

SIMULADOR DE SISTEMAS DE NAVEGAÇÃO PARA VEÍCULOS AUTÔNOMOS SUBMARINOS

Daniele Caroline Lima da Silva, daniele_caroline@usp.br¹
Adriano Bruno dos Santos Frutuoso, adriano.frutuoso@usp.br¹
Luiz Felipe Marinho de Souza, luiz_souza@usp.br¹
Ettore Apolônio de Barros, eabarro@usp.br¹

¹Escola Politécnica da Universidade de São Paulo

Resumo: O uso de veículos autônomos submarinos tem crescido significativamente em diversos setores, que incluem a indústria de petróleo e gás, a área militar e a pesquisa científica do ambiente marinho. Por serem autônomos e não tripulados, os veículos autônomos submarinos podem ser empregados na inspeção de dutos de gás e petróleo, exploração de recursos marinhos, estudos oceanográficos, aquisição de dados científicos, entre outras aplicações. O desempenho e a duração da missão em campo de um veículo autônomo submarino são limitados pelas baterias ou combustíveis internos e pelos erros cumulativos do sistema de navegação, de modo que, a estimação precisa da localização do veículo se constitui um fator importante para a sua autonomia. A estimação da localização de um veículo autônomo submarino apresenta desafios, tais como: 1) a impossibilidade de se utilizar sistemas de posicionamento por satélite em ambiente subaquático, uma vez que, os sinais de satélite são atenuados pela água; 2) os erros cumulativos no tempo das unidades de medida inercial utilizadas no sistema de navegação; 3) a restrição para importação de unidades de medida inercial de alta qualidade devido ao potencial uso em aplicações militares. Visando o aprimoramento dos estudos da navegação de veículos autônomos submarinos e a melhoria do planejamento de missão em campo, neste trabalho é apresentada uma ferramenta gráfica de simulação de manobras típicas de veículos autônomos submarinos, desenvolvida pela equipe do Laboratório de Veículos Não Tripulados da Universidade de São Paulo. O simulador de manobras permite a visualização gráfica do comportamento das variáveis de navegação, como atitude, velocidade e posição do veículo. Bem como, permite a visualização gráfica das variáveis associadas ao estimador de estados, este último podendo ser um filtro de Kalman convencional ou adaptativo. Ademais, parâmetros determinísticos e estocásticos dos sensores de navegação do veículo, como a unidade de medida inercial, o sensor acústico de velocidade e o sensor de pressão, podem ser configurados no simulador, com a finalidade de avaliação dos efeitos dos erros de tais sensores na navegação do veículo.

Palavras-chave: AUV, Simulador, Sistema de navegação, Filtro de Kalman.

1. INTRODUÇÃO

O avanço tecnológico das últimas décadas tem fomentado a expansão do campo da robótica, especificamente de robôs autônomos. Dentre estes, podem ser citados, de acordo com o seu ambiente de atuação, os robôs subaquáticos, aéreos, espaciais e terrestres (Shao *et al.*, 2016). Os veículos autônomos, independentemente de sua categoria, requerem significativa qualidade nas informações embarcadas de localização e orientação para definir as trajetórias a serem executadas pelo veículo.

Para execução das missões em campo, o AUV (*Autonomous Underwater Vehicle*) deve dispor de um sistema de navegação que permita associar as informações provenientes dos sensores de navegação com a sua localização. Deste modo, diferentes fatores podem degradar a estimativa de localização do veículo, dentre estes, destaca-se a atenuação de sinais GNSS (*Global Navigation Satellite System*) e a natureza instável do ambiente subaquático. Com o intuito de contornar tais dificuldades, realiza-se a integração de informações de sensores auxiliares, por meio de algoritmos de fusão sensorial como o Filtro de Kalman.

Neste cenário, este trabalho visa aperfeiçoar o desempenho da navegação do AUV através do desenvolvimento de um simulador de navegação. Este simulador permite a simulação de manobras típicas efetuadas pelo AUV, servindo de ferramenta para o estudo do comportamento *a priori* do veículo antes que ensaios em campo sejam realizados, antecipando possíveis problemas e comportamentos indesejáveis. Ademais, o simulador foi desenvolvido de modo a permitir o carregamento de dados de ensaios em campo para análises *a posteriori*.

Este trabalho está estruturado da seguinte forma: na Seção 2 é apresentada a estrutura da navegação inercial auxiliada, o modelo de propagação de erros e as equações do filtro de Kalman; Na Seção 3, são descritas as estruturas de entradas e saídas do simulador de navegação; já as Seções 4 e 5 são dedicadas aos resultados e conclusões.

2. NAVEGAÇÃO INERCIAL AUXILIADA

A estimativa da localização de um AUV apresenta desafios como a impossibilidade de se utilizar o GPS (*Global Positioning System*) em ambiente submerso, uma vez que, o sinal do mesmo é atenuado na água (Paull *et al.*, 2014). Além disso, o acúmulo de erro ao longo do tempo resultante do processo de integração das medições dos sensores inerciais contribui, de forma significativa, para a degradação da estimativa da localização do veículo.

Neste sentido, a navegação inercial auxiliada por DVL (*Doppler Velocity Log*) e profundímetro ou PS (*Pressure Sensor*) é uma das principais tecnologias empregadas na navegação de AUVs (Jalving *et al.*, 2004), (Paull *et al.*, 2014), (Liu *et al.*, 2019), uma vez que, o DVL e o profundímetro fornecem, respectivamente, medições de velocidade e de profundidade com melhor exatidão se comparada à obtida com a integração das medições dos acelerômetros da IMU (*Inertial Measurement Unit*). De certo, na superfície, as medições de posição fornecidas pelo GPS também podem ser utilizadas na navegação inercial auxiliada.

A estrutura típica da navegação inercial auxiliada é ilustrada na Figura 1. Na estrutura, o filtro de Kalman realiza a combinação das informações de posição, velocidade e de atitude fornecidas pelo INS (*Inertial Navigation System*) e pelos sensores auxiliares (GPS, DVL e profundímetro). A estimativa resultante dada pelo filtro é, em termos de otimização, de menor incerteza que as fornecidas individualmente pelos sensores auxiliares, bem como, de melhor exatidão que a fornecida pelo INS.




Figura 1. (a) Estrutura da navegação inercial auxiliada. (b) Estrutura do INS.

2.1. Modelo de propagação de erros

O modelo dinâmico expandido da propagação de erros do INS é dado por (Shin, 2001), (Titterton and Weston, 2004), (Silva, 2016):

$$\dot{\mathbf{x}}(t) = \begin{bmatrix} -[\boldsymbol{\omega}_{in}^n \times] & \mathbf{A}_1 & \mathbf{A}_2 & \mathbf{0}_{3 \times 1} & \mathbf{A}_3 & -\mathbf{C}_b^n & \mathbf{0}_{3 \times 3} \\ [\mathbf{f}^n \times] & ([\mathbf{v}^n \times] \mathbf{A}_1 - \mathbf{A}_4) & [\mathbf{v}^n \times] \mathbf{A}_5 & \mathbf{0}_{3 \times 1} & ([\mathbf{v}^n \times] \mathbf{A}_3 + \mathbf{C}_5) & \mathbf{0}_{3 \times 3} & \mathbf{C}_b^n \\ \mathbf{0}_{1 \times 3} & \mathbf{B}_1 & 0 & 0 & b_2 & \mathbf{0}_{1 \times 3} & \mathbf{0}_{1 \times 3} \\ \mathbf{0}_{1 \times 3} & \mathbf{C}_1 & c_2 & 0 & c_3 & \mathbf{0}_{1 \times 3} & \mathbf{0}_{1 \times 3} \\ \mathbf{0}_{1 \times 3} & \mathbf{C}_4 & 0 & 0 & 0 & \mathbf{0}_{1 \times 3} & \mathbf{0}_{1 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 1} & \mathbf{0}_{3 \times 1} & \mathbf{0}_{3 \times 1} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 1} & \mathbf{0}_{3 \times 1} & \mathbf{0}_{3 \times 1} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \end{bmatrix} \mathbf{x}(t) + \begin{bmatrix} -\mathbf{C}_b^n & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{C}_b^n \\ \mathbf{0}_{1 \times 3} & \mathbf{0}_{1 \times 3} \\ \mathbf{0}_{1 \times 3} & \mathbf{0}_{1 \times 3} \\ \mathbf{0}_{1 \times 3} & \mathbf{0}_{1 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \end{bmatrix} \begin{bmatrix} \mathbf{w}_g(t) \\ \mathbf{w}_a(t) \end{bmatrix} \quad (1)$$

onde $\mathbf{x}(t) = [\boldsymbol{\phi}^n \ \boldsymbol{\delta v}^n \ \delta L \ \delta \lambda \ \delta h \ \mathbf{b}_g \ \mathbf{b}_a]^T$ é o vetor de estados; $\boldsymbol{\phi}^n = [\phi_N \ \phi_E \ \phi_D]^T$ é o vetor de erro de atitude expresso no referencial de navegação NED (*North-East-Down*), representado pelo sobrescrito (n), e constituído pelos erros de alinhamento nas direções Norte (ϕ_N), Leste (ϕ_E) e Vertical (ϕ_D); $\boldsymbol{\delta v}^n$ é o vetor de erro de velocidade expressos no referencial de navegação; $\mathbf{v}^n = [v_N \ v_E \ v_D]^T$ é o vetor de velocidade expresso no referencial de navegação, constituído pelas componentes de velocidade nas direções Norte (v_N), Leste (v_E) e Vertical (v_D); $\delta L, \delta \lambda, \delta h$ correspondem aos erros de latitude, longitude e altitude, respectivamente; $\mathbf{b}_g(t)$ e $\mathbf{w}_g(t)$ são os vetores de vies e de ruído dos girômetros, respectivamente; $\mathbf{b}_a(t)$ e $\mathbf{w}_a(t)$ são os vetores de vies e de ruído dos acelerômetros, respectivamente; $\mathbf{C}_b^n$ representa a matriz de rotação do referencial do corpo (b) para o referencial de navegação; $\boldsymbol{\omega}_{in}^n$ é o vetor de rotação do

referencial de navegação em relação ao referencial inercial (i), descrito no referencial de navegação; e $\mathbf{f}^n$ é o vetor de força específica expresso no referencial de navegação.

Os coeficientes do modelo dinâmico são dados por:

$$\mathbf{A}_1 = \begin{bmatrix} 0 & \frac{1}{R_E+h} & 0 \\ -\frac{1}{R_N+h} & 0 & 0 \\ 0 & -\frac{\tan(L)}{R_E+h} & 0 \end{bmatrix}; \mathbf{A}_2 = \begin{bmatrix} -\Omega \sin(L) & 0 \\ 0 & -\Omega \cos(L) - \frac{v_E \sec^2(L)}{R_E+h} \end{bmatrix}; \mathbf{A}_3 = \begin{bmatrix} -\frac{v_E}{(R_E+h)^2} \\ \frac{v_N}{(R_N+h)^2} \\ \frac{v_E \tan(L)}{(R_E+h)^2} \end{bmatrix} \quad (2)$$

$$\mathbf{A}_4 = \begin{bmatrix} 0 & 2\Omega \sin(L) + \frac{v_E \tan(L)}{R_E+h} & -\frac{v_N}{R_N+h} \\ -2\Omega \sin(L) - \frac{v_E \tan(L)}{R_E+h} & 0 & -2\Omega \cos(L) - \frac{v_E}{R_E+h} \\ \frac{v_N}{R_N+h} & 2\Omega \cos(L) + \frac{v_E}{R_E+h} & 0 \end{bmatrix} \quad (3)$$

$$\mathbf{A}_5 = \begin{bmatrix} -2\Omega \sin(L) & 0 \\ 0 & -2\Omega \cos(L) - \frac{v_E \sec^2(L)}{R_E+h} \end{bmatrix}; \mathbf{B}_1 = \begin{bmatrix} \frac{1}{R_N+h} & 0 & 0 \end{bmatrix}; b_2 = -\frac{v_N}{(R_N+h)^2}; \mathbf{C}_1 = \begin{bmatrix} 0 & \frac{\sec(L)}{R_E+h} & 0 \end{bmatrix} \quad (4)$$

$$c_2 = \frac{\sec(L) \tan(L) v_E}{R_E+h}; c_3 = -\frac{v_E \sec(L)}{(R_E+h)^2}; \mathbf{C}_4 = \begin{bmatrix} 0 & 0 & -1 \end{bmatrix}; \mathbf{C}_5 = \begin{bmatrix} 0 \\ 0 \\ -\frac{2g}{R_0+h} \end{bmatrix} \quad (5)$$

onde R_N e R_E são os raios de curvatura meridiano e transversal, respectivamente; g é a magnitude da gravidade local (*plumb-bob*); e $R_0 = \sqrt{R_N R_E}$.

2.2. Filtro de Kalman

O Filtro de Kalman é um estimador estocástico recursivo cuja ideia central, de maneira simplificada, consiste na separação do sinal de uma combinação aditiva entre sinal e ruído (Brown and Hwang, 2012). Os estados do sistema e a incerteza das estimativas são dados continuamente, com variância mínima, através de dois conjuntos de equações: as equações de predição, que inserem no filtro as novas informações da dinâmica do sistema estimando o estado atual e a incerteza dessa estimativa; e as equações de atualização da medição, que atualizam as estimativas usando uma observação do verdadeiro estado do sistema (Gelb, 1974), (Chui and Chen, 2010). Em tempo discreto, o modelo dinâmico é dado por (Teixeira *et al.*, 2009):

$$\mathbf{x}_k = \Phi_{k-1} \mathbf{x}_{k-1} + \mathbf{G}_{k-1} \mathbf{w}_{k-1} \quad (6)$$

onde $\mathbf{x}_{k-1}$ e Φ_{k-1} representam, respectivamente, o vetor de estados do sistema, contendo as variáveis de interesse para a fusão sensorial, e a matriz de transição de estados na iteração $k-1$; $\mathbf{w}_{k-1}$ e $\mathbf{G}_{k-1}$ correspondem aos ruídos de processo (assumidos independentes, brancos e com distribuição normal) e à matriz linear que correlaciona os ruídos de processo aos estados, respectivamente.

O modelo discreto de observação linear do sistema é dado por:

$$\mathbf{y}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (7)$$

onde $\mathbf{y}_k$ e $\mathbf{v}_k$ representam os vetores de observação e de ruídos nas observações, respectivamente. Já $\mathbf{H}_k$ corresponde à matriz de observação. As matrizes de covariância dos ruídos de processo ($\mathbf{Q}_k$) e das medições ($\mathbf{R}_k$) são dadas pelas seguintes matrizes diagonais:

$$E[\mathbf{w}_k \mathbf{w}_i^T] = \begin{cases} \mathbf{Q}_k, & i = k \\ \mathbf{0}, & i \neq k \end{cases} \quad (8)$$

$$E[\mathbf{v}_k \mathbf{v}_i^T] = \begin{cases} \mathbf{R}_k, & i = k \\ \mathbf{0}, & i \neq k \end{cases} \quad (9)$$

$$E[\mathbf{w}_k \mathbf{v}_i^T] = \mathbf{0}, \quad \text{para todo } k \text{ e } i \quad (10)$$

onde $E[.]$ representa o operador esperança matemática.

O primeiro conjunto de equações do Filtro de Kalman, correspondente à etapa de predição, é dado por (Teixeira *et al.*, 2009):

$$\hat{\mathbf{x}}_{k/k-1} = \Phi_{k-1} \hat{\mathbf{x}}_{k-1/k-1} \quad (11)$$

$$\mathbf{P}_{k/k-1} = \Phi_{k-1} \mathbf{P}_{k-1/k-1} \Phi_{k-1}^T + \mathbf{G}_{k-1} \mathbf{Q}_{k-1} \mathbf{G}_{k-1}^T \quad (12)$$

onde $\hat{\mathbf{x}}_{k/k-1}$ é o vetor de estimativas *a priori* dos n estados; $\mathbf{P}_{k/k-1}$ é uma matriz $n \times n$, correspondendo às estimativas *a priori* das covariâncias dos erros dos estados; $\mathbf{G}_{k-1}$ e $\mathbf{Q}_{k-1}$ são matrizes $n \times n$ de correlação linear e de covariância dos ruídos de processo, respectivamente.

O segundo conjunto de equações, corresponde à etapa de atualização do filtro, é dada por (Hide, 2003), (Teixeira *et al.*, 2009), (Grewal and Andrews, 2001):

$$\boldsymbol{\varepsilon}_k = \mathbf{y}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k/k-1} \quad (13)$$

$$\mathbf{S}_k = \mathbf{H}_k \mathbf{P}_{k/k-1} \mathbf{H}_k^T + \mathbf{R}_k \quad (14)$$

$$\mathbf{K}_k = \mathbf{P}_{k/k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \quad (15)$$

$$\hat{\mathbf{x}}_{k/k} = \hat{\mathbf{x}}_{k/k-1} + \mathbf{K}_k \boldsymbol{\varepsilon}_k \quad (16)$$

$$\mathbf{P}_{k/k} = \mathbf{P}_{k/k-1} - \mathbf{K}_k \mathbf{S}_k \mathbf{K}_k^T \quad (17)$$

onde $\boldsymbol{\varepsilon}_k$ é o vetor de inovação do sistema; $\mathbf{S}_k$ é a matriz de covariância de erro do vetor de inovação; $\mathbf{K}_k$ é a matriz $n \times m$ de Ganho de Kalman, onde m é a dimensão do vetor de observações; $\hat{\mathbf{x}}_{k/k}$ e $\mathbf{P}_{k/k}$ correspondem ao vetor $n \times 1$ e matriz $n \times n$ com os valores *a posteriori* das estimativas dos estados e das covariâncias dos erros dos estados.

Em geral, os sistemas dinâmicos são modelados na representação de tempo contínuo. A relação entre a matriz dinâmica $\mathbf{F}$ do modelo contínuo e a matriz de transição de estados Φ_{k-1} é obtida a partir da seguinte aproximação (Hide, 2003):

$$\Phi_{k-1} \approx e^{\mathbf{F}\Delta t} = \sum_{n=0}^{\infty} \frac{(\mathbf{F}\Delta t)^n}{n!} = \left(\mathbf{I} + \mathbf{F}\Delta t + \frac{(\mathbf{F}\Delta t)^2}{2!} + \dots \right) \quad (18)$$

onde $\mathbf{I}$ é a matriz identidade e Δt é o intervalo de tempo.

3. ESTRUTURA DO SIMULADOR

O Simulador de Navegação do AUV foi desenvolvido no GUIDE, ambiente de desenvolvimento de interface gráfica do MATLAB®. Este ambiente possui um conjunto de ferramentas para a criação de interfaces gráficas de usuário (GUIs). A interface permite a visualização dos dados e a customização do projeto de acordo com o desejado pelo desenvolvedor.




Figura 2. Entradas e Saídas do simulador.

O simulador é dividido em entradas e saídas, conforme mostrado na Figura 2, e todos os blocos estão inseridos na tela principal do simulador. As entradas do simulador consistem em informações de configuração que são imputadas para gerar os dados de trajetória, de medições dos sensores de navegação, de alinhamento, e de navegação. Cada um dos blocos que formam as entradas do simulador possui uma subtela de configuração.

Os blocos associados às entradas do simulador são:

- Tipo de dados, que possui opções de simulação de dados reais ou simulados. A opção “real” consiste na utilização dos dados de campo, enquanto a opção “simulado” utiliza o modelo de erros dos sensores para simulação da navegação.
- Trajetória, onde o usuário define o tipo de trajetória, tendo como opções a linha reta padrão, o corte de relva padrão e o customizado. A opção customizado permite que o usuário altere a configuração padrão e permite a escolha de outras trajetórias, como a linha reta com ioiô, corte de relva com ioiô e o corte de relva com curva.
- Modelo de Erro dos Sensores, onde são atribuídas informações características de cada sensor de navegação, permitindo ao usuário customizar as configurações internas do DVL, Profundímetro e GPS.
- Alinhamento, onde se escolhe o tipo de método para a obtenção da orientação inicial do AUV em relação ao referencial de navegação. As opções de alinhamento são: 1) grosseiro, em que são utilizadas medições de inclinômetro e bússola para a orientação inicial do veículo; 2) fino, em que são empregados métodos de fusão sensorial para a melhoria da estimativa de orientação do veículo.
- Navegação, onde o tipo varia de acordo com os sensores empregados na fusão sensorial. Na subtela de configuração da navegação, o usuário pode inserir informações como o erro de fator de escala do DVL, o desalinhamento IMU/DVL, os parâmetros de sintonia do Filtro de Kalman, entre outros. A navegação utiliza todas as informações configuradas no simulador para gerar os dados de saída da navegação, que podem ser devidamente visualizadas pelo usuário.
- Gráficos de entrada, em que é possível observar o comportamento da trajetória simulada com base nas configurações inseridas pelo usuário. Além deste, pode-se observar os dados dos sensores de navegação.

Para exemplificar algumas das subtelas do conjunto de blocos da entrada, nas Figuras 3, 4, 5 e 6 são mostradas as subtelas da configuração de trajetória, do modelo de erros do DVL, alinhamento grosseiro e navegação, respectivamente.

Simulated Trajectory Settings

Type Trajectory: Lawn Mower

Time Curve (s): 5

Final Simulation Time (s): 1200

True Velocity in B Frame (m/s): [1 0 0]

Interval Between Epochs (s): 0.01

Attitude Angles (deg): [0 0 90]

Initial Depth (m): 2

Initial Coordinates (deg): [-23 -45]

Maximum depth (m): 12

Yoyo start time (s): 60

Yoyo repetition: 5

Pitch reference (deg): 10

Buttons: OK, DEFAULT, LOAD

Figura 3. Subtela de configuração da trajetória.

Error Model: DVL

Final Simulation Time (s): 1200

Sample Time (s): 0.01

DVL scale factor: [5 5 5]

Noise Signal: [1 1 -1]

DVL misalignment w.r.t B frame: [1 1 5]

Allan Parameters:

Q (mm): [0 0 0]

N (mm/sqrt(s)): [20 20 20]

B (m/s): [0 0 0]

K (m/s^1.5): [0 0 0]

R (m/s^1.2): [0 0 0]

wo (rad/s): [0 0 0]

beta (Hz): [0 0 0]

Buttons: OK, DEFAULT, LOAD

Figura 4. Subtela de configuração do modelo de erros do DVL.

Coarse Alignment

Alignment Type: COMPASS-INCLINOMETER

Filter Selection: KF

Sample Time (s): 0.1

Final Time Simulation [s]: 1200

Attitude Step Size: 0.01

Alignment Time [s]: 420

Magnetic Declination [deg]: -20.4

Position Step Size: 0.1

Magnetic Compass Heading: 74.6

Gyro Bias (deg/h): [23 -5.2 0.32]

KF tuning:

Q: 0.0001

R: 1

Inclinometer roll pitch [deg]: [2 -2]

Buttons: OK, LOAD, DEFAULT

Figura 5. Subtela de configuração do alinhamento grosseiro.

Inercial Aided

Final Simulation Time (s): 1200

Sample Time (s): 0.1

Gyro Bias (deg/h): [9 9 9]

Accel Bias (micro-g): [900 900 900]

DVL scale factor (%): 5

Interval update (s): 15000

Attitude Step Size: 0.01

Position Step Size: 0.1

Filter Selection: KF

IMU/DVL mis. error (deg): [1 1 5]

Parameters Kalman:

R =

0.0025	0	0	0	0	0	0
0	0.0025	0	0	0	0	0
0	0	0.0025	0	0	0	0
0	0	0	2.5000e-13	0	0	0
0	0	0	0	2.5000e-13	0	0
0	0	0	0	0	1.0000e-04	0

P =

P_mis_error:	1	1	5
P_vel_error:	0.1000	0.1000	0.1000
P_hor_pos_error:	5	5	0
P_ver_pos_error:	1	0	0
P_coord_error:	1.0000e-06	1.0000e-06	0
P_gyro_bias:	1	1	1
P_accel_bias:	100	100	100

Parameters Kalman:

Q =

diag([(2.14e-5)^2 (2.14e-5)^2 (2.14e-5)^2 (4.47e-4)^2 (4.47e-4)^2 (4.47e-4)^2 zeros(1,9)])

Buttons: OK, LOAD, DEFAULT

Progress bar: 0%

Figura 6. Subtela de configuração da navegação.

As saídas do simulador contêm os dados de navegação que foram gerados com base nas configurações definidas pelo usuário. Os blocos associados às saídas do simulador são:

- Variáveis de navegação, em que são gerados os dados de coordenadas, posição, velocidade e atitude produzidos pelos algoritmos de navegação;
- Variáveis KF, em que são gerados os dados de estimação das variáveis de estado do modelo dinâmico, as sequencias residuais e de inovação do Filtro de Kalman, e as variâncias dos erros de estimação dos estados;
- Gráficos e Estatísticas, onde os dados estatísticos exibidos pelo simulador correspondem aos erros de posição, velocidade e atitude absolutos, além dos erros RMS (*Root Means Square*) de posição. Por meio desses dados o usuário obtém informações sobre o desempenho da navegação;

4. RESULTADOS

Nesta seção, são apresentados resultados de simulação da navegação considerando uma manobra corte de relva à velocidade constante, de acordo com as seguintes condições: a) Atitude inicial de 2 graus (*roll*), -2 graus (*pitch*) e 90 graus (*yaw*); b) Coordenadas iniciais de -23 graus (Latitude) e -45 graus (longitude); c) Desalinhamento IMU/DVL de 1 grau para os eixos *x* e *y* e 5 graus para *z*; d) Erro de fator de escala do DVL de 5%; e) Girômetros de 10 graus/hora (viés) e 0,033 graus/sqrt(h) (*angle random walk*), e acelerômetros de 1000 micro-g (viés) e 0,0002 (m/s)/sqrt(s) (*velocity random walk*); f) Integração INS/GPS/DVL/PS fracamente acoplada, de acordo com o modelo dinâmico dado na equação (1).

A sintonia dos parâmetros do filtro de Kalman é mostrada na Tabela 1, onde *diag* representa uma matriz diagonal, $\mathbf{x}_0$ e $\mathbf{P}_0$ são os valores iniciais do vetor de estados e da matriz de covariância dos erros dos estados, respectivamente.

Tabela 1. Parâmetros de sintonia do filtro de Kalman.

Parâmetros	Valor
$\mathbf{x}_0$	$\mathbf{0}_{15 \times 1}$
$\mathbf{P}_0$	$diag[(1^\circ)^2 (1^\circ)^2 (5^\circ)^2 (0,1m/s)^2 (0,1m/s)^2 (0,1m/s)^2 (10^{-6}rad)^2 (10^{-6}rad)^2 (1m)^2 (1^\circ/h)^2 (1^\circ/h)^2 (1^\circ/h)^2 (100\mu g)^2 (100\mu g)^2 (100\mu g)^2]$
$\mathbf{Q}$	$diag \left[(2,14 \times 10^{-5} / \sqrt{h})^2 (2,14 \times 10^{-5} / \sqrt{h})^2 (2,14 \times 10^{-5} / \sqrt{h})^2 (4,47 \times 10^{-4} (m/s) / \sqrt{s})^2 (4,47 \times 10^{-4} (m/s) / \sqrt{s})^2 (4,47 \times 10^{-4} (m/s) / \sqrt{s})^2 \mathbf{0}_{1 \times 9} \right]$
$\mathbf{R}$	$diag[(0,05 m/s)^2 (0,05 m/s)^2 (0,05 m/s)^2 (5 \times 10^{-7} rad)^2 (5 \times 10^{-7} rad)^2 (0,01 m)^2]$

A tela principal do simulador é apresentada na Figura 7. Nesta tela, são apresentados os gráficos de entrada e saída, conforme as configurações do tipo de manobra, do modelo de erros dos sensores de navegação, do alinhamento e da navegação.




Figura 7. Tela principal do simulador de navegação do AUV.




Figura 8. Entrada: Manobra de corte de relva.

A manobra corte de relva é mostrada na Figura 8, considerando um tempo total de simulação de 1200 segundos e velocidade constante de 1,0 m/s. Para avaliação do desempenho do algoritmo de fusão sensorial implementado para o simulador, as figuras 9 a 12 mostram as coordenadas, a posição, a atitude e a velocidade do AUV nas direções Norte, Leste e Vertical (*Down*).

Nesta simulação, é possível verificar que a trajetória realizada pelo veículo se aproxima da trajetória de referência (vermelho pontilhado), conforme mostra a Figura 9. Inclusive, durante a ocorrência de curvas o veículo acompanhou a trajetória de referência, o que pode ser considerado um bom desempenho do algoritmo de navegação visto que as curvas mudam abruptamente a dinâmica do veículo.




Figura 9. Saída: trajetória.




Figura 10. Saída: posição.




Figura 11. Saída: atitude.




Figura 12. Saída: velocidade.

Ressalta-se, entretanto, que entre o intervalo de tempo de 120 e 500 segundos, houve um aumento significativo da variância da posição e da velocidade do veículo, como mostram as Figuras 10 e 12. Isto ocorreu devido a desabilitação da fusão sensorial INS/GPS/DVL/PS neste intervalo de tempo, de modo a ilustrar o efeito da fusão

sensorial na estimação das variáveis de navegação. A combinação das medições de cada sensor, por meio da técnica de filtragem de Kalman, resultou na redução da variância da posição e da velocidade do AUV.

A estimação dos vieses dos girômetros e acelerômetros são mostrados nas Figuras 13 e 14, de modo que estimação destes parâmetros apresentou o efeito da desabilitação da fusão sensorial. No caso dos girômetros, b_{gx} e b_{gy} tenderam a acompanhar o valor de referência (10 graus/h), enquanto o parâmetro que mais sofreu o efeito da desabilitação da fusão sensorial foi b_{gz} , que a partir de 500 segundos de simulação apresentou acréscimo atingindo aproximadamente 15 graus/h entre 1000 e 1100 segundos de simulação. Os vieses dos acelerômetros b_{ay} e b_{az} , por sua vez, tenderam a acompanhar o valor de referência (1000 micro-g) durante toda a duração da manobra. Entretanto, b_{ax} atingiu o patamar de 1500 micro-g durante o intervalo de tempo de 500 e 900 segundos de simulação.




Figura 13. Saída: viés dos girômetros.




Figura 14. Saída: viés dos acelerômetros.

Para avaliação estatística dos resultados da navegação, a Tabela 2 mostra que o erro de posição absoluta, por exemplo, variou em torno de 6,39 metros na direção Norte (com a desabilitação da fusão sensorial inclusa) após 1200 segundos de simulação.

Tabela 2. Estatística da Navegação.

Estatísticas da Navegação	Valores [Norte, Leste e Down]
Erro de Posição Absoluta (m)	[6,3924 5,7935 0,0106]
Erro de Velocidade Absoluta (m/s)	[0,0024 0,0161 0,0012]
Erro de Atitude Absoluta (graus)	[0,0024 0,0130 0,3824]
Erro RMS da posição (m)	[4,7138 3,6978 0,0664]

Considerando a simulação com fusão sensorial permanentemente habilitada, os resultados de estimação das coordenadas e da posição do veículo no referencial NED são mostrados nas Figuras 15 e 16, respectivamente. Ao realizar uma breve comparação entre as coordenadas mostradas nas Figuras 9 e 15, pode-se reafirmar que a integração das medições dos sensores de navegação por meio da fusão sensorial melhora a precisão da navegação.




Figura 15. Saída: trajetória (navegação com fusão INS/DVL/GPS/PS).




Figura 16. Saída: posição (navegação com fusão INS/DVL/GPS/PS).

A Tabela 3 apresenta os dados estatísticos da navegação considerando a fusão sensorial habilitada durante toda a simulação. Nota-se que o erro de posição absoluta, por exemplo, foi ao redor de 0,46 metros na direção Norte.

Tabela 3. Estatística da navegação com fusão INS/DVL/GPS/PS permanentemente habilitada.

Estatísticas da Navegação	Valores [Norte, Leste e Down]
Erro de Posição Absoluta (m)	[0,4653 2,5568 0,0050]
Erro de Velocidade Absoluta (m/s)	[0,0012 0,0198 5,18e-4]
Erro de Atitude Absoluta (graus)	[0,0045 5,69e-4 0,1895]
Erro RMS da posição (m)	[1,2777 2,4839 0,0160]

Por fim, a estimação dos vieses dos girômetros e acelerômetros são mostradas nas Figuras 17 e 18. Com a fusão sensorial permanentemente habilitada, tais parâmetros apresentaram melhor desempenho durante toda a duração da simulação.




Figura 17. Saída: viés dos girômetros. (navegação com fusão INS/DVL/GPS/PS).




Figura 18. Saída: viés dos acelerômetros (navegação com fusão INS/DVL/GPS/PS).

5. CONCLUSÃO

A proposta de construção do simulador de navegação foi desenvolver técnicas de fusão sensorial para serem utilizadas no sistema de navegação do veículo, uma vez que, tal implementação traz maior praticidade nas etapas de desenvolvimento dos algoritmos. E isto permite que novas propostas de técnicas sejam implementadas, devido a análise se tornar mais acessível por meio dos dados estatísticos e gráficos que estão disponíveis na interface.

As etapas de desenvolvimento consistiram na elaboração do algoritmo de geração de trajetória simulada, no estudo e implementação do modelo de propagação de erros do INS, na implementação dos algoritmos de alinhamento e de fusão sensorial com Filtro de Kalman. Estas etapas possibilitaram o desenvolvimento da interface gráfica do simulador.

Por meio do desenvolvimento do simulador de navegação foi possível obter algoritmos capazes de simular manobras realizadas pelo AUV, encontrar configurações adequadas para cada bloco, bem como analisar o desempenho da navegação.

6. REFERÊNCIAS

- Brown, G., Hwang, C., 2012. *Introduction to Random Signals and Applied Kalman Filtering with MATLAB Exercises*. Ed. 4ª. ed. [S.l.]: Wiley.
- Chui, C. K., Chen, G., 2010. *Kalman Filtering with Real-Time Applications*. 4ª. ed. [S.l.]: Springer.
- Gelb, A., 1974. *Applied Optimal Estimation*. [S.l.]: The M.I.T. Press.
- Grewal, M. S.; Andrews, A. P., 2001. *Kalman Filtering Theory and Practice Using MATLAB*. 4ª. ed. New York: Wiley.
- Hide, C., 2003. *Integration of GPS and low cost INS measurements*. PhD thesis, University of Nottingham.
- Jalving, B., Gade, K.; Svartveit, K.; Willumsen, A.; Sorhagen, R., 2004. DVL Velocity in the HUGIN 1000 Integrated Inertial Navigation System. *Modeling, Identification and Control*, pp. 223-235.
- Liu, J., Wang, B. and Deng, Z., 2019. *An Online Calibration Method of INS and Doppler Sensors*. Islamabad, IEEE, pp. 824-829.

- Paull, L., Saeedi, S., Seto, M. and Li, H., 2014. AUV Navigation and Localization: A Review. *IEEE Journal of Oceanic Engineering*, Janeiro, 39(1), pp. 131-149.
- Shao, X., He, B., Guo, J. & Tianhong, Y., 2016. *The application of AUV navigation based on adaptive extended Kalman filter*. In: OCEANS 2016, 2016. Anais [...]. Shanghai: IEEE.
- Shin, E.-H., 2001. *Accuracy Improvement of Low Cost INS/GPS for Land Applications*, Calgary: s.n.
- Silva, F. O. e., 2016. *Stationary Self-Alignment and Calibration Techniques for Strapdown Inertial Navigation Systems*, São Jose dos Campos: s.n
- Teixeira, B.; Chandrasekar, J.; Torres, L.; Aguirre, L.; Bernstein, D., 2009. *State estimation for linear and non-linear equality-constrained systems*. International Journal of Control - INT J CONTR.
- Titterton, D. H. and Weston, J. L., 2004. *Strapdown Inertial Navigation Technology*. 2 ed. s.l.:The Institution of Electrical Engineers.

7. RESPONSABILIDADE AUTORAL

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

NAVIGATION SYSTEMS SIMULATOR FOR AUTONOMOUS UNDERWATER VEHICLES

Daniele Caroline Lima da Silva, danielle_caroline@usp.br¹
Adriano Bruno dos Santos Frutuoso, adriano.frutuoso@usp.br¹
Luiz Felipe Marinho de Souza, luiz_souza@usp.br¹
Ettore Apolônio de Barros, eab Barros@usp.br¹

¹ Polytechnic School of the University of São Paulo

Abstract. The use of autonomous underwater vehicles has grown significantly in several areas, which include the inspection of gas and oil pipelines, exploration of marine resources, oceanographic studies, and the acquisition of scientific data. The performance and the field mission duration of an autonomous underwater vehicle are limited by the batteries or internal fuels and by the cumulative errors of the navigation system. So, the accurate estimation of the vehicle location is an important factor for its autonomy. The location estimative of an autonomous underwater vehicle presents challenges, which include: 1) the impossibility of using satellite positioning systems in an underwater environment, since the satellite signals are attenuated by the water; 2) the cumulative errors of the inertial measurement units used in the navigation system; 3) the restriction to import high-quality inertial measurement units due to potential use in military applications. Aiming at the improvements of the mission planning and navigation performance, this work presents a graphical tool for simulating typical maneuvers of autonomous underwater vehicles, developed by the team of the Unmanned Vehicles Laboratory of the University of Sao Paulo. The simulator allows the graphic visualization of the behavior of the navigation variables. Also, the simulator allows the graphic visualization of the variables associated with the state estimator, which can be a conventional or an adaptive Kalman filter. In addition, deterministic and stochastic parameters of the navigation sensors can be configured in the simulator, to evaluate the effects of the sensor errors on vehicle navigation.

Keywords: AUV, Simulator, Navigation System, Kalman Filter.