

# Assessment of Noise Impact on Hybrid Adaptive Computational Intelligence Multisensor Data Fusion Applied to Real-Time UAV Autonomous Navigation

Â. de Carvalho, L. Frutuoso, and E. Hideiti

**Abstract**—Recent work have successfully employed a low-cost Multisensor Data Fusion application based on Hybrid Adaptive Computational Intelligence (HACI) – the cascaded use of Fuzzy-based Computational Intelligence algorithms. The methodology has been shown able to improve considerably the accuracy of current positioning estimation systems for real-time Unmanned Aerial Vehicle (UAV) autonomous navigation – which are not robust – reducing the error in more than 45,19%. However, HACI methodology was found to have a sensitivity to noise in some parts of the estimated trajectories and, therefore, loss of performance. The problem is that none of these recent work assesses the impact of noise present on input signals and the potential benefits of their treatment prior to fusion itself. This is the main contribution of this work. Noise treatment is performed in two approaches: noise removal and noise filtering. It has been shown that for the studied dataset, the noise has a negative impact and that the chosen techniques are capable of adequately handling the noise so as to improve the original GPS precision by almost 57%.

**Index Terms**—Noise Treatment, Data Fusion, Computational Intelligence, Unmanned Aerial Vehicles, Autonomous Navigation, Inertial Sensors, Positioning Estimation, ANFIS, FCM.

## I. INTRODUÇÃO

SISTEMAS embarcados são cruciais para o desenvolvimento de tecnologias capazes de operar de forma autônoma. No que diz respeito a Aeronaves Remotamente Pilotadas (ARPs), também conhecidas como *Drones*, os sistemas tradicionalmente utilizados para sua navegação autônoma – Global Positioning System (GPS) e Inertial Navigation System (INS) [1] – não são imunes a falhas e/ou indisponibilidades, de origem natural ou humana [2], [3]. Segundo [4], a Fusão de Dados de diversos sensores embarcados pode ser um importante auxílio no aumento da precisão desses sistemas.

Diversos trabalhos apresentam o uso de Fusão de Dados aplicada ao problema da navegação de ARPs. Em [5], por exemplo, os autores estabelecem um modelo cinemático para a integração INS/GPS, combinando equações de navegação inercial e equações de erro da Unidade de Medidas Inerciais (do inglês: *Inertial Measurement Unit - IMU*), por meio de um *refined strong tracking unscented Kalman filter* (RSTUKF). Já [6] propõe um Filtro de Kalman (KF, do inglês: *Kalman Filter*) adaptativo para ajustar a covariância de ruídos não-gaussianos das medições do GPS sob diferentes precisões de posicionamento, baseado em um modelo de classificação de precisão

treinado por um método supervisionado de Aprendizado de Máquina. Em [7] se promove a melhoria na estimação do posicionamento por vias de fusão pura e simples da IMU com equações do modelo dinâmico da fuselagem da ARP à partir da análise de variações de forças e torques atuantes na fuselagem, utilizando um KF estendido. Por sua vez, [8] emprega duas abordagens em passos diferentes para a melhoria na estimação do posicionamento de um avião: a redução de ruídos pela utilização de transformadas *wavelet* discretas, capazes de preservar sinais de variação rápida, e a estimação de posicionamento propriamente dita usando a técnica *Extreme Learning Machine* (ELM).

Por fim, [4] e [9] usam uma metodologia de Fusão de Dados Multisensor baseada em Inteligência Computacional Híbrida Adaptativa (HACI, do inglês: *Hybrid Adaptive Computational Intelligence*) apta a ser embarcada em sua aviãoica, visando a navegação autônoma. Vê-se que a utilização de um Sistema de Inferência Fuzzy (do inglês: *Fuzzy Inference System - FIS*) como um Sistema de Fusão de Dados Multisensor é capaz de fornecer à malha de controle da aeronave uma estimação de posicionamento aperfeiçoada. Tal estimação mostrou-se suficientemente rápida para ser embarcada para operação em tempo real [4], [10]. Isto é desejável, posto que as ARPs costumam indispor de carga-paga para sistemas mais robustos. Além disso, é conhecido que o emprego de técnicas tradicionais como o KF apresentam uma série de limitações [11]. A metodologia HACI mostrou desempenho superior a duas outras metodologias de Inteligência Computacional, em 18 diferentes abordagens [4]. A fusão de dados dos sensores acelerômetro, giroscópio e GPS reduziu a área de erro de estimação horizontal (Latitude e Longitude) do GPS em mais de 45,19%, quando comparada com a posição assumida como verdade fornecida por um GPS do tipo *Real-Time Kinetic* (RTK) filtrado por um Filtro de Kalman (KF-GPS-RTK) [4].

Apesar dos bons resultados, nenhum dos trabalhos que usam a metodologia HACI considera o tratamento de ruídos em etapa prévia à fusão propriamente dita, como é feito em [8]. Vê-se em [4] que a metodologia HACI apresenta sensibilidade a ruídos em alguns trechos das trajetórias estimadas e que os dados utilizados tanto para treinamento quanto para validação e generalização não estavam isentos de ruído. Há, portanto, uma perda de desempenho. Almejando dar maior segurança no emprego da técnica em voo, este trabalho propõe uma análise do impacto dos ruídos no desempenho da metodologia HACI, sendo esta a principal contribuição deste trabalho. Isto objetiva avaliar uma eventual melhora na precisão do sistema de Fusão,

Ângelo de C. Paulino, Lamartine N. F. Guimarães e Elcio H. Shiguetori são Pesquisadores do Instituto de Estudos Avançados (IEAv), São José dos Campos, São Paulo, Brasil. (e-mails: angeloacp, guimarae e elcio@ieav.cta.br).

à partir de um tratamento prévio do conjunto de dados.

## II. METODOLOGIA HACI E RUÍDOS

Técnicas de Fusão de Dados podem ser usadas para a extrair informação útil de dados obtidos por sistemas aeroespaciais em voo [2], [12], o que não é trivial. Diante de vários contextos e cenários de voo possíveis, não há uma solução única para a Fusão de Dados [12]. Portanto, utilizar uma técnica adequada para a realização da fusão é de suma importância. A técnica escolhida – a metodologia HACI [4] – é baseada no emprego de duas técnicas de Inteligência Computacional em cascata, a técnica *Fuzzy C-Means Clustering* (FCM) [13] e *Adaptive-Neural-Network-Based Fuzzy Inference System* (ANFIS) [14].

Como outras técnicas de agrupamento, a FCM auxilia na obtenção de uma intuição a respeito de dados cujo volume torna problemática a análise por parte de seres humanos [15]. Mas, diferentemente de técnicas rígidas de agrupamento, a exemplo da  $k$ -médias e  $x$ -médias, a FCM permite que uma mesma amostra pertença, em maior ou menor grau, a mais de um centroide, o que é determinado por funções de pertencimento (do inglês: *membership functions* – *MFs*) da lógica *Fuzzy* [16]. Isso expande tanto a capacidade de diferenciação entre as amostras como de aglomeração e permite, por exemplo, a identificação de ruídos nas regiões de sobreposição de pertencimento [13]. Contudo, a possibilidade de identificar ruídos não quer dizer invariância ou mesmo tolerância a ruídos.

Já o algoritmo ANFIS [14] utiliza um esquema híbrido de aprendizagem e pode construir um mapeamento do tipo entradas-saídas baseado tanto em conhecimento humano (regras *se-então*), quanto por pares associados de entradas e saídas. Deste modo, é capaz de aprender a mapear funções altamente não-lineares [14], [17], [18]. Em suma, pode ser entendido como uma estrutura matemática flexível que pode tratar da aproximação de uma grande classe de sistemas não-lineares complexos com um nível de precisão desejável [18], sem, contudo, perder o rigor matemático [19].

No que tange aos ruídos, vê-se em [20] que o ruído está frequentemente presente em dados reais usados para treinar os algoritmos de Aprendizado de Máquina. Seus efeitos disruptivos no processo de aprendizagem podem incluir: aumento da complexidade dos modelos induzidos; maior tempo de processamento; e menor poder preditivo na classificação de novos exemplos. Assim, [20] conclui que o tratamento de dados ruidosos em uma etapa de pré-processamento é crucial para melhorar a qualidade dos dados e reduzir seus efeitos prejudiciais no processo de aprendizagem. Isso é especialmente verdade para a navegação de uma ARP em tempo real.

## III. O PROBLEMA DO RUÍDO E SEU TRATAMENTO

Após uma inspeção visual das melhores trajetórias estimadas pelos algoritmos utilizados em [4], a saber, HACI (FCM+ANFIS), Redes Neurais Artificiais (ANN) e Modelos de Regressão (RM), percebeu-se que as estimativas de posicionamento apresentam certo grau de sensibilidade aos ruídos dos sinais de entrada (dados dos sensores embarcados).

Tal sensibilidade pode ser facilmente percebida na Figura 1, que permite a identificação da tendência dos pontos estimados

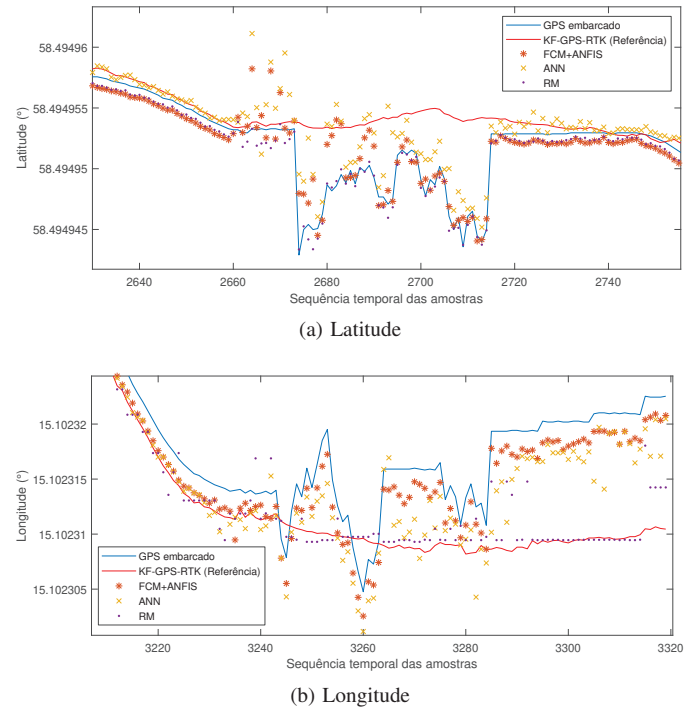


Fig. 1. Trecho das trajetórias estimadas por cada método evidenciando a influência dos ruídos na qualidade da estimação.

pelos diversos métodos acompanharem o sinal ruidoso original (linha azul). Devido à complexidade dos dados de um *log* de voo real, as estimativas divergem significativamente da trajetória real nos trechos onde os ruídos estão presentes. Em outras palavras, há uma tendência em acompanhar-se os ruídos de variação rápida do GPS, indicando que o tratamento prévio dos desvios do GPS pode trazer melhorias para o emprego da metodologia.

Para investigar o problema, é apresentado um estudo do impacto dos ruídos na precisão das estimativas, visando melhorar os resultados alcançados em [4]. Os filtros usados para a análise do impacto de ruídos na estimação do posicionamento de uma ARP em voo são os seguintes [21]–[26]:

- 1) Filtros móveis: uma média móvel é definida como uma média de um número fixo de itens (janela) de uma série temporal que vai percorrendo a série, excluindo os itens mais antigos do grupo anterior de média e adicionando um próximo item em cada média sucessiva. Portanto, seu princípio pode ser usado como filtro de suavização, especialmente no domínio do tempo. Outros filtros, elencados a seguir, são variações dessa média móvel:
  - a) Filtro *Moving Mean* - média móvel tradicional.
  - b) Filtro *Moving Median* - utiliza a mediana – e não a média – para a suavização, preservando picos.
  - c) Filtro *Gaussian-weighted* - utiliza um núcleo ponderado gaussiano para a suavização, capaz de tratar maior complexidade nos dados que os anteriores.
  - d) Filtro Savitzky-Golay de grau  $n$  - suaviza os dados de acordo com um polinômio de grau  $n$  e é efetivo para variações rápidas na série temporal.
- 2) Filtros de regressão: utilizam modelos de regressão para

efetuar o ajuste dos dados, de modo que os dados suavizados são, na verdade, resultado das estimativas dos modelos diante da apresentação dos dados originais.

- Filtro *Linear Regression* - utiliza a regressão linear para a suavização.
- Filtro *Quadratic Regression* - o polinômio local é ajustado por mínimos quadrados ponderados a todos os dados dentro de uma janela cuja largura é ajustada para conter uma proporção fixa dos dados.
- Filtro *Robust Linear Regression* - tal como a regressão linear, mas com certa robustez a *outliers*.
- Filtro *Robust Quadratic Regression* - tal como o filtro *Quadratic Regression*, mas com certa robustez.

#### IV. SOLUÇÃO PROPOSTA

Em face da debilidade identificada, buscou-se realizar um estudo dos possíveis efeitos de um tratamento prévio dos ruídos no desempenho geral da Fusão, em duas abordagens, em um conjunto de dados contendo amostras reais de voo [4]:

- Primeira abordagem: Retirada dos ruídos.
- Segunda abordagem: Filtragem dos ruídos.

A primeira abordagem consiste, basicamente, de uma análise dos gradientes da cinemática da ARP, aliada a uma análise visual da trajetória estimada com o fito de identificar pontos da trajetória fornecida pelo GPS embarcado que presumidamente são ruídos. Após identificados, tais pontos são completamente retirados do conjunto de dados, junto com demais dados relativos àquele instante temporal. Assim, há uma redução do conjunto de dados, de 3.319 amostras para 3.066 amostras consideradas sem ruídos e sem alterações.

Já a segunda abordagem visa um tratamento não-excludente dos dados de entrada por diversos algoritmos. Diferentemente da primeira abordagem, não há retirada de dados e, portanto, o conjunto permanece com 3.319 amostras, suavizadas por técnicas de filtragem. Devido à natureza das técnicas aplicadas, as 3.319 amostras podem, em geral, sofrer alterações e, assim, perder fidedignidade em relação aos dados originais. Isto se dá em virtude de que cada amostra filtrada é, na verdade, uma predição em cima do respectivo dado original [25], [27].

#### V. EXPERIMENTOS E RESULTADOS

##### A. Primeira Abordagem: Retirada dos Ruídos

A retirada dos ruídos foi realizada com base em uma análise dual, tanto dos gradientes de alguns dados captados pelos sensores embarcados da ARP, quanto da trajetória estimada pelos sensores GPS embarcado e KF-GPS-RTK. Foram escolhidos para este fim os dados mais diretamente relacionados à cinemática da ARP em voo, como visto na literatura [28]–[30] e percebido experimentalmente, a saber:

- Latitude e Longitude estimadas pelo GPS embarcado;
- Latitude e Longitude mensuradas pelo KF-GPS-RTK; e
- Componentes de aceleração NX e NY do sensor acelerômetro (ACCEL), que dizem respeito à variação da velocidade no plano horizontal (*Lat* e *Lon*).

Para estes dados foi dado um tratamento vetorial em função do instante  $t$  da amostra. Sabe-se, ainda, que é muito comum

encontrar na literatura uma grande utilização de gradientes e taxas de variação para a modelagem matemática da dinâmica de voo de ARPs, modelagens estas que são embarcadas em seus sistemas de controle, como visto em [28]–[30]. Dessa forma, a fim de identificar tendências, variações e – em última instância – ruídos na trajetória de voo, foram estabelecidas no escopo deste trabalho as seguintes métricas, em que é dado um tratamento vetorial para a sequência temporal dos dados:

- Norma da aceleração horizontal da ARP ( $\|\vec{a}_{Ph}\|$ ). Esta norma é tomada à partir da derivada primeira em função do tempo do gradiente dos dados normalizados (representado por duplas barras horizontais pequenas: “|| ||”) da componente horizontal (vetor “posição horizontal” –  $\vec{S}_h$ ) da cinemática da ARP estimada pelo GPS embarcado:

$$\vec{a}_{Ph}(t) = \dot{\nabla}(\|\vec{S}_h(t)\|), e \quad (1)$$

$$\vec{S}_h(t) = \langle \vec{Lat}(t), \vec{Lon}(t) \rangle \quad (2)$$

- Norma do arranco horizontal ( $\|\vec{j}_h\|$ ), ou seja, o gradiente dos dados normalizados das componentes de aceleração inercial horizontal do sensor ACCEL ( $\vec{a}_{Ih}$ ), com:

$$\vec{j}_h(t) = \nabla(\|\vec{a}_{Ih}(t)\|), e \quad (3)$$

$$\vec{a}_{Ih}(t) = \langle \vec{NX}(t), \vec{NY}(t) \rangle \quad (4)$$

- Velocidade horizontal da ARP ( $\vec{v}_h$ ), obtida à partir do cálculo do gradiente dos dados normalizados da componente horizontal da cinemática da ARP, tanto para o GPS embarcado (Eq. 5) quanto para o KF-GPS-RTK (Eq. 6):

$$\vec{v}_h(t) = \nabla(\|\vec{S}_h(t)\|) \quad (5)$$

$$\vec{v}_{h,RTK}(t) = \nabla(\|\vec{S}_{h,RTK}(t)\|), e \quad (6)$$

- Erro de estimação da velocidade horizontal da ARP ( $\epsilon_{vh}$ ), obtido pelo cálculo do Erro Quadrático Médio (do inglês: *Root-Mean Square Error* - RMSE) entre as velocidades calculadas à partir dos dados do KF-GPS-RTK e GPS:

$$\epsilon_{vh}(t) = RMSE(\vec{v}_h(t), \vec{v}_{h,RTK}(t)) \quad (7)$$

Tais cálculos geram novos vetores, à partir dos dados de entrada relativos a cada instante. Estes vetores viabilizaram a geração dos gráficos constantes da Figura 2, os quais estão ordenados de acordo com a sequência temporal das amostras. Para facilitar a análise e a compreensão de quais janelas de amostras saem da normalidade esperada, foram incluídas linhas que representam o valor médio dos dados em questão, bem como a média somada a 1, 2 ou 3 desvios-padrão.

Diante da análise dos gráficos constantes da Figura 2 e da análise das trajetórias estimadas apresentadas em [4], foram identificadas janelas de amostras com notória discrepância em relação à tendência cinemática da ARP, considerando ainda a trajetória tomada como real apresentada pelo KF-GPS-RTK.

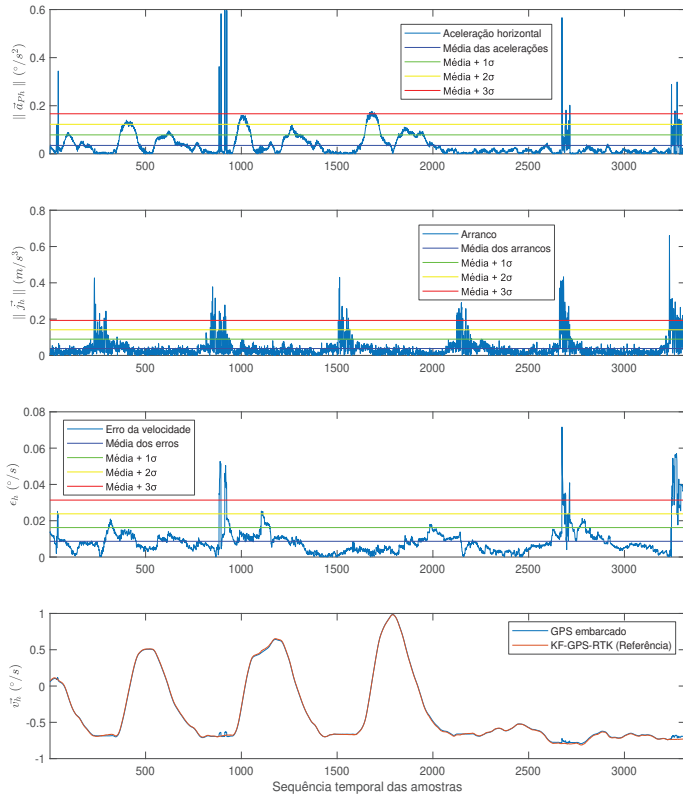


Fig. 2. Cálculos de gradientes e erro da cinemática da ARP.

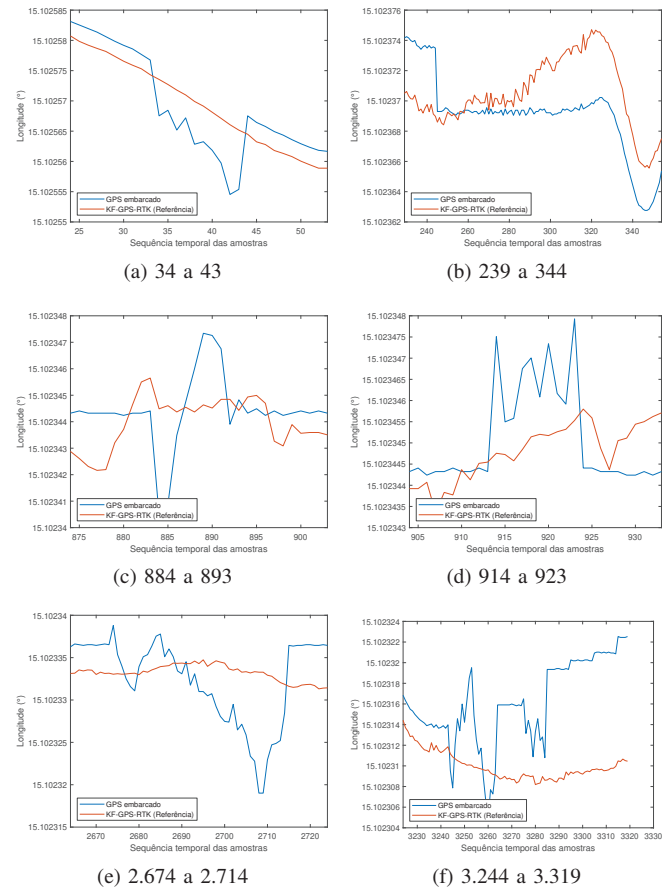


Fig. 4. Janelas identificadas como ruídos - Longitude.

As amostras temporais foram numeradas sequencialmente de 1 a 3.319 nas Figs. 3 e 4, onde se retratam as janelas de amostras com notória discrepância, tratadas como ruídos e, portanto, retiradas da trajetória fornecida pelo GPS embarcado.

Após a retirada de tais janelas, foram gerados novos gráficos de trajetória e, por nova análise visual, percebeu-se que, de fato, não havia nenhum ponto discrepante na trajetória. Na Fig. 5 pode-se ver tanto a trajetória “sem ruídos” (retirados) quanto seu distanciamento temporal dos dados originais. Então, a metodologia HACI foi empregada neste novo conjunto de dados “sem ruídos” a fim de aferir-se sua efetividade em dados presumidamente isentos de ruído, em 1.260 testes.

Para maior segurança estatística nos resultados, foram realizadas 5 repetições para cada um dos 42 grupos de *Cross-Validation* pré-determinados [4], totalizando 210 testes por coordenada (*Lat* e *Lon*) para cada uma das 6 combinações possíveis de sensores.

Em virtude dos bons desempenhos demonstrados em testes anteriores por estes parâmetros, foram fixadas as quantidades de 29 MFs por entrada para a Latitude e 17 MFs por entrada para a Longitude. Neste trabalho, o número de regras equivale ao número de funções de pertinência por entrada. O desempenho foi aferido pela capacidade de predição de cada grupo de *treinamento* sobre o respectivo grupo de *generalização*, para cada uma das 42 combinações de CV, dada determinada seleção de sensores. Os resultados constam da Tabela I.

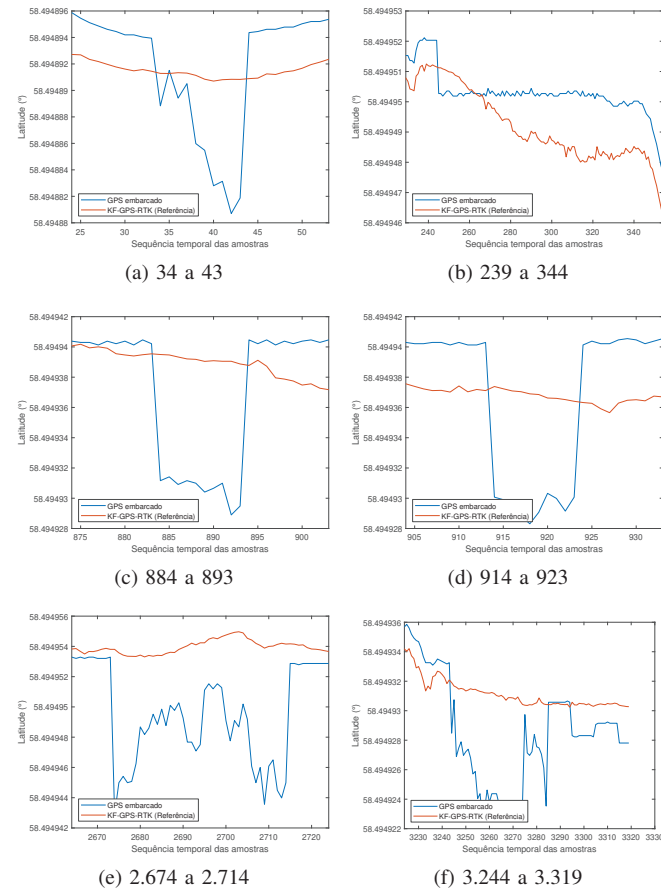


Fig. 3. Janelas identificadas como ruídos - Latitude.

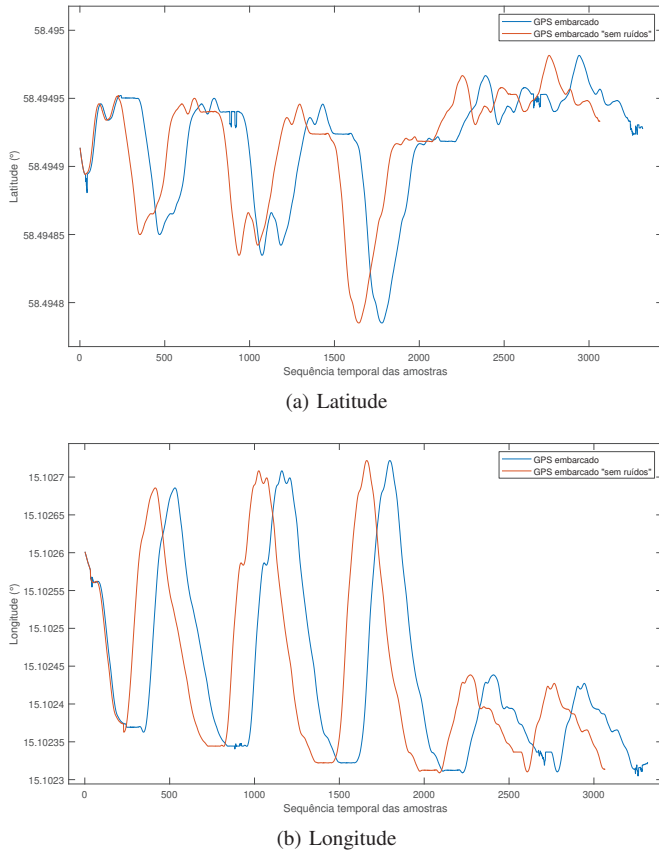


Fig. 5. Trajetórias com e “sem” ruídos.

TABELA I  
COMPARATIVO DOS RMSE E ACURÁCIA DE CADA MÉTODO DE ESTIMAÇÃO DE POSICIONAMENTO COM ELIMINAÇÃO DE RUÍDOS

| Sistema                   | DADOS ORIGINAIS |               | Imprecisão (área em cm <sup>2</sup> ) | DADOS "SEM RUÍDOS" |               | Imprecisão (área em cm <sup>2</sup> ) | Redução da imprecisão (%) |
|---------------------------|-----------------|---------------|---------------------------------------|--------------------|---------------|---------------------------------------|---------------------------|
|                           | Erro Lat (cm)   | Erro Lon (cm) |                                       | Erro Lat (cm)      | Erro Lon (cm) |                                       |                           |
| GPS                       | 21,10           | 30,81         | <b>650,10</b>                         | 16,52              | 26,02         | <b>429,92</b>                         | <b>33,87%</b>             |
| FCM+ANFIS                 | 16,60           | 21,47         | <b>356,31</b>                         | 11,31              | 18,12         | <b>204,89</b>                         | <b>42,50%</b>             |
| Redução da imprecisão (%) | 21,33%          | 30,33%        | <b>45,19%</b>                         | 31,55%             | 30,38%        | <b>52,34%</b>                         | <b>68,48%</b>             |

Da análise da Tabela I, conclui-se o seguinte:

- 1) Analisando-se as linhas, tanto a imprecisão do GPS embarcado quanto a imprecisão da metodologia FCM+ANFIS foram mitigadas pela retirada dos ruídos (33,87% e 42,50% respectivamente). Este resultado revela que, para o conjunto de dados em questão, a presença de ruídos tem um impacto negativo na precisão das estimações de posicionamento, tanto por sensores reais quanto por técnicas de Aprendizagem de Máquina.
- 2) Analisando-se as colunas, ao comparar-se os resultados da metodologia FCM+ANFIS (HACI) com os do GPS embarcado – tendo em mente o *dataset* “sem ruídos” – a redução da imprecisão de 52,34% já foi, por si só, superior aos resultados alcançados em [4] (45,19%).
- 3) A metodologia FCM+ANFIS mostrou-se mais eficiente

no *dataset* “sem ruídos” que no original. Isto indica que a presença de ruídos impacta negativamente na capacidade de aprendizado e generalização da metodologia.

- 4) Comparando a imprecisão do GPS embarcado nos dados originais (650,10cm<sup>2</sup>) com a redução na imprecisão alcançada pela metodologia proposta nos dados “sem ruído” (imprecisão total de 204,89cm<sup>2</sup>), percebe-se uma melhoria total de 68,48%. Logo, há indícios de que utilizar uma abordagem automatizada de identificação e descarte de ruídos em tempo real de voo pode promover uma sensível melhora na redução da imprecisão.

Diante de tais resultados, pode-se afirmar que, para o conjunto de dados estudado, é importante buscar mitigar a presença e o consequente impacto dos ruídos existentes nos dados obtidos pelos sensores durante o voo.

### B. Segunda Abordagem: Filtragem dos Ruídos

Foram testados diversos filtros aplicados aos dados originais a fim de verificar-se qual deles mostra-se o mais efetivo em reduzir a imprecisão da estimação realizada pelo GPS embarcado da ARP. Isto visa oferecer à metodologia HACI um dado mais coerente com a cinemática real da ARP com vistas à Fusão de Dados, à partir da suavização da trajetória.

Em suma, o objetivo é diminuir o impacto negativo dos ruídos para com o desempenho da etapa de treinamento da metodologia HACI e, conseqüentemente, sua capacidade de generalização sem, contudo, imperar na eliminação de dados amostrais. Para tanto, as técnicas de filtragem utilizadas consideram uma janela (*frame*) que se move a cada iteração, considerando  $n$  elementos anteriores para calcular-se o elemento atual ( $e_a$ ), constituindo-se de funções  $n$ -dimensionais:

$$e_a = f(e_{a-1}, e_{a-2}, \dots, e_{a-n})$$

Dessa forma, foram testadas as seguintes técnicas, amplamente discutidas na literatura [21]–[26]: Filtro Savitzky-Golay, variando-se de 1 a 10 graus; Filtro *Moving Mean*; Filtro *Moving Median*; Filtro *Gaussian-weighted*; Filtro *Linear Regression*; Filtro *Quadratic Regression*; Filtro *Robust Linear Regression*; e Filtro *Robust Quadratic Regression*.

As técnicas foram testadas com um tamanho de *frame* variado, a cada teste, de 11 a 101 elementos anteriores ( $n$ ), incrementados de 2 em 2 (11, 13, 15, ..., 101). Portanto, somou-se um total de 782 testes sendo 460 para as variações de grau do filtro Savitzky-Golay e mais 322 para as demais técnicas. Por se tratarem de técnicas determinísticas, e não estocásticas, não houve necessidade de repetições dos testes.

Assim, geraram-se a superfícies constantes das Figuras 6, 7, 8 e 9, duas para os testes com o filtro Savitzky-Golay e mais duas para os demais filtros, para as coordenadas Latitude e Longitude. Cabe ressaltar que o *eixo z* indica o valor da imprecisão em centímetros e que os tamanhos de *frame* superiores a 49 não foram exibidos para fins de clareza.

Os melhores resultados para o filtro Savitzky-Golay bem como os resultados para os demais filtros estão registrados na Tabela II. A referida Tabela indica o erro de cada técnica bem como o percentual de melhora de imprecisão relativamente ao erro do GPS embarcado na ordem dos melhores resultados.




Fig. 6. Desempenho das diversas configurações de graus do filtro Savitzky-Golay em função do tamanho do *frame* - Latitude.




Fig. 7. Desempenho das diversas configurações de graus do filtro Savitzky-Golay em função do tamanho do *frame* - Longitude.




Fig. 8. Desempenho dos demais filtros em função do tamanho do *frame* - Latitude.





Fig. 9. Desempenho dos demais filtros em função do tamanho do *frame* - Longitude.


TABELA II  
COMPARATIVO DOS RMSE E ACURÁCIA DE CADA MÉTODO

| Ord. | Filtro                      | Tamanho do frame | LAT   | Filtro                      | Tamanho do frame | LON   | Imprecisão (área em cm <sup>2</sup> ) | Redução da imprecisão (%) |
|------|-----------------------------|------------------|-------|-----------------------------|------------------|-------|---------------------------------------|---------------------------|
| 1º   | Robust quadratic regression | 55               | 18,50 | Robust quadratic regression | 45               | 29,37 | 543,32                                | <b>16,42%</b>             |
| 2º   | Robust linear regression    | 29               | 18,70 | Savitzky-Golay (4º grau)    | 59               | 29,56 | 552,61                                | <b>14,99%</b>             |
| 3º   | Quadratic regression        | 71               | 18,75 | Quadratic regression        | 57               | 29,61 | 555,02                                | <b>14,63%</b>             |
| 4º   | Savitzky-Golay (2º grau)    | 53               | 18,78 | Moving mean                 | 13               | 29,65 | 556,73                                | <b>14,36%</b>             |
| 5º   | Moving median               | 31               | 18,78 | Gaussian-weighted           | 21               | 29,66 | 557,00                                | <b>14,32%</b>             |
| 6º   | Moving mean                 | 21               | 18,90 | Linear regression           | 21               | 29,71 | 561,41                                | <b>13,64%</b>             |
| 7º   | Gaussian-weighted           | 33               | 18,91 | Moving median               | 31               | 29,74 | 562,42                                | <b>13,49%</b>             |
| 8º   | Linear regression           | 33               | 19,00 | Robust linear regression    | 17               | 29,82 | 566,74                                | <b>12,82%</b>             |

Diante de tais resultados, fica evidenciado que o filtro *Robust Quadratic Regression* (RQR) mostrou desempenho superior às demais técnicas. Devido ao grande volume de testes do passo seguinte, apenas este filtro foi utilizado para tratar os dados de entrada — Latitude e Longitude do GPS embarcado — e gerar um novo conjunto de dados filtrados para estas coordenadas, com igual quantidade de amostras. A comparação da trajetória filtrada com as trajetórias real e estimada pelo sensor GPS embarcado consta da Figura 10, que retrata os mesmos trechos ruidosos já apresentados na Fig. 1.



(a) Latitude



(b) Longitude

Fig. 10. Trechos ruidosos já apresentados na Fig. 1, onde se nota maior suavidade e fidelidade da trajetória filtrada com RQR em relação à trajetória real.

À partir deste novo *dataset*, foi novamente empregada a metodologia HACI a fim de aferir-se seu desempenho —

agora em dados previamente tratados. Estes dados tratados das coordenadas são utilizados em substituição aos originais.

Testes iniciais com o *dataset* filtrado demonstraram que a eficiência da metodologia em reduzir a imprecisão mostrou-se mais do que 10% melhor do que quando se utilizou o *dataset* original. Ainda, verificou-se que o desempenho para esta nova configuração dos dados foi melhor quando empregados apenas 2 sensores, a saber, GPS-Lat/Lon + ACCEL. Portanto, para os demais testes realizados a seguir fixou-se essa combinação.


A fim de buscar melhorar ainda mais os resultados, foi feita uma avaliação do impacto do número de MFs por entrada durante o processamento do algoritmo FCM no desempenho geral da rede ANFIS. Os resultados indicaram que a escolha apropriada do número de MFs por entrada é imprescindível.

Desta feita, mais 12.096 testes foram procedidos aplicando-se a metodologia HACI, agora com o *dataset* filtrado pela técnica RQR, com 3 repetições para cada um dos 42 grupos de Cross-Validation. Isto foi feito para cada coordenada fusionada apenas com o sensor ACCEL (GPS-LAT + ACCEL e GPS-LON + ACCEL) e ainda para um número de MFs por entrada (*clusters*) que variou de 3 até 50. Assim, totalizam-se 6.048 testes para Latitude e 6.048 testes para Longitude. O desempenho foi novamente aferido pela capacidade de predição de cada grupo de *treinamento* sobre o respectivo grupo de *generalização*, para cada combinação de CV, dada determinada seleção de sensores. A Fig. 11 concentra os resultados do desempenho de cada configuração testada na forma de *boxplots*, a fim de demonstrar de forma concisa e otimizada a influência do fator “número de MFs por entrada” no desempenho da técnica RQR+FCM+ANFIS.


TABELA III  
COMPARATIVO DOS RMSE E ACURÁCIA DE CADA MÉTODO

| Sistema                          | Coordenada | Sensores fusionados | Método de treinamento | Erro Lat (cm) | Erro Lon (cm) | Imprecisão (área em cm <sup>2</sup> ) | Redução da imprecisão (%) |
|----------------------------------|------------|---------------------|-----------------------|---------------|---------------|---------------------------------------|---------------------------|
| GPS                              | LAT, LON   | -                   | -                     | 21,10         | 30,81         | 650,10                                | -                         |
| GPS PÓS-FILTRO RQR               | LAT, LON   | -                   | -                     | 18,50         | 29,37         | 543,32                                | 16,42%                    |
| GPS "SEM RUÍDOS"                 | LAT, LON   | -                   | -                     | 16,52         | 26,02         | 429,92                                | 33,87%                    |
| Regression Models                | LAT        | GPS-Lat +ACCEL+GYRO | Interactions          | 19,15         | 24,34         | 465,92                                | 28,33%                    |
|                                  | LON        | GPS-Lon+ACCEL       | Linear Fine Tree      |               |               |                                       |                           |
| Neural Networks                  | LAT        | GPS-Lat+ACCEL       | Bayesian              | 17,02         | 24,70         | 420,35                                | 35,34%                    |
|                                  | LON        | GPS-Lon+ACCEL       | Regularization        |               |               |                                       |                           |
| FCM + ANFIS                      | LAT        | GPS-Lat+ACCEL       | Híbrido               | 16,60         | 21,47         | 356,31                                | 45,19%                    |
|                                  | LON        | GPS-Lon +ACCEL+GYRO |                       |               |               |                                       |                           |
| RQR+FCM+ANFIS                    | LAT        | GPS-Lat+ACCEL       | Híbrido               | 14,21         | 20,53         | 291,65                                | 55,14%                    |
|                                  | LON        | GPS-Lon+ACCEL       |                       |               |               |                                       |                           |
| RQR+FCM (pos-análise)+ANFIS      | LAT        | GPS-Lat+ACCEL       | Híbrido               | 13,80         | 20,43         | 281,98                                | 56,62%                    |
|                                  | LON        | GPS-Lon+ACCEL       |                       |               |               |                                       |                           |
| FCM + ANFIS (dataset sem ruídos) | LAT        | GPS-Lat+ACCEL       | Híbrido               | 11,31         | 18,12         | 204,89                                | 68,48%                    |
|                                  | LON        | GPS-Lon+ACCEL       |                       |               |               |                                       |                           |

Analisando resultados, a Fig. 11 e a Tabela III, conclui-se que tanto para Latitude quanto para Longitude, o desempenho da técnica RQR+FCM+ANFIS foi consideravelmente afetado pela quantidade de MFs por entrada. Provavelmente, isto está relacionado à capacidade de determinada quantidade tratar adequada e convenientemente a complexidade do problema. Logo, pressupõe-se a existência de um número “ideal” de



(a) Latitude



(b) Longitude

Fig. 11. Desempenho (escala *semilog*) da técnica RQR+FCM+ANFIS em 12.096 testes variando-se a quantidade de funções de pertencimento.

MFs por entrada. Viu-se, também, que quanto mais de MFs por entrada, piores, em geral, o desempenho, a variância, a média e as medianas, possivelmente em virtude do aumento da complexidade das redes (maior dificuldade de convergência).

Tanto a imprecisão medida do GPS embarcado quanto a imprecisão obtida pela metodologia HACI foram mitigadas pela filtragem automática dos ruídos por meio da técnica RQR (16,42% e 56,62% respectivamente). Logo, de fato a presença de ruídos tem um impacto negativo na precisão das estimações de posicionamento. Considerando uma comparação dos resultados da metodologia pós-análise de número de MFs por entrada com o GPS embarcado tendo em vista o *dataset* filtrado pela técnica RQR para ambos, a redução da imprecisão (aumento da precisão) de 56,62% também foi superior a [4].

A metodologia FCM+ANFIS mostrou-se mais eficiente no *dataset* filtrado pela técnica RQR que no original. Isto confirma que a presença de ruídos tem impacto negativo em sua capacidade de aprendizado e generalização. Logo, apesar da análise do número de MFs por entrada ter viabilizado um aumento extra de apenas cerca de 1,5% na precisão da estimação, tal análise foi importante para uma melhor compreensão da influência da quantidade de MFs no desempenho da técnica.

A metodologia FCM+ANFIS, quando aplicada ao *dataset* filtrado pela técnica RQR, não apresentou um desempenho

superior à sua aplicação ao *dataset* “sem ruídos”. Mas, comparando-se a imprecisão do GPS embarcado nos dados originais (650,10cm<sup>2</sup>) com a redução na imprecisão alcançada pela metodologia HACI nos dados filtrados pela técnica RQR (imprecisão total de 281,98cm<sup>2</sup>), percebe-se uma melhoria total de quase 57%.

## VI. CONCLUSÕES

Verificou-se que, para este conjunto de dados, realizar uma análise e tratamento dos ruídos presentes no sinal de entrada é importante pois, em última instância, afeta o desempenho final da metodologia de Fusão de Dados HACI. Contudo, isso não é necessariamente verdade para aeronaves mais modernas, em geral dotadas de sensores mais avançados e precisos. Além disso, um ponto negativo dessa abordagem é que se perdeu parcialmente a riqueza dos dados originais, tanto em uma abordagem quanto em outra. Finalmente, a redução da imprecisão da estimação de posicionamento mostra a efetividade das técnicas empregadas em melhorar os resultados de [4] tendo em vista a navegação de ARPs em tempo real. Sugere-se, em trabalhos futuros, testar a metodologia HACI em novas aeronaves e em voos distintos dos usados para treinamento.

## REFERÊNCIAS

- [1] A. Al-Kaff, D. Martín, F. García, A. Escalera, and J. Armingol, “Survey of computer vision algorithms and applications for unmanned aerial vehicles,” *Expert Systems with Applications*, vol. 92, pp. 447–463, 2018.
- [2] J. R. G. Braga, “Navegação autônoma de VANT por imagens LiDAR,” Ph.D. dissertation, Instituto Nacional de Pesquisas Espaciais, 2018.
- [3] L. Davis, M. J. McNerney, J. Chow, T. Hamilton, S. Harting, and D. Byman, “Armed and Dangerous? UAVs and U.S. Security,” RAND Corporation, Santa Monica, CA, Tech. Rep., 2014.
- [4] Â. de C. Paulino, L. N. F. Guimarães, and E. H. Shiguemori, “Hybrid Adaptive Computational Intelligence-based Multisensor Data Fusion applied to real-time UAV autonomous navigation,” *Inteligência Artificial*, vol. 22, no. 63, pp. 162–195, may 2019.
- [5] G. Hu, W. Wang, Y. Zhong, B. Gao, and C. Gu, “A new direct filtering approach to INS/GNSS integration,” *Aerospace Science and Technology*, vol. 77, pp. 755–764, jun 2018.
- [6] G. Zhang and L.-T. Hsu, “Intelligent GNSS/INS integrated navigation system for a commercial UAV flight control system,” *Aerospace Science and Technology*, vol. 80, pp. 368–380, sep 2018.
- [7] S. Zahran, A. Moussa, and N. El-Sheimy, “Enhanced UAV navigation in GNSS denied environment using repeated dynamics pattern recognition,” in *2018 IEEE/ION PLANS*. IEEE, apr 2018, pp. 1135–1142.
- [8] E. S. Abdolkarimi, G. Abaei, and M. R. Mosavi, “A wavelet-extreme learning machine for low-cost INS/GPS navigation system in high-speed applications,” *GPS Solutions*, vol. 22, no. 1, p. 15, jan 2018.
- [9] G. d. P. Neto, Â. de C. Paulino, E. H. Shiguemori, H. F. d. C. Velho, and L. N. F. Guimarães, “Computational Intelligence-based Multisensor Data Fusion applied to positioning estimation and autonomous navigation of an UAV,” in *Conf. of Comp. Interdisciplinary Sci. 2019*, 2019, pp. 1–13.
- [10] M. Chetto and A. Queudet, “Real-time Computing,” in *Energy Autonomy of Real-Time Systems*. Kidlington, Oxford: Elsevier, jan 2016, ch. Real-Time, pp. 1–26.
- [11] X. Wang and W. Wang, “Nonlinear Signal-Correction Observer and Application to UAV Navigation,” *IEEE Transactions on Industrial Electronics*, vol. 66, no. 6, pp. 4600–4607, jun 2019.
- [12] B. Khaleghi, A. Khamis, F. O. Karray, and S. N. Razavi, “Multisensor data fusion: A review of the state-of-the-art,” pp. 28–44, jan 2013.
- [13] J. C. Bezdek, R. Ehrlich, and W. Full, “FCM: The fuzzy c-means clustering algorithm,” *Computers & Geosciences*, vol. 10, no. 2, pp. 191–203, 1984.
- [14] J.-S. Jang, “ANFIS: adaptive-network-based fuzzy inference system,” *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, no. 3, pp. 665–685, 1993.
- [15] P. Nerurkar, A. Shirke, M. Chandane, and S. Bhirud, “Empirical Analysis of Data Clustering Algorithms,” *Procedia Computer Science*, vol. 125, pp. 770–779, jan 2018.
- [16] A. Saxena, M. Prasad, A. Gupta, N. Bharill, O. P. Patel, A. Tiwari, M. J. Er, W. Ding, and C.-T. Lin, “A review of clustering techniques and developments,” *Neurocomputing*, vol. 267, pp. 664–681, dec 2017.
- [17] A. A. Sarhan and A. Hafez, “UAV Brushless DC motor Speed Control via Adaptive Neuro Fuzzy Inference Systems (ANFIS) and Self-Adaptive PID,” in *AIAA Scitech 2019 Forum*. Reston, Virginia: American Institute of Aeronautics and Astronautics, jan 2019.
- [18] S. Kamarian, M. Yas, A. Pourasghar, and M. Daghigh, “Application of firefly algorithm and ANFIS for optimisation of functionally graded beams,” *Journal of Experimental and Theoretical Artificial Intelligence*, vol. 26, no. 2, pp. 197–209, 2014.
- [19] L. Zadeh, “Fuzzy sets,” *Inf. & Control*, vol. 8, no. 3, pp. 338–353, 1965.
- [20] L. P. Garcia, J. Lehmann, A. C. de Carvalho, and A. C. Lorena, “New label noise injection methods for the evaluation of noise filters,” *Knowledge-Based Systems*, vol. 163, pp. 693–704, jan 2019.
- [21] K. Molugaram and G. S. Rao, “Analysis of Time Series,” in *Statistical Techniques for Transp. Eng.*, 1st ed. Elsevier, 2017, pp. 463–489.
- [22] H. David, “Order Statistics,” in *International Encyclopedia of the Social & Behavioral Sciences*. Elsevier, jan 2015, pp. 291–295.
- [23] M. L. Hazelton, “Nonparametric Regression,” in *International Encyclopedia of the Social & Behavioral Sciences: Second Edition*. Elsevier, jan 2015, pp. 867–877.
- [24] S. W. Smith, “Moving Average Filters,” in *Digital Signal Processing*. Elsevier, 2003, pp. 277–284.
- [25] G. M. Fitzmaurice, “Regression,” *Diagnostic Histopathology*, vol. 22, no. 7, pp. 271–278, jul 2016.
- [26] I. The MathWorks, “smoothdata,” 2019.
- [27] M. Fernández-Delgado, M. Sirsat, E. Cernadas, S. Alawadi, S. Barro, and M. Febrero-Bande, “An extensive experimental survey of regression methods,” *Neural Networks*, vol. 111, pp. 11–34, mar 2019.
- [28] M. Saied, H. Shraim, B. Lussier, I. Fantoni, and C. Francis, “Local controllability and attitude stabilization of multirotor UAVs: Validation on a coaxial octorotor,” *Robotics and Autonomous Systems*, vol. 91, pp. 128–138, may 2017.
- [29] D. Pandey, T. Uppal, S. Rataneekar, and D. Bhattacharya, “Controller Development for a Rotary UAV using Physics Based Non-Linear Helicopter Model,” *IFAC-PapersOnLine*, vol. 51, no. 1, pp. 166–171, 2018.
- [30] F. Caliskan and C. Hacizade, “Sensor and Actuator FDI Applied to an UAV Dynamic Model,” *IFAC Proceedings Volumes*, vol. 47, no. 3, pp. 12 220–12 225, jan 2014.



**Ângelo de Carvalho Paulino** Possui Mestrado em Ciências e Tecnologias Espaciais (2019) pelo Instituto Tecnológico de Aeronáutica (ITA), na área de Sensores e Atuadores Espaciais (CTE-S), e graduação em Ciências da Logística pela Academia da Força Aérea (2011). Atualmente, é pesquisador no Laboratório de Engenharia Virtual (LEV), da Subdivisão de Eletromagnetismo Aplicado, da Divisão de Física Aplicada (EFA-E), do Instituto de Estudos Avançados (IEAv).



**Lamartine Nogueira Frutuoso Guimarães** É Doutor em Nuclear Engineering na The University Of Tennessee (1992). Atualmente é Pesquisador Titular do Instituto de Estudos Avançados onde atua como chefe da Divisão de Energia Nuclear. É professor Titular do curso de pós-graduação de Computação Aplicada do Instituto Nacional de Pesquisas Espaciais e professor do curso de pós-graduação de Ciências e Tecnologias Espaciais do Instituto Tecnológico de Aeronáutica.



**Elcio Hideiti Shiguemori** É pesquisador do Instituto de Estudos Avançados (IEAv) do Departamento de Ciência e Tecnologia Aeroespacial (DCTA). Doutor em computação aplicada pelo Instituto Nacional de Pesquisas Espaciais (INPE) (2007). Mestre em Computação Aplicada pelo INPE (2002), possui graduação em Engenharia da Computação (1998) e em Ciências da Computação pela UBC (1999). É coordenador do curso de Engenharia da Computação da UNIP.