

ANÁLISE DE INTEGRAÇÃO ENTRE IMU E GPS UTILIZANDO FILTRO DE KALMAN

Islan Peterson Monteiro Ferreira, islanpeterson@yahoo.com.br¹
Elder Moreira Hemerly, hemerly@ita.br¹

¹Instituto Tecnológico de Aeronáutica, Praça Marechal Eduardo Gomes, 50, São José dos Campos, São Paulo, Brasil.

Resumo: Este trabalho apresenta uma análise da integração de dados provenientes de uma unidade de medidas inerciais, IMU (Inertial Measurement Unit), e de um sistema de posicionamento por satélite, GNSS (Global Navigation Satellite System), através do Filtro de Kalman, ou Kalman Filter (KF), que tem como característica a utilização de equações diferenciais que modelam o comportamento dinâmico do sistema em questão. Neste caso, a partir das informações de força específica e velocidade angular fornecidas pela IMU, obtém-se os dados de navegação (posição, velocidade e atitude) e com os dados do GNSS, o KF pode estimar e compensar os erros existentes, melhorando o resultado da integração quando se compara o seu desempenho àquele de cada sistema separadamente (inercial e GNSS).

Com esta integração, busca-se aliar as melhores características de cada sistema, de forma a se obter resultados com taxa de atualização da ordem daquela da IMU (entre 100Hz e 400Hz) ao mesmo tempo que se consegue a limitação do erro através os dados do GNSS, além de se ter menor influência das condições ambientais (como acontece com GNSS) e permitir o uso da solução de navegação por um período prolongado (sistemas puramente inerciais apresentam erros crescentes no tempo).

A implementação do Filtro de Kalman é feita em ambiente MATLAB/Simulink, em que o movimento simulado de uma aeronave é utilizado como referência e o algoritmo é analisado, comparando-se dados de navegação estimados da aeronave, com a trajetória originalmente simulada, inclusive com a interrupção do sinal GNSS por um determinado período.

Palavras-chave: Filtro de Kalman, Navegação Inercial, IMU, GNSS.

1. INTRODUÇÃO

Sistemas de navegação integrados, baseados em sensores inerciais (Inertial Measurement Unit (IMU)), e em sistemas de posicionamento por satélite (Global Navigation Satellite Systems (GNSS) ou especificamente Global Positioning System (GPS)), vêm sendo amplamente utilizados em várias áreas. Enquanto aplicações independentes uma da outra, estes sistemas apresentam capacidades de navegação aceitáveis para o caso em que ter um erro muito pequeno, ou mantê-lo limitado por muito tempo, não são requisitos mandatórios. Entretanto, quando se necessita maior exatidão e disponibilidade, suas deficiências ficam evidentes, podendo comprometer o grau de confiabilidade desejado.

Uma das soluções possíveis para se reduzir os erros gerados é a adoção de sensores da IMU ainda melhores. Esta opção, entretanto, mesmo que traga melhoria no desempenho, após um período longo, também apresenta erros crescentes e não limitados. Além disso, existem barreiras tanto econômicas quanto políticas, ditadas por proteção tecnológica. Por outro lado, sistemas de posicionamento por satélite podem se apresentar indisponíveis por conta de obstrução do sinal eletromagnético, além de poderem sofrer *jamming*. Em casos assim, são utilizadas técnicas para realizar a chamada fusão de dados, em que se procura compensar imperfeições de sensores menos exatos, de forma a aproveitar características complementares dos sistemas envolvidos. É o que se consegue de forma bastante satisfatória na integração entre IMU e GPS.

Este trabalho apresenta o desenvolvimento da simulação de integração de dados provenientes de sensores inerciais e dados obtidos por satélite, através do algoritmo Filtro de Kalman Estendido. Além disso, é feita uma abordagem para o cálculo das matrizes de linearização com base na construção da Jacobiana a partir da partição em funções mais básicas e utilizando-se a Regra da Cadeia, diminuindo a complexidade dos cálculos de funções derivadas.

Em seguida, dados obtidos da simulação da integração realizada são exibidos e os resultados são avaliados. Toda a simulação feita neste trabalho utiliza a ferramenta Matlab/Simulink.

2. NAVEGAÇÃO E MODELO MATEMÁTICO

Os sensores inerciais medem o movimento com base nas leis da física e não dependem de qualquer sinal de referência externa ao corpo em que se encontra. A ideia básica por trás de um sistema puramente inercial está na integração de sinais de aceleração para obtenção de velocidade e posição a partir de uma condição inicial conhecida, bem como na obtenção dos ângulos de atitude através da integração dos dados coletados pelos giroscópios.

Esta seção apresenta o modelo utilizado para a navegação, que é utilizado pelo algoritmo do Filtro de Kalman no processo de estimação.

2.1. Equações de Mecanização

Para um sistema de navegação operando no sistema de referência NED, considerando-se a força específica medida pelos acelerômetros e a velocidade de rotação da Terra, as equações associadas à computação do movimento podem ser descritas por (Titterton and Weston, 2004; Farrell and Barth, 1998; Kuga, 2007)

$$\begin{bmatrix} \dot{\phi} \\ \dot{\lambda} \\ \dot{h} \end{bmatrix} = \begin{bmatrix} \frac{1}{R_n+h} & 0 & 0 \\ 0 & \frac{1}{(R_e+h)\cdot\cos(\phi)} & 0 \\ 0 & 0 & -1 \end{bmatrix} \cdot \begin{bmatrix} V_N \\ V_E \\ V_D \end{bmatrix} \quad (1)$$

$$\begin{bmatrix} \dot{V}_N \\ \dot{V}_E \\ \dot{V}_D \end{bmatrix} = \begin{bmatrix} f_N \\ f_E \\ f_D \end{bmatrix} + \begin{bmatrix} -2 \cdot \Omega_e \cdot V_E \cdot \text{sen}(\phi) + \frac{V_N \cdot V_D}{R_n+h} - \frac{V_E^2 \cdot \tan(\phi)}{R_e+h} \\ 2 \cdot \Omega_e (V_N \cdot \text{sen}(\phi) + V_D \cdot \cos(\phi)) + \frac{V_E (V_N \cdot \tan(\phi) + V_D)}{R_e+h} \\ -2 \cdot \Omega_e \cdot V_E \cdot \cos(\phi) - \frac{V_E^2}{R_e+h} - \frac{V_N^2}{R_n+h} \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ \gamma \end{bmatrix} \quad (2)$$

$$\begin{bmatrix} \dot{\Phi} \\ \dot{\Theta} \\ \dot{\Psi} \end{bmatrix} = \begin{bmatrix} 1 & \text{sen}(\Phi) \cdot \tan(\Theta) & \cos(\Phi) \cdot \tan(\Theta) \\ 0 & \cos(\Phi) & -\text{sen}(\Phi) \\ 0 & \text{sen}(\Phi)/\cos(\Theta) & \cos(\Phi)/\cos(\Theta) \end{bmatrix} \cdot \left\{ \begin{bmatrix} p - b_p \\ q - b_q \\ r - b_r \end{bmatrix} - \mathbf{R}_{n2p} \cdot \begin{bmatrix} \Omega_e \cdot \cos(\phi) + V_E/(R_e + h) \\ -V_N/(R_n + h) \\ -\Omega_e \cdot \text{sen}(\phi) - V_E \cdot \tan(\phi)/(R_e + h) \end{bmatrix} \right\} \quad (3)$$

onde:

$$\begin{bmatrix} f_N \\ f_E \\ f_D \end{bmatrix} = \mathbf{R}_{p2n} \cdot \left(\begin{bmatrix} f_u \\ f_v \\ f_w \end{bmatrix} - \begin{bmatrix} b_u \\ b_v \\ b_w \end{bmatrix} \right) \quad (4)$$

onde \mathbf{R}_{n2p} e \mathbf{R}_{p2n} são matrizes de rotações que permitem transformações entre os sistemas de navegação e o da plataforma. ϕ é a latitude geodésica, λ é a longitude, h é a altitude acima do elipsóide de referência, R_n e R_e são os raios de curvatura Norte e Leste do elipsóide de referência, V_N , V_E e V_D são as componentes da velocidade nas direções norte, leste e para baixo, respectivamente, Ω_e é a velocidade de rotação da Terra, Φ , Θ e Ψ são os ângulos de arfagem, rolagem e guinada respectivamente, p , q e r são as velocidades angulares nos eixos de arfagem, rolagem e guinada, respectivamente, b_p , b_q e b_r são *biases* associados às velocidades angulares, f_u , f_v , f_w são as forças específicas no sistema da plataforma, f_N , f_E , f_D são as forças específicas convertidas para o sistema de navegação e b_u , b_v e b_w são os *biases* associados às forças específicas.

A Fig. (1) apresenta em forma gráfica a relação trazida pelas equações de navegação.

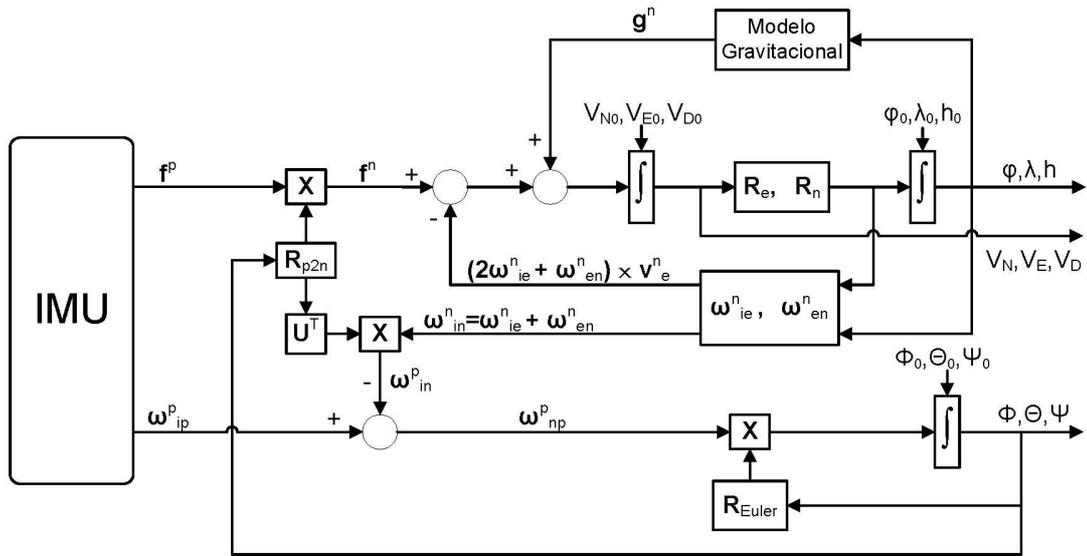


Figura 1. Diagrama de Blocos da Mecanização.

Na Fig. (1), \mathbf{R}_{Euler} é dado por:

$$\mathbf{R}_{Euler} = \begin{bmatrix} 1 & \text{sen}(\Phi) \cdot \tan(\Theta) & \cos(\Phi) \cdot \tan(\Theta) \\ 0 & \cos(\Phi) & -\text{sen}(\Phi) \\ 0 & \text{sen}(\Phi)/\cos(\Theta) & \cos(\Phi)/\cos(\Theta) \end{bmatrix} \quad (5)$$

3. INTEGRAÇÃO IMU/GPS

O sistema utilizado é baseado na modelagem do sistema inercial, que, a partir de dados de acelerômetros e giroscópios, fornece as informações de navegação da aeronave, sejam posição, velocidade e ângulos de atitude. A geração dos dados simulados para o sistema GPS é obtida a partir da inserção de ruído sobre os dados obtidos do INS. A partir daí, o Filtro de Kalman pode realizar a integração dos dados, de forma a obter resultados melhores que cada sistema individualmente.

O Filtro de Kalman é projetado originalmente para aplicações em sistemas lineares. Como no caso em estudo, as equações do modelo de navegação são fortemente não-lineares, o Filtro de Kalman deve ser substituído por sua versão adaptada para sistemas não-lineares, o Filtro de Kalman Estendido ou EKF (*Extended Kalman Filter*) (Carvalho, 2007a; Carvalho, 2007b), e pode ser representado pela seguinte equação dinâmica:

$$\dot{\mathbf{x}}(t) = \mathbf{f}(\mathbf{x}(t), \mathbf{u}(t), t) + \mathbf{G} \cdot \mathbf{w}(t), \quad \mathbf{w} \sim N(0, \mathbf{Q}) \quad (6)$$

$$\mathbf{z}_k = \mathbf{h}_k(\mathbf{x}(t_k), \mathbf{u}(t_k), t_k) + \mathbf{v}_k, \quad \mathbf{v} \sim N(0, \mathbf{R}) \quad (7)$$

onde \mathbf{x} é o vetor de estados, \mathbf{u} é o vetor contendo as variáveis de entrada do sistema, \mathbf{w} representa o ruído associado ao processo, \mathbf{G} é a matriz de intensidade do ruído de processo, $\mathbf{f}(\mathbf{x}, \mathbf{u}, t)$ é o campo vetorial e \mathbf{Q} é matriz de covariâncias dos ruídos associados ao processo, que são considerados com distribuição normal e média zero.

Para a Eq. (7), tem-se \mathbf{z}_k representa o vetor das variáveis medidas; $\mathbf{h}_k(\mathbf{x}, \mathbf{u}, t)$ é a função que relaciona variáveis medidas e os estados; \mathbf{v}_k é o ruído das medidas, também considerado com distribuição normal e média zero; e \mathbf{R} , a matriz de covariâncias dos ruídos associados às medidas.

Para um sistema linearizado, as funções \mathbf{f} e \mathbf{h} se tornam

$$\mathbf{f}(\mathbf{x}(t), \mathbf{u}(t), t) = \mathbf{F}(t) \cdot \mathbf{x}(t) + \mathbf{C}(t) \cdot \mathbf{u}(t) \quad (8)$$

$$\mathbf{h}(\mathbf{x}(t_k), \mathbf{u}(t_k), t_k) = \mathbf{H}_k(t_k) \cdot \mathbf{x}(t_k) + \mathbf{D}(t_k) \cdot \mathbf{u}(t_k) \quad (9)$$

onde \mathbf{F} e \mathbf{H} são linearizações das equações \mathbf{f} e \mathbf{h} em torno do vetor atual de estimativas dos estados, conforme

$$\mathbf{F}(\hat{\mathbf{x}}(t), \mathbf{u}(t), t) = \left. \frac{\partial \mathbf{f}(\mathbf{x}(t), \mathbf{u}(t), t)}{\partial \mathbf{x}(t)} \right|_{\mathbf{x}(t)=\hat{\mathbf{x}}} \quad (10)$$

$$\mathbf{H}(\hat{\mathbf{x}}_k^-, \mathbf{u}(t_k), t_k) = \left. \frac{\partial \mathbf{h}_k(\mathbf{x}(t_k), \mathbf{u}(t_k), t_k)}{\partial \mathbf{x}(t_k)} \right|_{\mathbf{x}(t_k)=\hat{\mathbf{x}}_k^-} \quad (11)$$

O objetivo do processo é a obtenção da estimativa do vetor de estados, $\hat{\mathbf{x}}$, em relação ao vetor real \mathbf{x} , a partir da estimativa da matriz de covariâncias \mathbf{P} , sendo que o início do algoritmo usa os dados iniciais $\hat{\mathbf{x}}_0$ e \mathbf{P}_0 .

A predição (discreta) das medidas pode ser dada por

$$\hat{\mathbf{z}}_k = \mathbf{H}_k \cdot \hat{\mathbf{x}}_k^- \quad (12)$$

o que leva em conta a estimativa atual do vetor de estados.

Para a propagação (contínua), durante o intervalo em que não ocorre aquisição de novas medidas para atualização, tem-se para o vetor de estados

$$\dot{\hat{\mathbf{x}}}(t) = \mathbf{F} \cdot \hat{\mathbf{x}} + \mathbf{B} \cdot \mathbf{u} \quad (13)$$

$$\hat{\mathbf{x}}^- = \hat{\mathbf{x}}^+ + \int_{t_0}^t \dot{\hat{\mathbf{x}}}(t) dt \quad (14)$$

Para matriz de covariâncias dos estados, são utilizadas (Grewal et al, 2007; Carvalho, 2007c)

$$\dot{\mathbf{P}}(t) = \mathbf{F} \cdot \mathbf{P} + \mathbf{P} \cdot \mathbf{F}^T + \mathbf{G} \cdot \mathbf{Q} \cdot \mathbf{G}^T \quad (15)$$

$$\mathbf{P}^- = \mathbf{P}^+ + \int_{t_0}^t \dot{\mathbf{P}}(t) dt \quad (16)$$

Na etapa de atualização discreta das estimativas, os cálculos de $\hat{\mathbf{x}}^+$ e \mathbf{P}^+ são definidos por

$$\hat{\mathbf{x}}_k^+ = \hat{\mathbf{x}}_k^- + \mathbf{K}_k(\mathbf{z}_k - \hat{\mathbf{z}}_k) \quad (17)$$

$$\mathbf{P}_k^+ = \mathbf{P}_k^- - \mathbf{K}_k \mathbf{H}_k \mathbf{P}_k^- \quad (18)$$

onde \mathbf{K}_k é definido como o Ganho de Kalman:

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k^- \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad (19)$$

Percebe-se então que a atualização dos estados $\hat{\mathbf{x}}_k^+$, a ser usado na próxima iteração, depende da diferença entre as medidas \mathbf{z}_k e as estimativas das medidas $\hat{\mathbf{z}}_k$, do ganho de Kalman, \mathbf{K}_k , que por sua vez depende do valor propagado da covariância dos estados \mathbf{P}_k^- e da matriz de covariância dos ruídos das medidas \mathbf{R}_k , e também da estimativa atual dos estados $\hat{\mathbf{x}}_k^-$.

4. AMBIENTE E IMPLEMENTAÇÃO DA SIMULAÇÃO

Na definição das equações de mecanização da navegação, foram inseridos no vetor das variáveis de estado os erros associados a *biases*, ou polarizações, de acelerômetros e de giroscópios. O Filtro de Kalman e o Filtro de Kalman Estendido são ambos baseados no modelo de navegação, que a princípio não possui variáveis de bias. Contudo, pode-se adicionar mais estados ao modelo, incluindo variáveis associadas a estas grandezas, para que sejam estimadas e possam ser compensadas. As estimativas dos *biases*, em sua forma mais simples, podem ser modeladas constantes, como mostra (Kuga et al, 2007)

$$[\dot{b}_u \quad \dot{b}_v \quad \dot{b}_w \quad \dot{b}_p \quad \dot{b}_q \quad \dot{b}_r]^T = \mathbf{0}_{6 \times 1} \quad (20)$$

onde b_u , b_v e b_w representam respectivamente os *biases* de acelerômetros nas direções x, y, z do sistema de coordenadas do avião. Analogamente, b_p , b_q e b_r são os *biases* de giroscópios nos eixos de rolagem, arfagem e guinada, respectivamente.

O vetor de estados \mathbf{x} , agora complementado pelas variáveis associadas aos *biases*, fica então

$$\mathbf{x} = [\phi \quad \lambda \quad h \quad V_N \quad V_E \quad V_D \quad \Phi \quad \Theta \quad \Psi \quad b_u \quad b_v \quad b_w \quad b_p \quad b_q \quad b_r]^T \quad (21)$$

onde, em grupos de três variáveis, tem-se a representação das componentes de posição, em seguida as de velocidade, as que representam a atitude da aeronave, as associadas aos *biases* de acelerômetros e as dos *biases* de giroscópios.

Os valores dos erros dos sensores dos modelos estão descritos na Tab. (1). Os dados inerciais são computados a uma taxa de 100 Hz e os dados de GPS, a uma taxa de 1 Hz. Estes dados foram adotados com base em valores típicos de sensores inerciais do tipo MEMS e GPS comercialmente disponíveis (Barbour, 2009; Wolf, 1996).

Tabela 1. Características dos sensores.

Parâmetro	Valor	Unidade
Bias dos Acelerômetros	10	mg
Bias dos Giroscópios	50	°/h
Erro Horizontal de Posição do GPS (RMS)	5	m
Erro Vertical de Posição do GPS (RMS)	8	m
Erro de Velocidade do GPS (RMS)	0,1	m/s

4.1. Cálculo das Matrizes Linearizadas **F** e **H**

As matrizes **F** e **H**, definidas pelas Eqs. (10) e (11), são linearizações das equações que relacionam as transições de estados e as que relacionam estimativas de medidas e estados, respectivamente. São utilizadas pelo Filtro de Kalman Estendido para as etapas de atualização e propagação.

As matrizes devem ser calculadas a cada iteração. No caso de **F**, sua definição pode ser obtida a partir do cálculo das derivadas das equações diferenciais em relação ao vetor das variáveis de estados, constituindo uma Jacobiana. Para evitar cálculos provenientes da complexidade de alguns elementos das equações diferenciais, **F** pode ser definida a partir de um processo que "quebra" cada elemento em equações básicas. A partir daí, as derivadas dessas equações mais simples são calculadas e, com o uso da Regra da Cadeia, a derivada da equação original é gerada. Para facilitar o entendimento, segue abaixo um exemplo, onde se deseja calcular a derivada de

$$R = \frac{Ae(1 - e^2)}{\sqrt{1 - e^2 \sin^2(\phi)}} \quad (22)$$

em relação à latitude geodésica, ϕ .

Primeiramente são definidas no algoritmo todas as constantes usadas nas equações e, neste caso, a seguir aparece a definição de uma equação R . Para o cálculo da derivada, é usada então a Regra da Cadeia. Com a definição de

$$\frac{d}{d\phi} \sin(\phi) = \cos(\phi) \quad (23)$$

pode-se chegar, portanto, a

$$\frac{d}{d\phi} R = \frac{R e^2 \sin(\phi) \left(\frac{d}{d\phi} \sin(\phi) \right)}{1 - e^2 \sin^2(\phi)} \quad (24)$$

Assim, pode-se elaborar um algoritmo que utilize menor carga computacional para construção da matriz **F** a partir de cálculos de derivadas mais simples, de forma estruturada.

Para o caso da matriz **H**, que relaciona as estimativas dos estados com as estimativas das medidas, poderia ser obtida de forma similar à apresentada para **F**. Entretanto, como as variáveis do vetor de medidas representam parte do vetor dos estados, a matriz **H** é formada por elementos unitários nas posições correspondentes às variáveis do vetor de estados **x** que se deseja para compor o vetor de medidas **z**, isto é,

$$\mathbf{h}(\mathbf{x}, \mathbf{u}) = [\phi \quad \lambda \quad h \quad V_N \quad V_E \quad V_D]^T \quad (25)$$

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad \mathbf{0}_{6 \times 9} \quad (26)$$

5. SIMULAÇÃO E ANÁLISE CRÍTICA

Aqui são apresentados resultados e avaliações obtidos de simulações construídas a partir de (Ferreira, 2009) e das descrições das seções anteriores.

É importante ressaltar que no caso de uma implementação em um sistema real, tem-se acesso apenas ao vetor de entrada \mathbf{u} acrescido de ruído, e ao vetor de medidas \mathbf{z} , também com ruído. Os estados do sistema real, vetor \mathbf{x} , estão disponíveis apenas em um ambiente de simulação. Assim, para se avaliar o desempenho do algoritmo de integração, em uma implementação real, pode-se utilizar como referência um sistema que tenha sabidamente erros bem menores que aqueles dos sensores da IMU e do GPS.

As figuras a seguir exibem o comportamento dos erros das variáveis de estado em relação aos valores originais do movimento simulado. Para estas figuras, as linhas cheias em azul representam o erro do sistema filtrado em relação à referência; as curvas representadas por cruzes (+) verdes são os erros do GPS; e traços e pontos (---) vermelhos são os valores de desvio-padrão de cada variável, obtidos através da raiz quadrada dos elementos da diagonal da matriz de covariâncias \mathbf{P} . Os eixos das abscissas em cada gráfico representam o tempo e estão em segundos.

Para a configuração da simulação, são considerados desvios dos valores iniciais das estimativas em relação aos valores de referência. Para a posição, o erro inicial é de 50 m; para a velocidade, o erro considerado é de 0.1 m/s; para os ângulos de atitude da aeronave, são considerados erros iniciais de 1° . Os *biases* são estimados inicialmente como nulos, diferindo do valor de referência em ± 10 mg para os acelerômetros e ± 50 /h para os giroscópios. É também simulada a interrupção de sinal do GPS por 60 segundos (a partir do instante $t = 500$ s).

A Fig. (2) apresenta os erros de posição, que possui valor de regime para o desvio-padrão em torno de 1 m, enquanto o erro do GPS é de 5 m para o eixo horizontal e 8 m para o eixo vertical.

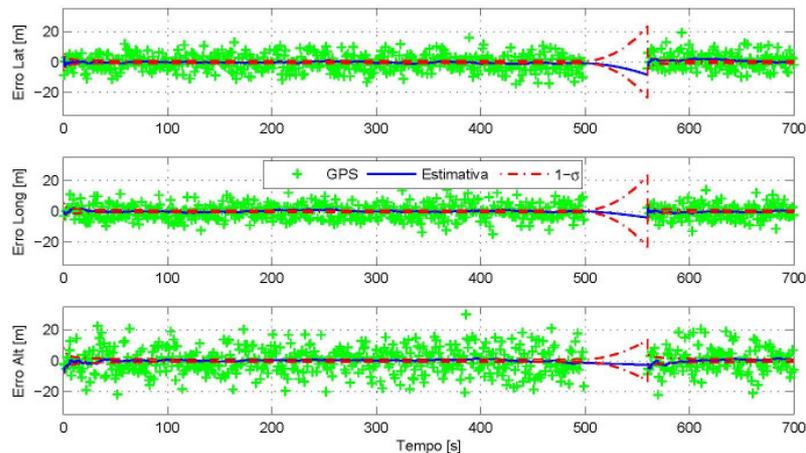


Figura 2. Posição: Erro e Desvio-Padrão.

A Fig. (3) exhibe os erros relacionados com as componentes NED da velocidade provenientes do Filtro de Kalman, e também do GPS, relacionados com os valores originalmente gerados pela simulação, bem como as envoltórias de desvio-padrão. O período de ausência do sinal de GPS mostrou um crescimento pequeno do erro, considerando que neste intervalo, o algoritmo usa apenas os dados dos sensores inerciais, e apresenta desvio-padrão menor que aquele do GPS, que é de 0.1 m/s.

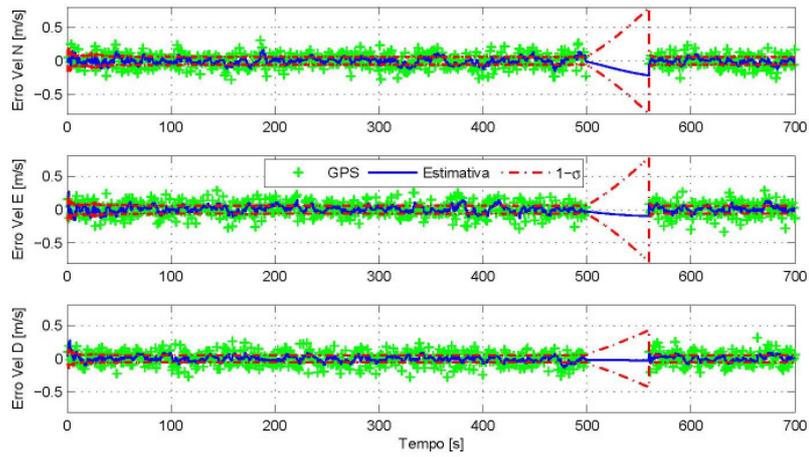


Figura 3. Velocidade: Erro e Desvio-Padrão.

Na Fig. (4) são exibidos os erros dos ângulos de rolagem, arfagem e guinada em relação aos valores de referência gerados pela referência simulada. Também são exibidas as curvas representando o desvio-padrão de cada variável estimada. No caso dos ângulos de atitude, não há informações provenientes do GPS. Portanto, os valores são estimados, a partir dos dados que o modelo interno do EKF gera com base nas observações dos demais estados observáveis. As

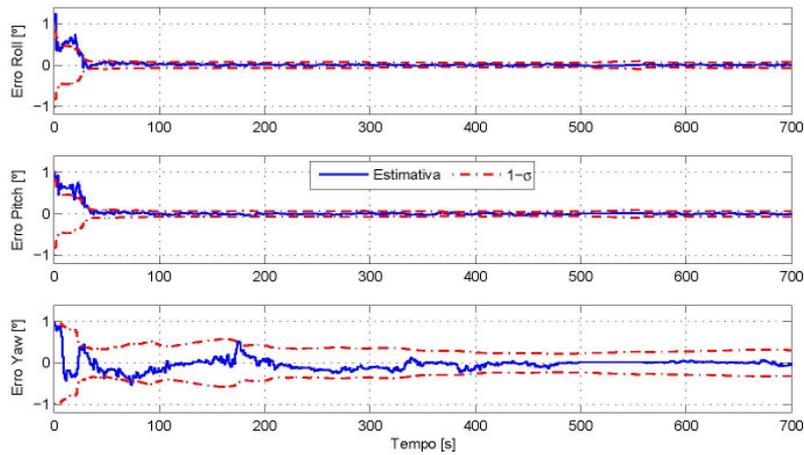


Figura 4. Atitude: Erro e Desvio-Padrão.

As Figs. (5) e (6) mostram estimativas dos *biases* de acelerômetros e de giroscópios, respectivamente. Os valores inseridos no modelo de referência são $[10 \ -10 \ 10]^T$ em mg para os acelerômetros e $[-50 \ 50 \ -50]^T$ em $^{\circ}/h$ para os giroscópios.

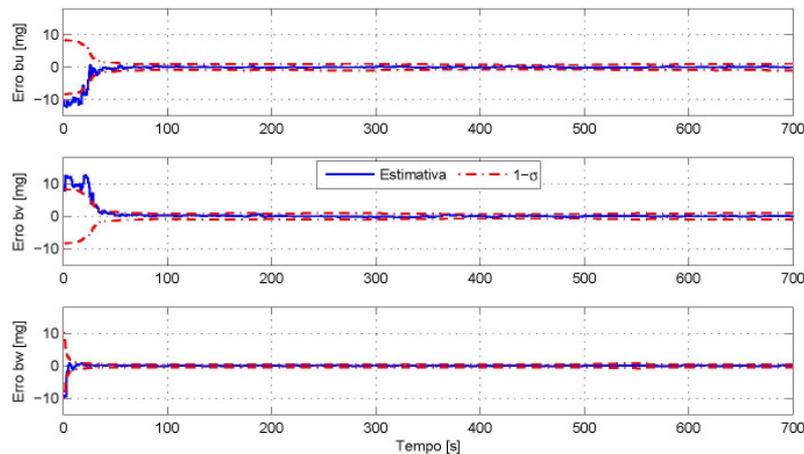


Figura 5. Bias de Acelerômetros: Erro e Desvio-Padrão.

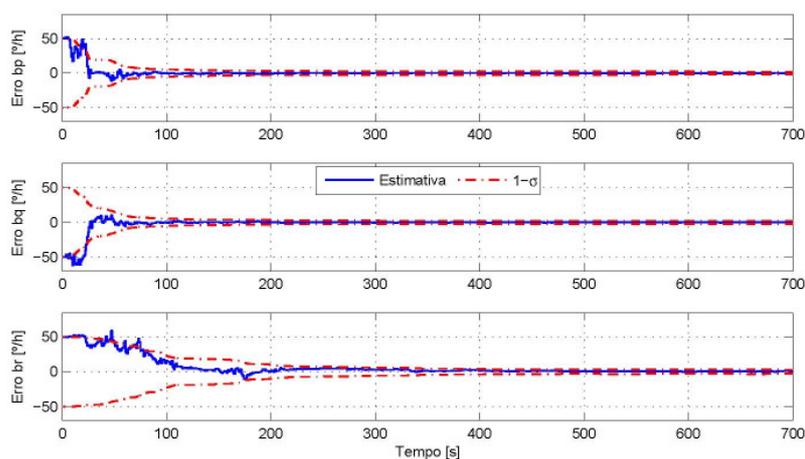


Figura 6. Bias de Giroscópios: Erro e Desvio-Padrão.

Como também neste caso não há observação direta dos estados, os valores estimados apresentam transientes bem diferentes daqueles exibidos pelos estados em que se consegue atualizações provenientes do GPS (posição de velocidade). Uma vez que a convergência tenha ocorrido, estes valores estimados são descontados dos dados gerados pela IMU, melhorando o desempenho do sistema integrado, inclusive durante a ausência do sinal de GPS

6. CONCLUSÕES

Pela característica não-linear do modelo, o Filtro de Kalman Estendido (EKF) foi o algoritmo usado para constituir um sistema com características de desempenho melhores que as observadas pelos IMU e GPS individualmente, o que de fato foi observado.

Com a estimativa das variáveis de bias dos sensores, após a convergência das variáveis, mesmo quando se considerou a indisponibilidade do GPS por um período de 60 segundos, o algoritmo, apesar do aumento inevitável dos erros, ainda os manteve menores que o sistema GPS, mostrando uma maior acurácia.

Como sugestão de trabalhos futuros, pode-se realizar a implementação em uma plataforma real, utilizando-se acelerômetros e giroscópios reais, bem com um receptor GNSS, para cálculo em tempo real dos dados filtrados e assim dar suporte à navegação inclusive quando da ausência dos sinais de satélite.

7. REFERÊNCIAS

- Barbour, N. M., 2009, "Low-Cost Navigation Sensors and Integration Technology", (RTO-EN-SET-116), Disponível em: <<http://ftp.rta.nato.int/public/PubFullText/RTO/EN/RTO-EN-SET-116///EN-SET-116-02.doc>>. Acesso em: 14 ago 2009.
- Carvalho, G. B., 2007a, "Linear/Extended Continuous-Discrete Kalman Filter Tutorial". Bremen: ZARM, (INT-EKF-TU-ZAR-001).
- Carvalho, G. B., 2007b, "Linear/Extended Continuous-Discrete Kalman Filter Model Application Example". Bremen: ZARM, (INT-EKF-TU-ZAR-002).
- Carvalho, G. B., 2007c, "Practical Approaches for the Extended Kalman Filter". Bremen: ZARM, 2007. (INT-EKF-TN-ZAR-001).
- Farrell, J. A.; Barth, M., 1998, "The Global Positioning System & Inertial Navigation", New York: McGraw-Hill.
- Ferreira, I., 2009, "Análise de Integração entre IMU e GPS Utilizando Filtro de Kalman", 86f. Dissertação de Mestrado – Instituto Tecnológico de Aeronáutica, São José dos Campos.
- Grewal, M. S.; Weill, L. R.; Andrews, A. P., 2007, "Global Positioning Systems, Inertial Navigation, and Integration", 2nd. ed., New York: John Wiley & Sons.
- Kuga, H. et al., 2007, "Integração de Sistema DGPS e Unidade Inercial para Navegação Precisa de Aeronave em Tempo-Real". In: Simpósio Brasileiro de Engenharia Inercial, 5. Rio de Janeiro: CENPES, p. 80-84.
- Titterton, D. H.; Weston, J. L., 2004, "Strapdown Inertial Navigation Technology", London: IEE/AIAA.
- Wolf, R. et al., 1996, "An Integrated Low Cost GPS/INS Attitude Determination and Position Location System", Disponível em: <http://www.ifen.com/content/publications/IONGPS1996_GPS_INS.pdf>, Acesso em: 20 ago 2009.

8. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído no seu trabalho.



VI CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA
VI NATIONAL CONGRESS OF MECHANICAL ENGINEERING
18 a 21 de agosto de 2010 – Campina Grande – Paraíba - Brasil
August 18 – 21, 2010 – Campina Grande – Paraíba – Brazil

ANALYSIS ON THE IMU/GPS INTEGRATION USING THE KALMAN FILTER

Islan Peterson Monteiro Ferreira, islanpeterson@yahoo.com.br¹
Elder Moreira Hemerly, hemerly@ita.br¹

¹Instituto Tecnológico de Aeronáutica, Praça Marechal Eduardo Gomes, 50, São José dos Campos, São Paulo, Brasil.

Abstract. *Satellite-based positioning systems, GNSS (Global Navigation Satellite System), are widely used, as in ships, cars, aircraft, military troops, geological measurements, providing mainly position, velocity and time reference. Its use, however, is conditioned to the availability of the electromagnetic signal from the satellites, which can be obstructed by mountains, buildings, forests and tunnels, for instance, besides of being subjected to weather conditions. Another feature of the satellite-based positioning systems is that the data are updated to a rate typically between 1Hz and 10Hz. Therefore, these systems represent a source of information that, even though has time-limited and eventually small errors, presents a low update rate in comparison to the navigation dynamic and may not be available at all periods of time.*

Inertial Measurement Units, IMU, are composed by sensors that provide specific forces and angular rates. From that, the computations are made to calculate the navigation equations provide position, velocity and body attitude data and, as they rely only on measurements from acceleration and angular rate sensors and on the knowledge of initial state, they are autonomous and independent of any external source of signal. Besides, the update rate are much higher, varying in general from 100Hz to 400Hz, and are less influenced by weather conditions than the GNSS. Nonetheless, the inertial sensors errors, even small, cause time increasing errors to the navigation solution, making the inertial system less reliable for long duration navigation.

One way of gathering together the best of each system – Inertial and GNSS – is by their integration, in such a way that the results can be available at a higher rate and with lower and limited errors, by the updates from the GNSS. For that, an extensively used algorithm is the Kalman Filter (KF).

This work presents a study of an integrating system of inertial navigation data, from and IMU, and satellite positioning systems data. Here, the chosen GNSS is the GPS (Global Positioning System). The implementation of the Kalman Filter is built in the MATLAB/Simulink® environment, in which the simulated movement of an aircraft is used as reference and the algorithm is analyzed for the comparison of the estimated navigation data, with the original simulated aircraft trajectory.

The results herein presented show the behavior of the error from the Kalman Filter integrated system with relation to the reference data from the aircraft simulated movement. In addition, it is considered the absence of the GNSS signal during a specific period of time.

Keywords: *Kalman Filter, Inertial Navigation, IMU, GNSS.*