

Implementación de un Sistema de Odometría Visual y Estructura a Partir del Movimiento para la Estabilización de Vehículos Aéreos No Tripulados

Tarrio Juan José, Instituto Balseiro, CNEA

31 de octubre de 2014

Resumen

En este trabajo se describe la implementación de un algoritmo eficiente para determinar la velocidad y estructura del entorno de un vehículo aéreo no tripulado (VANT), equipado con cámara frontal y unidad de medición inercial. El mismo permite la auto-estabilización del VANT en un ambiente cerrado. El sistema descrito es capaz de correr en tiempo real sobre el vehículo, utilizando unidades de procesamiento comunes en aplicaciones de telefonía celular.

1. Introducción

Los Vehículos Aéreos No Tripulados (VANTs) forman un área de investigación activa muy amplia en esta época. La miniaturización y descenso del costo de los componentes ha permitido que este tipo de sistema estén al alcance de un gran número de personas.

Sin embargo el vuelo y navegación autónoma todavía presenta numerosos desafíos, muchos de los cuales se deben a las características del vehículo aéreo en si mismo (control y estabilización) y otros son compartidos con la robótica móvil en general (reconocimiento del entorno, navegación, planeo de trayectorias, etc.)

Debido a que los vehículos de despegue y aterrizaje vertical (VTOL), entre los que se encuentran los multirrotores, son naturalmente inestables, el sistema de control debe ser capaz de estabilizarlo antes de aplicar cualquier estrategia de navegación de alto nivel. En este sentido, el problema más difícil no es la ley de control en sí, sino estimar las variables relevantes para el control (estado del sistema). Sensores inerciales como giróscopos, acelerómetros y magnetómetros permiten detectar la velocidad angular y orientación del vehículo, pero no son capaces de detectar la velocidad. Instrumentos como el GPS detectan posición y velocidad pero no funcionan en ambientes interiores ni poseen la precisión necesaria para desenvolverse en ambientes cerrados.

En este sentido, la visión por computadora presenta una alternativa muy prometedora para realizar navegación en interiores, ya que no solo puede proveer información sobre la ubicación del vehículo, sino sobre la estructura del ambiente en general. Sin embargo la visión tiene sus problemas específicos, y en general el procesamiento de los datos

de imágenes es un problema difícil, que requiere gran poder de procesamiento (el cual no suele encontrarse en las computadoras montadas sobre VANTS).

Con respecto a la medición de velocidad utilizando visión, existe una solución muy conocida que consiste en utilizar una cámara apuntando hacia el suelo y técnicas de Flujo Óptico para detectar el movimiento en la imagen. Esta información debe ser complementada con la de un sensor que realice una medición de la distancia al suelo, ya que la cámara puede determinar las velocidades hasta un factor de escala que es inversamente proporcional a la distancia a los objetos observados.

Una vehículo comercial muy conocido que realiza la estimación de velocidad de esta manera es el Parrot ArDrone ([1]), es cual es muy usado como plataforma de investigación en visión, ya que además de una cámara inferior, posee una cámara frontal que permite ensayar estrategias de navegación visual de alto nivel.

Sin embargo, el método de estimación de velocidad utilizando cámara inferior tiene sus limitaciones, en particular asume que el suelo es un plano uniforme, con lo cual resulta complicado volar sobre zonas con múltiples objetos, como pueden ser escritorios en una oficina. Por otro lado, el sonar es un instrumento ruidoso, más aun a baja altura, lo que complica las maniobras de aterrizaje y despegue, o vuelo a baja altitud. También, si se piensa en un sistema de procesamiento On-Board que debe obtener información de 2 cámaras (inferior y frontal), es necesario realizar el procesamiento de ambas, cuando en realidad la misma información puede extraerse completamente de la cámara frontal.

El problema de localización y mapeo utilizando una sola cámara (SLAM Monocular) se encuentra ampliamente estudiado y existen soluciones cerradas que permiten resolverlo, siendo la más relevante el Parallel Tracking and Mapping [2], este tipo de algoritmos permiten detectar la posición y orientación de una cámara, así como también un mapa del ambiente, sin conocimiento previo del mismo.

Aunque estos algoritmos son suficientes para resolver el problema de ubicación de alto nivel, en general carecen de la robustez necesaria para conformar la realimentación de velocidad de un control de bajo nivel. Son sistemas que necesitan una inicialización previa, y que pueden perder el seguimiento de posición, caso en el cual pueden recuperarlo pero no con los requerimientos de tiempo que necesita

un lazo de control en un vehículo aéreo que vuela en un ambiente cerrado. Por otro lado, ya que en su versión original estos algoritmos fueron pensados para aplicaciones de reconstrucción y realidad aumentada (no para navegación) la mayoría no utiliza la información provista por sensores inerciales, muy comunes en VANTs.

En este trabajo se presenta un sistema que permite detectar la velocidad de un vehículo aéreo equipado con una cámara frontal y una unidad de medición inercial. Este conjunto mínimo de sensores permite realizar la estabilización del vehículo sin suposiciones sobre la estructura geométrica del entorno, a excepción de que el mismo sea estático. Además de la velocidad, el sistema es capaz de estimar la distancia a los objetos observados, lo que puede servir para realizar estrategias de esquivar de objetos. Debido a que funciona como un filtro, no requiere pasos de inicialización, lo que lo hace apto para recuperar las mediciones rápidamente en caso de que se pierdan temporalmente las referencias visuales, logrando la robustez necesaria para una etapa de estabilización de bajo nivel.

Este sistema fue probado en un cuadrirotor fabricado específicamente para este propósito, realizando todo el procesamiento sobre el vehículo.

2. Descripción general del Método

El sistema utiliza una cámara frontal y una unidad de medición inercial (giróscopo + acelerómetro) para estimar el movimiento relativo de los objetos circundantes y su distancia relativa (profundidad). El mismo realiza iterativamente para cada cuadro de video (frame) cuatro pasos, que se resumen brevemente a continuación.

El primer paso es la extracción de características robustas de la imagen y correspondencias con la imagen anterior. De esta forma se obtiene el desplazamiento en pixels de dichas características, entre frames.

Debido a que la cámara se encuentra rígidamente acoplada a un giróscopo, la rotación de la misma es directamente mensurable. De esta forma es posible discriminar el desplazamiento de las características debido al movimiento y a la rotación. Esto permite eliminar este último de la cadena de cálculo, simplificando fuertemente el problema, proceso que se denomina “desrotación” de las características.

En un segundo paso, esta información es combinada con la estimación de las profundidades de cada característica realizada en la iteración (frame) anterior. Dicha profundidad corresponde con la distancia al objeto medida en el eje de profundidad de la cámara. Esta información se utiliza para realizar una estimación de velocidad que mejor explique los desplazamientos observados.

Una vez obtenida esta velocidad, la información de profundidad de cada característica es actualizada independientemente utilizando un Filtro de Kalman Extendido para cada una. Esta simplificación subóptima evita tener que

propagar e invertir una matriz de covarianza entre características, que puede llegar a ser de gran tamaño, logrando aun así resultados suficientemente buenos para la estabilización.

Por último, es necesario estimar la escala de la velocidad observada visualmente, para esto se calcula la evolución de dicha velocidad (aceleración) y se compara con la medición del acelerómetro utilizando un Filtro de Kalman Extendido. De esta forma se obtiene una medición de velocidad, orientación y profundidad escalada al mundo real.

A continuación se explican cada uno de estos pasos con mayor precisión.

2.1. Extracción de características y correspondencias

Para la extracción de características en tiempo real sobre el sistema embebido se utilizó una modificación de detector SIFT[3], donde se realizan 3-4 iteraciones de un filtro caja para aproximar un filtro gausseano [4]. Los filtros caja pueden calcularse eficientemente utilizando imágenes integrales, lo que permite calcular el espacio de escalas en un tiempo aceptable. De esta forma, es posible obtener características tipo SIFT a 16.7fps (50/3) sobre una imagen de 320x240 pixels, debido a que el detector posee buena selectividad, normalmente se obtienen entre 40 y 200 características por cuadro.

Como descriptor se utilizó el propuesto en SIFT, pero sin detección de rotación y con histogramas de tamaño 4x4x4, es decir un descriptor de 64 bytes. Debido a que se está realizando seguimiento entre frames sucesivos, el cambio entre ellos es pequeño, por lo que esta combinación es más que suficiente para alcanzar la robustez necesaria.

Para encontrar las correspondencias se utilizó un esquema de fuerza bruta. Sin embargo, teniendo en cuenta las mediciones del giróscopo, es posible “desrotar” la posición de las características, de tal forma de acotar fuertemente la zona de búsqueda. En general la búsqueda se limitó a un área de 20 pixels de radio. Dicho radio corresponde a un objeto que se encuentra a 1 m de distancia, moviéndose a 1.3 m/s con respecto al VANT. Téngase en cuenta que las velocidades de un VANT en interiores raramente superan los 0.5 m/s.

2.2. Cálculo de la velocidad

Del paso anterior se obtiene la ubicación de una misma característica en el frame anterior y en el actual. También se obtiene la última información de profundidad, calculada por los respectivos Filtros de Kalman en el frame anterior. Debe notarse, que dicho filtros no estiman la profundidad, sino la profundidad inversa. El porque de esto esta bien probado en la literatura ([5]), y tiene que ver con que la profundidad inversa permite modelar mejor los puntos lejanos (profundidad infinita), además de que dichos filtros presentan mejores características frente al ruido.

Las ecuaciones que relacionan las posiciones de una característica en dos frames consecutivos con su profundidad inversa y la velocidad relativa pueden verse a continuación, donde se supone que ya se ha realizado la desrotación de las mismas:

$$q_{it} - q_{it-1} = \Delta q_{it} = \rho_{it-1}(v_x z_f - v_z q_{it}) \quad (1)$$

$$p_{it} - p_{it-1} = \Delta p_{it} = \rho_{it-1}(v_x z_f - v_z p_{it}) \quad (2)$$

q y p son las coordenadas x e y , respectivamente, de la característica i en el frame actual (t) y el anterior ($t-1$), $\rho_{it-1} = \frac{1}{z_{it-1}}$ es la profundidad inversa calculada en el frame anterior y $\bar{v} = (v_x, v_y, v_z)$ la velocidad buscada (desplazamiento de la cámara entre frames).

Escribiendo estas ecuaciones para cada una de las características encontradas es posible obtener la velocidad buscada realizando una optimización de mínimos cuadrados. La solución a este problema es muy eficiente debido a que sólo cuenta con tres incógnitas, por lo cual no es necesario realizar factorizaciones tipo SVD, ya que la inversa de una matriz 3x3 tiene solución explícita.

Aunque este sistema puede resolverse directamente, es conveniente considerar que las profundidades inversas también son resultado de un proceso de estimación y poseen una incertidumbre σ_{ρ_i} que puede extraerse del filtro de Kalman correspondiente. Esta incertidumbre puede utilizarse para sopesar las ecuaciones 2, de tal forma de darle más importancia a las características que tienen menor incertidumbre (mayor información).

Para llevar esto a un plano más formal, es conveniente recordar que el método de mínimos cuadrados resuelve el sistema $\bar{Y} = A\bar{x}$ sujeto a que el ruido se encuentra montado sólo sobre las mediciones Y . Si las mismas poseen matriz de covarianza M , la solución al problema de mínimos cuadrados, sopesado con la incertidumbre toma la forma:

$$\bar{x} = (A^t M^{-1} A)^{-1} A^t Y \quad (3)$$

Para llevar la incertidumbre en la estimación de la profundidad ρ_i al vector de mediciones Y es posible reacomodar las ecuaciones 2 en la siguiente forma:

$$\frac{\Delta q_{it}}{\rho_{it-1}} = v_x z_f - v_z q_{it} \quad (4)$$

$$\frac{\Delta p_{it}}{\rho_{it-1}} = v_x z_f - v_z p_{it} \quad (5)$$

Como resulta evidente, las mediciones $\frac{\Delta q_{it}}{\rho_{it-1}}$ y $\frac{\Delta p_{it}}{\rho_{it-1}}$ se encuentran correlacionadas. Es posible encontrar una aproximación de su matriz de covarianza utilizando una aproximación de Taylor de primer orden, obteniéndose:

$$M_i = \frac{1}{\rho_{it-1}^2} \begin{bmatrix} (\sigma_{\Delta q}^2 + \frac{\Delta q_{it}^2 \sigma_{\rho_i}^2}{\rho_{it-1}^2}) & \frac{\Delta q_{it} \Delta p_{it} \sigma_{\rho_i}^2}{\rho_{it-1}^2} \\ \frac{\Delta q_{it} \Delta p_{it} \sigma_{\rho_i}^2}{\rho_{it-1}^2} & (\sigma_{\Delta p}^2 + \frac{\Delta p_{it}^2 \sigma_{\rho_i}^2}{\rho_{it-1}^2}) \end{bmatrix} \quad (6)$$

$$= \frac{1}{\rho_{it-1}^2} M'_i \quad (7)$$

Suponiendo que el ruido en las mediciones es independiente para cada característica, puede simplificarse la matriz de covarianzas a una forma diagonal en bloques:

$$M = \begin{bmatrix} \frac{1}{\rho_{1t-1}^2} M'_1 & 0 & \cdots & 0 \\ 0 & \ddots & & \vdots \\ \vdots & & \frac{1}{\rho_{it-1}^2} M'_i & 0 \\ 0 & \cdots & 0 & \frac{1}{\rho_{nt-1}^2} M'_n \end{bmatrix} \quad (8)$$

Cuya inversa es:

$$M^{-1} = \begin{bmatrix} \rho_{1t-1}^2 M_1'^{-1} & 0 & \cdots & 0 \\ 0 & \ddots & & \vdots \\ \vdots & & \rho_{it-1}^2 M_i'^{-1} & 0 \\ 0 & \cdots & 0 & \rho_{nt-1}^2 M_n'^{-1} \end{bmatrix} \quad (9)$$

Se puede comprobar fácilmente que este sistema es equivalente a resolver el sistema su forma original, con las ecuaciones 2, pero utilizando como peso la matriz:

$$M'^{-1} = \begin{bmatrix} M_1'^{-1} & 0 & \cdots & 0 \\ 0 & \ddots & & \vdots \\ \vdots & & M_i'^{-1} & 0 \\ 0 & \cdots & 0 & M_n'^{-1} \end{bmatrix} \quad (10)$$

La ventaja de utilizar esta forma es que se evita una posible división por cero en el caso que ρ_{it-1} sea muy pequeño (objeto muy lejano). Resolver este sistema es también muy sencillo, y se obtiene una medición de velocidad \bar{v} que refleja el movimiento de la cámara entre frames. Como paso intermedio, también se obtiene la matriz de covarianza de los parámetros obtenidos:

$$M_v = (A^t M'^{-1} A) \quad (11)$$

Dicha matriz sirve como entrada para las siguientes etapas del algoritmo.

2.3. Estimación de la profundidad

Para estimar la profundidad de cada característica se utilizó para cada una de ellas un Filtro de Kalman Extendido de primer orden. El estado a estimar es la profundidad ρ_t , de esta manera las ecuaciones de predicción toman la siguiente forma:

$$\rho_{t|t-1} = f(\rho, v_z) = \frac{1}{\frac{1}{R(\bar{\omega}, q_{it-1}, p_{it-1}) \rho_{t-1|t-1}} + v_z} \quad (12)$$

$$F = \left. \frac{\delta f}{\delta \rho_{t-1|t-1}} \right|_{\rho_{t-1|t-1}} = \rho_{t|t-1}^2 R(\bar{\omega}, q_{it-1}, p_{it-1}) \quad (13)$$

$R(\bar{\omega}, q_{it-1}, p_{it-1})$ depende de la rotación de la cámara entre frames y puede obtenerse a partir de las mediciones del

gir6scopo y la posici6n de la caracter6stica en la imagen. Las fuentes de ruido en la ecuaci6n de predicci6n aparecen sumadas a R y a v_z . Aunque estas entran no linealmente, el EKF se calcula con la forma linealizada, cuyas ecuaciones se omiten por simplicidad.

Las ecuaciones de salida son similares a las ecuaciones 2 pero aplicadas a la profundidad actual:

$$\Delta q_t = h1(\rho_{t|t-1}, \bar{v}) = \rho_{t|t-1}(v_x z_f - v_z q_{it-1}) \quad (14)$$

$$\Delta p_t = h2(\rho_{t|t-1}, \bar{v}) = \rho_{t|t-1}(v_x z_f - v_z p_{it-1}) \quad (15)$$

Dado que la principal fuente de ruido proviene de los desplazamientos ($\Delta q_{it}, \Delta p_{it}$), se observa la conveniencia de estimar la profundidad inversa, debido a que este ruido aparece en forma aditiva en las ecuaciones de salida, lo que permite una mejor estimaci6n por parte del filtro.

Con respecto al ruido en las velocidades, se utiliza la forma linealizada sobre el punto de operaci6n $\rho_{t|t-1}$ utilizando como matriz de covarianza la obtenida en el paso anterior.

2.4. Estimaci6n de la escala

El sistema descrito hasta aqu6 permite obtener una medici6n de velocidad y profundidad hasta un factor de escala desconocido. Esto se debe a las caracter6sticas proyectivas de la c6mara y es una caracter6stica com6n a todos los sistemas de visi6n.

Para obtener una medici6n de este factor de escala, ser6 posible por ejemplo utilizar alg6n m6todo directo de medici6n de distancia, como puede ser el sonar en el caso que la c6mara apunte hacia abajo.

Dado que se busc6 utilizar un conjunto m6nimo de sensores para navegaci6n, adem6s de tratar de obtener un sistema lo m6s vers6til posible, se intent6 utilizar la unidad de medici6n inercial, en particular el aceler6metro, para estimar este factor de escala.

El aceler6metro es un sensor que, como dice su nombre, mide la aceleraci6n de su centro de masa con respecto a un sistema de coordenadas solidario a este. De esta manera, comparando la aceleraci6n medida por el aceler6metro con la obtenida derivando la velocidad de la c6mara, es posible encontrar la relaci6n entre ellas. El problema es que la medici6n del aceler6metro lleva montada el vector gravitacional \bar{g} , es decir:

$$\bar{a}_s = \bar{a} - \bar{g} \quad (16)$$

Donde \bar{a}_s es la medici6n del aceler6metro y \bar{a} la aceleraci6n del sensor. Por otro lado, el conocimiento del vector \bar{g} es de suma importancia para el sistema de control, ya que proporciona una medici6n de la inclinaci6n del veh6culo.

Es por esto que se construy6 un Filtro de Kalman Extendido con doble prop6sito: estimar la escala k que relaciona la velocidad medida 6pticamente con la real y la orientaci6n del vector \bar{g} . De esta manera el filtro tiene 4 estados: la escala k y las 3 componentes del vector g . Las ecuaciones

de predicci6n est6n dadas por la matriz de rotaci6n R_t , que se obtienen directamente de las mediciones realizadas con el gir6scopo:

$$k_{t|t-1} = k_{t-1|t-1} \quad (17)$$

$$\bar{g}_{t|t-1} = R_t \bar{g}_{t-1|t-1} \quad (18)$$

Aunque puede verse que son lineales en el estado, el ruido entra en forma multiplicativa. Luego para las ecuaciones de salida se utilizan las relaciones:

$$\|g\|^2 = g^2 \simeq 9,8^2 \quad (19)$$

$$\bar{a}_{s_t} = \bar{a}_{v_t} k_{t|t-1} - \bar{g}_{t|t-1} \quad (20)$$

Donde \bar{a}_{v_t} es la aceleraci6n visual, calculada por derivaci6n num6rica de la velocidad obtenida por mediante la c6mara. Debido a que esta aceleraci6n aparece multiplicando al estado, se utiliza tambi6n una linealizaci6n sobre el punto de operaci6n para modelar el ruido proveniente de esta. La matriz de covarianza utilizada para la aceleraci6n visual se deriva directamente de la obtenida para la velocidad en el paso 2 antes descrito.

2.5. Ley de control

Los datos de velocidad angular, inclinaci6n (vector \bar{g}) y velocidad obtenidos se utilizan para implementar un sistema por realimentaci6n de estados que permite estabilizar el veh6culo hasta una referencia de velocidad.

Tambi6n se utiliz6 una integraci6n de la velocidad para encontrar informaci6n de la posici6n que puede ser usada para mejorar la estabilizaci6n. Esta odometr6a, como es de esperarse, presenta una desviaci6n en el tiempo. Sin embargo, utilizar referencias de posici6n mejora sustancialmente la controlabilidad del sistema, logrando estabilizar el cuadr6tor con una intervenci6n humana casi nula.

3. Resultados Obtenidos

Un ensayo t6pico consiste en inicializar el sistema dentro de una oficina (cuya foto puede observarse en la Fig. 1) y observar la convergencia de los filtros. En la Fig 2 puede verse una medici6n de velocidad t6pica. Inicialmente el nivel de ruido es alto, ya que el conocimiento de la estructura del ambiente es bajo. Sin embargo, una vez que el veh6culo comienza a moverse las mediciones mejoran r6pidamente, como puede verse el Fig. 3 que muestra la desviaci6n estimada para la velocidad, por el algoritmo descrito en la secci6n 2.2. El sistema de referencia utilizado se encuentra fijo a la c6mara y posee el eje X posicionado horizontalmente, el eje Y apuntando hacia abajo y el eje Z apuntando en la direcci6n de profundidad. En la Fig. 4 puede verse la medici6n del aceler6metro contra la estimada por el observador de escala. Se observa como este 6ltimo es capaz de ajustar la aceleraci6n obtenida visualmente con la medici6n del sensor. La relaci6n de escala obtenida para



Figura 1: Fotografía de un entorno típico




Figura 2: Velocidad estimada antes del escalamiento




Figura 3: Desviación estándar estimada de la velocidad previo al escalamiento




Figura 4: Aceleración medida por el acelerómetro y estimada por el filtro EKF

este ensayo se muestra en la Figura 5. Aunque el procesamiento se realiza completamente a bordo del vehículo, el mismo envía mediante una enlace WiFi una transmisión de video comprimida en MotionJPEG, esta transmisión también contiene la información de los objetos y la distancia detectada. En la Fig. 6 puede verse una visualización de la cámara frontal del vehículo, sobre la cual se dibujaron los objetos detectados, con círculos cuyo diámetro es inversamente proporcional a la distancia, el color visualiza la incertidumbre sobre la distancia, siendo azul poco conocimiento y rojo buen conocimiento, también puede verse en texto la distancia observada. En la Fig. 7 puede verse una visualización de los objetos como si estuvieran vistos desde arriba, la cruz representa al VANT y las elipses los objetos detectados. La longitud horizontal de las elipses representa el tamaño del objeto, obtenido a partir del detector SIFT, y la longitud horizontal la incertidumbre en la profundidad. Puede verse que las mediciones obtenidas resultan convincentes, y son suficientes para realizar vuelos controlados en ambientes cerrados.

4. Descripción del equipamiento utilizado

Antes de concluir se realiza una breve descripción del equipamiento utilizado. El vehículo experimental fue construido específicamente para probar técnicas de control y estabilización utilizando odometría visual.

El mismo cuenta con una cámara frontal tipo PlayStation Eye Visión, la cual presenta una excelente relación calidad/precio, por lo que es muy utilizada en visión. Como unidad de procesamiento se utilizó una placa de desarrollo Odroid U3, la cual cuenta con 4 procesadores tipo ARM9. Dicha multiplicidad permitió distribuir las tareas, utilizando 2 procesadores para el procesamiento de visión, otro procesador para el control y un cuarto para el sistema operativo (Linux XUBUNTU) y tareas auxiliares.

Como interfase entre los drivers de motores y la unidad de medición se utilizó una placa de diseño propio, que utiliza un microcontrolador de 16bits. El mismo se comunica con la computadora embebida mediante una interfase serie.

Como ya se ha dicho, el hardware cuenta con conecti-




Figura 5: Escala estimada por el filtro EKF



Figura 6: Vista desde la cámara sobre el vehículo

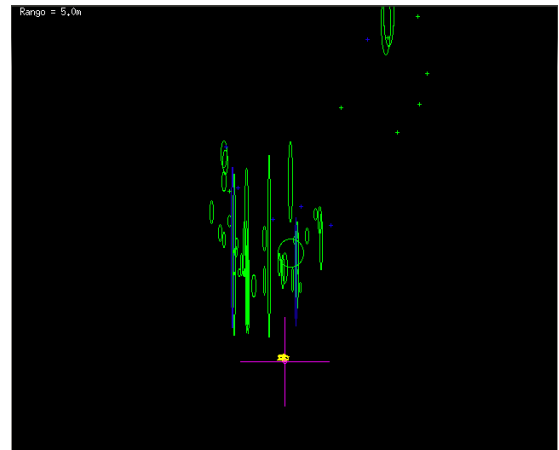


Figura 7: Visualización de la estructura de los objetos observada

Sin embargo, la principal limitación práctica de este tipo de sistema no es la precisión en las mediciones, sino las suposiciones iniciales realizadas sobre la estructura de la escena, en particular que la misma sea estática es completamente inválida para un ambiente humano. Es por esto que se seguirá trabajando en este camino, en particular en el algoritmo de detección de velocidad, intentando, en lugar de utilizar mínimos cuadrados, nuevas técnicas [6] de identificación multimodelo. Esto podría permitir identificar conjuntos de características que se mueven a diferente velocidad con respecto al vehículo, obteniéndose así no sólo un sistema más robusto, sino también valiosa información sobre la semántica de escena.

vidad WiFi y un módulo GPS, que en este momento no se esta utilizando. Los motores y sus respectivos drivers son comunes de aeromodelismo.

Todas estas características, hacen de este vehículo una plataforma muy versátil y de bajo costo para la implementación y prueba de nuevos algoritmos de control y posicionamiento. Cabe mencionar que todo el hardware y el software, así como el algoritmo de control son de desarrollo propio.

5. Conclusiones y Trabajo Futuro

Aunque el algoritmo aquí descrito continua en desarrollo, ha logrado cumplir el objetivo de estabilizar el vehículo en ambientes cerrados, con una precisión que supera las expectativas impuestas inicialmente.

Este algoritmo puede complementarse con sistemas de SLAM de alto nivel, que permitan construir un mapa preciso y estimar en forma más global el error de posición a largo plazo. Una optimización tipo Bundle Adjustment usando KeyFrames tomados cada cierto tiempo, no debería ser difícil de implementar, ya que el sistema ya provee una estima de la posición, orientación y profundidad que se encuentra cerca de los valores reales.

Referencias

- [1] Pierre-Jean Bristeau, François Callou, David Visière, Nicolas Petit *The Navigation and Control technology inside the AR.Drone micro UAV*
- [2] Georg Klein and David Murray, *Parallel Tracking and Mapping for Small AR Workspaces*, Proc. International Symposium on Mixed and Augmented Reality (ISMAR'07, Nara)
- [3] David G. Lowe, *Distinctive Image Features from Scale-Invariant Keypoints*, International Journal of Computer Vision, 2004.
- [4] Peter Kovesi, *Fast Almost-Gaussian Filtering*
- [5] Javier Civera, Andrew J. Davison, and J. M. Martínez Montiel, *Inverse Depth Parametrization for Monocular SLAM*, IEEE Transactions on Robotics, vol. 24, no. 5, October 2008.
- [6] Hossam Isack and Yuri Boykov, *Energy-based Geometric Multi-Model Fitting*, International Journal of Computer Vision, vol. 97, no. 2, pp. 123-147, April 2012