

SENSORIAMENTO DE UM CUBESAT UTILIZANDO FUSÃO DE SENSORES

Vinícius Rosolen Altarni, vinicius.altarni@unesp.br¹
Henrique Barboza Ferreira, h.ferreira@unesp.br¹
Denilson Paulo Souza dos Santos, denilson.santos@unesp.br¹
Wilian Miranda dos Santos, wilian.santos@unesp.br¹

¹Universidade Estadual Paulista “Júlio de Mesquita Filho” - Faculdade de Engenharia, Campus de São João da Boa Vista.
Av. Profª Isette Corrêa Fontão, 505 - Jardim das Flores - São João da Boa Vista/SP - CEP 13876-750

Resumo: O CubeSat é um tipo de nanosatélite projetado para operar na órbita terrestre baixa. O baixo custo de desenvolvimento e lançamento permite que universidades e pequenas empresas acessem o espaço. Uma etapa importante no projeto de um CubeSat diz respeito ao sistema de referência de atitude e rumo (AHRS do inglês Attitude and Heading Reference System), que pode ser entendido como o sistema que estima o estado do satélite (atitude e posição). O sistema de posicionamento global (GPS do inglês Global Positioning System) pode fornecer uma estimativa de posição precisa. No entanto, devido à falta de confiabilidade, usar apenas o GPS não é uma solução satisfatória. Os sinais GPS estão sujeitos a interferências, podem ser facilmente obstruídos, suas medições são transmitidas em baixas frequências e sua precisão é bastante degradada com a perda de satélites. Para resolver esses problemas, o GPS pode ser combinado com uma unidade de medição inercial (IMU do inglês Inertial Measurement Unit), portanto, se o sinal do GPS estiver indisponível a posição poderá ser obtida pela IMU. As IMUs não são sensíveis a interferências ou obstruções e permitem uma alta taxa de amostragem. No entanto, sua desvantagem está no aumento do erro na estimativa de atitude e posição devido à integração numérica das medidas dos sensores e seus erros inerentes (ruídos). Neste artigo, é apresentada a estimativa de atitude e posição de um CubeSat. São utilizados sensores inerciais de baixo custo, o que significa maior incerteza e ruído nas medições. Obter a atitude do CubeSat apenas com acelerômetro captura corretamente a movimentação, porém o ruído dos dados não é aceitável. Utilizando apenas o giroscópio, tem-se uma redução significativa destes, mas surge o efeito de escorregamento (drift) causado pela integração numérica. Esses problemas podem ser corrigidos combinando os sensores ao fusionar os dados através do filtro de Kalman, observando-se um sinal sem ruídos e sem erros acumulados. Além disso, estimadores robustos baseados no filtro de Kalman são empregados para minimizar esses efeitos. Para validar a abordagem proposta, são apresentados resultados experimentais com um estudo comparativo entre o filtro robusto e o filtro de Kalman padrão.

Palavras-chave: CubeSat, sensores de baixo custo, fusão de sensores, filtro de Kalman, filtro robusto.

1. INTRODUÇÃO

O CubeSat é um tipo de nanosatélite projetado para operar na órbita terrestre baixa. O baixo custo de desenvolvimento e lançamento permite que universidades e pequenas empresas acessem o espaço (Tawk, 2019). A principal característica desse tipo de satélite é o seu tamanho compacto. As topologias do CubeSat podem ser classificadas em 1U, 2U, 3U e assim por diante, onde o menor CubeSat tem uma dimensão 10×10×10 cm (1U) e uma massa de 1,3 kg (Initiative (2017)). O espaço muito limitado em um CubeSat é um fator-chave no projeto dos subsistemas necessários e impulsiona a necessidade de combinar várias soluções para diferentes problemas em uma única estrutura (Bakkali *et al.* (2018)).

Uma etapa importante no projeto de um CubeSat diz respeito ao sistema de sensoriamento de navegação, que pode ser entendido como o sistema que estima o estado do satélite (posição, velocidade e atitude) em tempo real (Stewart *et al.* (2005)). A estimativa de atitude, orientação e posição pode ser feita através dos sinais de uma IMU (*Inertial Measurement Unit*) composta por acelerômetro, giroscópio e magnetômetro e de um receptor GPS (*Global Positioning System*).

Os receptores GPS podem fornecer estimativa de posição e velocidade com precisão para diversas tarefas. No entanto, devido à falta de confiabilidade, a utilização apenas dos receptores GPS não é uma solução satisfatória. Os sinais de GPS estão sujeitos a interferências, podem facilmente ser obstruídos, suas medidas são transmitidas em baixas frequências e sua precisão é muito degradada com a perda de satélites (Farrell and Barth (1999)). Para solucionar este problema, uma abordagem que tem sido bastante difundida é a integração dos receptores GPS com outros tipos de sensores, como por exemplo sensores inerciais (Inoue (2012); Rezaie *et al.* (2007)).

Os sensores inerciais são baseados em medidas de acelerações lineares e velocidades angulares obtidas através de acelerômetros e giroscópios, respectivamente. Estas medidas por sua vez não são sensíveis a interferências ou obstruções e permitem uma alta taxa de amostragem (Inoue (2012)). As informações de posição e atitude são obtidas através de uma dupla integração das acelerações lineares e uma simples integração das velocidades angulares, respectivamente. Contudo, sua desvantagem está no crescimento do erro de estimativa de posição e atitude devido à integração numérica das medidas dos sensores e seus erros inerentes (ruídos).

Neste artigo, propõe-se desenvolver um sistema de sensoriamento de baixo custo para um CubeSat utilizando uma IMU, com técnicas de fusão de sensores, que consiste na utilização de filtros para integrar os sinais de diferentes sensores, minimizando assim os erros provenientes de cada um na composição da média final. Além disso, estuda-se filtros robustos para garantir uma alta precisão de medição, pois eles levam em conta as incertezas paramétricas e ruídos presentes nos sistemas considerados.

2. METODOLOGIA

2.1 Determinação da Atitude de Navegação

Uma aeronave possui 6 graus de liberdade, entretanto, para uma boa navegação, é importante conhecer suas rotações possíveis, *roll* (rolagem), *pitch* (arfagem) e *yaw* (guinada), relacionadas respectivamente com os ângulos de Euler ϕ , θ e ψ mostrados na Fig. 1 abaixo. Esses ângulos podem ser medidos a partir de giroscópios e acelerômetros, que são sensores inerciais, ou seja, retornam um valor com referência ao plano inercial. Na mecânica Newtoniana, esse é o padrão para o sistema coordenado. A navegação que utiliza esses sensores, por sua vez, é denominada navegação inercial. É importante destacar que, a navegação inclui informações sobre posição, atitude e velocidade, mas neste tópico será abordado apenas a atitude.




Figura 1: Definição dos ângulos de Euler e ϕ , θ e ψ .

Primeiramente, utilizando apenas o giroscópio, não se pode obter os referidos ângulos a partir de uma simples integração da velocidade angular pois elas não são taxas de variação dos ângulos de Euler ($\dot{\phi}$, $\dot{\theta}$, $\dot{\psi}$), mas simplesmente velocidades angulares de um sistema (p , q , r). A relação entre eles é conhecida da cinemática:

$$\begin{bmatrix} \dot{\phi} \\ \dot{\theta} \\ \dot{\psi} \end{bmatrix} = \begin{bmatrix} 1 & \sin(\phi) \tan(\theta) & \cos(\phi) \tan(\theta) \\ 0 & \cos(\phi) & -\sin(\phi) \\ 0 & \sin(\phi) / \cos(\theta) & \cos(\phi) / \cos(\theta) \end{bmatrix} \begin{bmatrix} p \\ q \\ r \end{bmatrix} \quad (1)$$

A atitude atual pode ser obtida aplicando as velocidades medidas (p , q , r) pelo giroscópio e integrando no tempo, porém isso acarretará o acúmulo de erros ao longo do processo de integração numérica. A atitude obtida por esse método captura os movimentos realizados, porém os valores e amplitudes divergem da realidade, além do erro acumulado.

Agora com o acelerômetro, que retorna a aceleração nos eixos (f_x , f_y e f_z), em um sistema movendo-se com velocidade constante e sem rotação, tem-se a seguinte modelagem em relação aos ângulos de Euler:

$$\begin{bmatrix} f_x \\ f_y \\ f_z \end{bmatrix} = g \begin{bmatrix} \sin(\theta) \\ -\cos(\theta) \sin(\phi) \\ -\cos(\theta) \cos(\phi) \end{bmatrix} \quad (2)$$

A partir de (2), facilmente são obtidos os ângulos de arfagem e rolagem, porém sensores de baixo custo retornam um sinal com ruído considerável.

2.2 Considerações Sobre a Estimativa da Posição

As estimativas de orientação e posicionamento de um objeto podem ser obtidas pela fusão dos sinais de sensores inerciais com os dados por um receptor GPS. Com isso é possível acompanhar a trajetória desse objeto. A filtragem

mais apropriada é a robusta, uma vez que os sensores de baixo custo representam incertezas e ruídos significativos para a modelagem, assim é preciso levar essas características em consideração.

Além disso, o modelo cinemático baseado em quatérnios para estimar a atitude é o ideal para descrever a movimentação de um corpo rígido, uma vez que é livre de singularidades. A estimativa da posição propriamente dita utilizando receptores GPS pode fornecer informações precisas de posição e velocidade de plataformas móveis em tarefas de agrimensura, entretanto, para navegação não é uma solução satisfatória. Os sinais apenas do GPS estão sujeitos a interferências, operam em baixas frequências, além do sinal ser facilmente obstruído ou perder precisão (Lopes, 2010). Dessa forma, integrar um sistema de navegação inercial ao receptor GPS configura-se um método interessante, mais eficiente e confiável para a navegação.

Os sinais dados pela navegação inercial (acelerômetro e giroscópio) não são sensíveis a interferências ou obstruções e permitem uma alta taxa de amostragem. Entretanto, como a posição e atitude são obtidas numericamente por integração, ocorre o acúmulo do erro de estimativa, consequência dos ruídos e polarizações dos sensores.

Ao combinar esses dois sistemas por uma fusão, consegue-se obter as melhores características de cada um isoladamente. Assim, o INS fornece o posicionamento quando o sinal do receptor GPS estiver indisponível ou for ruim, enquanto que o GPS será responsável por corrigir os dados e manter os erros do sistema inercial dentro de uma certa faixa.

2.3 Estudo da Fusão de Sensores

Como discutido anteriormente na seção 2.1, ambos os sensores isoladamente não fornecem uma medida confiável para a atitude de determinado objeto. Acelerômetros contém algum ruído associado, além de serem mais precisos quando o sistema não está em movimento, e giroscópios tendem a divergir com o passar do tempo (Liu *et al.*, 2014).

Assim, o princípio por detrás da fusão de sensores, como o próprio nome sugere, é combinar os dados provenientes deles afim de obter uma melhor estimativa dos parâmetros buscados, utilizando as melhores propriedades de cada sensor. A Fig. 2 abaixo apresenta o diagrama de blocos para o método de processamento dos dados via fusão dos sensores.




Figura 2: Método da fusão de sensores com filtragem Kalman

2.4 Filtro de Kalman

Um filtro de Kalman, embora tenha ‘filtro’ no nome, nada mais é do que um algoritmo computacional, recursivo. Ele é um método de filtragem baseado no critério de erro quadrático médio mínimo, que obtém uma estimativa dos parâmetros de estado iterativamente. O desempenho é aprimorado para sistemas lineares, com ruído branco Gaussianos.

O primeiro passo é dedicado à predição, e nessa etapa são calculadas duas variáveis que serão utilizadas nos passos II a IV: $\hat{x}_k^-$ e P_k^- . O sobrescrito ‘-’ significa valores previstos. No segundo passo é calculado o ganho de Kalman, que será usado nas etapas subsequentes. Por sua vez, no terceiro passo, é calculada uma estimativa dado um valor de entrada medido. Finalmente na quarta e última etapa é calculado o erro da covariância, que indica quão precisa foi a estimativa feita. Pode-se subdividir esses quatro passos em dois processos, um de predição e outro de estimativa (Kim (2010); (Guo and Hong, 2019)). Assim, o filtro de Kalman resume-se em:

1. Prever a estimativa e o erro da covariância do próximo instante de tempo – etapa I;
2. Compensar a diferença entre a medição e estimativa, e calcular nova estimativa – etapas II, III e IV;
3. Refazer o Loop.

Processo de predição

Este processo corresponde ao primeiro passo do algoritmo, e é calculado como a estimativa variará de um instante de tempo para o próximo.

$$\hat{x}_{k+1}^- = A\hat{x}_k + Bw_k \quad (3)$$

$$P_{k+1}^- = AP_k A^T + Q \quad (4)$$

onde A , B e Q são constantes da modelagem do sistema, $\hat{x}_k$, P_k são obtidas do loop anterior nas etapas III e IV respectivamente (ou definidas inicialmente para o primeiro loop) e w_k é o ruído associado.

Processo de estimativa

Na etapa II o ganho de Kalman é calculado da seguinte forma:

$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1} \quad (5)$$

onde P_k^- é a predição calculada na primeira etapa e H e R contantes da modelagem do sistema.

É importante destacar que um novo ganho é calculado e ajustado a cada ciclo do loop. Na etapa III, o cálculo da estimativa é dado por:

$$\hat{x}_k = \hat{x}_k^- + K_k(z_k - H\hat{x}_k^-) \quad (6)$$

$$z_k = Hx_k + v_k \quad (7)$$

onde $\hat{x}_k^-$ é a predição calculada na primeira etapa, z_k o valor de entrada medido, v_k o ruído associado à medição, H uma constante relacionada com a modelagem do sistema, e K_k o ganho de Kalman calculado anteriormente.

A quarta etapa é a última do algoritmo e a última dentro do processo de estimativa, onde o erro da covariância é calculado. Ele nos indica a diferença entre a estimativa do filtro de Kalman e um valor verdadeiro, porém desconhecido, ou seja, é um grau de acuracidade da estimativa.

$$P_k = P_k^- - K_k H P_k^- \quad (8)$$

O resultado calculado nessa etapa será utilizado na primeira etapa ao reiniciar o loop e é atualizado a cada ciclo, assim como o ganho de Kalman. O erro da covariância significa que basicamente a variável x_k segue uma distribuição normal de probabilidade, com média $\hat{x}_k$ e covariância P_k . O filtro nada mais faz do que calcular essa distribuição de probabilidades e selecionar a maior como estimativa.

Por último, é importante destacar que as variáveis relacionadas à modelagem do sistema A , Q , H e R não são calculadas nem modificadas pelo algoritmo e devem ser definidas antes da implementação pelo usuário, de acordo com as características de cada sistema.

Entretanto, a performance do filtro está diretamente associada com a precisão que essas constantes modelam o sistema. Quanto mais próximas forem a modelagem feita com a modelagem do sistema real, melhor será o resultado entregue pelo filtro de Kalman. A e Q são usadas no processo de predição do filtro, enquanto que H e R no processo de estimativa.

Filtro de Kalman e Atitude

Desejando obter a atitude, selecioná-la como variável de estado $x = [\phi \ \theta \ \psi]^T$ é natural, porém não é possível extrair os ângulos de Euler da matriz em (1). Assim, uma alternativa é utilizar os quaternions como variável de estado, que nada mais é do que uma outra maneira de expressar a atitude (Islam *et al.*, 2017). As relações entre velocidade angular e taxa de variação dos quaternions são bem conhecidas, podendo agora utilizá-la da seguinte forma $\{\dot{q}\} = B\{q\}$, onde B é uma matriz e q um vetor com os quaternions.

2.5 Filtro de Kalman Estendido

Modelo linearizado

O algoritmo utilizado no filtro linearizado é idêntico ao apresentado anteriormente, no filtro de Kalman cujo modelo do sistema é linear. A diferença entre os filtros linear e linearizado é que o modelo do sistema nesse primeiro, é linear desde o início, enquanto que no segundo, ele é linearizado de um sistema não linear. Isso implica que o modelo linearizado é coerente com o sistema real apenas nas proximidades do ponto de linearização, e distante dele a acurácia não pode mais ser garantida. Ao desconsiderar essa limitação, o filtro pode não convergir e o resultado não ser satisfatório.

Primeiramente, como apresentado, a modelagem do sistema agora no filtro estendido considera um sistema não linear, como o a seguir:

$$x_{k+1} = f(x_k) + w_k \quad (9)$$

$$z_k = h(x_k) + v_k \quad (10)$$

Ao comparar com o modelo linear, fica evidente que a equação matricial linear é substituída por funções não lineares, $Ax_k \Rightarrow f(x_k)$ e $Hx_k \Rightarrow h(x_k)$, e é a única diferença entre os filtros, todo o restante do algoritmo é idêntico, entretanto, existem algumas diferenças importantes implícitas.

Além disso, agora as matrizes A e H , determinadas na modelagem, porém desconhecidas, devem ser as derivadas das funções não lineares.

$$A \equiv \left. \frac{\partial f}{\partial x} \right|_{\hat{x}_k}, \quad H \equiv \left. \frac{\partial h}{\partial x} \right|_{\hat{x}_k^-} \quad (11)$$

O ponto de linearização adotado não é fixo, mas a estimativa anterior, uma vez que é o valor mais próximo do estado atual do sistema. Sendo f e x vetores, o resultado se torna uma matriz.

Adotando as mesmas variáveis de estado $x = [\phi \ \theta \ \psi]^T$ e modelagem do sistema apresentada em (1), agora a função f é função das velocidades angulares (p, q, r), e não linear por conter funções trigonométricas e o produto entre elas. Assim, é possível implementar o filtro estendido ao extrair o Jacobiano do produto à direita da igualdade na modelagem.

$$A = \begin{bmatrix} \frac{\partial f_1}{\partial \phi} & \frac{\partial f_1}{\partial \theta} & \frac{\partial f_1}{\partial \psi} \\ \frac{\partial f_2}{\partial \phi} & \frac{\partial f_2}{\partial \theta} & \frac{\partial f_2}{\partial \psi} \\ \frac{\partial f_3}{\partial \phi} & \frac{\partial f_3}{\partial \theta} & \frac{\partial f_3}{\partial \psi} \end{bmatrix} \quad (12)$$

2.6 Filtro de Kalman Robusto

Na modelagem robusta de Kalman, as matrizes constantes de (3) são tomadas como contendo algum tipo de incertezas, do tipo:

$$\hat{x}_{k+1}^- = (A + \delta A)\hat{x}_k + (B + \delta B)w_k \quad (13)$$

com variável de medição

$$z_k = Hx_k + v_k \quad (14)$$

Os distúrbios são modelados como

$$[\delta A \ \delta B] = M\Delta_k [\delta N_A \ \delta N_B] \quad (15)$$

sendo $|\Delta_k| < 1$, e os ruídos dados por $w_k = N(0, Q)$ e $v_k = N(0, R)$, onde $N(\mu, \sigma)$ é uma distribuição normal com média μ e variância σ .

Este filtro robusto procura minimizar o erro de estimativa para o pior caso possível criado pela faixa de incerteza δA e δB ((Nogueira *et al.*, 2013), (Nogueira, 2017)). Novamente, o filtro agora nada mais é do que um algoritmo a ser seguido recursivamente, com essas modificações.

3. RESULTADOS

Utilizando apenas os dados provenientes do acelerômetro e giroscópio, é possível fundi-los e filtrá-los a fim de determinar com precisão os ângulos de *pitch* e *roll* de um objeto, uma vez que necessita-se de um magnetômetro para corrigir os dados do giroscópio e determinar *yaw*.

A Fig. 3 a seguir apresenta a atitude determinada de forma isolada pelos sensores e o resultado da fusão de ambos, onde a movimentação feita foram oscilações de arfagem seguidas de oscilações de rolagens.




Figura 3: Determinação de θ e ϕ , respectivamente

Com base na figura acima, observa-se que utilizando apenas o acelerômetro existe um ruído considerável no sinal, apesar de certa forma representar adequadamente os movimentos. Em relação ao giroscópio, nota-se o fenômeno conhecido como *escorregamento (drift)*, causado pelo erro de integração numérica para determinação da atitude. Esse erro é devido ao ruído também presente nesse sinal, que é acumulado ao longo do tempo, visível na porção final do ângulo de rolamento. Por fim, ao fusionar os dados provenientes de ambos os sensores através do filtro de Kalman, observa-se um sinal sem ruídos e sem erros acumulados.

3.1 Orientação completa, Filtro de Kalman Estendido e XSENS

Nessa parte da pesquisa foi adicionado o magnetômetro com o objetivo de corrigir a velocidade angular no eixo z e assim determinar o ângulo ψ , da guinada. A filtragem realizada a partir de agora foi feita através do filtro de Kalman Estendido. Além disso, os dados nessa etapa foram coletados no laboratório da Universidade de São Paulo (USP), campus de São Carlos, na plataforma sensorial XSENS. Essa plataforma coleta os dados sem processamento provenientes dos sensores e simultaneamente captura e retorna a atitude (*roll, pitch, yaw*) tratada independentemente.

As figuras a seguir apresentam os resultados obtidos.




Figura 4: Comparação do resultado obtido por diferentes métodos

Novamente aqui é possível observar que o sinal dado tanto pelo acelerômetro como pelo magnetômetro contém ruído, além do escorregamento com o passar do tempo no caso do giroscópio. Em relação à filtragem, nota-se que ela mostrou-se precisa ao comparar com a resposta exata dada pelo XSENS, exceto pelo ângulo de guinada, no qual os resultados apresentaram uma leve divergência, provavelmente por mau posicionamento do magnetômetro, uma vez que as oscilações estão relativamente paralelas umas às outras.

A Fig. 5 abaixo ilustra outra movimentação realizada na plataforma. Para uma melhor visualização, estão apresentados os resultados apenas retornados do XSENS e da filtragem por Kalman.




Figura 5: Comparação dos resultados dados pelo filtro de Kalman Estendido e pelo XSENS

Da figura acima, fica evidente como a filtragem por Kalman produz uma resposta excelente para os ângulos de rolamento e arfagem, uma vez que as curvas estão praticamente sobrepostas, e satisfatória para o ângulo de guinada.

3.2 Filtragem Robusta




Figura 6: Comparação entre os filtros de Kalman Estendido e Robusto

O resultado obtido pela filtragem robusta apresentou um desempenho satisfatório, com um erro equivalente ou menor que o filtro estendido na maior parte do tempo. Em alguns momentos seu desempenho é prejudicado pela qualidade da medição, principalmente por irregularidades, inconstâncias ou movimentação brusca, além dos ruídos associados. Quando há incertezas e distúrbios relacionados à modelagem do sistema, essa filtragem se mostra mais apropriada.

4. CONSIDERAÇÕES FINAIS

Nesse trabalho propôs-se desenvolver um estudo sobre a fusão de dados provenientes de sensores inerciais de baixo custo (do tipo MEMS), com o objetivo de determinar a atitude e posição de um CubeSat. A utilização individual de cada sensor não é ideal pois os dados contêm ruídos, resultados dos erros inerentes, além do efeito de escorregamento (*drift*) no caso do giroscópio causado pelo acúmulo do erro na integração numérica. Esses problemas podem ser corrigidos ou reduzidos ao combinar os sensores e fusionar os dados através de diferentes filtros de Kalman.

Todos os ensaios realizados foram estáticos, entretanto, espera-se que o desempenho do filtro ainda seja satisfatório em aplicações dinâmicas, mesmo com os dados do acelerômetro menos precisos. Esse fato deve ser corrigido automaticamente pelo filtro através das diferentes ponderações calculadas pelo ganho de Kalman e pelas filtragem estendida e robusta ao considerar não linearidades e incertezas associadas. Os resultados obtidos foram satisfatórios, evidenciando a eficácia e a superioridade dos algoritmos de filtragem sobre os dados tratados individualmente ou sem filtragem. Como trabalho futuro propõe-se, através da modelagem apresentada, implementar a fusão entre os sensores inerciais e um receptor GPS.

5. AGRADECIMENTOS

O autor agradece o apoio da agência de fomento FAPESP (Processo n° 2020/08356-2) pelo financiamento durante o desenvolvimento da pesquisa.

O agradecimento se estende também à UNESP, pela divulgação no evento científico VII ENSET - Encontro Sanjoanense de Tecnologia (2020), virtual. Por último, à Universidade de São Paulo (USP), campus de São Carlos - EESC, pela utilização do laboratório e da plataforma sensorial XSENS, fundamental para a coleta e comparação dos dados para a fusão dos sensores inerciais.

6. REFERÊNCIAS

- Bakkali, M.E., Idrissi, N.E.A.E., Tubbal, F.E. and Gaba, G.S., 2018. "Optimum design of a tri-band mpa with parasitic elements for cubesat communications using genetic algorithm". In *2018 6th International Conference on Wireless Networks and Mobile Communications (WINCOM)*. pp. 1–4.
- Farrell, J. and Barth, M., 1999. *The global positioning system and inertial navigation*. McGraw-Hill. ISBN 9780070220454. URL <https://books.google.com.br/books?id=pdubAAAAMAAJ>.
- Grewal, M.S., Weill, L.R. and Andrews, A.P., 2001. "Global positioning systems, inertial navigation, and integration". John Wiley Sons, Inc. New York.
- Guo, H. and Hong, H., 2019. "Research on filtering algorithm of mems gyroscope based on information fusion". College of Intelligence Science and Technology, National University of Defense Technology. Changsha, China. Disponível em: <https://www.mdpi.com/1424-8220/19/16/3552/htm>. Acesso em 22 de Jun. 2021.
- Initiative, N.C.L., 2017. *NASA CubeSat 101: Basic Concepts and Processes for First-Time CubeSat Developers*.
- Inoue, R.S., 2012. *Controle robusto descentralizado de movimentos coordenados de robôs heterogêneos*. Ph.D. thesis, Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos.
- Islam, T., Islam, S., Shajid-UI-Mahmud and Hossam-E-Haider, 2017. "Comparison of complementary and kalman filter based data fusion for attitude heading reference system". In *Proceedings of the 1st International Conference on Mechanical Engineering and Applied Science (ICMEAS)*. haka, Bangladesh. Disponível em: <https://aip.scitation.org/doi/pdf/10.1063/1.5018520>. Acesso em 19 Abr. 2021.
- Kim, P., 2010. *"Kalman Filter for Beginners: with matlab examples"*. A-Jin, Republic Of Korea. Translated by Lynn Huh.
- Liu, Y., Noguchi, N. and Ishii, K., 2014. "Development of a low-cost imu by using sensor fusion for attitude angle estimation". In *Proceedings of the 19th World Congress IFAC - The International Federation of Automatic Control*. Cape Town, South Africa. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1474667016422974>. Acesso em 12 Mai. 2021.
- Lopes, D.F.d.A., 2010. "Estimativa da atitude e posição e controle robusto de um helicóptero autônomo". Dissertação de Mestrado. Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos.
- McCarron, B., 2013. *Low-Cost IMU Implementation via Sensor Fusion Algorithms in the Arduino Environment*. California Polytechnic State University - Faculty of the Aerospace Engineering Department. San Luis Obispo, California. Disponível em: <https://core.ac.uk/download/pdf/18293757.pdf>. Acesso em 14 Mai. 2021.
- Mohan, A., 2017. "Sensor fusion – part 3: Implementation of gyro-accel sensor fusion". Telesens. Disponível em: <https://www.telesens.co/2017/05/02/sensor-fusion-part-3-implementation-of-gyro-accel-sensor-fusion/>. Acesso em 15 de Jun. 2021.
- Nogueira, S.L., 2017. "Sistemas markovianos para estimativa de ângulos absolutos em exoesqueletos de membros inferiores". Doi:10.11606/T.18.2015.tde-19052015-172242. São Carlos: Escola de Engenharia de São Carlos, University of São Paulo, 2015. Doctoral Thesis in Dinâmica das Máquinas e Sistemas.
- Nogueira, S.L., Siqueira, A.A.G., Inoue, R.S. and Terra, M.H., 2013. "Estimation of lower limbs angular positions using robust kalman filter and genetic algorithm". In: 22nd International Congress of Mechanical Engineering (COBEM 2013), Ribeirão Preto.
- Oliveira, W.d.S. and Gonçalves, E.N., 2017. "Implementação em c: filtro de kalman, fusão de sensores para determinação de ângulos". ForScience: revista científica do IFMG, Formiga, v. 5, n. 3, e00287, jul./dez.
- Rezaie, J., Moshiri, B., Araabi, B.N. and Asadian, A., 2007. "Gps/ins integration using nonlinear blending filters". In *SICE Annual Conference 2007*. pp. 1674–1680.
- Salmony, P., 2017. *IMU Attitude Estimation*. Disponível em: <http://philsal.co.uk/projects/imu-attitude-estimation>. Acesso em 28 Abr. 2021.
- Sayed, A.H., 2001. "A framework for state-space estimation with uncertain models". In *IEEE Transactions on Automatic Control*, vol. 46, no. 7, pp. 998-1013, July, doi: 10.1109/9.935054.
- Stewart, S., Holt, G.N. and Lightsey, G., 2005. "Real-time attitude determination of a nanosatellite using gps signal-to-noise ratio observations".
- Tawk, Y., 2019. "Physically controlled cubesat antennas with an adaptive frequency operation". *IEEE Antennas and Wireless Propagation Letters*, Vol. 18, No. 9, pp. 1892–1896.

7. RESPONSABILIDADE AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

SENSING A CUBESAT USING SENSOR FUSION

Vinícius Rosolen Altarni, vinicius.altarni@unesp.br¹

Henrique Barboza Ferreira, h.ferreira@unesp.br¹

Denilson Paulo Souza dos Santos, denilson.santos@unesp.br¹

Wilian Miranda dos Santos, wilian.santos@unesp.br¹

¹Universidade Estadual Paulista “Júlio de Mesquita Filho” - Faculdade de Engenharia, Campus de São João da Boa Vista.
Av. Profª Isette Corrêa Fontão, 505 - Jardim das Flores - São João da Boa Vista/SP - CEP 13876-750

Abstract: *CubeSat is a nanosatellite designed to operate at low earth orbit (LEO). The low cost of development and launching allows that universities and small companies access the space. An important step in a CubeSat project concerns to the attitude and heading reference system (AHRS) that can be understood as the system that estimates the satellite state (attitude and position). The global positioning system (GPS) can provide an accurate position estimative, however, due to lack of reliability, using just GPS is not a satisfying solution. The GPS signals can undergo interferences, can be easily obstructed, their measurements are transmitted at low frequencies and the accuracy is affected with the loss of satellites. To solve this problem, the GPS can be combined with an inertial measurement unit (IMU), so if the GPS signal is unavailable the position can be given by the IMU. The IMU's are not sensitive to interference or obstruction, and can provide a high sampling rate. Nonetheless, its disadvantage is in the growth of the error in the attitude and position estimation due to the numerical integration of the measurements of the sensors and their inherent errors. In this paper, an attitude and position estimation of a CubeSat is presented. It's used low cost inertial sensors, which means a higher uncertainty and noise at the measurements. Obtaining the attitude of the CubeSat just with an accelerometer captures properly the movimentation, but the noise data is not acceptable. Using just the gyroscope has significant reduction of the noise, but appears the drift effect occasioned by the numerical integration. These problems can be solved by combining the sensors, fusing the data throughout a Kalman filter, resulting in a signal without noises and accumulated errors. Moreover, robust estimators based on the Kalman filter are used to minimize these effects. To validate this approach, will be presented experimental results with a comparative analysis between the filters.*

Keywords: *CubeSat, low cost sensors, sensor fusion, Kalman filter, robust filter.*