

Metodologia Baseada em Inteligência Computacional para Rastreamento de Foguetes Suborbitais por Triangulação de Antenas

1st Arthur Medeiros Macedo
Universidade Federal do Maranhão
São Luís, Brasil
arthurmacedo01@gmail.com

2nd Ginalber Luiz de Oliveira Serra
Instituto Federal do Maranhão
São Luís, Brasil
ginalber@ifma.edu.br

Abstract—In order to track a suborbital vehicle, some tracking system are used. Tracking radar can be used for this purpose. This paper presents a method using triangulation of antennas other than radars, for estimating the position of the vehicle. The goal is to improve the capability of keeping tracking the vehicle, even in loss of signal scenarios. Also, a dynamic filter is proposed for improving the estimation accuracy, based on a fuzzy system identification. Simulations were performed to demonstrate the proposed methods in estimating a suborbital vehicle position.

Index Terms—Input and excitation design, Estimation and Filtering, Fuzzy Clustering, Observer Kalman Filter Identification, Position Tracking.

I. INTRODUÇÃO

Veículos suborbitais são foguetes projetados para levar carga paga a um ambiente suborbital, geralmente para realizar medições e experimentos científicos [3]. Além disso, o desenvolvimento de veículos suborbitais contribuem no processo de desenvolvimento de veículos orbitais.

No Brasil, o Centro de Lançamento de Alcântara, dentre outras atividades, realiza lançamentos de veículos suborbitais [2]. O Centro de Lançamento é o responsável pela segurança de voo com respeito à segurança das pessoas, meio ambiente e instalações em uma operação de lançamento. Para se garantir a segurança nestas áreas, o Centro de Lançamento deve dispor de sistema de terminação de voo, que tem a capacidade de destruir o veículo durante o voo [5] através de telecomando.

O comando da terminação do voo deve seguir as diretrizes estabelecidas no plano de segurança do Centro [15]. Um dos critérios para se comandar a terminação de voo é a perda de sinal de localização do veículo. Este procedimento mitiga a possibilidade de o veículo adentrar uma zona protegida.

No Brasil, o Centro de Lançamento dispõe de radares de rastreamento para executar a localização do veículo durante o voo [9]. Este trabalho apresenta uma metodologia de localização de veículos suborbitais usando outros sinais além dos radares de rastreamento. O método proposto utiliza dados de antenas de telemédidas, ao invés de radares de rastreamento, para estimação da posição do veículo. O trabalho estuda em nível acadêmico o rastreamento de veículos espaciais mesmo em cenários de perda de sinal radar.

O objetivo final do trabalho é de elevar o nível de disponibilidade de dados de localização do veículo para a segurança de voo de um centro de lançamento, principalmente em momentos de tomada de decisão para terminação de voo em cenário de perda de sinal radar.

A proposta apresentada utiliza sinais das antenas de telemédidas, inicialmente através de triangulação de antenas em pares. O resultado das triangulações são sinais de entrada para um filtro dinâmico que tem como objetivo entregar uma precisão próxima à do sinal radar. Este filtro dinâmico deverá considerar não linearidades inerentes à dinâmica da trajetória [10]. Para tratar tais não linearidades, uma técnica de agrupamento nebuloso foi usada para particionar a trajetória e então utilizar um sistema nebuloso para tratar tais agrupamentos. Técnicas de identificação de sistemas foram aplicadas [11] para converter o sinal de triangulação para um sinal semelhante ao do radar de rastreamento.

Foram realizadas simulações para demonstrar o desempenho do método proposto utilizando dados reais de voo de um veículo suborbital. Os resultados foram comparados e discutidos.

Este trabalho está dividido em seções. Após a introdução e contextualização, a Seção II aborda a estimação da posição do foguete pelo cálculo da triangulação de antenas. A Seção III descreve a utilização de algoritmos nebulosos em técnica de agrupamento no problema apresentado. A Seção IV aborda as técnicas de identificação de sistema utilizadas para projeto de filtro dinâmico. A Seção V apresenta a utilização do filtro projetado com o sistema nebuloso. A Seção VI descreve uma metodologia para estimação da posição do foguete em cenário de perda dos sinais dos sensores. A implementação da metodologia proposta foi simulada, cujos resultados estão apresentados na Seção VII. Por fim, a Seção VIII apresenta a conclusão e comentários finais sobre o trabalho.

II. TRIANGULAÇÃO DE ANTENAS

Além de radares de rastreamento, o Centro de Lançamento de Alcântara possui estações de telemédidas. Cada estação possui sua antena com ângulos de azimute e elevação que apontam para a direção do foguete. O primeiro desafio é portanto

estimar a posição do veículo baseado somente em tais ângulos. Para isto, podemos utilizar dados de mais de uma antena para esta estimação.

Dado que o Centro de Lançamento possui diversas antenas de telemedidas, podemos preliminarmente estimar a posição do foguete por triangulação de antenas duas a duas, e então utilizar um filtro dinâmico para obter a estimativa final da posição. O projeto do filtro dinâmico será explicado em seções mais adiante.

O procedimento para se estimar a posição do veículo através de ângulos de azimute e elevação por triangulação de antenas está descrito em [8].

É importante mencionar que a posição calculada por triangulação é apenas uma estimativa da posição real do veículo. Se comparado com sinais de radar de rastreo, que são dedicados a essa atividade, a triangulação entrega uma estimação com elevados ruídos e erros. Com o objetivo de reduzir tais erros e ruídos, podemos projetar um filtro dinâmico cuja entrada são os sinais provenientes das triangulações, e cuja saída é uma estimação com mais acurácia e precisão.

III. AGRUPAMENTO NEBULOSO

A dinâmica do filtro para reduzir os erros e ruídos dos sinais das triangulações pode ser de elevada complexidade, devido à presença de não linearidades inerentes ao sistema. Para contornar isto, podemos particionar a trajetória do foguete em *clusters*, por técnica de agrupamento [7], e então projetar filtros dinâmicos mais simples para cada *cluster*.

Técnicas de agrupamento podem ser aplicadas em dados históricos de voos passados para definir as partições baseado em métodos orientado por dados [12]. Este trabalho utilizou o algoritmo Gustafson-Kessel como o método de agrupamento.

O algoritmo Gustafson-Kessel é parte da família de algoritmos orientados por dados e é derivado da base do funcional *c-means*. Uma vantagem desse algoritmo sobre o clássico *c-means* é sua capacidade de identificar *clusters* com diferentes formatos e orientações [12].

A. Determinação do Número de Clusters

O algoritmo Gustafson-Kessel considera o número total de *clusters* já definido de antemão. A abordagem padrão para se determinar o número de *clusters* apropriado é através de medições de validade. Este trabalho utilizou a medição de hipervolume para determinação do número total de *clusters*.

O hipervolume nebuloso V_h é definido como:

$$V_h = \sum_{i=1}^c [\det(F_i)]^{1/2} \quad (1)$$

em que F_i é a matriz de covariância do i -ésimo *cluster*. Um pequeno valor de V_h indica um número de *clusters* apropriado. Então deve-se analisar V_h para diferentes números de *clusters* e escolher um número que ao mesmo tempo entregue um valor pequeno para V_h e também mantenha o número de *clusters* razoavelmente baixo.

IV. IDENTIFICAÇÃO DE SISTEMA

Após a etapa de particionamento do conjunto de dados, um filtro dinâmico deve ser projetado para tomar os valores provenientes da etapa de triangulação e filtrá-los para um sinal com características próximas às do radar de trajetografia. Para isto, pode-se usar um algoritmo de identificação de sistemas.

O método utilizado neste trabalho objetiva obter a representação de um modelo em espaço de estados baseado nos dados de entrada e saída do filtro, conhecido como OKID *Observer/Kalman Filter Identification* [6].

Considere o sistema linear discreto com representação em espaço de estados após adição e subtração do termo $Ky(k)$ na parte direita da equação:

$$\begin{aligned} x(k+1) &= Ax(k) + Bu(k) - Ky(k) + Ky(k) \\ y(k) &= Cx(k) + Du(k) \end{aligned} \quad (2)$$

em que $u(k)$ é o sinal de entrada do filtro, $y(k)$ a saída. Neste caso, $u(k)$ são as estimações de posição baseada em triangulação de um *cluster* particular.

Rearranjando os termos, temos:

$$\begin{aligned} x(k+1) &= \bar{A}x(k) + \bar{B}v(k) \\ \bar{A} &= A - KC \\ \bar{B} &= [B - KD, \quad K] \\ v(k) &= \begin{bmatrix} u(k) \\ y(k) \end{bmatrix} \end{aligned} \quad (3)$$

Os Parâmetros do Observador de Markov podem ser obtidos por [6]:

$$\bar{Y} = \bar{y}\bar{V}^T [\bar{V}\bar{V}^T]^{-1} \quad (4)$$

em que

$$\begin{aligned} \bar{y} &= [y(p) \quad y(p+1) \quad \dots \quad y(l-1)] \\ \bar{V} &= \begin{bmatrix} u(p) & u(p+1) & \dots & u(l-1) \\ v(p-1) & v(p) & \dots & v(l-2) \\ v(p-2) & v(p-1) & \dots & v(l-3) \\ \vdots & \vdots & \vdots & \vdots \\ v(0) & v(1) & \dots & v(l-p-1) \end{bmatrix} \end{aligned} \quad (5)$$

l é o tamanho do conjunto de dados, p é um número inteiro arbitrado pequeno para que \bar{A}^p seja suficientemente pequeno.

Uma vez calculados os Parâmetros do Observador de Markov \bar{Y} , podemos recuperar os Parâmetros de Markov originais do sistema, primeiramente separando \bar{Y} em:

$$\bar{Y} = [\bar{Y}_0 \quad \bar{Y}_1 \quad \bar{Y}_2 \quad \dots \quad \bar{Y}_p] \quad (6)$$

e

$$\begin{aligned} \hat{D} &= \bar{Y}_0 \\ \bar{Y}_k &= [\bar{Y}_k^{(1)} \quad -\bar{Y}_k^{(2)}]; k = 1, 2, 3, \dots \end{aligned} \quad (7)$$

Então, os Parâmetros de Markov Y do sistema podem ser obtidos por [6]:

$$\begin{aligned} Y_0 &= \hat{D} \\ [Y_k \ Y_k^o] &= \begin{bmatrix} \bar{Y}_k^{(1)} - \bar{Y}_k^{(2)} D & \bar{Y}_k^{(2)} \\ -\sum_{i=1}^{k-1} \bar{Y}_i^{(2)} [Y_{k-i} \ Y_{k-i}^o] \end{bmatrix} \end{aligned} \quad (8)$$

em que Y_k é o k -ésimo Parâmetro de Markov. Y_k^o será usado posteriormente para cálculo dos ganhos de Kalman K em (2).

Uma vez calculados os Parâmetros de Markov do sistema, podemos utilizar um método de identificação para determinar as matrizes A , B e C em (2). Neste trabalho, o algoritmo ERA (*Eigensystem Realization Algorithm*) foi utilizado [13].

A. Ganho de Kalman

Dado que as matrizes A , B , C e D foram calculadas na etapa anterior, o ganho de Kalman K em (2) é dado por [6]:

$$K = -(P^T P)^{-1} P^T Y^o \quad (9)$$

em que Y^o foi calculado em (8), e P é a matriz de observabilidade do sistema:

$$P = [C \ CA \ CA^2 \ \dots \ CA^k]^T \quad (10)$$

A Figura 1 apresenta o processo de identificação de sistema até esta etapa, considerando a etapa de agrupamento nebuloso.

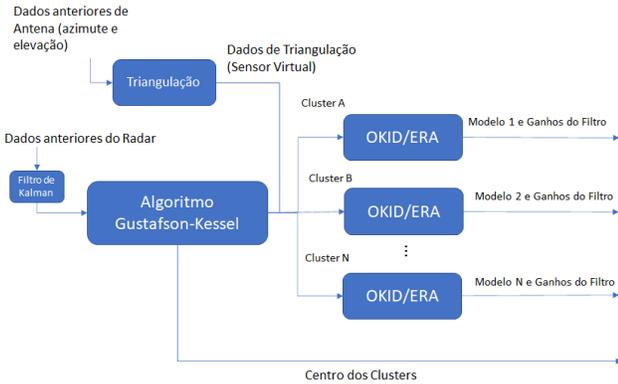


Fig. 1. Diagrama de Identificação do Sistema

V. FILTRO DE KALMAN NEBULOSO

Como mencionado anteriormente, cada par de antenas entrega uma estimaco da posico do veculo suborbital baseado no mtodo de triangulao, gerando vrias estimaces. Estes valores podem ser utilizados como entrada de um filtro que os convertam em uma nica estimaco com caractersticas semelhantes s do radar.

Para se obter o filtro dinmico que realiza esta converso, o algoritmo OKID é utilizado [14] tomando como dado de entrada todos os sinais histricos proveniente das diferentes triangulaes realizadas, e tomando como sada os dados histricos provenientes do sensor radar.

Aps a separao da trajetria em *clusters* como explicado anteriormente, ao invs de se utilizar os dados histricos de

toda a trajetria para o algoritmo OKID, pode-se utilizar apenas aqueles dados que fazem parte do mesmo *cluster* (de maior grau de pertinncia) para cada rodada do algoritmo OKID. Ao fim deste processo, tem-se c nmeros de filtros dinmicos (A , B , C , D and K), em que c é o nmero de *clusters*.

At aqui, todos os procedimentos foram realizados anteriormente ao voo, com dados histricos, para se definir os c filtros que sero usados durante o voo. Portanto, durante o voo, pode-se obter a posico estimada utilizando a seguinte relao [6]:

$$\hat{x}_i(k+1) = [\hat{A}_i - K_i \hat{C}_i] \hat{x}_i(k) + [\hat{B}_i - K_i \hat{D}_i] u(k) + K_i y(k) \quad (11)$$

$$\hat{y}_i(k) = \hat{C}_i \hat{x}_i(k) + \hat{D}_i u(k) \quad (12)$$

Os sinais $u(k)$ e $y(k)$ so sinais da etapa de triangulao e dados do sensor radar respectivamente. \hat{A}_i , \hat{B}_i , \hat{C}_i , \hat{D}_i e K_i so matrizes do filtro do i -simo *cluster* obtido pelo algoritmo OKID. O nmero total de filtros é o nmero total de *clusters*. Portanto, a estimaco final, considerando todos os filtros, pode ser calculado por:

$$\hat{y}(k) = \mu_1 \times \hat{y}_1(k) + \mu_2 \times \hat{y}_2(k) + \dots + \mu_c \times \hat{y}_c(k) \quad (13)$$

onde μ_i é o grau de pertinncia de $\hat{y}(k-1)$ com relao ao *cluster* i .

Note que (11) utiliza dados do radar de trajetografia em $y(k)$ para atualizar o vetor de estados $\hat{x}(k)$. Contudo, uma vez que os dados do radar estejam disponveis, podemos utilizar eles prprios como uma estimaco final da posico do veculo, no apresentando nenhuma vantagem na utilizao de (12) e (13) para estimaco da posico do veculo.

Contudo, se o sinal do radar de trajetografia $y(k)$ no estiver disponvel, pode-se utilizar os filtros dinmicos projetados para estimar o estado por:

$$\hat{x}_i(k+1) = \hat{A}_i \hat{x}_i(k) + \hat{B}_i u(k) \quad (14)$$

e ento usar (12) e (13) para estimaco da posico do veculo.

VI. INTERVALO CEGO

Para efeitos de estudo, podemos definir um mtodo para o cenrio em que nem os sinais do radar nem os sinais das triangulaes estejam disponveis por certo intervalo de tempo durante um voo. Neste caso, podemos estimar a posico do veculo baseado to somente em dados dos sensores de instantes anteriores.

No caso em que no h nenhuma fonte de estimaco de posico do veculo, o Oficial de Segurana de Voo de um Centro de Lanamento pode tomar a deciso de terminar o voo, caso o Plano de Segurana assim o determine. Contudo, este trabalho apresenta um mtodo para fins acadmicos que

propaga a dinâmica que o veículo tomou até o momento de perda dos sinais.

Esta propagação da dinâmica pode ser utilizada como a estimação da posição do veículo durante este intervalo cego. O sistema de radar poderia portanto se utilizar desta estimação para ajustar seu sistema de servomecanismos na tentativa de apontar novamente para o veículo e restabelecer o rastreamento do voo.

O Filtro de Kalman Padrão [16] pode ser usado como método de propagação da dinâmica do veículo.

Considerando os estados como posição, velocidade e aceleração em todos os três eixos, pode-se representar a dinâmica do veículo em espaço de estado como segue:

$$x_{k+1} = Ax_k + w_k \quad (15)$$

$$y_k = Cx_k + n_k \quad (16)$$

em que w_k é o ruído de processo, uma variável aleatória independente com média zero e covariância Q . n_k é o ruído de medição, uma variável aleatória independente com média zero e covariância R .

O vetor de estados pode ser escrito como:

$$x = [P_x \ \dot{P}_x \ \ddot{P}_x \ P_y \ \dot{P}_y \ \ddot{P}_y \ P_z \ \dot{P}_z \ \ddot{P}_z]^T \quad (17)$$

em que P_x , P_y e P_z é a posição do veículo no eixo x , y e z respectivamente.

O Filtro de Kalman Padrão pode ser dividido em dois passos. O passo de predição e o passo de atualização [1].

Portanto, durante o voo, no caso em que pelo menos uma fonte de posição esteja disponível (sinal do radar e/ou de triangulação), ambos os passos de predição e de atualização podem ser realizados. Contudo, durante o período quando não há nenhuma fonte de estimação de posição, apenas o passo de predição pode ser realizado. Portanto, a posição estimada \hat{y}_k é calculada com base apenas em dados anteriores.

Figura 2 demonstra o diagrama que cobre o processo de filtragem proposto.

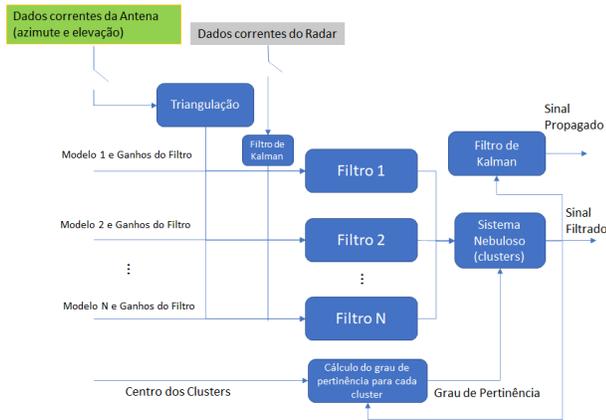


Fig. 2. Triangulação por Filtro de Kalman

VII. RESULTADOS

Foram realizadas simulações utilizando a metodologia apresentada neste trabalho. Foram utilizados dados de um voo real de um veículo suborbital. Os dados do radar de trajetografia foram usados para determinar os *clusters* que serão utilizados nos próximos passos. Seguindo a metodologia apresentada anteriormente, o hipervolume para diferentes número de *clusters* foi calculado pelo algoritmo Gustafson-Kessel, com expoente de peso $m = 1,5$.

A Figura 3 mostra a curva representando o hipervolume para diferentes escolhas de número de *clusters*.

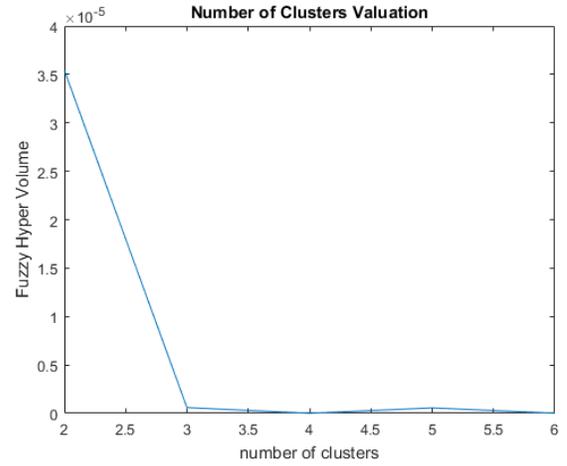


Fig. 3. Definição do Número de Cluster

De acordo com a Figura 3, três *clusters* é um número razoável, pois representa um baixo hipervolume mantendo um número baixo de *clusters*.

Portanto, o algoritmo de Gustafson-Kessel para três *clusters* foi utilizado. A Figura 4 mostra como o conjunto de dados foi particionado em *clusters*.

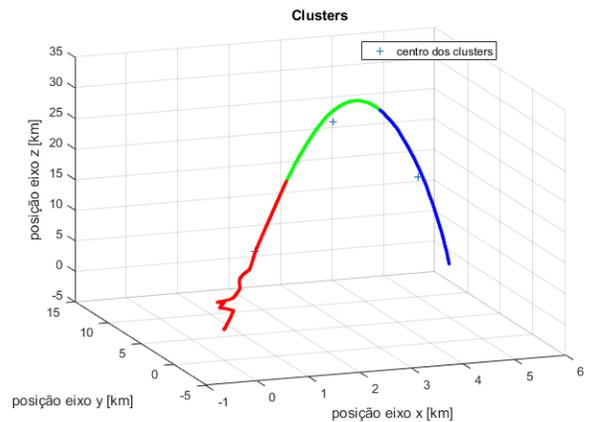


Fig. 4. Particionamento do Conjunto de Dados em Clusters

Para cada *cluster*, o algoritmo OKID foi utilizado para determinar os Parâmetros de Markov. Duas triangulações

foram realizadas como entradas do algoritmo OKID. Cada triangulação é um resultado de cálculos para diferentes pares de antenas de telemidas. Nesta etapa, o OKID foi utilizado para cada eixo separadamente, e então as matrizes do sistema nos três eixos foram concatenadas posteriormente. Todas as rodadas de OKID, para cada eixo separadamente, utilizaram os parâmetros de dimensão da matriz A como $n = 2$, número inteiro arbitrário em (5) $p = 2$ e quantidade de parâmetros de Markov $q = 2$ para cada eixo. Portanto, ao final deste processo, obtemos três modelos de filtro de ordem seis.

Para se obter os resultados finais, dois cenários foram simulados. No primeiro cenário, o filtro foi usado juntamente com os dados do radar, exceto durante certo intervalo, simulando assim uma perda de sinal de radar. Durante este período, apenas os sinais de triangulação ficaram disponíveis.

A Figura 5 demonstra a simulação de perda do sinal radar durante o intervalo entre 5 e 25 segundos, entre 60 e 80 segundos e entre 110 e 130 segundos. O voo total possui duração de 166 segundos.

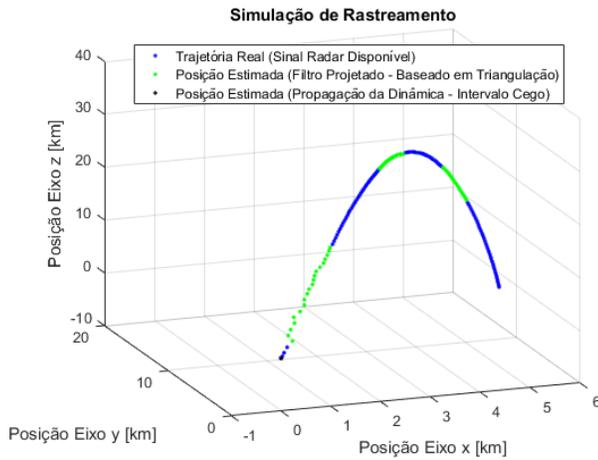


Fig. 5. Simulação de Rastreamento de Veículo Suborbital com Perda de Sinal Radar

Note que a posição estimada segue a trajetória real, mostrando que o filtro teve sucesso convertendo os sinais de triangulação em uma estimativa próxima da trajetória real.

Para efeitos de comparação, a Figura 6 apresenta os erros absolutos durante o intervalo de perda de sinal simulado. Note que o nível de erro para cada intervalo é menor no caso do sinal filtrado se comparado com os sinais de triangulações sem o filtro.

A Tabela I apresenta métricas de desempenho para a estimação de posição durante os intervalos simulados de perda de sinal radar. Observe que para todas as métricas, o RMSE (*Root Mean Square Error*), o MAE (*Mean Absolute Error*) e o MAPE (*Mean Absolute Percentage Error*), a estimação utilizando o filtro projetado apresenta desempenho superior ao da triangulação sem o filtro.

É importante destacar que as métricas de desempenho apresentadas consideram a simulação de três intervalos com

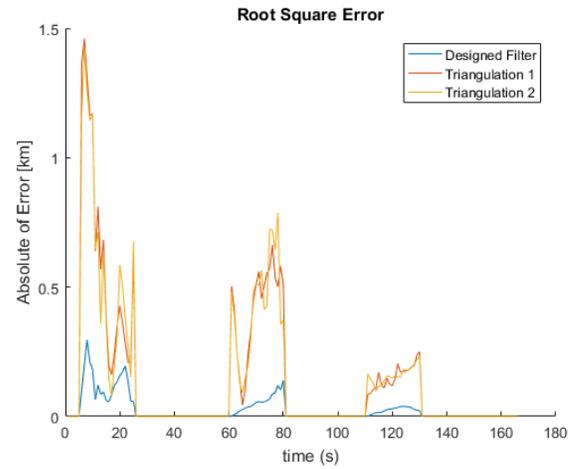


Fig. 6. Simulação de Rastreamento de Veículo Suborbital com Perda de Sinal Radar

TABLE I
MÉTRICAS DE DESEMPENHO.

Método de Rastreamento	RMSE	MAE	MAPE
Filtro Projetado	0.09	0.07	0.01
Triangulação 1	0.52	0.40	0.04
Triangulação 2	0.51	0.40	0.04

duração de 20 segundos cada, como mencionado anteriormente. Durante o restante do voo, o sinal de radar também serviu como entrada do observador do filtro projetado. O sinal de radar é importante neste processo pois auxilia o filtro a melhorar a sua precisão através do observador. Se considerarmos o voo completo sem nenhum sinal de radar disponível, o filtro projetado não terá o mesmo desempenho.

O segundo cenário simulado inclui intervalos em que nem sinal de radar nem sinal de triangulação estão disponíveis, portanto a propagação baseada no Filtro de Kalman foi utilizada durante este intervalo cego. O Filtro de Kalman utilizado possui os parâmetros de covariância do ruído do processo $Q = 10^{-3}I$, covariância do ruído de medição $R = 10^{-1}I$ e matriz de covariância do erro inicial de $P_0 = 10^3I$.

Neste segundo cenário, uma perda de sinal radar foi simulado entre os intervalos de 5 a 30 segundos, de 60 a 85 segundos e de 110 a 135 segundos, e uma perda de sinais de triangulação foi simulada entre os intervalos de 20 e 25 segundos, de 80 a 85 segundos e de 125 a 130 segundos.

A Figura 7 mostra que mesmo no cenário simulado de completa perda de sinal, o filtro é capaz de propagar a dinâmica do veículo com base em posições anteriores para estimar sua posição.

VIII. CONCLUSÃO

Este trabalho apresenta um método para estimação de posição de um veículo suborbital usando triangulação de antenas. Objetiva-se elevar a capacidade do Centro de Lançamento para rastrear os veículos mesmo em cenários de indisponibil-

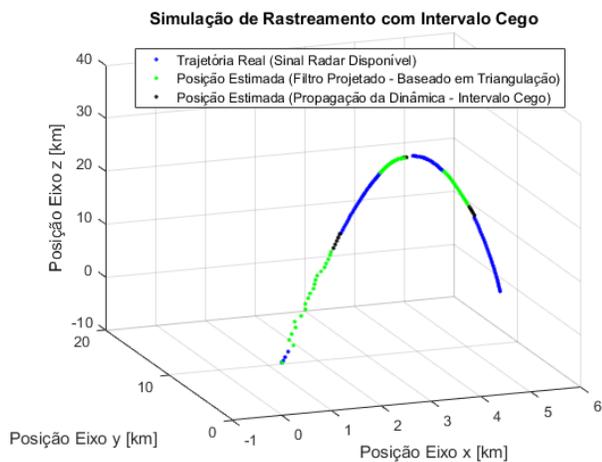


Fig. 7. Simulação de Rastreamento de Veículo Suborbital com Perda de Sinal Radar e Perda de Sinal de Triangulação

idade temporária dos radares de trajetografia. Também, este trabalho apresenta um método para projeto de filtro dinâmico com observador, baseado em sistema nebuloso, que melhora a precisão da estimação da posição do veículo. Algumas simulações foram realizadas considerando diferentes cenários de perda de sinal de radar durante o voo suborbital.

Os resultados mostram que as técnicas de triangulação de antenas passivas permitem estimar a posição do foguete, contudo é necessário a implementação de um filtro dinâmico para melhorar a acurácia da estimação. A utilização apenas da triangulação apresenta elevados erros de estimação, que podem ser atribuídos às dinâmicas dos sensores, às limitações dos servomecanismos das antenas e às distorções da direção de propagação do sinal recebido.

O projeto do filtro dinâmico para atenuar o erro de estimação foi apresentado. Foi considerado uma abordagem nebulosa com a separação da trajetória em cluters para lidar com as não linearidades da dinâmica do voo. Observou-se que a implementação do filtro reduziu os erros de estimação da triangulação, entregando um resultado com maior precisão. O filtro projetado implementa um observador, que se beneficia dos sinais dos radares, enquanto estes estiverem disponíveis, para atualizar sua estimação.

No cenário de perda do sinal radar, o filtro projetado não se utiliza do observador, contudo ainda assim entrega uma estimação da posição do foguete baseado nos sinais de triangulações somente. Observa-se que esta estimação possui um erro menor se comparado à triangulação, contudo o grande tempo de permanência nesse cenário pode ocasionar elevação no erro de estimação, uma vez que o observador não garante a atualização do filtro.

Também foi considerado cenário de perda total dos sinais, incluindo perda dos sinais de triangulação. Para este cenário foi utilizado a abordagem de propagação da dinâmica do foguete. Observamos contudo que no caso de um veículo controlado, a sua dinâmica pode mudar radicalmente através

de suas superfícies de controle e de seus atuadores. Portanto, para estes tipos de veículos, deve-se considerar também as possíveis trajetórias durante o tempo de perda dos sinais dos sensores.

Por fim, para trabalhos futuros, pode-se estudar e definir os erros esperados de estimação da metodologia proposta, bem como utilizar tais valores de erros para a definição das margens do envelope da trajetória de um voo seguro. Também pode-se estudar a otimização da implementação da metodologia visando a viabilidade e o desempenho computacional dos algoritmos em tempo real durante um lançamento.

REFERENCES

- [1] Luiz Antonio Aguirre. *Introdução à Identificação de Sistemas*. Editora UFMG, Belo Horizonte, 4th edition, 2015.
- [2] Centro de Lançamento de Alcântara. *Missão*, 2019. [Acessado em: 10-Jul-2019].
- [3] José Alano Peres de Abreu, Roberto Célio Limão de Oliveira, and João Viana da Fonseca Neto. Predição do ponto de impacto para rastreamento de foguetes usando os filtros alpha-beta, kalman padrão, kalman estendido e kalman sem cheiro: uma análise comparativa. *Research, Society and Development*, 9(3), 2020.
- [4] E. O. do Nascimento and L. N. de Oliveira. Numerical optimization of flight trajectory for rockets via artificial neural networks. *IEEE Latin America Transactions*, 15(8):1556–1565, 2017.
- [5] Federal Aviation Administration. *Flight Safety Analysis Handbook*. Washington, DC, USA, 2011.
- [6] Jer-Nan Juang. *Applied System Identification*. Prentice Hall PTR, 1994.
- [7] Jun Ma, Jie Yang, and Sarah K. Howard. A clustering algorithm based on fuzzy sets and its application in learning analytics. In *2019 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, pages 1–6, 2019.
- [8] Arthur Medeiros Macedo and Ginalber Luiz de Oliveira Serra. Localização de veículos aeroespaciais por triangulação de antenas. *Simpósio de Aplicações Operacionais em Áreas de Defesa*, 2020.
- [9] Omnisys grupo Thales. *Radar de Trajetografia Banda C*, 2010. [Acessado em: 10-Jul-2019].
- [10] Arioaldo Felix Palmerio. *Introdução à Tecnologia de Foguetes*. SindCT, São José dos Campos, SP, 2nd edition, 2017.
- [11] Danúbia Soares Pires and Ginalber Luiz de Oliveira Serra. Fuzzy kalman filter modeling based on evolving clustering of experimental data. In *2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, pages 1–6, 2018.
- [12] Robert Babuska. *Fuzzy Modeling for Control*. Springer Science Business Media, LLC, New York, USA, 1998.
- [13] Niloy Sarkar, Krishna Rao, and K. N. Shubhanga. A comparative study between prony and eigensystem realization algorithm for identification of electromechanical modes. In *2018 20th National Power Systems Conference (NPSC)*, pages 1–6, 2018.
- [14] Jorge Sampaio Silveira Júnior and Edson Bruno Marques Costa. Data-driven fuzzy modelling methodologies for multivariable nonlinear systems. In *2018 International Conference on Intelligent Systems (IS)*, pages 125–131, 2018.
- [15] Wallops Flight Facility. *Range Safety Manual RSM2002C*. Natinal Aeronautics and Space Administration (NASA), Wallops Island, Virginia, USA, 2002.
- [16] Yanjun Li Shuwen Pan Weiran Li, Jie Pan and Yan Liu. A kalman filtering for linear discrete-time system with unknown inputs. *2018 Chinese Control And Decision Conference (CCDC)*, 2018.