

ESTIMACIÓN HÍBRIDA DE POSICIÓN ANGULAR EN DISPOSITIVOS DE CAPTURA DE IMÁGENES AÉREAS

Marco Miretti*, Facundo Busano, Emanuel Bernardi, Hugo Pipino, Gastón Peretti

*Grupo de Investigación y Desarrollo Electrónico (GIDE)
Universidad Tecnológica Nacional, Facultad Regional San Francisco (UTN-FRSFCO)
Avenida de la Universidad 501 (2400) San Francisco. Argentina.*

Resumen

El presente trabajo aborda el análisis, implementación y comparación de resultados de dos técnicas frecuentemente empleadas en la fusión de sensores. Éstas son: filtro de Kalman y filtro complementario. Además, se trata la adecuación de la información brindada por los sensores involucrados.

Dichas técnicas se utilizan para lograr una estimación óptima de los estados del sistema. Para luego, en base a posición angular estimada, desarrollar un sistema de estabilización de un dispositivo de captura de imágenes aéreas que nos permita la evaluación cuantitativa de superficies sembradas, inundadas o sin explotar.

Palabras clave: control, filtro de Kalman, fusión de sensores, filtro complementario.

1. Introducción

En las últimas décadas, el avance de la tecnología sobre los procesos y técnicas agro-industriales ha fortalecido el crecimiento de esta actividad y contribuido al desarrollo de la explotación óptima de los recursos disponibles. Un requisito básico e indispensable para dichas mejoras es el conocimiento preciso de las características y cualidades del entorno en el que se desarrollan las mismas.

Históricamente, la evaluación de superficies sembradas, inundadas o sin explotar, la estimación de rendimientos, necesidades hídricas o tipos de cultivos se llevó a cabo mediante imágenes satelitales. Este tipo de tecnologías involucran un alto costo para la ejecución de sus misiones y por consiguiente su explotación es de acceso limitado. En cambio, la reciente evolución de los vehículos aéreos no tripulados (*Unmanned Aerial Vehicle, UAV*) permite sobrevolar regiones de interés invirtiendo menor cantidad de recursos y, de este modo, capturar imágenes para el posterior análisis de las características deseadas.

Para la correcta obtención de imágenes, es necesaria la utilización de sistemas de captura que permiten el seguimiento preciso del objetivo, la reducción de vibraciones y la estabilización del elemento de captura, o cámara. Los desarrollos en UAV, tales como el sistema de captura de imágenes, exigen la implementación de dispositivos de control y elementos de medición pequeños, ligeros y de bajo consumo de energía. Específicamente, la estimación precisa y sencilla de los estados del sistema resulta fundamental a la hora de implementar técnicas de control modernas. Es por ello, que en el presente trabajo nos enfocamos en la estimación de los parámetros necesarios para el control del sistema de estabilización,

*Autor en correspondencia.

Correo electrónico: marco.miretti@gmail.com (Marco Miretti)

empleando sensores inerciales micro-electro-mecánicos (*MicroElectroMechanical Systems*, MEMS). Los MEMS de bajo costo, son ideales para la construcción de sistemas de medición móviles, debido a su tamaño, peso y consumo de energía.

La medición de la posición angular en base a sensores inerciales MEMS se lleva a cabo de diferentes maneras. La primera surge de integrar, a reducidos períodos de muestreo, la velocidad angular instantánea medida por el giróscopo. Esta medición está sujeta a errores acumulados a lo largo del tiempo, por lo que, la implementación de este método requiere del uso de giróscopos con salidas excepcionalmente precisas y estables. Desafortunadamente, los MEMS de bajo costo no cumplen con este requisito. Por otra parte, la segunda aproximación supone una baja aceleración dinámica lineal, y de este modo, utiliza acelerómetros para estimar la posición angular en base a proyecciones de las componentes gravitacionales. Por lo tanto, el estado de los acelerómetros en un instante particular en el tiempo predice la orientación del sistema.

Como consecuencia de la presencia de las perturbaciones, el ruido inherente y la deriva que afecta las mediciones, es estrictamente necesaria la implementación de técnicas capaces de acondicionar e integrar ambas aproximaciones, y así lograr la correcta estimación de los parámetros involucrados. Entre las herramientas más comunes se encuentran el filtro de Kalman y el filtro complementario.

La formulación original del filtro de Kalman, fue desarrollada por Rudolf Emil Kálmán a principios de los años sesenta [1, 2, 3]. Está conformado por un conjunto de ecuaciones matemáticas que implementan un estimador del tipo predictor-corrector óptimo, en el sentido que minimiza la covarianza del error de estimación, siempre que se cumplan ciertas condiciones. Desde su introducción, el filtro de Kalman ha sido sujeto de extensas investigaciones y aplicaciones, particularmente en el área de sistemas de navegación autónomos o asistidos. Por otro lado, el filtro complementario constituye una sencilla técnica de fusión de sensores [3, 4, 5], debido a que no posee una fuerte fundamentación matemática.

Por lo tanto, nuestro trabajo propone el análisis, clasificación e implementación de técnicas de fusión de sensores (filtro de Kalman y filtro complementario) que nos permiten la óptima estimación de los estados involucrados, para luego, en base a estos resultados contribuir a un proyecto de mayor alcance, como lo es la evaluación cuantitativa de superficies sembradas, inundadas o sin explotar.

2. Filtro de Kalman

El algoritmo del filtro de Kalman asume un sistema lineal e invariante en el tiempo discreto, afectado por perturbaciones de distribución gaussiana y representado por un modelo en espacio de estados:

$$\begin{aligned}x_k &= Ax_{k-1} + Bu_{k-1} + \omega_{k-1} \\z_k &= Hx_k + \gamma_k\end{aligned}\tag{1}$$

donde $x \in \mathbb{R}^{nx}$ es el vector de estados, $u \in \mathbb{R}^{nu}$ el vector de entradas y $z \in \mathbb{R}^{nm}$ el vector de mediciones. Además, $\omega_k \sim N(0, Q)$ es el ruido de proceso y $\gamma_k \sim N(0, R)$ el ruido de medición, ambos gaussianos y asumidos no correlacionados. Por último, A , B y H son matrices conocidas de dimensiones adecuadas.

El filtro de Kalman es un algoritmo recursivo, que a partir del conocimiento de la covarianza esperada de las variables de estado corrige una estimación a priori de los estados del sistema y la covarianza misma. La estimación obtenida por el filtro de Kalman es estadísticamente óptima. Además, tal como se observa en la Fig. 1, el algoritmo se divide en dos etapas principales, éstas son: predicción y corrección.

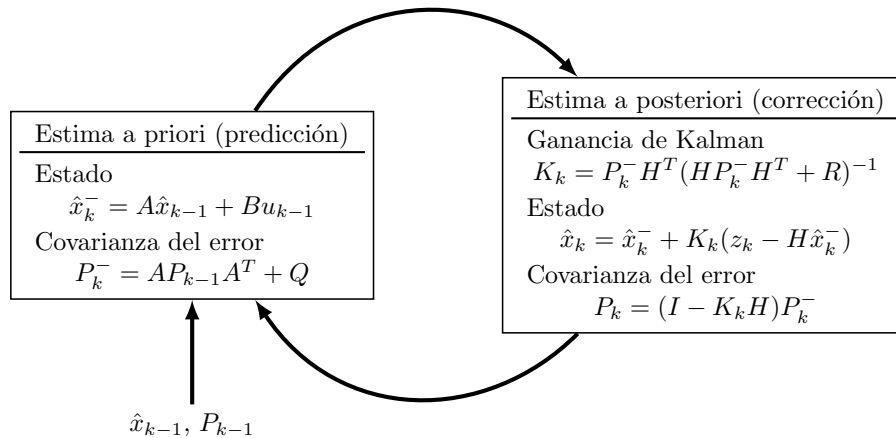


Figura 1: Algoritmo del filtro de Kalman.

De este modo, el filtro de Kalman se aboca a la estimación de los estados x_k en base al conocimiento de la dinámica del sistema (1), las características de la perturbación y la disponibilidad de las mediciones ruidosas z_k .

Las matrices Q y R se corresponden con la covarianza del ruido de proceso y el ruido de medición, respectivamente, P_k es la matriz de la covarianza del error de estimación y K_k es la matriz de ganancia de Kalman. Es importante notar que si el ruido de proceso es significativamente mayor al ruido de medición, la ganancia de Kalman crece, lo que trae aparejado que el algoritmo confíe más en las mediciones que en la estimación. Por el contrario, si el ruido de proceso es considerablemente menor que el ruido de medición, la ganancia de Kalman se vuelve pequeña conduciendo al filtro a confiar más en la estimación por sobre la medición.

3. Filtro complementario

La estructura básica del filtro complementario se muestra en la Fig. 2, donde θ_{acel} y $\dot{\theta}_{giro}$ son las mediciones ruidosas de la posición y velocidad angular, respectivamente. Además, θ se corresponde con la estimación de la posición angular producida por el filtro.




Figura 2: Diagrama de bloques del filtro complementario.

Para el análisis del funcionamiento del filtro complementario se asume que θ_{acel} posee principalmente ruido de alta frecuencia, el cual se atenúa a través de un filtro pasa bajos. Por otro lado, la integración de la señal $\dot{\theta}_{giro}$, para obtener θ_{giro} , atenúa el ruido gaussiano de alta frecuencia en la medición de la velocidad angular, y luego a partir de un filtro pasa altos, complementario del filtro pasa bajos de la rama superior, se atenúan las componentes de baja frecuencia, ó derivas, que afectan la medición. La estimación del ángulo θ se compone de los resultados de ambas operaciones.

A continuación, se presenta la implementación digital del filtro complementario como una ecuación recursiva. Esto es,

$$\theta_k = \underbrace{\alpha(\theta_{k-1} + \theta_{giro}\Delta t)}_{\text{filtro pasa altos}} + \underbrace{(1 - \alpha)\theta_{accel}}_{\text{filtro pasa bajos}} \quad (2)$$

donde θ se corresponde con el ángulo estimado, $\dot{\theta}_{giro}$ la velocidad angular medida por el giróscopo, θ_{accel} el ángulo proyectado por el acelerómetro y α la constante del filtro pasa altos (complementario a la constante del filtro pasa bajos).

La constante de ponderación α se elige a partir de la constante de tiempo deseada en el filtro τ y del período de muestreo del sistema Δt . Esto es,

$$\alpha = \frac{\tau}{\tau + \Delta t} \quad (3)$$

4. Aplicación

Tal como introdujimos en § 1, para la estimación de los parámetros involucrados en el control del sistema de estabilización (ángulos de balanceo y cabeceo) se utilizó un conjunto de sensores MEMS que componen una unidad de medición inercial (*Inercial Measurement Unit*, IMU). Para ello, en base a su bajo costo y alta disponibilidad, optamos por la IMU de seis grados de libertad MPU6050 [6] compuesta de un giróscopo y un acelerómetro, ambos de tres ejes. Desafortunadamente, la medición de la posición angular empleando una IMU no es factible en forma directa y es preciso acondicionar su salida para obtener una correcta estimación de los parámetros de interés. Por lo tanto vamos a analizar el comportamiento de cada uno de sus componentes

4.1. Giróscopo

Un giróscopo es un elemento capaz de medir la tasa de cambio de la posición angular en un intervalo de tiempo, dicho de otro modo la velocidad angular $\dot{\theta}_k$. Por lo tanto, es posible obtener la posición angular en cada instante de tiempo θ_k a partir de la integración de la velocidad angular a reducidos períodos de muestreo. Esto es,

$$\theta_k = \sum_{i=0}^k \dot{\theta}_i \Delta t \quad (4)$$

de forma recursiva, $\theta_k = \theta_{k-1} + \dot{\theta}_k \Delta t$.

Es importante notar, que debido a la acumulación de errores en el tiempo, dicha implementación es susceptible a derivas. Como consecuencia, a menor período de muestreo menor será la deriva.

4.2. Acelerómetro

Un acelerómetro, es un dispositivo capaz de medir la fuerza empleada para acelerar una masa de prueba, previamente calibrada. De este modo, dicha información puede usarse para obtener la posición angular del sensor en relación a la superficie de la tierra, suponiendo una baja aceleración dinámica lineal.

Por lo tanto, la posición angular se obtiene en base a las proyecciones de las componentes gravitacionales [7, 8]. Esto es,

$$\zeta = \arctan \left(\frac{x_a}{\sqrt{y_a^2 + z_a^2}} \right), \quad \beta = \arctan \left(\frac{y_a}{\sqrt{x_a^2 + z_a^2}} \right) \quad (5)$$

donde x_a , y_a y z_a son las mediciones del acelerómetro. Además, las proyecciones ζ y β son el ángulo de cabeceo y balanceo, respectivamente, ambos en radianes. Los cuales constituyen la medición angular entregada por el acelerómetro $\theta_{acel} = \{\zeta, \beta\}$. Gráficamente, vemos en la Fig. 3 la variación angular experimentada en el acelerómetro. Donde en Fig. 3a se observa el balanceo y en la Fig. 3b se muestra el cabeceo.




Figura 3: Variación angular.

4.3. Modelo de medición inercial

Para evaluar la validez del filtro de Kalman, se implementó un sistema de medición inercial en base al modelo de tiempo discreto (1) cuyos estados y matrices son:

$$x = \begin{bmatrix} \zeta \\ \beta \\ \dot{\zeta} \\ \dot{\beta} \end{bmatrix}, \quad A = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad B = \begin{bmatrix} \Delta t & 0 \\ 0 & \Delta t \\ 1 & 0 \\ 0 & 1 \end{bmatrix}, \quad H = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \quad (6)$$

donde $\Delta t = 0,05$ s y las matrices de covarianza, obtenidas en base al análisis estadístico de mediciones estacionarias y a la observación del comportamiento del filtro, son:

$$Q = 1 \times 10^{-6} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad R = 1 \times 10^{-5} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad (7)$$

5. Resultados

A partir de las matrices (6) y (7) que conforman el modelo (1) se ensayaron las técnicas de fusión de sensores en el sistema de medición inercial frente a distintas perturbaciones durante 30 s, sus resultados se muestran en la Fig. 4.

Así, luego de aproximadamente 2 s de iniciar la corrida se imprimió sobre la IMU un cabeceo, en ambos sentidos, de duración 11 s, que se observa con claridad en la Fig. 4b. Inmediatamente se realizó un balanceo, también en ambos sentidos, hasta los 22 s, como se muestra en la Fig. 4a. Por último, se realizó una leve vibración y a los 25 s se la dejó reposar.

Los resultados del ensayo, frente a una baja aceleración dinámica, muestran como la deriva afecta al giróscopo mientras que las mediciones del acelerómetro prácticamente coinciden con las estimaciones. Además, se observa que en presencia de una mayor aceleración sobre la IMU, las estimaciones se aproximan a las mediciones del giróscopo, y en consecuencia, se aprecia una elevada sensibilidad del acelerómetro frente a las vibraciones.

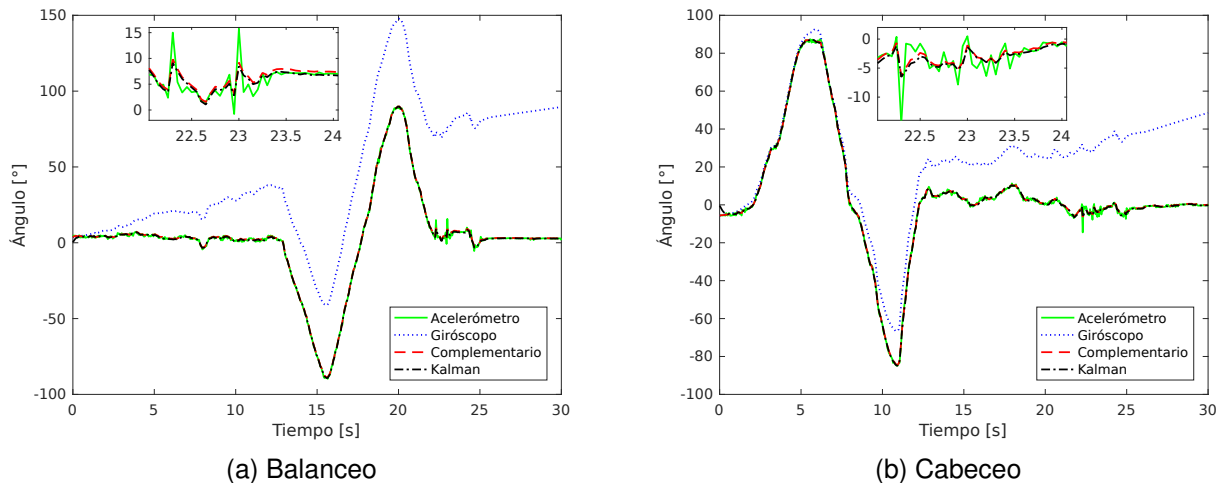


Figura 4: Resultados.

6. Conclusión

En base al análisis, implementación y evaluación de las técnicas de fusión de sensores presentadas, vemos que sus desempeños son por demás satisfactorios. Esto es, tanto el filtro de Kalman como el filtro complementario son capaces de lograr una estimación correcta de la posición angular a partir de la fusión de los sensores disponibles.

Por otro lado, la complejidad inherente a la comprensión e implementación del algoritmo del filtro de Kalman, frente a la simplicidad del filtro complementario hace que, en aplicaciones donde los recursos de procesamiento disponibles sean reducidos, resulte recomendable la utilización de este último.

Como consecuencia, pese a todas las bondades matemáticas y estadísticas que posee el filtro de Kalman, resulta considerablemente más razonable y viable la utilización del filtro complementario en el dispositivo de estabilización y captura de imágenes aéreas que nos permita la evaluación cuantitativa de superficies sembradas, inundadas o sin explotar.

Referencias

- [1] R. E. Kalman, A New Approach to Linear Filtering and Prediction Problems, *Journal of Fluids Engineering* 82 (1960) 35–45.
- [2] R. Faragher, Understanding the basis of the kalman filter via a simple and intuitive derivation [lecture notes], *IEEE Signal Processing Magazine* 29 (2012) 128–132.
- [3] R. G. Brown, P. Y. C. Hwang, *Introduction to Random Signals and Applied Kalman Filtering With MATLAB Exercises*, John Wiley & Sons, Inc, 4 edition, 2012.
- [4] E. Malinen, *Fusion of data from quadcopter's inertial measurement unit using complementary filter*, 2015.
- [5] S. Colton, *The balance filter: a simple solution for integrating accelerometer and gyroscope measurements for a balancing platform*, white paper, Massachusetts Institute of Technology, Cambridge, MA (2007).
- [6] InvenSense, *MPU-6000 and MPU-6050 Product Specification - Revision 3.4*, Technical Report, 2013.
- [7] J. Diebel, *Representing attitude: Euler angles, unit quaternions, and rotation vectors* (2006).
- [8] STMicroelectronics, *AN4509 - Tilt measurement using a low-g 3-axis accelerometer*, Technical Report, 2014.