

# Filtragem Computacional Nebulosa para Rastreamento e Previsão Adaptativa da Trajetória de Foguetes 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:** Alcântara Launch Center (CLA), among its activities, tracks aerospace vehicles. The positioning data is mainly provided by tracking radars. If there is loss of radar signal, the position is based on a predefined nominal trajectory. In order to estimate the vehicle position in situations of radar signal loss, this work proposes a fuzzy adaptive filter. Simulations of tracking a real flight launched from the CLA in 2018 were performed. The data show that the proposed filter models the nonlinearities of the actual flight, and estimates the vehicle position for radar signal loss scenarios.

**Resumo:** O Centro de Lançamento de Alcântara (CLA), dentre suas atividades, realiza o rastreamento de veículos aeroespaciais. Os dados de localização são fornecidos principalmente pelos radares de rastreamento. Em caso de perda dos sinais dos radares, a localização é baseada em uma trajetória nominal pré definida. Com o objetivo de se estimar a localização do veículo, em situações de perda dos sinais dos radares, este trabalho propõe um filtro adaptativo nebuloso. Foram realizadas simulações de rastreamento de um voo real lançado a partir do CLA em 2018. Os dados mostram que o filtro proposto modela as não linearidades do voo real, e estima a posição do veículo para os cenários de perda dos sinais dos radares.

*Keywords:* Adaptive Filter; RLS; System Identification; Fuzzy Systems; Parameter Estimation.

*Palavras-chaves:* Filtro Adaptativo; RLS; Identificação de Sistemas; Sistemas Nebulosos; Estimação de Parâmetro.

---

## 1. INTRODUÇÃO

O Centro de Lançamento de Alcântara (CLA) tem como missão executar atividades de lançamento e rastreamento de engenhos aeroespaciais (Centro de Lançamento de Alcântara, 2019). Foguetes suborbitais são lançados transportando carga úteis para o ambiente de microgravidade (de Abreu et al., 2020). Após o retorno do foguete à superfície terrestre, pode-se ocorrer o resgate da carga útil para análises posteriores. Além das aplicações da atividade aeroespacial e o acesso ao espaço, a atividade de lançamento de foguete promove o desenvolvimento científico e tecnológico cujos ganhos atingem diversos setores (Robertson and Webb, 2011).

Os dados de rastreamento do veículo são monitorados pela Segurança de Voo, utilizados principalmente para determinar se o voo está dentro do limite de segurança previsto, ou se há necessidade de terminar o voo através da destruição do veículo (Federal Aviation Administration, 2011). Os dados de rastreamento também são utilizados para auxiliar no apontamento das antenas do sistema de telemetrias do Centro. Portanto, a disponibilidade de dados de localização do veículo é crítica para a segurança do voo assim como

para o cumprimento da missão como um todo (Wallops Flight Facility, 2002).

Atualmente, o CLA realiza o rastreamento de veículos aeroespaciais através de sistemas com radares de rastreamento (Omnisys grupo Thales, 2010). Os radares operam em modo automático, manual ou designado. O modo automático é baseado no apontamento da antena de forma automática na direção do melhor sinal ruído. O modo manual permite o operador controlar o apontamento da antena manualmente. No modo designado, o apontamento da antena é baseado em informações externas, a exemplo de dados de outro radar ou uma trajetória nominal pré definida. Este trabalho aborda uma alternativa de designação por uma trajetória definida pelo algoritmo proposto em caso de perda do sinal dos radares.

Sabe-se que um voo de veículo aeroespacial sofre de diversas não linearidades difíceis de serem modeladas (Cihan and Kaya, 2015), a exemplo da influência de forças aerodinâmicas não modeladas, erros de modelagem do empuxo do motor, variação da força gravitacional, influencia das condições climáticas etc (Palmerio, 2017). Ainda que há modelos matemáticos para descrever a trajetória do foguete, pode-se considerar que tal modelagem em sua

totalidade é complexo e com custo computacional elevado Jenie et al. (2019).

Pode-se dividir um voo de um foguete em três fases (do Nascimento and de Oliveira, 2017). A primeira fase é a de lançamento, ou *boost phase*, na qual as forças de propulsão resultam numa velocidade é ascendente do foguete. A segunda fase é após a queima do combustível *burnout*, na qual a velocidade do foguete descrese principalmente às forças aerodinâmicas resistivas. A terceira fase é chamada de recuperação ou *recovery*, na qual ocorre um aumento de velocidade após o foguete atingir o apogeu da trajetória.

Entende-se ainda que o voo pode ser visto como um sistema não linear não estacionário, pois suas estatísticas se alteram no decorrer do voo. Portanto, propõe-se um algoritmo adaptativo de filtragem que consiga acompanhar as mudanças das características durante o voo (Farina et al., 2002).

No contexto de filtro adaptativo, o algoritmo LMS é largamente utilizado devido sua simplicidade computacional (Sireesha et al., 2013). Contudo, para se obter maior velocidade de convergência para sistema com elevado número de parâmetros a estimar (Eweda and Macchi, 1987), o algoritmo RLS é uma alternativa (Ghauri and Sohail, 2013).

Na modelagem de sistemas dinâmicos não lineares, os sistemas nebulosos são muito utilizados devido a facilidade de sua implementação comparado com seu desempenho (Melin and Castillo, 1999). Sistemas nebulosos são amplamente utilizados para projeto de controle, mas também pode-se utilizar seus conceitos para projeto de filtro preditivo (Wang, 1996).

Este trabalho propõe um projeto de filtro adaptativo nebuloso com o objetivo de estimar a localização de veículos aeroespaciais em caso de perda do sinal dos radares.

## 2. METODOLOGIA

A metodologia deste trabalho se inicia com a definição de uma trajetória nominal aproximada e definição de um sistema nebuloso. A trajetória aproximada permite a redução do número de parâmetros do sistema nebuloso a se estimar. Definido a quantidade de parâmetros segue-se para uma fase de aprendizado e ajuste dos parâmetros. Esta fase de aprendizado definirá as condições iniciais para a estimação da localização por filtro adaptativo nebuloso.

A Figura 1 apresenta o diagrama de blocos das fases do algoritmo de previsão de trajetória.

### 2.1 Definição de trajetória nominal inicial aproximada

Para problemas com elevado número de parâmetros a estimar, as condições iniciais na execução do LMS ou RSL influenciam diretamente em sua performance. Com o objetivo de se obter as condições iniciais apropriadas, deve-se estimar uma trajetória que se aproxime de alguma forma com a trajetória esperada.

De forma simplificada, para o eixo vertical de um voo suborbital, uma definição da trajetória nominal inicial

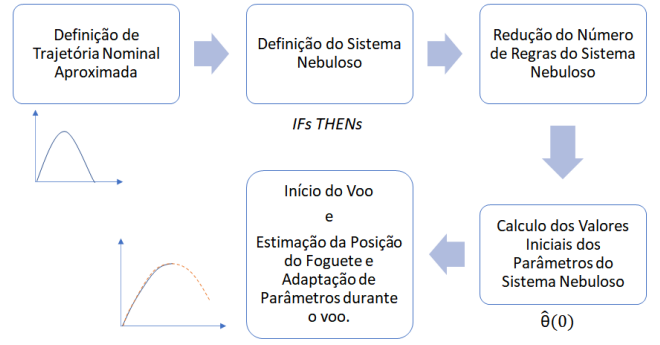


Figura 1. Diagrama de blocos das fases do algoritmo de previsão de trajetória

aproximada pode ser baseada em uma parábola com a segunda derivada igual a aceleração da gravidade.

$$y(t) = \frac{-g}{2}t^2 + v_0t \quad (1)$$

A velocidade inicial, pode ser determinada considerando o pico da parábola igual ao apogeu esperado do voo.

$$\frac{\partial y(t_a)}{\partial t} = -gt_a + v_0 = 0 \quad (2)$$

$$t_a = \frac{v_0}{g} \quad (3)$$

Em que  $t_a$  é o tempo em que ocorre o apogeu. Substituindo (3) em (1), temos:

$$a = -\frac{v_0^2}{2g} + \frac{v_0^2}{g} \quad (4)$$

$$v_0 = \sqrt{2ga} \quad (5)$$

Em que  $a$  é o apogeu esperado. Substituindo (5) em (1), temos a trajetória inicial nominal aproximada simplificada.

$$y(t) = \frac{-g}{2}t^2 + \sqrt{2gat} \quad (6)$$

Considerando que o algoritmo proposto tem característica adaptativa, pode-se considerar essa trajetória apenas como condição inicial, ainda que esta trajetória não representa um voo suborbital, por não considerar os diversos fatores inerentes ao voo.

### 2.2 Definição das Regras do Sistema Nebuloso

Para aplicação de filtro adaptativo nebuloso, usamos uma estrutura baseada em regras *IF THEN* da seguinte forma.

Considere  $n$  variáveis nebulosas  $x_1 = y_1(k - 1l)$ ,  $x_2 = y_2(k - 2l)$ , ...,  $x_n = y_n(k - nl)$ , em que  $k$  representa o instante atual e  $l$  o espaçamento entre as amostras do filtro. Cada variável é dividida em  $N$  partições.

Para melhor entendimento, podemos considerar o seguinte exemplo. Considere um sistema com total de 2 variáveis

aleatórias, ou seja  $n = 2$ , com o espaçamento de amostra  $l = 1$ . Considere cada variável nebulosa sendo dividida em 2 partições,  $N = 2$ . Para este caso, as regras seriam do tipo:

Se a posição do veículo no instante  $k-2$  estiver na partição 1 e a posição do veículo no instante  $k-1$  estiver na partição 2, então a posição do veículo no instante  $k$  será  $\bar{y}_{12}$ .

A mesma lógica seria aplicada para as demais regras considerando todas as combinações entre as posições nas partições 1 e 2 para instantes  $k-2$  e  $k-1$ .

Tabela 1. Exemplo de Regras no Sistema Nebulosos.

	Posição no Instante $k-2$	Posição no Instante $k-1$	Posição no Instante $k$
1ª Regra	Partição 1	Partição 1	$\bar{y}_{11}$
2ª Regra	Partição 1	Partição 2	$\bar{y}_{12}$
3ª Regra	Partição 2	Partição 1	$\bar{y}_{21}$
4ª Regra	Partição 2	Partição 2	$\bar{y}_{22}$

O cálculo de  $\bar{y}_{ij}$ , conforme apresentado na Tabela (1), é baseado na extração de dados numéricos e será explicado mais adiante. Assim, a construção das regras do sistema nebuloso proposto não é realizado através de um especialista, mas sim mediante cálculos numéricos do sistema simulado ou real.

### 2.3 Saída do Sistema Nebuloso

Pretende-se transformar o conjunto de regras do sistema nebuloso em um único filtro de resposta ao impulso finita (FIR), e que o vetor de parâmetros seja calculado por algoritmo adaptativo. Assim, devemos ter a saída do sistema como um produto entre dois vetores, sendo um vetor com os parâmetro a determinar, e outro vetor com valores de entrada do sistema (Serra, 2018).

Para isto, propõe-se um sistema completo nebuloso com máquina de inferência tipo produto, fuzzificador *singleton* e a média dos centróides como defuzzificador (Wang, 1996). Essa configuração resulta em uma soma de produtos, o que pode ser decomposto em um produto de vetores conforme desejamos, e detalhado mais adiante.

Assim, a saída do sistema é representada por:

$$y(x) = \frac{\sum_{l_1=1}^N \sum_{l_2=1}^N \cdots \sum_{l_n=1}^N \bar{y}_{l_1 \dots l_n} \prod_{i=1}^n \mu_{i,l_i}(x_i)}{\sum_{l_1=1}^N \sum_{l_2=1}^N \cdots \sum_{l_n=1}^N \prod_{i=1}^n \mu_{i,l_i}(x_i)} \quad (7)$$

Em que  $\mu$  representa uma função de pertinência da variável nebulosa  $i$  e partição  $l_i$ . Os termos  $\bar{y}_{l_1, \dots, l_n}$  são variáveis livres a serem otimizadas pelo filtro adaptativo. Podemos agrupar essas variáveis em um vetor  $\theta$ .

Podemos então reescrever (7) como:

$$y(x) = b^T(x)\theta \quad (8)$$

$$b(x) = \begin{bmatrix} b_{1\dots 1}(x) \\ b_{2\dots 1}(x) \\ \dots \\ b_{N\dots 1}(x) \\ b_{121\dots 1}(x) \\ \dots \\ b_{N21\dots 1}(x) \\ \dots \\ b_{1N\dots N}(x) \\ \dots \\ b_{NN\dots N}(x) \end{bmatrix} \theta = \begin{bmatrix} \bar{y}_{1\dots 1}(x) \\ \bar{y}_{2\dots 1}(x) \\ \dots \\ \bar{y}_{N\dots 1}(x) \\ \bar{y}_{121\dots 1}(x) \\ \dots \\ \bar{y}_{N21\dots 1}(x) \\ \dots \\ \bar{y}_{1N\dots N}(x) \\ \dots \\ \bar{y}_{NN\dots N}(x) \end{bmatrix} \quad (9)$$

Em que

$$b_{l_1, l_2, \dots, l_n} = \frac{\prod_{i=1}^n \mu_{i, l_i}(x_i)}{\sum_{l_1=1}^N \sum_{l_2=1}^N \cdots \sum_{l_n=1}^N \prod_{i=1}^n \mu_{i, l_i}(x_i)} \quad (10)$$

Observe que caso outro método fosse utilizado como máquina de inferência ou defuzzificador, a exemplo de utilizar *max* e *min* ao invés do produto, isso poderia inviabilizar a separação do sistema em dois vetores em um filtro FIR conforme em (8).

### 2.4 Redução de número de regras

Observe em (9) que a dimensão do vetor de parâmetros a estimar é  $N^n$ . Isso provoca um elevado custo computacional para a estimação dos parâmetros.

Esse elevado número de parâmetros é consequência da consideração de um sistema nebuloso completo. Contudo, na prática, nem todas as  $N^n$  regras *IF THEN* contribuem para a solução.

A Figura (2) demonstra a influência de cada regra na composição final de  $y$ . Cada regra está ligada à uma posição no vetor  $b(x)$ .




Figura 2. Diagrama da influência de Regras em  $y$

Caso haja alguma posição do vetor de  $b(x)$  que assuma apenas valores de zero, significa que aquela regra não contribui para a solução do sistema, podendo ser assim removida. Nesse caso, o filtro adaptativo atribuirá valor zero para  $\bar{y}_i$  relacionada àquela regra. Portanto, para identificar qual regra resulta em valor zero em  $b_i(x, t)$  para todo instante de tempo, basta olhar qual a posição do vetor que resultou em  $\bar{y}_i$  igual a zero no final da simulação com filtro adaptativo em toda trajetória.

Podemos então identificar quais regras não contribuem para a solução. Para isto, basta executar um algoritmo LMS utilizando como o sinal desejado uma trajetória inicial aproximada, com condições iniciais nulas de  $\hat{\theta}$ . Após a execução do LMS, os elementos do vetor  $b(x)$  que apresentarem valor nulo em  $\hat{\theta}$  não estão contribuindo para a solução. Portanto, pode-se excluir do conjunto de regras

nebulosas aquelas relacionadas aos elementos de  $b(x)$  que anularam os elementos de  $\hat{\theta}$ .

Este procedimento de eliminação de regras nebulosas inutilizadas, podem ser visualizado de forma de diagrama na Figura (3).




Figura 3. Procedimento de eliminação de regras inutilizadas

Esse procedimento reduz a dimensão dos novos vetores  $\theta$  e  $b$ , o que implica em reduzir o custo computacional nas próximas fases. Observe que foi escolhido o algoritmo LMS nesta fase pois requer menor recurso computacional se comprado ao RLS neste caso.

### 2.5 Aprendizado da trajetória inicial aproximada

Observe que apesar do comportamento do voo ser considerado um sistema não linear, (8) representa um sistema linear em seus parâmetros. Isso nos permite utilizar algoritmo de filtro linear.

O voo de um veículo aeroespacial é considerado um sistema não estacionário, em que se varia as estatísticas dos sinais durante o voo. Exemplo disso é a transição do fim da queima do primeiro estágio para o início da queima do segundo estágio, ou na abertura do paraquedas em voos suborbitais, ou ainda a saída do veículo da atmosfera terrestre. Para tratar essa característica não estacionárias, usamos um filtro adaptativo RLS.

Sabemos que as condições iniciais em um filtro adaptativo influencia em muito na velocidade de convergência de seu resultado. Assim, deve-se primeiramente calcular  $\hat{\theta}$  como a estimativa de  $\theta$  utilizando uma trajetória inicial aproximada como o sinal desejado, ainda que ela não represente todas as não linearidades do voo. Deve-se executar esse algoritmo quantas vezes forem necessário até a convergência de  $\hat{\theta}$ , pois essa será a condição inicial para a filtragem durante a trajetória real do voo.

### 2.6 Algoritmos LMS e RLS

Neste trabalho foram utilizados os algoritmos LMS e RLS para estimar  $\theta$  em (8).

Ambos os algoritmos utilizam a estrutura da Figura 4, para o ajuste dos parâmetros  $\hat{\theta}$ , baseado na entrada de dados proveniente do radar ou da trajetória nominal aproximada.

O algoritmo LMS é um método estocástico baseado no gradiente desceste, cuja adaptação de parâmetros se dá considerando erro de aproximação em cada instante. É um filtro ótimo que objetivo minimizar o erro quadrático médio do sinal filtrado comparado com o sinal desejado. Nesta

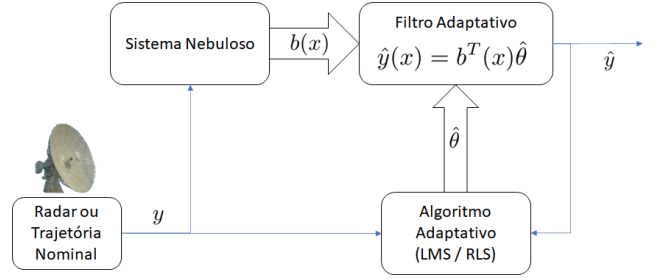


Figura 4. Diagrama do sistema nebuloso com filtro adaptativo

aplicação, foi utilizado a variação algoritmo normalizado, assim as seguintes equações de atualização forma utilizadas para se obter o ajuste dos parâmetros  $\hat{\theta}$ :

$$e(x) = d(x) - b(x)^T \hat{\theta}(k-1) \quad (11)$$

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \frac{\mu e(x) b(x)}{b(x)^T b(x)} \quad (12)$$

No algoritmo acima, deve-se definir a condição inicial  $\hat{\theta}(0)$  além de o tamanho do passo  $0 < \mu < 2$ .

O algoritmo RLS como segundo método de filtro adaptativo. Diferentemente do método LMS apresentado anteriormente, o RLS objetiva minimizar a função de custo de mínimos quadrados ponderados apresentado na seguinte equação.

$$C(\theta_n) = \sum_{i=0}^n \lambda^{n-1} e^2(i) \quad (13)$$

Em que  $0 < \lambda \leq 1$  representa o fator de esquecimento do filtro, e  $e$  o erro entre o sinal desejado e o sinal filtrado. Portanto, quanto menor o fator  $\lambda$ , os erros de filtragem mais antigos terão menos peso no ajuste dos parâmetros do filtro. Neste trabalho foi utilizado  $\lambda = 1$ .

Para o RSL, as seguintes equações de atualizações foram utilizadas:

$$e(x) = d(x) - b(x)^T \hat{\theta}(k-1) \quad (14)$$

$$P(k) = P(k-1) - \frac{P(k-1) b(x) b^T(x) P(k-1)}{1 + b^T(x) P(k-1) b(x)} \quad (15)$$

$$\hat{\theta}(k) = \hat{\theta}(k-1) + P(k) b(x) e(x) \quad (16)$$

No algoritmo acima, deve-se definir as condições iniciais  $\hat{\theta}(0)$  e  $P(0)$ .

### 2.7 Estimação da localização por filtro nebuloso

Após calcular as condições iniciais de  $\hat{\theta}$  utilizando uma trajetória aproximada, podemos calcular a estimação da localização do veículo aeroespacial utilizando o algoritmo RLS de (14) a (16).

$$\hat{y}(x) = b^T(x) \hat{\theta} \quad (17)$$

### 3. RESULTADOS

Para a simulação do trabalho proposto, foram utilizados dados de rastreamento de um veículo suborbital lançado no Centro de Lançamento de Alcântara em 2018. Foi considerado apenas o eixo vertical nas simulações.

Para a definição da trajetória nominal aproximada, foi considerado uma parábola conforme (6), com aceleração da gravidade  $g = 9.8m/s^2$  e apogeu esperado  $a = 140 Km$ .

Para a definição do sistema nebuloso em (7), foram considerados  $n = 3$  variáveis nebulosas com espaçamento  $l = 206$ . É importante observar que os dados possuem intervalo de amostragem de  $0.05 s$ , ou seja, as variáveis nebulosas são espaçadas no tempo em  $10.3 s$ . Para cada variável nebulosa, foram consideradas  $N = 10$  partições. Cada partição é definida com uma função de pertinência gaussiana com variância  $\sigma = 14 Km$ . A Figura 5 representa a distribuição das funções de pertinência das partições de cada variável nebulosa.




Figura 5. Funções de Pertinência

Considerando um sistema nebuloso completo com 3 variáveis nebulosas e com 10 partições, resulta em inicialmente 300 regras *IF THEN*.

Foi executado portanto a redução do número de regras conforme descrito na seção anterior utilizando o algoritmo LMS em (11) e (12), com  $\hat{\theta}(0)$  um vetor nulo e  $\mu = 1$ . Portanto o número de regras reduziu de 300 para 256, ou seja, uma redução de aproximadamente 15%.

Após a redução do número de regras, foi utilizado o algoritmo RLS juntamente com a trajetória nominal aproximada para se calcular o  $\hat{\theta}(0)$  que será utilizado na fase de estimação.

Foram realizadas 10 execuções da trajetória para se garantir a convergência. Para se verificar a convergência de  $\hat{\theta}$ , para cada iteração e execução do RLS, a norma  $\|\hat{\theta}\|$  foi calculada e pode ser visualizada na figura 6.

Uma vez calculado as condições iniciais do vetor de parâmetros  $\hat{\theta}(0)$  com base na trajetória aproximada, pode-se calcular a estimação da posição do foguete por filtro RLS e o sistema nebuloso definido anteriormente com os dados

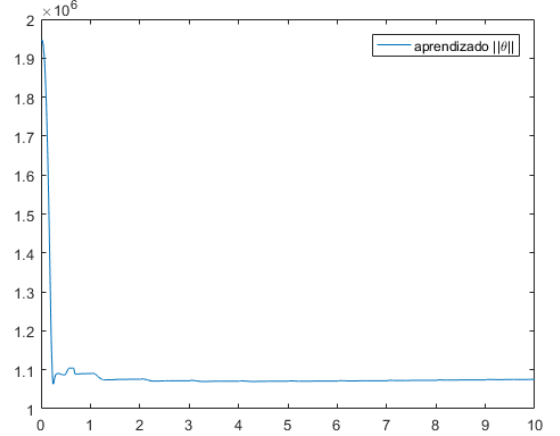


Figura 6. Convergência de  $\hat{\theta}$

do voo real como entrada. Para isto, executou-se uma vez o algoritmo RLS com a trajetória real como sinal desejado.

#### 3.1 Simulação com Perda Parcial de Sinal

Para fins de simulação, foi considerado uma primeira situação na qual entre 50% e 60% do tempo de simulação o algoritmo não obteve os valores da trajetória real disponíveis.

Durante o tempo com sinais da trajetória real indisponíveis, considerou-se (11) como  $e(x) = 0$ . Este artifício elimina o ajuste dos parâmetros do sistema nebuloso pelo filtro adaptativo. Assim, a estimativa da posição do foguete seria mediante a saída do sistema nebuloso utilizando seus parâmetros atualizados apenas até o momento de indisponibilidade dos dados da trajetória real. Este cenário simula uma perda do sinal dos radares.

A mesma consideração de indisponibilidade dos dados da trajetória real entre 50% e 60% também foi realizada com os dados entre 80% e 90% do tempo de simulação.

A figura 7 demonstra o resultado desta simulação.




Figura 7. Simulação de perda de sinal dos radares entre 50% e 60% e entre 80% e 90% do tempo de simulação.

Observe na figura 7 que a trajetória nominal aproximada utilizada para calcular  $\hat{\theta}(0)$  não modela precisamente a

trajetória real, contudo fornece uma aproximação geral. A trajetória real, por sua vez apresenta comportamento com não linearidades. Destaca-se o momento de abertura do paraquedas da carga útil em aproximadamente 60% do tempo de simulação. O filtro nebuloso, por sua vez, se adapta nas não linearidades da trajetória real tanto na fase inicial quanto na fase final do voo.

Observa-se ainda que houve uma boa aproximação da estimação do filtro durante os instantes considerados como perda de sinal dos radares.

### 3.2 Propagação do Sistema Nebuloso sem Adaptação

Por fim, uma última simulação foi realizada para demonstrar a modelagem da não lineares possibilitada pelo sistema nebuloso proposto.

Foi considerado o resultado final de  $\hat{\theta}$  da simulação anterior como um valor fixo  $\bar{\theta}$  para esta nova simulação. Esta consideração elimina a etapa de ajuste dos parâmetros do sistema nebuloso pelo algoritmo RLS. Dessa forma, a estimação não considerou os dados da trajetória real para ajuste de parâmetros, mas sim apenas uma propagação da estimação pelo sistema nebuloso proposto, resultando na curva da figura 8.

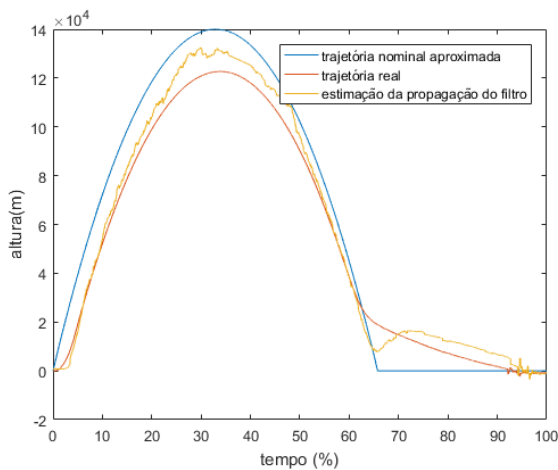


Figura 8. Propagação do filtro sem considerar dados da trajetória real.

Observe que a curva da propagação, ainda que ruidosa, contém aspectos de não linearidades da trajetória real, a exemplo da não linearidade apresentada após 60% do tempo de simulação, com a abertura do paraquedas, demonstrando que o sistema nebuloso possibilitou a modelagem aproximada de tal não linearidade.

## 4. CONCLUSÃO

Foi apresentada uma abordagem ao desafio de estimar a posição de veículos aeroespaciais em voo suborbital em cenários de perda dos sinais dos radares. A solução proposta é baseada em um sistema nebuloso com parâmetros ajustados dinamicamente por filtro adaptativo.

Primeiramente se definiu uma trajetória nominal aproximada assim como um sistema nebuloso baseado em regras *IF THEN*. Foi realizado uma redução de número de regras

do sistema nebuloso e o ajuste inicial dos parâmetros do filtro baseado na trajetória nominal aproximada. Por fim, foi executado a simulação da estimação da localização baseado em filtro adaptativo RLS.

As simulações mostraram que foi possível estimar a posição do veículo para uma trajetória contendo não linearidades ainda que em cenários de perda dos sinais do radar.

O sistema nebuloso também foi capaz de modelar, ainda que de maneira aproximada, as não linearidades de um voo real, a exemplo da mudança de trajetória no instante de abertura do paraquedas da carga útil. Observa-se contudo que a aplicação em operação real do algoritmo em voo depende da capacidade de o radar retomar o rastreamento a partir da localização aproximada prevista pelo algoritmo. Esta capacidade está relacionada a diversos fatores a exemplo da largura do lóbulo da antena de recepção e resolução do sistema radar.

Como trabalho futuro, pode-se estudar a utilização de uma arquitetura ANFIS (*Adaptive Neuro Fuzzy Inference System*) para se obter um sistema nebuloso com capacidades de aprendizado, utilizado em aplicações em sistemas não lineares. Além disso pode-se estudar a aplicação de algoritmos de agrupamento para otimizar o sistema nebuloso, a exemplo do fuzzy c-means.

## REFERÊNCIAS

- Centro de Lançamento de Alcântara (2019). Missão. URL <http://www2.fab.mil.br/cla/index.php/missao>. [Acessado em: 10-Jul-2019].
- Cihan, M. and Kaya, M.O. (2015). On the dynamic stability of a rocket under constant thrust. In *2015 7th International Conference on Recent Advances in Space Technologies (RAST)*, 467–470. Istanbul, Turkey.
- de Abreu, J.A.P., de Oliveira, R.C.L., and 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).
- do Nascimento, E.O. and de Oliveira, L.N. (2017). Numerical optimization of flight trajectory for rockets via artificial neural networks. *IEEE Latin America Transactions*, 15(8), 1556–1565.
- Eweda, E. and Macchi, O. (1987). Convergence of the rls and lms adaptive filters. *IEEE Transactions on Circuits and Systems*, 34(7), 799–803.
- Farina, A., Ristic, B., and Benvenuti, D. (2002). Tracking a ballistic target: comparison of several nonlinear filters. *IEEE Transactions on Aerospace and Electronic Systems*, 38(3), 854–867.
- Federal Aviation Administration (2011). *Flight Safety Analysis Handbook*. Washington, DC, USA.
- Ghuri, S.A. and Sohail, M.F. (2013). System identification using lms, nlms and rls. In *2013 IEEE Student Conference on Research and Development*, 65–69. Putrajaya.
- Jenie, Y.I., Suarjaya, W.W.H., and Poetro, R.E. (2019). Falcon 9 rocket launch modeling and simulation with thrust vectoring control and scheduling. In *2019 IEEE 6th Asian Conference on Defence Technology (ACDT)*, 25–31.

- Melin, P. and Castillo, O. (1999). A new neuro-fuzzy-fractal approach for adaptive model-based control of non-linear dynamic systems: the case of controlling aircraft dynamics. In *FUZZ-IEEE'99. 1999 IEEE International Fuzzy Systems. Conference Proceedings (Cat. No.99CH36315)*, volume 3, 1470–1475.
- Omnisys grupo Thales (2010). *Radar de Trajetografia Banda C*. URL [http://www.omnisys.com.br/prod\\_radar\\_trajetografia.asp](http://www.omnisys.com.br/prod_radar_trajetografia.asp). [Acessado em: 10-Jul-2019].
- Palmerio, A.F. (2017). In *Introdução à Tecnologia de Foguetes*. SindCT, São José dos Campos, SP.
- Robertson, G.A. and Webb, D.W. (2011). The death of rocket science in the 21st century. *Space, Propulsion and Energy Sciences International Forum - 2011*, 20, 319–330.
- Serra, G.L. (2018). *Kalman Filters Theory for Advanced Applications*. 1st edition.
- Sireesha, N., Chithra, K., and Sudhakar, T. (2013). Adaptive filtering based on least mean square algorithm. In *2013 Ocean Electronics (SYMPOL)*, 42–48. Kochi, India.
- Wallops Flight Facility (2002). *Range Safety Manual RSM2002C*. Natinal Aeronautics and Space Administration (NASA), Wallops Island, Virginia, USA.
- Wang, L.X. (1996). *A Course in Fuzzy Systems and Control*. Prentice Hall International, Inc, 1st edition.