

Application of the Three State Kalman Filtering for Moving Vehicle Tracking

R. Olivera, R. Olivera, O. Vite, H. Gamboa, M. A. Navarrete and C. A. Rivera

Abstract— The three-state Kalman filter (KF) is applied in the optimal estimation of three state (position, velocity and acceleration) in a moving vehicle; the problem is modeled like linear time invariant (LTI) system in presence of additive white Gaussian noise (AWGN). The steady-state filter parameters have been simulated and analyzed for different process acceleration noise (covariance). We show that KF estimation produce minimum mean square error (MSE) if acceleration noise and measurement noise are lower.

Keywords— LTI systems, optimal estimation, Kalman filter, mean square error, steady-state.

I. INTRODUCCIÓN

La inferencia probabilística o filtrado, consiste en estimar el estado de un sistema a partir de mediciones ruidosas o incompletas; históricamente el primer algoritmo de estimación óptimo fue el filtro Kalman. En 1960, Rudolf E. Kalman publicó su famoso trabajo describiendo una solución recursiva al problema de filtrado lineal en tiempo discreto [1]. A esta solución propuesta por Kalman se le conoce hoy en día como filtro Kalman. El filtro Kalman, después de más de cincuenta años de su publicación, sigue siendo uno de los algoritmos de estimación más utilizados. En términos matemáticos se puede decir que el algoritmo de Kalman estima los estados de un sistema lineal e invariante en el tiempo (LIT). La estimación mediante el filtro Kalman requiere sin embargo, del conocimiento previo de los valores estadísticos iniciales del ruido del proceso (evento físico) y del ruido de la medición u observación, así como también de la matriz de covarianza del error en la estimación. En este trabajo se presenta la simulación numérica de la estimación (rastreo) óptima de la posición, la velocidad y la aceleración de un vehículo utilizando el filtro Kalman de tres estados; el sistema se modela utilizando ecuaciones de estado que responden a la naturaleza de los sistemas lineales e invariantes en el tiempo. Se tomó como punto de partida un sistema con movimiento rectilíneo uniformemente acelerado (MRUA), con aceleración constante distinta de cero. Durante la etapa de simulación numérica, se hizo variar la desviación estándar del ruido

producido tanto en el proceso (movimiento del vehículo), así como también el ruido producido durante la medición u observación del proceso. Como medida de optimización en la estimación obtenida por el filtro, se utilizó el mínimo error cuadrático medio (ECM) cuando la respuesta del filtro alcanza su estado estable (estacionario). Los detalles inherentes al ruido del proceso en la solución al problema de estimación óptima del vehículo se explican en este reporte.

II. EL PROBLEMA DE ESTIMACIÓN

La estimación es el proceso de inferir el valor de una cantidad de interés de forma indirecta, a partir de mediciones imprecisas y ruidosas [2].

En la Fig. 1 se muestra el diagrama a bloques con cada una de las etapas que representa el problema de estimar los estados de un determinado proceso. En este caso particular, el sistema dinámico representa el movimiento del vehículo a lo largo de una determinada trayectoria o camino, cabe señalar que ésta etapa depende completamente de las ecuaciones del modelo matemático del proceso. El estimador de estados es el filtro Kalman de tres estados, el cual utiliza las mediciones obtenidas, generalmente contaminadas con cierto nivel de ruido.

Un sistema LIT en tiempo discreto [3], [4], [5], se puede describir en el espacio de estados utilizando las ecuaciones (1) y (2):

$$X_n = FX_{n-1} + \Gamma w_n \quad (1)$$

$$Y_n = HX_n + z_n \quad (2)$$

Donde $X_n \in \mathbb{R}^k$ es el vector de estado del sistema, $Y_n \in \mathbb{R}^q$ es el vector de las mediciones obtenidas. Aquí F y H son matrices. El ruido $w_n \in \mathbb{R}^p$ del sistema y el ruido $z_n \in \mathbb{R}^q$ de la medición son de tipo Gaussiano con media cero; típicamente los vectores de ruido se toman como no correlacionados, esto es $\{w_i z_j^T\} = 0$ para todo j e i . La ganancia del ruido del sistema es Γ . Las covarianzas de w_n y z_n son:

$$R = E\{w_n w_n^T\}, \quad (3)$$

$$Q = E\{z_n z_n^T\}, \quad (4)$$

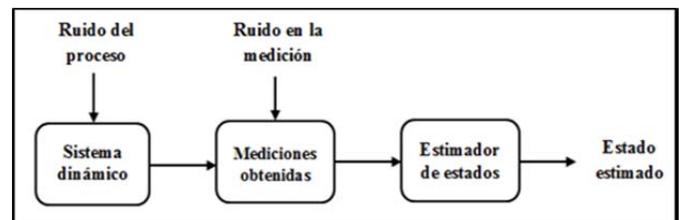


Figura 1. Diagrama general del problema de estimación de estado.

Como el objetivo principal de este trabajo es mostrar la estimación de los tres estados de un vehículo utilizando el filtro Kalman, para su mejor identificación se propone utilizar

R. Olivera, Universidad Autónoma de Zacatecas, Jalpa, Zac., México, roliverar@uaz.edu.mx

R. Olivera, Universidad Autónoma de Zacatecas, Jalpa, Zac., México, reynel@uaz.edu.mx

O. Vite, Universidad Autónoma de Zacatecas, Jalpa, Zac., México, osvichz@uaz.edu.mx

H. Gamboa, Universidad Autónoma de Zacatecas, Zacatecas, Zac., México, hamurabigr@uaz.edu.mx

M. A. Navarrete, Universidad Autónoma de Zacatecas, Jalpa, Zac., México, mecnavarrete@gmail.com

C. A. Rivera, Universidad Autónoma de San Luis Potosí, San Luis Potosí, SLP., México, c.a.riveraromero@alumnos.uaslp.edu.mx

las siguientes variables: p_n indica la posición, v_n es la velocidad y a_n la aceleración del vehículo. Como se analizará en este trabajo, el movimiento de un vehículo con aceleración constante realmente es perturbado por una cantidad de ruido en la aceleración, lo cual dará una variación en la aceleración. A continuación se presenta el modelo matemático de cada uno de los estados a estimar y su representación en el espacio de estado.

III. MODELADO MATEMÁTICO DEL PROCESO

Tomando en cuenta que las ecuaciones (1) y (2) describen el comportamiento dinámico de un proceso de aceleración constante de Wiener con segmentos constantes [4], las ecuaciones de estado se hallaron de la siguiente forma: se supone que un objeto se desplaza en línea recta y se quiere medir su posición p_n , su velocidad v_n y la aceleración a_n ; las ecuaciones derivadas son las siguientes:

$$p_{n+1} = p_n + Tv_n + \frac{1}{2}T^2a_n + \frac{1}{2}T^2w_n, \quad (5)$$

$$v_{n+1} = v_n + Ta_n + Tw_n, \quad (6)$$

$$a_{n+1} = a_n + w_n \quad (7)$$

La posición p_n , la velocidad v_n , y la aceleración a_n , son medidas en n muestras con un tiempo de muestreo T . w_n es el ruido del proceso (cambios en la aceleración), como se puede observar, el ruido está presente en cada uno de los estados del sistema.

Entonces el vector de estado que contiene a la posición, la velocidad y aceleración se puede mostrar como:

$$X_n = \begin{bmatrix} p_n \\ v_n \\ a_n \end{bmatrix} \quad (8)$$

Finalmente, sabiendo que la salida es igual a la medición actual de la posición del vehículo, entonces el sistema lineal modelado por las ecuaciones (1) y (2) puede ser reescrito como sigue:

$$X_{n+1} = \begin{bmatrix} 0 & T & \frac{1}{2}T^2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix} X_n + \begin{bmatrix} \frac{1}{2}T^2 \\ T \\ 1 \end{bmatrix} w_n \quad (9)$$

$$Y_n = [1 \ 0 \ 0]X_n + z_n \quad (10)$$

La matriz F de 3x3, es la matriz de transición que permite relacionar el estado anterior del sistema con el estado actual, en este caso F es:

$$A = \begin{bmatrix} 0 & T & \frac{1}{2}T^2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix}, \quad (11)$$

La matriz de observación $H = [1 \ 0 \ 0]$, permite la medición actual del estado del sistema mediante Y_n , la matriz de observación indica que al momento de hacer la medición solo se tiene presente la posición del vehículo. El vector de ruido del sistema es $w_n = [w_{p_n} \ w_{v_n} \ w_{a_n}]^T$, el ruido es

blanco de tipo Gaussiano con media cero, esto es $E\{w_n\} = 0$. El vector de ruido de la medición es $z_n = [z_{p_n} \ z_{v_n} \ z_{a_n}]^T$, $E\{z_n\} = 0$.

Con la descripción dada de las ecuaciones de estado, ahora el siguiente paso consiste en describir el filtro Kalman utilizado en el proceso de estimación de los estados del sistema.

IV. EL ALGORITMO DEL FILTRO KALMAN DE TRES ESTADOS

Tomando como base las ecuaciones (9) y (10) para el desarrollo del filtro de Kalman, el algoritmo de estimación se consiguió de la siguiente manera [6]. La estimación óptima de la posición, velocidad y aceleración está dada por:

$$\hat{X}_n = \bar{X}_n + K_n(Y_n - C\bar{X}_n) \quad (12)$$

$$\bar{X}_n = \Phi\bar{X}_{n-1} \quad (13)$$

Donde $\hat{X}_n = \begin{bmatrix} \hat{p}_n \\ \hat{v}_n \\ \hat{a}_n \end{bmatrix}$ es la estimación óptima de los estados

después que la medición (observación) Y_n ha sido procesada, y

$\bar{X}_n = \begin{bmatrix} \bar{p}_n \\ \bar{v}_n \\ \bar{a}_n \end{bmatrix}$ es la estimación óptima de los estados antes que la

medición Y_n sea procesada.

La ganancia K_n del filtro Kalman está dada por la matriz:

$$K_n = \bar{P}_n H' (H \bar{P}_n H' + R)^{-1} \quad (14),$$

donde $R = \sigma_x^2$ es la varianza del ruido en la observación y \bar{P}_n es la matriz de covarianza del error de estimación previo al procesamiento de Y_n . La matriz de covarianza \bar{P}_n se calcula recursivamente usando la ecuación de la varianza:

$$\bar{P}_{n+1} = \Phi \bar{P}_n \Phi' + \Gamma Q \Gamma' \quad (15)$$

con

$$\hat{P}_n = (I - K_n H) \bar{P}_n \quad (16)$$

O equivalentemente,

$$\hat{P}_n^{-1} = \bar{P}_n^{-1} + H' R^{-1} H \quad (17),$$

donde \hat{P}_n es la matriz de covarianza del error de estimación después (posterior) de procesar la medición Y_n y $Q = \sigma_a^2$ es la varianza de la aceleración aleatoria.

En el estado estable, $\bar{P}_{n+1} = \bar{P}_n = \bar{P}$ y $\hat{P}_{n+1} = \hat{P}_n = \hat{P}$. Por lo tanto las ecuaciones (15) y (17) se transforman en:

$$\bar{P} = \Phi \bar{P} \Phi' + \Gamma Q \Gamma' \quad (18)$$

$$\hat{P}^{-1} = \bar{P}^{-1} + H' R^{-1} H \quad (19)$$

Para facilitar el análisis del sistema, las ecuaciones (15) y (16) son reescritas de la siguiente manera:

$$\bar{P} - \Gamma Q \Gamma' = \Phi (I - K_n H) \bar{P} \Phi', \quad (20)$$

la matriz de covarianza \bar{P} tiene sus componentes definidos como

$$\bar{P} = \begin{bmatrix} \bar{P}_{11} & \bar{P}_{12} & \bar{P}_{13} \\ \bar{P}_{21} & \bar{P}_{22} & \bar{P}_{23} \\ \bar{P}_{31} & \bar{P}_{32} & \bar{P}_{33} \end{bmatrix} \quad (21).$$

En la diagonal principal de la matriz de covarianza previa, se encuentran los valores medios cuadráticos del error en la estimación de cada estado.

Los elementos que componen a la matriz de covarianza posterior \hat{P} se pueden definir de la siguiente forma:

$$\hat{P} = \begin{bmatrix} \hat{P}_{11} & \hat{P}_{12} & \hat{P}_{13} \\ \hat{P}_{21} & \hat{P}_{22} & \hat{P}_{23} \\ \hat{P}_{31} & \hat{P}_{32} & \hat{P}_{33} \end{bmatrix} \quad (22)$$

V. ANÁLISIS DEL FILTRO KALMAN EN EL ESTADO ESTABLE

Partiendo de la premisa que el sistema bajo análisis es del tipo lineal e invariante en el tiempo con ruido blanco gaussiano, el candidato ideal para resolver el problema de estimación óptimo es el filtro Kalman. La solución mostrada por el filtro Kalman se divide en transitoria y estacionaria, siendo la respuesta estacionaria de particular interés en este trabajo. A partir de este punto, se introduce un importante parámetro denominado el índice de rastreo λ , el cual caracteriza la solución general del problema de rastreo o seguimiento. El índice de rastreo es un parámetro adimensional, proporcional a la relación de la varianza en la posición debida a la maniobrabilidad del objeto (vehículo) y la medición entregada por el sensor:

$$\lambda \triangleq \frac{\sigma_a^2 T^2}{\sigma_x^2} \quad (23)$$

En el estado estable o invariante en el tiempo, la matriz de ganancia del filtro Kalman se puede aproximar de la siguiente forma como en [5], [6], [7]:

$$K = \begin{bmatrix} K_p \\ K_v \\ K_a \end{bmatrix} = \begin{bmatrix} \alpha \\ \beta/T \\ \gamma/2T^2 \end{bmatrix}, \text{ de esta forma se asume que una vez}$$

alcanzado la respuesta en el estado estable, la ganancia del filtro no variará, manteniéndose constante cuando $n \rightarrow \infty$.

La solución general en el estado estable de la matriz de ganancia del filtro Kalman de tres estados nos conduce a los coeficientes del filtro *alfa-beta-gamma* (α - β - γ) [8]. Tomando como referencia las ecuaciones descritas en [4], las incertidumbres (varianza) del filtro Kalman en estado estable son:

$$\hat{P}_{11} = \alpha \sigma_x^2 \quad \hat{P}_{12} = \frac{\beta}{T} \sigma_x^2 \quad \hat{P}_{13} = \frac{\gamma}{2T^2} \sigma_x^2 \quad (24)$$

$$\hat{P}_{22} = \frac{8\alpha\beta + \gamma(\beta - 2\alpha - 4)}{8T^2(1-\alpha)} \sigma_x^2 \quad (25)$$

$$\hat{P}_{23} = \frac{\beta(2\beta - \gamma)}{4T^3(1-\alpha)} \sigma_x^2 \quad \hat{P}_{33} = \frac{\gamma(2\beta - \gamma)}{4T^4(1-\alpha)} \sigma_x^2 \quad (26)$$

Como se puede observar en (24), las ganancias del filtro Kalman en estado estacionario se definen como

$$K_p = \alpha = \frac{\hat{P}_{11}}{\sigma_x^2}, \quad K_v = \frac{\beta}{T} = \frac{\hat{P}_{12}}{\sigma_x^2}, \quad K_a = \frac{\gamma}{2T^2} = \frac{\hat{P}_{13}}{\sigma_x^2} \quad (27)$$

VI. RESULTADOS.

Una vez descritas las ecuaciones matemáticas del filtro Kalman de tres estados, así como sus ganancias en el estado estacionario, se procedió a realizar la simulación computacional correspondiente a las estimaciones de los tres estados; el software utilizado para la simulación computacional fue el Matlab® 2009, ejecutándose en una computadora portátil DELL con procesador Intel® Core(TM) i5-337U CPU @ 1.80 GHz. El proceso de simulación y estimación se formó con una señal de medición utilizando los

primeros 1500 puntos de observación, tal como se muestra en la Fig. 2. En la Fig. 3 y Fig. 4 se muestra el resultado de las estimaciones de la velocidad y la aceleración del vehículo. La frecuencia de muestreo utilizada en este experimento fue de 10 muestras por segundo ($T = 0.1$ s), la desviación estándar en la medición de la posición $\sigma_x = 10$ m, un ruido de proceso de aceleración discreto con aceleración $\sigma_a = 0.001$ m/s²; el estado inicial del sistema se tomó como $\hat{x}_{0|0}^T = [0 \ 0 \ 0]$, la matriz

$$\Gamma Q \Gamma' = \begin{bmatrix} 2.5 \times 10^{-11} & 5 \times 10^{-10} & 5 \times 10^{-9} \\ 5 \times 10^{-10} & 1 \times 10^{-8} & 1 \times 10^{-7} \\ 5 \times 10^{-9} & 1 \times 10^{-7} & 1 \times 10^{-6} \end{bmatrix}, \text{ la covarianza del}$$

error en la medición fue $R = 100$ m², el índice de rastreo o maniobrabilidad fue $\lambda = 1 \times 10^{-10}$. Los parámetros anteriormente mencionados fueron tomados en cuenta por el filtro Kalman para hacer la estimación correspondiente de la posición, velocidad y aceleración. En la Fig. 5 se muestra el error de estimación en la posición alcanzado por el filtro Kalman.

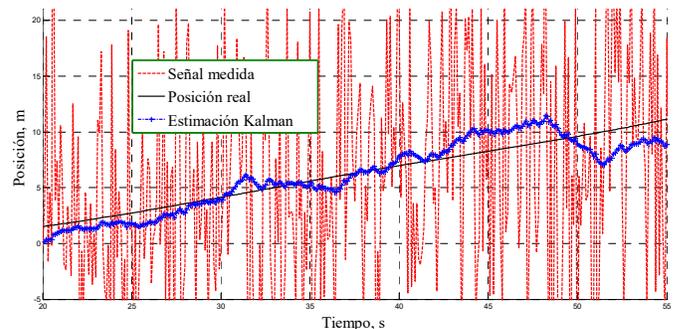


Figura 2. Estimación de la posición utilizando el filtro Kalman de tres estados.

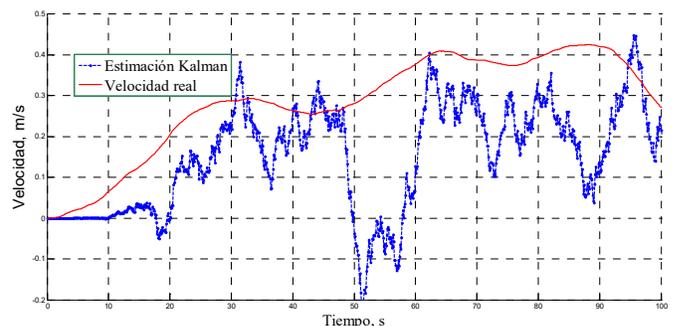


Figura 3. Estimación de la velocidad utilizando el filtro Kalman de tres estados.

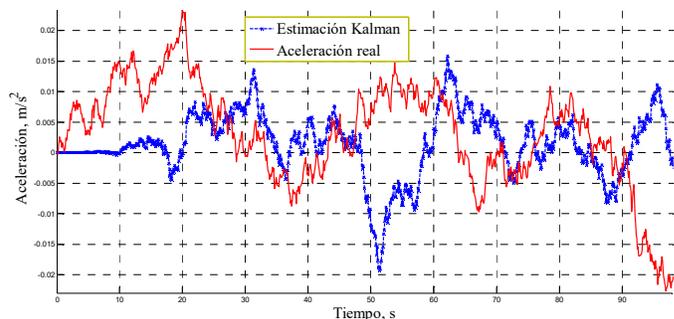


Figura 4. Estimación de la aceleración utilizando el filtro Kalman de tres estados.

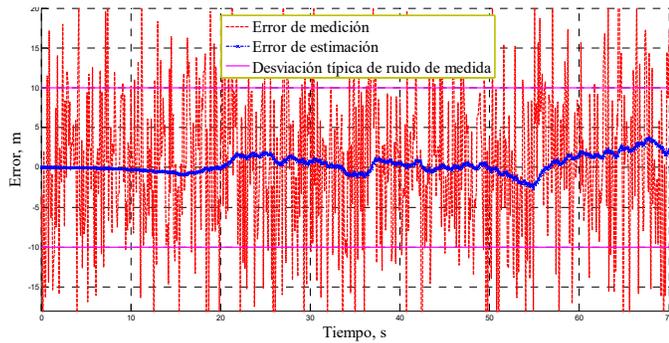


Figura 5. Error en la medición y estimación de la posición logrado por el filtro Kalman de tres estados con $\sigma_a = 0.001 \text{ m/s}^2$ y $\sigma_x = 10 \text{ m}$.

Como se puede observar en la Fig. 5, el error en la estimación de la posición del vehículo se reduce a un nivel mínimo, también en esta misma figura se puede apreciar la desviación típica en la medición (calidad del sensor), el cual da un rango de 10 metros, aunque como se puede analizar, en algunos instantes de tiempo discreto se toman mediciones que alcanzan aproximadamente los 30 metros; razón por la cual se confirma la eficacia del filtro Kalman de tres estados en la estimación de la posición del vehículo. En la Tabla 1 se resumen los resultados alcanzados en la estimación de la posición utilizando los parámetros de simulación anteriormente mencionados, así como también la variación del nivel de aceleración en el proceso; en esta tabla se muestra el ECM tanto en la medición como en la estimación de la posición.

TABLA I

ECM EN LA MEDICIÓN Y ESTIMACIÓN DE LA POSICIÓN DE UN VEHÍCULO APLICANDO EL FILTRO KALMAN DE TRES ESTADOS

Nivel de aceleración (m/s^2)	Precisión del sensor (m)	ECM en la medición (m)	ECM en la estimación (m)
$\sigma_a = 0.001$	$\sigma_x = 10$	92.85	2.77
$\sigma_a = 0.01$	$\sigma_x = 10$	103.13	5.23
$\sigma_a = 0.1$	$\sigma_x = 10$	100.62	16.50

En la Fig. 6 se muestra el efecto en la estimación de la posición del vehículo variando en nivel de aceleración $\sigma_a = 0.01 \text{ m/s}^2$, en contraste con los resultados obtenidos en la Fig. 5, en la Fig. 6 se observa una mayor variación en la estimación como resultado del incremento en el ruido de aceleración del proceso.

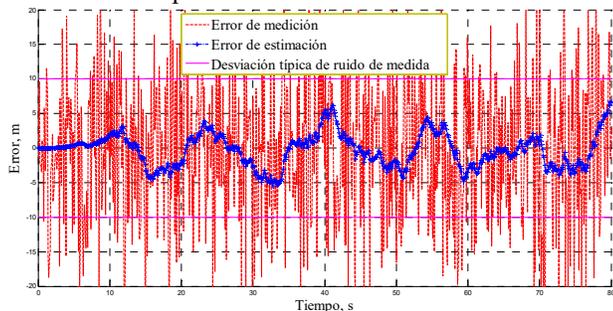


Figura 6. Error en la medición y estimación de la posición logrado por el filtro Kalman de tres estados con $\sigma_a = 0.01 \text{ m/s}^2$ y $\sigma_x = 10 \text{ m}$.

En la Fig. 7 se muestra el comportamiento de las ganancias del filtro Kalman para la posición, la velocidad y la aceleración, como se puede observar la respuesta para en cada una de ellas es similar a la respuesta de un sistema LIT de primer orden, mostrando una respuesta transitoria de aproximadamente 25 muestras discretas. Es de importancia hacer notar que las ganancias del filtro Kalman de tres estados (estacionario) están directamente relacionadas con el periodo de muestreo T , el ruido del proceso σ_a y el ruido en la medición σ_x empleados.

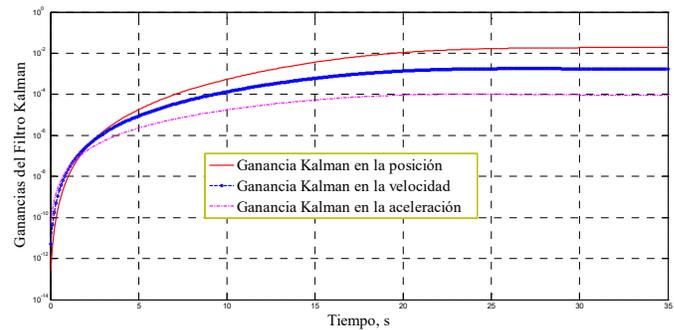


Figura 7. Comportamiento de las ganancias del Filtro Kalman de tres estados.

VII. CONCLUSIONES.

En este reporte se mostró el comportamiento mediante simulación numérica del filtro Kalman de tres estados, los estados estimados fueron la posición, la velocidad y la aceleración de un vehículo; primeramente cabe mencionar que el filtro Kalman necesitó del conocimiento total del ruido del proceso a estimar, así como también de la desviación típica del sensor, lo que se podría traducir en la calidad del sensor utilizado. Como el sistema analizado mediante las ecuaciones de estado es un sistema LIT, se puede utilizar el filtro Kalman estacionario con sus respectivas ganancias; mismas que se alcanzan con el conocimiento del ruido y el periodo de muestreo del filtro. Es de notar también que la variación en el nivel de aceleración del proceso afecta al ECM en la estimación, lo que se podría mejorar con un sensor de mayor precisión. Finalmente cabe resaltar, que el problema de estimación óptima en el posicionamiento y rastreo de un objeto puede ser de menor consecuencia si se trata por ejemplo de estacionar un vehículo en una calle común de nuestro vecindario; sin embargo el resultado podría ser desastroso si se trata de posicionar un satélite en el espacio o conducir una aeronave cercana a una frontera de un país en guerra.

REFERENCIAS

- [1] R. Olivera, R. Olivera, O. Vite, H. Gamboa, M. Á. Navarrete, C. A. Rivera, "Optimal States Estimation of an LTI System Using the Unbiased FIR Filter", *IEEE Latin America Transaction*, vol. 13, no. 3, pp 609-612, 2015.
- [2] Y. B. Shalom, X. R. Li, *Estimation and Tracking: Principles, Techniques, and Software*, Artech House, Norwood, 1993.
- [3] D. Simon, Y. S. Shmaliy, "Unified Forms for Kalman and Finite Impulse Response Filtering and Smoothing", *Automatica*, vol. 49, no. 6, pp. 1892-1899, 2013.

- [4] Y. B. Shalom, X. R. Li, T. Kirubarajan, *Estimation with Applications to Tracking and Navigation: Theory Algorithms and Software*, John Wiley and Sons, Inc., 2001.
- [5] K. V. Ramachandra, "Optimum Steady State Position, Velocity, and Acceleration Estimation Using Noisy Sampled Position Data", *IEEE Transaction on Aerospace and Electronic Systems*, vol. AES-23, no. 5, pp. 705-709, 1987.
- [6] B. Friedland, "Optimum Steady State Position and Velocity Estimation Using Noisy Sampled Position Data", *IEEE Transaction on Aerospace and Electronic Systems*, vol. AES-9, no. 6, pp. 906-911, 1973.
- [7] P. R. Kalata, "The Tracking Index: A Generalized Parameter for α - β and α - β - γ Target Trackers", *IEEE Transaction on Aerospace and Electronic Systems*, vol. AES-20, no. 2, pp. 174-182, 1984.
- [8] C. Pérez-Vidal, L. Gracia, O. Reinoso, "Fusión Borrosa de Estimadores para Aplicaciones de Control Basado en Imagen", *Revista Iberoamericana de Automática e Informática Industrial*, vol. 7, no. 2, pp. 81-90, 2010.



Roberto Olivera Reyna recibió el grado de Ingeniero Electromecánico por parte del Instituto Tecnológico del Istmo en el año 2000. Obtuvo el grado de Maestro en Ingeniería Eléctrica con especialidad en Procesamiento Digital de Señales por parte de la Facultad de Ingeniería Mecánica Eléctrica y Electrónica (FIMEE) en la Universidad de Guanajuato en 2003. Actualmente es Profesor-Investigador en la Unidad Académica de Ingeniería Eléctrica Jalpa de la Universidad Autónoma de Zacatecas, México. Sus áreas de investigación incluyen el procesamiento digital de señales y el control.



Reynel Olivera Reyna recibió el grado de Ingeniero Electromecánico por parte del Instituto Tecnológico del Istmo en el año 2000. Obtuvo el grado de Maestro en Ingeniería Eléctrica con especialidad en Procesamiento Digital de Señales por parte de la Facultad de Ingeniería Mecánica Eléctrica y Electrónica (FIMEE) en la Universidad de Guanajuato en 2003. Actualmente es Profesor-Investigador en la Unidad Académica de Ingeniería Eléctrica Jalpa de la Universidad Autónoma de Zacatecas, México. Sus áreas de interés incluyen el procesamiento digital de señales y la instrumentación.



Osbaldo Vite Chávez es Ingeniero en Instrumentación Electrónica egresado de la Universidad Veracruzana en 2000. Obtuvo el grado de Maestro en Ingeniería Eléctrica con especialidad en Procesamiento Digital de Señales por parte de la Facultad de Ingeniería Mecánica Eléctrica y Electrónica (FIMEE) en la Universidad de Guanajuato en 2003. Actualmente es Profesor-Investigador en la Unidad Académica de Ingeniería Eléctrica Jalpa de la Universidad Autónoma de Zacatecas, México. Sus áreas de interés incluyen el procesamiento digital de imágenes y la instrumentación electrónica.



Hamurabi Gamboa Rosales es Ingeniero en Electrónica y Comunicaciones egresado de la Facultad de Ingeniería de la Universidad Autónoma de Guadalajara en 2000. Realizó sus estudios de Maestría de 2001 a 2003 con orientación en Procesamiento Digital de Señales (FIMEE) en la Universidad de Guanajuato. Realizó sus estudios de Doctorado en la Universidad Técnica de Dresde, Alemania en el área de Procesamiento de Voz 2010. Actualmente labora como Profesor-Investigador en la Unidad Académica de Ingeniería Eléctrica de la Universidad Autónoma de Zacatecas, México en el área de investigación de Procesamiento Digital de Señales.



Miguel Ángel Navarrete Sánchez es Ingeniero en Sistemas Computacionales egresado del Instituto Tecnológico de Zacatecas en el año 2002. Obtuvo el grado de Maestro en Ciencias de la Computación por parte del Laboratorio Nacional de Informática Avanzada (LANIA) Xalapa, Veracruz en 2007. Actualmente es Profesor-Investigador en la Unidad Académica de Ingeniería Eléctrica Jalpa de la Universidad Autónoma de Zacatecas, México. Sus áreas de interés incluyen la robótica y computación aplicada.



Claudia Angélica Rivera Romero es Ingeniero en Computación egresada de la Universidad Autónoma de Zacatecas en el año 2006. Obtuvo el grado de Maestro en Ingeniería en la División de Ingenierías Campus Irapuato-Salamanca de la Universidad de Guanajuato en el año 2012. Actualmente es Docente Investigador de la Unidad Académica de Ingeniería Eléctrica Jalpa en la Universidad Autónoma de Zacatecas, México. Sus áreas de interés son el procesamiento de imágenes, instrumentación electrónica y la computación aplicada.