

# Filtro de Información Unscented en Arquitectura Distribuida aplicada a la destilación

## Unscented Information filter in Distributed Architecture applied to distillation

Miranda, Moira<sup>1\*</sup>; Rosales, Diego; Méndez, Dayana; Flores, Rigoberto  
<sup>1</sup> Escuela de Ingeniería Química, Universidad de Los Andes, Mérida, Venezuela.  
\*[moira@ula.ve](mailto:moira@ula.ve)

### Resumen

*Este artículo presenta la aplicación del filtro de Información Unscented para la estimación de estado de una columna de destilación por lotes a través de la fusión de múltiples filtros individuales, bajo un esquema distribuido. Se propone el uso de un esquema federado usando un algoritmo de Información Unscented Adaptativo. La propuesta de filtro consiste en utilizar dos estrategias: a) Filtros locales de Información Adaptativos, cada filtro local de información será robusto a las variaciones de las señales de medición, por medio de la adaptación de la covarianza del ruido. b) Un filtro maestro que trabajara bajo una estructura de Información Federada con factor de distribución de información adaptativo. El filtro es comparado con las tradicionales soluciones centralizadas y con un esquema de filtro distribuido con detección de fallas. Los resultados muestran que el filtro de Información Unscented Adaptativo tiene el mismo rendimiento que el filtro distribuido con detección de fallas, sin presentar los inconvenientes de detección errónea de fallas en el sistema.*

**Palabras clave:** Filtro de Información Unscented adaptativo, tolerancia a fallas, destilación por lote.

### Abstract

*This article submits the state estimation of a batch distillation column through fusion information from multiples individual filters, under a Federated architecture using an Adaptive Unscented Information algorithm. The proposed of the filter consist in the use of two strategies: a) Locals adaptives information filters, where each local information filter will be robust to the variations of the measurement signals, by adjusting the noise covariance. b) A master filter that will work under a structure of information federated with adaptive information sharing factor. The filter is compared with traditional centralized solution and a distributed mode filter fault detection. The results show that the Adaptive Unscented Information filter has the same performance as the distributed filter with fault detection, without presenting the drawbacks of erroneous detection of faults in the system.*

**Keywords:** Adaptive Kalman filter, Sensor fault tolerance, Batch distillation.

### 1 Introducción

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 en diversos campos de la industria química, 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. Por estas razones, las plantas industriales están equipadas con numerosos sensores y alarmas para el control de las variables de interés. Cuando varios sensores miden el mismo estado del sistema en general se tienen dos enfoques para procesar los datos de los sensores: el centralizado y el distribuido. En el primer enfoque, todos los datos de los sensores de medición se comunican a un solo filtro el cual es usado para estimar el conjunto completo de las variables de estado del sistema. La ventaja de este método es que implica la pérdida mínima de infor-

mación. Sin embargo puede resultar en una sobrecarga de cálculo y es poco fiable cuando existe una falla grave en los datos. En el segundo enfoque el descentralizado o distribuido, existen varios nodos o filtros que procesan su propia información a partir de las mediciones obtenidas de sus sensores. Luego los datos de cada filtro son comunicados a un nivel superior para producir una estimación global mejorada. Este esquema tiene algunas ventajas, por ejemplo, el filtro descentralizado puede tratar muchos datos debido a su estructura paralela. Por otra parte el filtro descentralizado es robusto al fallo de un sensor, ya que cada nodo se ocupa de su propio procesamiento.

Para el procesamiento de múltiples datos el filtro de Información de Kalman ha sido utilizado ampliamente tanto en el enfoque centralizado, como en el descentralizado. Este filtro, que es esencialmente un filtro de Kalman expresado en términos de la matriz inversa de la covarianza ha sido utilizado en la estimación lineal con múltiples sensores, debido a sus ventajas con respecto a la norma del filtro de Kalman (Liu y col., 2011). Para sistemas no lineales el filtro de Información de Kalman puede ampliarse mediante un algoritmo de estimación linealizado utilizando el filtro de Kalman Extendido (FKE), el cual es llamado Filtro de Información Extendido (FIE). Sin embargo, algunos de los inconvenientes del FKE son heredados por el FIE, en términos de truncamiento debido a las aproximaciones de primero y segundo orden de las series de Taylor.

Para resolver este problema, Deok-Jin (2008), desarrolló un algoritmo llamado Filtro de Información de Sigma Puntos (FIU), basado en la transformación Unscented usando la estructura de filtro de Información. El FIU utiliza un número de puntos determinísticos llamados sigma puntos que permiten captar la verdadera matriz de Información y el vector de Información. El FIU es superior al FIE, no solo en términos de la precisión de la estimación, sino también en la velocidad de convergencia para la estimación no lineal y la fusión de múltiples sensores. (Deok-Jin, 2008).

El FIU, puede ser adaptado para trabajar bajo una estructura particular de Filtro de Kalman Federado (FKF) desarrollado por Carlson (1988, 1993), el cual se basa en el principio de distribución de la información a través de los filtros. La estructura consiste en varios filtros locales y un filtro maestro o de fusión, 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.

En este artículo, se propone un filtro de Información Adaptativo en una Arquitectura Federada (FIAF), para estimar el estado de una columna de destilación por lotes. El filtro combinara dos estrategias, primero, se usara un filtro

de Información Federado donde el filtro maestro, usará un enfoque de adaptación de factores de distribución de información y segundo los filtros locales serán filtros de Información Unscented Adaptativos (FIUA). La combinación de estas dos estrategias adaptadas a filtros de Información Unscented, permitirá mejorar potencialmente la tolerancia a fallas y obtener robustez ante los cambios estadísticos del ruido de observación. El rendimiento de este filtro será comparado con un filtro en un esquema distribuido con detección de falla y los tradicionales filtros centralizados.

El artículo esta estructurado de la siguiente manera, en la sección 2, se detallan los fundamentos básicos de la estructura del Filtro de Información Unscented y el filtro de Información Federado. En la sección 2.2 se presenta el modelo de la columna de destilación por lotes, que utilizarán los diferentes algoritmos de filtrado. En la sección 3 se especifica la estrategia de funcionamiento del filtro propuesto, y por último se muestran los resultados obtenidos de las simulaciones de los filtros para estimar el estado de la columna de destilación bajo diferentes escenarios de operación.

## 2 Filtro de Información Unscented

El filtro de Kalman Unscented (FKU) es una formulación para sistemas altamente no lineales, presentada por Julier y col. (1995) y perfeccionada por Wan y Van der Merwe, (2000). Este filtro emplea la transformación ‘Unscented’, que calcula un conjunto mínimo de puntos de muestreo seleccionados cuidadosamente, llamados ‘puntos sigma’. Estos puntos capturan completamente la media y covarianza verdadera del estado y cuando se propagan a través del sistema no lineal, la media y covarianza posterior se obtiene para cualquier no-linealidad presente en el sistema de forma precisa.

El algoritmo básico del Filtro de Información Unscented (FIU) es una adaptación del FKU, pero en términos de variables analíticas de información, las cuales son medidas de la cantidad de información de un parámetro (estado) de interés.

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

$$\begin{aligned} \hat{x}_{k+1} &= f_i(x_k, u_k) + w_k, \\ z_k &= h(x_k) + v_k, \end{aligned} \quad (1)$$

donde  $x \in \mathbb{R}^n, u \in \mathbb{R}^m, z \in \mathbb{R}^p$ , 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  $z_k$  la cual es corrompida por un ruido  $v_k$  que tienen una distribución gaussiana con media cero. El estimado local y su covarianza del filtro  $k$  serán representados por  $\hat{x}_k$  y  $P_k$ . El algoritmo del filtro de Información Unscented es considerado como una extensión del filtro Unscented de Kalman, en términos de la matriz de información  $Y_k = P_{k/k}^{-1}$  y el vector de información de estado  $\hat{y}_{k/k}$ . El FIU puede ser ilustrado como sigue:

**Paso 1: Iniciación.**

Se fija a priori el vector inicial de estados  $x_{k-1}$  y la covarianza del error  $P_{k-1}$ .

**Paso 2: Cálculo de los puntos sigma y sus pesos.**

$$\begin{aligned} \chi_k &= [\hat{x}_{k-1} \quad \hat{x}_{k-1} + \gamma\sqrt{P_{k-1}} \quad \hat{x}_{k-1} - \gamma\sqrt{P_{k-1}}] \\ W_o^m &= \lambda/(L + \lambda) \\ W_o^c &= \lambda/(L + \lambda) + (1 - \alpha^2 + \beta) \\ W_i^c &= W_i^m = \lambda/(2(L + \lambda)), \quad i = 1, \dots, 2L \end{aligned} \quad (2)$$

Donde  $\gamma = \sqrt{L + \lambda}$ ,  $L$  es la dimensión del estado y  $\lambda$ , es un parámetro escalar.

**Paso 3: Ecuaciones de predicción.**

$$\begin{aligned} \chi_{k/k-1}^* &= f[\chi_{k-1}, u_{k-1}] \\ \hat{y}_{k/k-1} &= Y_{k/k-1} \sum_{i=0}^{2L} W_i^m \chi_{i,k|k-1}^* \end{aligned} \quad (3)$$

$$Y_{k/k-1} = P_{k/k-1}^{-1} \quad (4)$$

$$P_{k/k-1} = \sum_{i=0}^{2L} W_i^c [\chi_{i,k|k-1}^* - \hat{x}_{k/k-1}] [\chi_{i,k|k-1}^* - \hat{x}_{k/k-1}]^T + Q, \quad (5)$$

**Paso 4: Ecuaciones para la medición actual**

$$\hat{y}_{k/k} = \hat{y}_{k/k-1} + i_{k/k-1} \quad (6)$$

$$Y_{k/k} = Y_{k/k-1} + I_{k/k-1} \quad (7)$$

donde

$$I_{k/k-1} = H_{k/k-1} R^{-1} H_{k/k-1}^T \quad (8)$$

$$H_{k/k-1} = Y_{k/k-1} P_{xy_{k/k-1}} \quad (9)$$

$$\begin{aligned} i_{k/k-1} &= H_{k/k-1} R^{-1} [v_{k/k} + P_{xy_{k/k-1}}^T Y_{k/k-1} y_{k/k-1}] \\ v_{k/k} &= z_k - \hat{z}_{k/k-1} \end{aligned} \quad (10)$$

$$P_{xy_{k/k-1}} = \sum_{i=0}^{2L} W_i^c [\chi_{i,k} - \hat{x}_{k/k-1}] [Y_{i,k|k-1} - \hat{z}_{k/k-1}]^T \quad (11)$$

$$Y_{i,k} = h[\chi_{i,k|k-1}^*] \quad (12)$$

$$\hat{z}_{k/k-1} = \sum_{i=0}^{2L} W_i^c Y_{i,k|k-1} \quad (13)$$

$$\hat{x}_{k/k-1} = Y_{k/k-1}^{-1} \hat{y}_{k/k} \quad (14)$$

donde  $i_{k/k-1}$ , es la aportación de información del estado y

$I_{k/k-1}$ , es su matriz de información asociada.

### 2.1 Filtro de Información distribuido

La fusión de sensores en términos generales es la integración de las diferentes observaciones de una misma variable de proceso en un único valor sobre el cual basar la toma de decisiones en los sistemas de control. Se denominan como arquitecturas de fusión a los diferentes esquemas con los que se puede implementar la fusión de sensores. Uno de los más usados es el esquema central. En este esquema de estimación, la información de todos los sensores es alimentada a un bloque de procesamiento llamado filtro central de procesamiento, obteniéndose la estimación del estado a la salida. Por lo tanto se procesan 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 centralizado se hace más grande, la carga de cálculo en el sistema aumenta. Además, esta estructura carece de robustez frente a datos de un sensor defectuoso, ya que toda la información

del sistema se ve afectada por estos datos errados dentro del filtro.

El principio básico de un enfoque distribuido, es el hecho de que cada filtro local opera autónómicamente e independientemente con sus propias mediciones. Se asume que los filtros locales no comparten información y que el filtro maestro no tiene acceso a las mediciones que alimentan a cada filtro. La arquitectura descentralizada mostrada en la figura 1, tiene un modo de operación jerárquico, porque las salidas de los filtros locales actúan como entradas al filtro maestro de fusión. Las salidas de los filtros locales corresponden a las mediciones del filtro maestro. El filtro maestro realiza la fusión de los filtros locales, como una combinación lineal del vector de información de estado y su matriz de información. Por lo tanto, las ecuaciones de actualización son expresadas en términos de la contribución de cada filtro local como:

$$\begin{aligned} \hat{y}_{k/k} &= \hat{y}_{k/k-1} + \sum_{i=1}^N i_{i/k} \quad (17) \\ Y_{k/k} &= Y_{k/k-1} + \sum_{i=1}^N I_{i/k} \quad (18) \end{aligned} \quad (5) \quad (6) \text{ donde } Q \text{ es la covarianza}$$

para la etapa de predicción se utilizan las ecuaciones 4y 5.

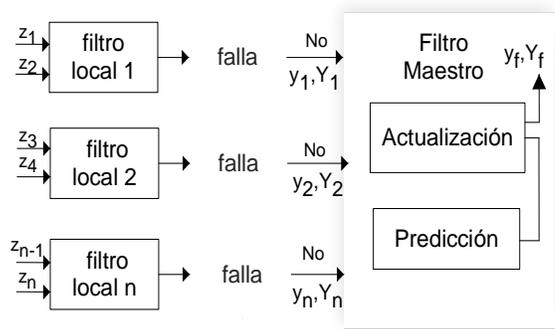


Fig. 1. Arquitectura del Filtro de Información Distribuido, con detección de falla

Una de las ventajas de una arquitectura distribuida jerárquicamente, es la posibilidad de detección de fallas en un sensor y su capacidad de aislar la misma. La validación de la medición de un sensor puede realizarse comparando la observación obtenida del sensor con respecto a la observación prevista por el modelo y aceptando únicamente las que se encuentren dentro de un intervalo predeterminado. (Deok-Jin 2008). Con este fin se puede utilizar la relación funcional de los residuos normalizados  $r_k$  definida por la ecuación:

$$r_k = \frac{1}{n} \sum_{j=k-n+1}^k e_j^T (P_{j/j-1}^{yy} + R_k)^{-1} e_j \quad (19)$$

donde  $e_k = z_k - \hat{z}_k$ . La función  $r_k$  tiene una distribución Chi Cuadrado  $\chi^2$ . La detección está basada en el contraste de dos hipótesis, la nula  $H_0$  correspondiente al sistema trabajando de forma normal, y la alternativa  $H_1$  definida para el sistema en estado anormal. Según (Soken y col., 2010) si  $n r_k$  es menor al valor crítico de  $\chi^2$ , correspondiente, la hipótesis nula no se puede rechazar con una probabilidad  $1 - \alpha$ , o expresado de otra forma:

$$P(n r_k \leq \chi_{1-\alpha}^2 | H_0) = 1 - \alpha \quad (20)$$

El filtro de Kalman Federado es un caso especial de las arquitecturas jerárquicamente descentralizados propuestos inicialmente por (Carlson1990). Bajo este esquema, la información referente a las estimaciones globales obtenida por el filtro maestro es dividida y compartida con los filtros locales individuales según el principio de distribución de la información que a su vez se basa en el axioma de conservación de la información (Zhang et al., 2002). De acuerdo a este principio, a cada uno de los filtros locales participantes en la fusión (junto con el filtro maestro en caso de considerarse) se le asigna lo que se denomina un factor de distribución de la información  $\beta_i \geq 0$ , que cumple con la propiedad establecida en la ecuación  $\beta_1 + \beta_2 + \dots + \beta_{N+1} = 1$ . Este concepto de compartir información distingue al filtro Federado del filtro centralizado y descentralizado. El reto en el filtro Federado es determinar como la información total será dividida entre los filtros individuales para lograr una mayor tolerancia a fallos y un mejor rendimiento. Entre más pequeño es este factor de distribución para un filtro dado, mayor será su incertidumbre asociada representada por su matriz de covarianza y menor será su contribución alestimado global, mitigando así los errores asociados a las fallas.

Para sistemas con filtros locales con estructura como (7) y (8), el vector de información global y su matriz asociada se define como:

$$Y_f = \sum_{i=1}^N Y_i \quad (21)$$

$$y_f = \sum_{i=1}^N y_i \quad (22)$$

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

$$Q_i = (1/\beta_i)Q, \quad Y_i = \beta_i Y_f, \quad (23)$$

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.

## 2.2 Modelo de la columna

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 rehevador, 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.

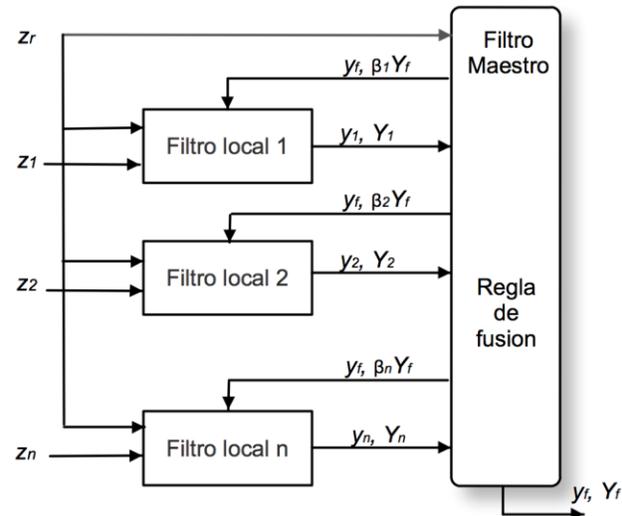


Fig.2. Arquitectura del Filtro de Kalman Federado

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

$$u = R = \left[ \frac{L}{V} \right], \quad (24)$$

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 :

$$\begin{bmatrix} \bar{x}_1 \\ \square \\ \bar{x}_j \\ \square \\ \bar{x}_n \end{bmatrix} = \begin{bmatrix} \frac{V}{M_1}(y_2 - x_1) \\ \square \\ \frac{V}{M_j}(y_{j+1} - y_j) + \frac{RV}{M_j}(x_{j-1} - x_j) \\ \square \\ \frac{RV}{M_n}(x_{n-1} - x_n) + \frac{V}{M_n}(y_n - x_n) \end{bmatrix} + \begin{bmatrix} w_1 \\ \square \\ w_j \\ \square \\ w_n \end{bmatrix}, \quad (25)$$

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  $g(x)$  corrompida por ruido, según la ecuación (26)  $T = g(x) + v(26)$

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.

La precisión del modelo simplificado del proceso (25) 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).

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.

### 3 Propuesta de un filtro

La propuesta de filtro de este trabajo consiste en utilizar dos estrategias: a) Filtros locales de Información adaptativos, cada filtro local de información será robusto a las variaciones de las señales de entrada, por medio de la adaptación de la covarianza del ruido. Para tal efecto la covarianza será corregida basada en las características del ruido, pensando fallas incipientes en los sensores. b) El filtro maestro trabajará bajo una estructura de Información Federada con factor de distribución de información adaptativo. 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.

#### 3.1 Estimación de la covarianza del ruido

El funcionamiento del FIU se basa en el conocimiento de los modelos del proceso y de la medición, y las propiedades de sus ruidos. La incertidumbre en la covarianza del error de la observación (R) tiene un impacto crucial en el rendimiento del filtro. La forma convencional de determinar R, es del conocimiento a priori de los errores de medición, que en general se hace de un análisis empírico. En la practica este valor no siempre se mantiene constante ya que puede ser afectado por el medio ambiente, fallas en los sensores, etc.

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 Información Unscented adaptativo (FIUA). La idea es adecuar el filtro de Kalman Unscented Adaptativo a la estructura del filtro de Información Unscented, para realizar la estimación de estado.

Una de las técnicas empleadas en la estimación adaptativa esta basada en la evaluación secuencial de los residuos, en la cual se estiman las matrices de covarianza del ruido de los sensores o del proceso, usando como métrica los conjuntos de diferencias entra las mediciones y las estimaciones, también llamadas residuos. Cada filtro individual fue modificado para obtener sus versiones robustas, basas en los resultados de (Soken y col., 2010), donde se la matriz del ruido de los sensores por una matriz variable, en vez de estimar directamente los valores de los elementos de la matriz de covarianza. El funcionamiento es relativamente sencillo al comparar la covarianza teórica de las innovaciones con una real obtenida usando un conjunto de los últimos valores residuales. Esta comparación se establece como muestra la ecuación (27)

$$\frac{1}{m} \sum_{j=k-m+1}^k (e_j e_j^T) = P_{k/k-1}^{yy} + S_k R_k \quad (27)$$

donde el vector de residuales  $e \in \mathbb{R}^p$ , es la diferencia entra las mediciones  $z_k$  y las observaciones estimadas  $\hat{z}_{k/k}$ , mientras que el termino  $m$ , es el tamaño de la ventana de monitoreo de los residuales y depende de la aplicación. El termino  $P_k^{yy}$  es la covarianza de la estimación en el paso de la actualización de las mediciones y se calcula

$$P_{k/k-1}^{yy} = E[(z_k - \hat{z}_{k-1})(z_k - \hat{z}_{k-1})^T] \quad (28)$$

y puede ser aproximada

$$P_{k/k-1}^{yy} \approx H P_k H^T \quad (29)$$

donde H es obtenido de la ecuación (10).

En un sistema normal ambas covarianzas deben ser iguales dentro de cierto margen de error pero en el caso de una falla la matriz dada por los residuales incrementa sus valores, violando la igualdad de la ecuación (26). Despejando  $S_k$  de (26) se obtiene la ecuación (29), con lo que se busca una matriz diagonal  $S_k \in \mathbb{R}^{p \times p}$ , que al multiplicarla por  $R_k \in \mathbb{R}^{p \times p}$ ,

se vuelvan a igualar las covarianzas reales y teóricas.

$$S_k = \left[ \frac{1}{m} \sum_{k=1}^m (e_k e_k^T) - P_k^{yy} \right] R_k^{-1} \quad (30)$$

La matriz  $S_k$  calculada con la ecuación (29) debe ser diagonal con valores mayores a 1. Para garantizar esto se crea una matriz corregida  $S_k^*$  donde sus valores de la diagonal están definidos por:

$$s_i = \max(1, S_k^{ii}) \quad (31)$$

y por la tanto la covarianza queda definida por:

$$P_{k/k-1}^{yvy} = P_{k/k-1}^{yy} + S_k^* R_k \quad (32)$$

### 3.2 Filtro Federado Adaptativo

El factor de distribución de la información juega un importante rol en determinar el rendimiento del FKF. Diferentes enfoques para especificar el factor de distribución de la información fueron discutidos por (Carlson 1988).

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 distribución de la información están fijos resultando en el deterioro del rendimiento de los filtros de Kalman asociados.

En los casos adaptativos los  $\beta_i$ , son recalculados a cada paso de fusión, permitiendo que los sensores con fallas sean ignorados por el filtro maestro y dándoles en teoría más robustez. La lógica es hacer los factores de distribución de información inversamente proporcionales a la incertidumbre de la estimación representada por la matriz de covarianza, los valores de  $P_k$  y  $Q_k$  correspondientes son escalados en caso de falla y el filtro maestro puede dejar de tomarlos en cuenta. Este es el método usado por (Guan y col., 2012) mostrado en el conjunto de ecuaciones siguientes:

$$\|P_{k/ki}\| = \sqrt{\text{tr}(P_{k/ki}^T P_k)} \quad (33)$$

$$\beta_i = \frac{\|P_{k/ki}\|^{-1}}{\sum_{j=1}^{N+1} \|P_{k/kj}\|} \quad (34)$$

## 4 Resultados y discusión

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 5, 7, 8 y 9 y 10, fueron utilizadas como entradas al filtro. Todas las simulaciones fueran hechas en el ambiente de programación MATLAB. En este trabajo se comparó el rendimiento de cuatro filtros, el filtro de Información en arquitectura centralizada (FIC), el filtro de Información en arquitectura Distribuida (FID), el filtro en arquitectura distribuida con detección de falla, (FIDF) y el filtro de Información Adaptativo en una arquitectura Federada (FIAF).

El filtro con detección de falla trabajará en una arqui-

tectura distribuida, en el momento que el filtro maestro detecte una falla, ecuación (19), la contribución de la información a la fusión de datos correspondiente al filtro con falla se anulara, generando un mejor ajuste de la estimación. El tiempo que tarde el filtro maestro en detectar la falla dependerá de los límites de valor crítico de  $\chi^2$

En el FIC las señales de los 5 sensores son alimentadas al filtro. En el FID, el FIDF y el FIAF, las señales de los sensores son alimentadas por pares a cada filtro individual o filtro local (5;10), (8;10), (7,10) y (9;10) de acuerdo a la arquitectura de la figura 1 y 2. Se utilizó como sensor de referencia ( $zr$ ) 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 (Zampronga y col. 2005).

La respuesta de los filtros será evaluada en diferentes escenarios con falla en el sensor de temperatura de la etapa 9, como se representa en la figura 3. En el primer escenario representado por la figura 3a, se estudia una falla de desviación, donde los errores de precisión aumentan con el tiempo en el momento que la simulación alcanza el minuto 100. En el segundo escenario, una falla de congelación es considerada, la señal del sensor permanece constante con ruido gaussiano a partir del minuto 100. En el tercer escenario, se evalúa una falla de sesgo donde la señal medida se desplaza de su valor real como se representa en la figura 3c.

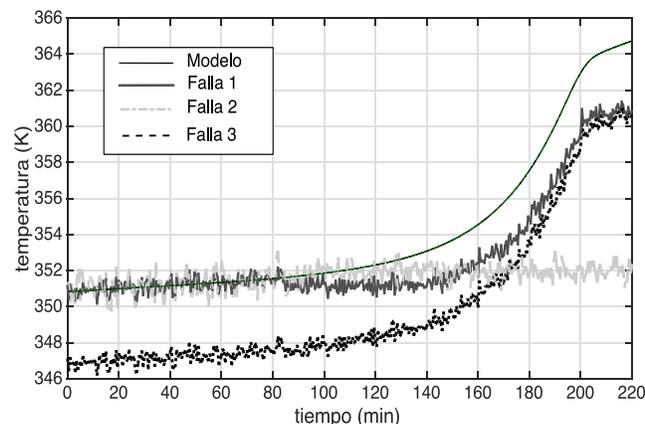


Fig.3. Fallas en el sensor 9: a) Desviación partir del minuto 100, línea negra b) Congelación c) Sesgo, línea gris a trazos. Línea continua temperaturas de referencia.

En la figura 4 se muestran los resultados de la estimación de las composiciones para tres etapas de la columna, con falla tipo 2, se puede ver como la precisión de la estimación varía de acuerdo al enfoque de filtrado. Mientras que la estimación con el FIC, casi inmediatamente después del momento del fallo del filtro, no puede seguir el estado real, el FID presenta una desviación con respecto al estado real, mientras que el FIAF y el FIAD permanecen casi invariante a la alteración introducida, haciendo que la estimación tenga el mismo comportamiento que el estado real, en

todas las etapas. El FIAF y el FIAD tienen un rendimiento muy similar, por lo que sus gráficas prácticamente se superponen. La acotación evidente que se puede hacer es que la arquitectura centralizada no es tolerante a fallas como establece la bibliografía y de hecho es la que peor desempeño tuvo.

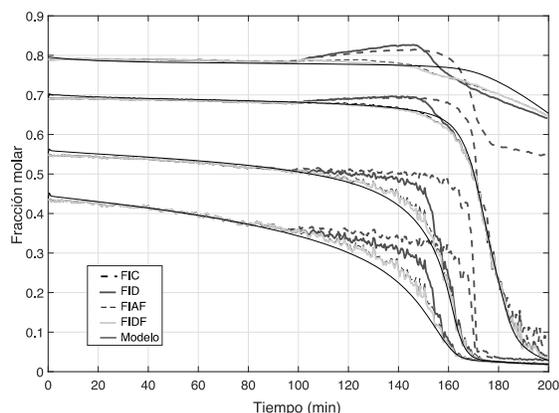


Fig.4. Estimación de la fracción molar con falla 2, sensor 9. Filtros FIC, FID, FIAF y FIDF.

La tabla 1 reporta la suma del error porcentual medio absoluto (EPMA) de la estimación de la composición de las etapas, de las pruebas realizadas para los diferentes escenarios, de manera de cuantificar el desempeño de los estimadores, corroborando los resultados de la figura 4. En el escenario 1, el error de estimación del FIAF en promedio es 16% menor que el FIC. En el escenario 2 y 3, se evidencia la superioridad del FIAF con respecto al FIC y FID. El error del FIC excede en más de un 100% al FIAF. El FIDF muestra un rendimiento muy similar al FIAF, la diferencia en el EPMA se puede adjudicar al tiempo en que tarda el filtro en detectar la falla. El FIDF tendrá un mejor rendimiento siempre que sea capaz de detectar la falla y eliminarla de la fusión, el problema es determinar de forma autónoma si se está en presencia de una falla o no. Cuando la falla es evidente, como en el escenario E3, se observa un mejor rendimiento del FIDF, pero en el caso del escenario E1 y E2, el rendimiento es el mismo. El principal inconveniente que presenta el FIDF, es que la prueba de los residuos normalizados puede generar falsas alarmas.

Tabla 1. EPMA en la estimación de la composición.

	EPMA		
	E1	E2	E3
FIC	0.1423	0.4910	0.2652
FID	0.1285	0.1903	0.2230
FIAF	0.1226	0.0981	0.9840
FIDF	0.1229	0.0946	0.9340

## 5 Conclusiones

La implementación y rendimiento de la solución estándar del filtro de Información Unscented en arquitectura

centralizada y descentralizada es comparada con el filtro propuesto bajo una estructura Federada Adaptativa y un filtro con detección de falla. Los algoritmos de filtrado fueron usados para la estimación del estado de una columna de destilación por lote a partir de datos reales de la columna. Los resultados confirman que el FIAF, con factores de distribución de información adaptativo, es capaz de incrementar la robustez del filtro contra variaciones en la señal de medición y fallas en los sensores mejorando de manera significativa la precisión de la estimación. El filtro con detección de falla tendrá un mejor rendimiento siempre que sea capaz de detectar la falla sin retraso, su desventaja es que puede causar una falsa alarma eliminando un filtro del sistema.

## Referencias

- Carlson NA, 1988, Information-sharing approach to federated Kalman filtering, In Proc. IEEE National Aerospace and Electronics Conf., pp. 1581-1586.
- Deok-Jin Lee, 2008, Nonlinear Estimation and Multiple Sensor Fusion Using Unscented Information Filtering, IEE signal processing letters, Vol.15, pp. 861-864.
- Edelmayer A, Miranda M, 2011, Federated Filtering Revisited: New Directions to Distributed Systems Estimation and Filtering- a Case Study, Acta Technica Jaurinensis, Vol.4. No.3, pp. 365-391.
- Guan B, Tang X, Ge Q, 2012, Federated Cubature Kalman Filter for Multi-sensor Information Fusion, International Conference on Computer Technology and Science 47, 253-258.
- Jonghee B, Youdan Kim, 2010, Attitude Estimation for Satellite Fault Tolerant System Using Federated Unscented Kalman Filter, Int'l J. of Aeronautical & Space Sci. Vol 11(2), pp. 80-86.
- Julier S, Uhlmann J, Durant-White H, 1995, A new Approach for filtering Nonlinear Systems, In Proceedings of the American Control Conference, pp. 1628-1632.
- Liu G, Wörgötter F, Markelic I, 2011, Nonlinear estimation using central difference information filter. In IEEE Workshop on Statistical Signal Processing, pp.593-596.
- Manasi D, Sadhu S, Ghoshal T, 2013, An Adaptive Sigma Point Filter for Nonlinear Filtering Problems, International Journal of Electrical, Electronics and Computer Engineering, Vol.2, No.2, pp. 13-19.
- 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
- Perry JH, 1967, Perry's Chemical Engineer's Handbook. 7 ed. McGraw-Hill., pp.320-330.
- Wan ER, Van der Merwe R, 2000, The Unscented Kalman Filter for Nonlinear Estimation, In Proceedings of Sympos-

sium on Adaptive Systems for Signal Processing Communication and Control, pp.153-158.

Soken, H, Hajjiyed C, 2010, Robust UKF Insensitive to Measurement Faults for Pico Satellite Attitude Estimation' International Journal of Mechanical, Aerospace, Industrial, Mechatronic and Manufacturing Engineering 4(8), pp.707-712.

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

Zamproga E, Barolo M, Seborg D, 2005, Optimal selection of soft sensor inputs for batch distillation columns using principal component analysis, Journal of Process Control, Vol.15, pp. 39-52

Zhang HB, Lenos P, Goulding Y, Wang, 2002, Adaptive Information sharing factors in Federated Kalman Filtering, 15<sup>th</sup>Triennial World Congress, IFAC, pp.211-220

**Miranda, Moira:** *Profesor Asociado de la Escuela de Ingeniería Química (ULA). Ingeniero Químico (ULA, 1998).*

*Doctor en Ingeniería de Procesos de la Universidad de Pau (Francia, 2005).*

**Méndez Dayana:** *Ingeniero Químico, Universidad de Los Andes (ULA, 2006).MSc. en Automatización e Instrumentación (ULA,2016).Correo electrónico: [daynamen@ula.ve](mailto:daynamen@ula.ve)*

**Diego Rosales.** *Ingeniero Químico (ULA, 2018).Correo electrónico:[diego.250893@gmail.com](mailto:diego.250893@gmail.com)*

**Rigoberto Flores.** *Ingeniero Químico (ULA, 2016). Correo electrónico: [rigoflores85@gmail.com](mailto:rigoflores85@gmail.com)*