

Metodologia de Modelagem e Filtragem Baseada em Triangulação de Sensores para Rastreamento de Veículos Suborbitais

Arthur Medeiros Macedo* Ginalber Luiz de Oliveira Serra**

* *Universidade Federal do Maranhão, Av. dos Portugueses, 1966 - Vila Bacanga, 65080-805, São Luís - MA (e-mail: arthurmacedo01@gmail.com).*

** *Instituto Federal do Maranhão, Av. Getúlio Vargas, 04, Monte Castelo, 65030-005, São Luís - MA, (e-mail: 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.

Resumo: Centros de Lançamento rastreiam o voo de veículos suborbitais a partir de sistemas e equipamentos a exemplo de radares de rastreamento. Este trabalho apresenta um método baseado em triangulação de antenas para estimar a posição do veículo. O objetivo é aumentar a capacidade de rastreamento, mesmo em cenários de perda de sinais de rastreamento. Além disso, é proposto um filtro dinâmico para melhorar a precisão da estimação, utilizando técnicas de identificação de sistemas nebulosas.

Keywords: Input and excitation design, Estimation and Filtering, Fuzzy Clustering, Observer Kalman Filter Identification, Position Tracking.

Palavras-chaves: Projeto por Excitação de Entrada, Estimação e Filtragem, Agrupamento Nebuloso, Identificação por Observador de Filtro de Kalman, Rastreamento de Posição.

1. INTRODUÇÃO

Veículos suborbitais são foguetes projetados para levar carga útil a um ambiente suborbital, geralmente para realizar medições e experimentos científicos (de Abreu et al., 2020). 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 (Centro de Lançamento de Alcântara, 2019). 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 (Federal Aviation Administration, 2011) através de telecomando.

O comando da terminação do voo deve seguir as diretrizes estabelecidas no plano de segurança do Centro (Wallops Flight Facility, 2002). 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 (Omnisys grupo Thales, 2010). 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 (Palmerio, 2017). 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 (Pires and

Serra, 2018) 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.

2. TRIANGULAÇÃO DE ANTENAS

Além de radares de rastreamento, o Centro de Lançamento de Alcântara possui estações de telemetrias. 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, pode-se utilizar dados de mais de uma antena para esta estimativa.

Dado que o Centro de Lançamento possui diversas antenas de telemetrias, pode-se 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 por triangulação de antenas está descrito em (Macedo and Serra, 2020).

A posição do foguete é calculada através dos ângulos de azimute e elevação, considerando a distância entre as antenas. O cálculo é baseado na soma vetorial do triângulo que se forma pelos vetores de posição, considerado os ângulos entre eles, conforme o esquema da Figura 1.

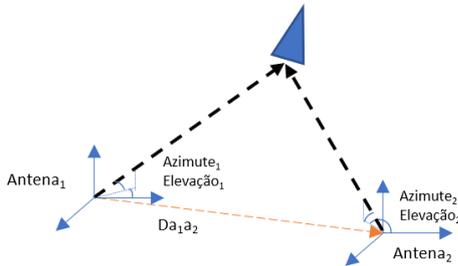


Figura 1. Triangulação

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 rastreamento, que são dedicados a essa atividade, a triangulação entrega uma estimativa com elevados ruídos e erros. Com o objetivo de reduzir tais erros e ruídos, pode-se projetar um filtro dinâmico cuja entrada são os sinais provenientes das triangulações, e cuja saída é uma estimativa com mais acurácia e precisão.

3. 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, pode-se particionar a trajetória do foguete em *clusters*, por técnica de agrupamento (Ma et al., 2019), 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 (Babuska, 1998). Este trabalho utilizou o algoritmo Gustafson-Kessel como o método de agrupamento (Babuska, 1998).

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 (Babuska, 1998).

3.1 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.

4. 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* (Juang, 1994).

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 estimativas de posição baseada em triangulação de um *cluster* particular.

Rearranjando os termos, temos:

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

Os Parâmetros do Observador de Markov podem ser obtidos por:

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

em que

$$\bar{y} = [y(p) \quad y(p+1) \quad \dots \quad y(l-1)]$$

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

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

Uma vez calculados os Parâmetros do Observador de Markov \bar{Y} , pode-se 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

$$\hat{D} = \bar{Y}_0$$

$$\bar{Y}_k = [\bar{Y}_k^{(1)} \quad -\bar{Y}_k^{(2)}]; k = 1, 2, 3, \dots \quad (7)$$

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

$$Y_0 = \hat{D}$$

$$[Y_k \quad Y_k^o] = [\bar{Y}_k^{(1)} \quad -\bar{Y}_k^{(2)} D \quad \bar{Y}_k^{(2)}] - \sum_{i=1}^{k-1} \bar{Y}_i^{(2)} [Y_{k-i} \quad Y_{k-i}^o] \quad (8)$$

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, pode-se 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 (Sarkar et al., 2018).

4.1 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:

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

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

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

A Figura 2 apresenta o processo de identificação de sistema até esta etapa, considerando a etapa de agrupamento nebuloso.

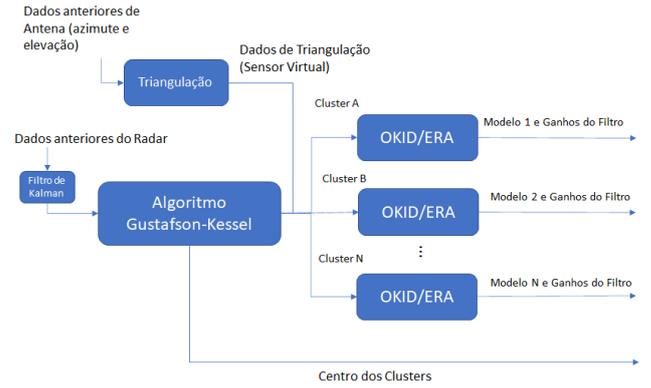


Figura 2. Diagrama de Identificação do Sistema

5. FILTRO DE KALMAN NEBULOSO

Como mencionado anteriormente, cada par de antenas entrega uma estimativa da posição do veículo suborbital baseado no método de triangulação, gerando várias estimativas. Estes valores podem ser utilizados como entrada de um filtro que os convertam em uma única estimativa com características semelhantes às do radar.

Para se obter o filtro dinâmico que realiza esta conversão, o algoritmo OKID é utilizado (Júnior and Costa, 2018) tomando como dado de entrada todos os sinais históricos proveniente das diferentes triangulações realizadas, e tomando como saída os dados históricos provenientes do sensor radar.

Após a separação da trajetória em *clusters* como explicado anteriormente, ao invés de se utilizar os dados históricos de toda a trajetória para o algoritmo OKID, pode-se utilizar apenas aqueles dados que fazem parte do mesmo *cluster* (de maior grau de pertinência) para cada rodada do algoritmo OKID. Ao fim deste processo, tem-se c números de filtros dinâmicos (A , B , C , D and K), em que c é o número de *clusters*.

Até aqui, todos os procedimentos foram realizados anteriormente ao voo, com dados históricos, para se definir os c filtros que serão usados durante o voo. Portanto, durante o voo, pode-se obter a posição estimada utilizando a seguinte relação:

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

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

Os sinais $u(k)$ e $y(k)$ são sinais da etapa de triangulação e dados do sensor radar respectivamente. \hat{A}_i , \hat{B}_i , \hat{C}_i , \hat{D}_i e K_i são matrizes do filtro do i -ésimo *cluster* obtido pelo algoritmo OKID. O número total de filtros é o número total de *clusters*. Portanto, a estimativa 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 pertinência de $\hat{y}(k-1)$ com relação a *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 disponíveis, pode-se utilizar eles próprios como uma estimativa final da posição do veículo, não apresentando nenhuma vantagem na utilização de (12) e (13) para estimativa da posição do veículo.

Contudo, se o sinal do radar de trajetografia $y(k)$ não estiver disponível, pode-se utilizar os filtros dinâmicos 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 então usar (12) e (13) para estimativa da posição do veículo.

6. INTERVALO CEGO

Para efeitos de estudo, pode-se definir um método para o cenário em que nem os sinais do radar nem os sinais das triangulações estejam disponíveis por certo intervalo de tempo durante um voo. Neste caso, estima-se a posição do veículo baseado tão somente em dados dos sensores de instantes anteriores.

No caso em que não há nenhuma fonte de estimativa de posição do veículo, o Oficial de Segurança de Voo de um Centro de Lançamento pode tomar a decisão de terminar o voo, caso o Plano de Segurança assim o determine. Contudo, este trabalho apresenta um método para fins acadêmicos que propaga a dinâmica que o veículo tomou até o momento de perda dos sinais.

Esta propagação da dinâmica pode ser utilizada como a estimativa da posição do veículo durante este intervalo cego. O sistema de radar poderia portanto se utilizar desta estimativa 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 (Li et al., 2018) 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 (Aguirre, 2015).

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 estimativa 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 3 demonstra o diagrama que cobre o processo de filtragem proposto.

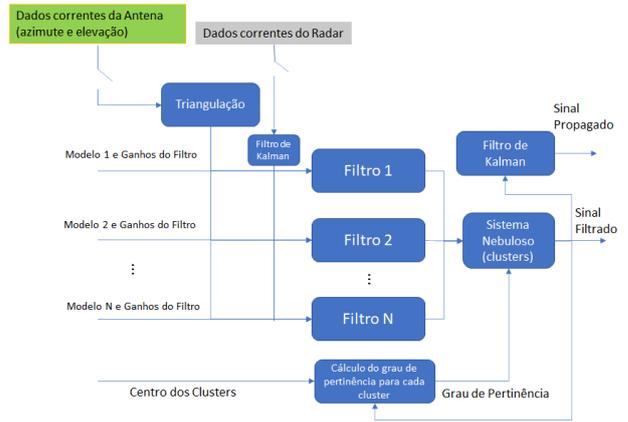


Figura 3. Triangulação por Filtro de Kalman

7. RESULTADOS

Foram realizadas simulações utilizando a metodologia apresentada neste trabalho. Foram utilizados dados de um voo real de um veículo suborbital. Os dados são de um lançamento realizado em 2018 no Centro de Lançamento de Alcântara de uma Operação com Foguete de Treinamento. Os dados de rastreamento dos radares bem como os de ângulos das antenas de teledetecção são provenientes dos sistemas de rastreamento daquele Centro. As simulações para emprego da metodologia exposta foi realizada em computador com Sistema Operacional Windows 10 com o software MATLAB R2016a.

Para a etapa de identificação do sistema e projeto de filtros, foi utilizado apenas os sinais dos radares. Para a simulação final, foram utilizados os dados dos ângulos de elevação e azimute dos equipamentos de teledetecção.

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 4 mostra a curva representando o hipervolume para diferentes escolhas de número de *clusters*.

De acordo com a Figura 4, 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 5 mostra como o conjunto de dados foi particionado em *clusters*.

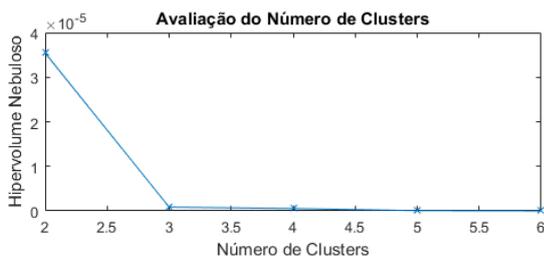


Figura 4. Definição do Número de *Cluster*

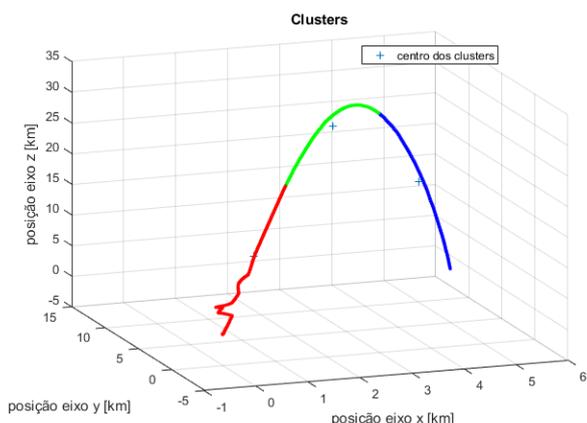


Figura 5. Particionamento do Conjunto de Dados em *Clusters*

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. Após esta etapa, o algoritmo ERA determinou as matrizes do espaço de estados para cada *cluster* em cada eixo. Portanto, ao final deste processo, obtêm-se 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 6 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.

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.

Idealmente seria interessante se o filtro projetado estimasse uma posição idêntica àquela caso fosse calculada pelo

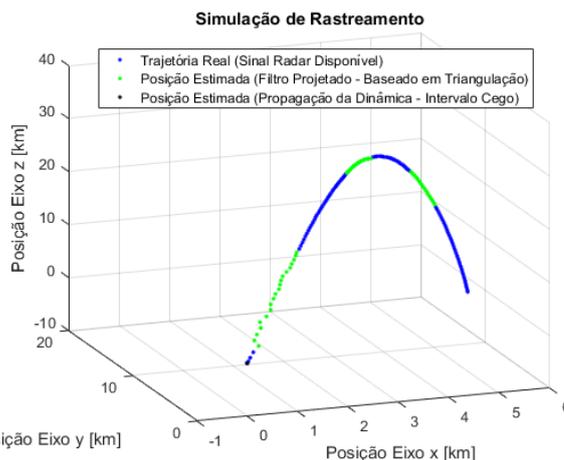


Figura 6. Simulação de Rastreamento de Veículo Suborbital com Perda de Sinal Radar

radar. Contudo, há a presença de erros de estimação, ainda que pequenos. Para aplicações de segurança de área, como a introduzida no contexto do problema deste trabalho, o erro de estimação deverá ser considerado para definir as margens do envelope da trajetória que, caso o veículo esteja dentro do envelope definido, o voo ainda é considerado seguro. Assim, quanto menor é o erro esperado de estimação, maior poderá ser estas margens de segurança do voo.

Para efeitos de comparação, a Figura 7 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.

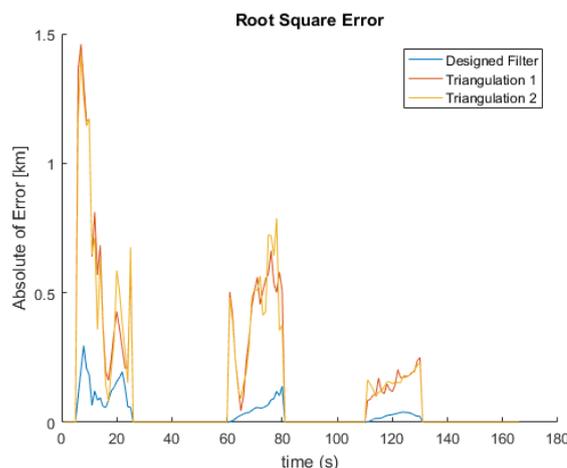


Figura 7. Simulação de Rastreamento de Veículo Suborbital com Perda de Sinal Radar

A Tabela 1 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.

Tabela 1. 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

É importante destacar que as métricas de desempenho apresentadas consideram a simulação de três intervalos com 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 8 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.

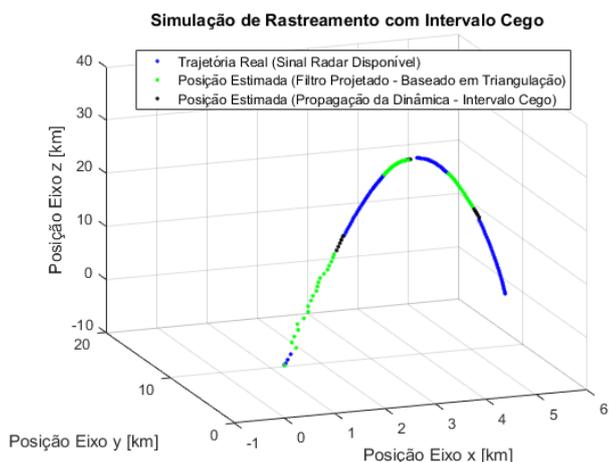


Figura 8. Simulação de Rastreamento de Veículo Suborbital com Perda de Sinal Radar e Perda de Sinal de Triangulação

8. 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 indisponibilidade 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 o método proposto pode colaborar para a estimação da posição do veículo em alguns cenários.

REFERÊNCIAS

- Aguirre, L. A., 2015. Introdução à Identificação de Sistemas, 4th Edition. Editora UFMG, Belo Horizonte.
- Babuska, R., 1998. Fuzzy Modeling for Control. Springer Science Business Media, LLC, New York, USA.
- Centro de Lançamento de Alcântara, 2019. Missão. [Acessado em: 10-Jul-2019].
 URL <http://www2.fab.mil.br/cla/index.php/missao>
- de Abreu, J. A. P., de Oliveira, R. C. L., da Fonseca Neto, J. V., 2020. 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).
- Federal Aviation Administration, 2011. Flight Safety Analysis Handbook. Washington, DC, USA.
- Júnior, J. S. S., Costa, E. B. M., 2018. Data-driven fuzzy modelling methodologies for multivariable nonlinear systems. In: 2018 International Conference on Intelligent Systems (IS). pp. 125–131.
- Juang, J.-N., 1994. Applied System Identification. Prentice Hall PTR.
- Li, W., Pan, J., Li, Y., Pan, S., Liu, Y., 2018. A kalman filtering for linear discrete-time system with unknown inputs. 2018 Chinese Control And Decision Conference (CCDC).
- Ma, J., Yang, J., Howard, S. K., 2019. A clustering algorithm based on fuzzy sets and its application in learning analytics. In: 2019 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE). pp. 1–6.
- Macedo, A. M., Serra, G. L. d. O., 2020. Localização de veículos aeroespaciais por triangulação de antenas. Simpósio de Aplicações Operacionais em Áreas de Defesa.
- Omnisys grupo Thales, 2010. Radar de Trajetografia Banda C. [Acessado em: 10-Jul-2019].
 URL http://www.omnisys.com.br/prod_radar_trajetografia.asp
- Palmerio, A. F., 2017. Introdução à Tecnologia de Foguetes, 2nd Edition. SindCT, São José dos Campos, SP.
- Pires, D. S., Serra, G. L. d. O., 2018. Fuzzy kalman filter modeling based on evolving clustering of experimental data. In: 2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE). pp. 1–6.
- Sarkar, N., Rao, K., Shubhanga, K. N., 2018. A comparative study between prony and eigensystem realization algorithm for identification of electromechanical modes. In: 2018 20th National Power Systems Conference (NPSC). pp. 1–6.
- Wallops Flight Facility, 2002. Range Safety Manual RSM2002C. Natinal Aeronautics and Space Administration (NASA), Wallops Island, Virginia, USA.