1. Se utilizó como sensor de referencia ( $\phi_r$ ) el sensor de la etapa 10, correspondiente al rehervidor por ser la etapa que tiene una dinámica de respuesta más rápida y por lo tanto las mediciones son más sensibles durante todo el periodo de destilación (Zamprogna y col. 2005).

En este trabajo los resultados de tres soluciones diferentes de filtrado son reportados: i) el EKF, ii) el AEKF iii) el FKF adaptativo, en respuesta a dos escenarios típicos con fallos en el sensor de temperatura de la etapa 8. En el primer escenario se estudia, el efecto del aumento del ruido en el sensor e incipiente fallo. Para este fin, un aumento de la covarianza del ruido fue aplicado a la señal de entrada del filtro en el momento que la simulación alcanzaba el minuto 70. En la figura 3a, se presenta el perfil de temperatura para los sensores 8 y 10. En el segundo escenario, representado por la figura 3b, se estudió otro fallo típico en los sensores, la señal del sensor es afectada por una función tipo escalón a partir del minuto 100 de la simulación, permaneciendo luego constante con ruido gaussiano.

Para el escenario 1, tanto el AEKF y el FKF presentaron un buen rendimiento en la estimación de estado. Esto se aprecia en la figura 4, donde se muestra la estimación del estado para varias etapas. En ambos casos los filtros fueron capaces de adaptarse a los cambios estadísticos de la covarianza del ruido de medición y compensar la falla del incremento del ruido en el sensor. Para el caso del EKF, el filtro no convergió, por lo que no se obtuvo ningún resultado.



a) Incremento del ruido



b) Falla tipo escalón

Figura. 3. Mediciones de temperatura del filtro sujetas a ruido y fallas: a) Con incremento del ruido del sensor 8 a partir del minuto 100 b) Con falla tipo escalón a partir del minuto 100. Líneas de trazos temperaturas de referencia.

En la figura 5, se presentan los resultados de las simulaciones para la falla tipo escalón. Se puede ver como la precisión de la estimación varía de acuerdo al enfoque de filtrado. Mientras que la estimación 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 solo en la primera y última etapa, mientras que el FKF es casi invariante a la alteración introducida, haciendo que la estimación tenga el mismo comportamiento que el estado real, en todas las etapas.

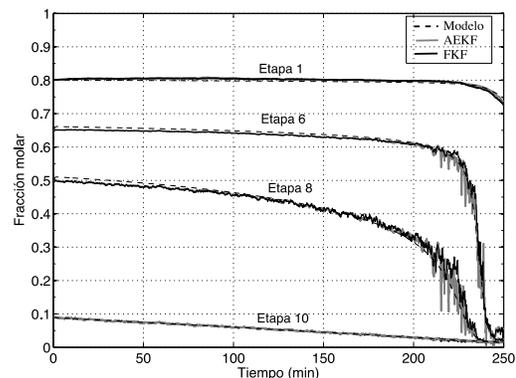


Figura 4. Estimación de la fracción molar con incremento de la covarianza del ruido en el sensor 8. Filtros AEKF y FKF

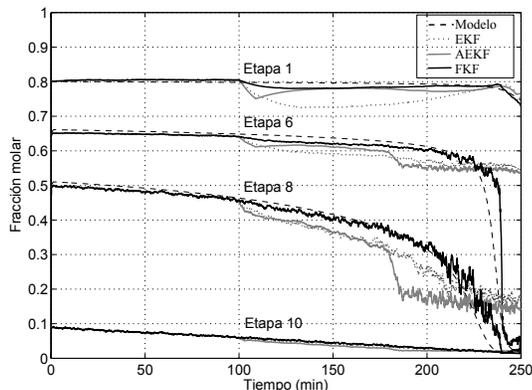


Figura. 5. Estimación de la fracción molar con falla tipo escalón, sensor 8. Filtros EKF,AEKF y FKF.

La tabla I, muestra la raíz del error cuadrático medio porcentual RECMF, para la etapa 1 y 10, correspondiente a los productos de tope, fondo y dos etapas intermedias. En la tabla se evidencia, el rendimiento similar de los filtros AEKF y FKF, para el escenario 1, siendo la estimación del FKF, en promedio 5% mejor que la estimación del AEKF. En el escenario 2, se evidencia la superioridad del FKF con respecto al AEKF y el EKF. El error cuadrático del AEKF casi duplica el error del FKF.

Tabla I. RECMF en la estimación de la composición

Escenario 1			
Etapa	EKF	AEKF	FKF
1	-	0.66	0.62
6	-	1.38	1.23
8	-	1.26	1.27
10	-	0.13	0.13
Escenario 2			
1	3.95	1.62	0.90
6	10.37	11.73	4.18
8	5.71	6.79	2.25
10	0.32	0.58	0.13

#### IV. CONCLUSIONES

La implementación y rendimiento de la solución estándar de EKF en comparación con el AEKF y con el FKF adaptativo son 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 FKF, con factores de intercambio de información adaptativo, es capaz de incrementar la robustez del filtro contra variaciones en la señal de medición mejorando de manera significativa la precisión de la estimación.

#### REFERENCIAS

- Ali, J., Fang, J., 2005. Multisensor data synthesis using federated of unscented kalman filtering. In: IEEE International Conference on Industrial Technology, 524-529
- Carlson N. A. y M.P. Berarducci (1993). Federated Kalman filter simulation results, Journal of the Institute of Navigation, Vol. 41, No. 3, 1993
- Carlson, N. A. (1988). Federated filter for fault-tolerant integrated navigation systems. Proceedings of IEEE Position Location and Navigation Symposium, 225-236
- Gao, Y., J. Krakiwsky, M.A. Abousalem, y J. F. McLellan (1993). A comparison and analysis of Centralized, decentralized and federated filters. Journal of the Institute of Navigation, Vol. 40, No. 1, 69-86
- Hassan, M. F., G. Salut, A. Singh (1978) A decentralized computational algorithm for the global kalman filter. IEEE Trans. Aut. Control, 23(2), 262-268
- Julier S., Uhlmann J. y Durant-White H.,(1995), A new Approach for filtering Nonlinear Systems, In Proceedings of the American Control Conference, pp. 1628-1632
- Mehra R. (1970). On the identification of variance and adaptive Kalman filtering. IEEE Trans. Aut. Cont., 15(2), 175-184.
- Miranda M., Edelmayer A., y Encinoza A.,(2011), Case study of unscented state estimation for batch distillation processes, in Proc. IEEE Int. Conf. Cont., ICCA'11, 919-924.
- Mujtaba I.M. (2004). Batch Distillation: Design and Operation. Series on Chemical Engineering, Vol. 3, Imperial College Press, London.
- Oisiovici, R.M.y Cruz, S.L.,(2000) State estimation of batch distillation columns using an extended Kalman filter, Chem Eng Sci, 55: 4667-4680
- Perry J.H. (1967) (Ed.) Perry's Chemical Engineer's Handbook. 7 ed. McGraw-Hill.
- Speyer J.L. (1979). Computation and transmission requirements for a decentralized linear quadratic-gaussian control problem. IEEE Trans. Aut. Cont., 24(2), 266-269.
- Venkateswarlu, C., Avantika, S., (2001). Optimal state estimation of multicomponent batch distillation. Chemical Engineering Science 56, 5771-5786
- Venkateswarlu, C., Kumar, B.J., (2006). Composition estimation of multicomponent reactive batch distillation with optimal sensor configuration. Chemical Engineering Science 61, 5560-5574.
- Zhang H, B. Lennox, P. Goulding, Y. Wang. (2002). Adaptive Information sharing factors in Federated Kalman Filtering, In Proc. Triennial World Congress, 664-670
- Wang J. (2000). Stochastic modeling for real-time kinematic GPS/GLONASS positioning. Navigation, 46(4) 297-305.
- Yu C.C. y Luyben W.L., (1987). Control of multicomponent distillation columns using rigorous composition estimators. Int. Chem. Eng. Symp. Series, 104, 29-69.
- Zamprogna E., Barolo M. y Seborg D. (2005). Optimal selection of soft sensor inputs for batch distillation columns using principal component analysis, Journal of Process Control 15, 39-52