

Algoritmo de Filtro de Kalman Baseado em Modelo *Fuzzy* Tipo-2 Evolutivo para Rastreamento Intervalar de Dados Experimentais

1st Daiana Caroline dos Santos Gomes
Universidade Federal do Maranhão
São Luís - MA, Brazil
daianagomes159@gmail.com

2nd Ginalber Luiz de Oliveira Serra
Instituto Federal de Educação, Ciência e Tecnologia do Maranhão
São Luís - MA, Brazil
ginalber@ifma.edu.br

Abstract—Neste artigo, um filtro de Kalman *fuzzy* tipo-2 evolutivo é proposto para o processamento intervalar de dados experimentais a partir de componentes espectrais não-observáveis. A metodologia adotada considera as seguintes etapas: um modelo inicial do filtro de Kalman *fuzzy* tipo-2 evolutivo é identificado de forma *off-line* a partir de uma janela inicial de dados experimentais; a atualização da proposição do antecedente do filtro de Kalman *fuzzy* tipo-2 evolutivo é realizada usando uma formulação *fuzzy* tipo-2 intervalar do algoritmo de agrupamento *evolving* Takagi-Sugeno (eTS) e a atualização da proposição consequente é realizada usando uma formulação *fuzzy* tipo-2 do algoritmo *Observer/Kalman Filter Identification* (OKID), levando em consideração as componentes espectrais não-observáveis extraídas dos dados experimentais por meio de um algoritmo de Análise Espectral Singular Recursiva Multivariável. Resultados experimentais e análise comparativa referentes ao rastreamento intervalar de um helicóptero 2DoF ilustram a eficiência da metodologia proposta.

Index Terms—Identificação de Sistemas, Filtragem de Kalman, Modelo *fuzzy* tipo-2 intervalar, Análise Espectral Singular, Sistemas *fuzzy* evolutivos.

I. INTRODUÇÃO

A modelagem *fuzzy* a partir de dados experimentais tem sido largamente desenvolvida e aplicada com sucesso em diferentes domínios de aplicação, tais como biomédica [1], epidemiologia [2], processamento digital de imagem [3], reconhecimento de padrão [4], controle e automação de sistemas dinâmicos [5], [6], entre outros. O interesse crescente da comunidade científica pelos sistemas *fuzzy* é devido a algumas de suas vantagens sobre outras técnicas de inteligência artificial, tais como a sua capacidade de combinar o conhecimento do especialista com informações extraídas de dados experimentais, sua fácil formulação e implementação, maior interpretabilidade e alta precisão no tratamento de não-linearidades e incertezas [7]. Portanto, os sistemas *fuzzy* representam uma poderosa ferramenta para solucionar problemas nas ciências e engenharias, uma vez que eles fornecem modelos altamente precisos com melhor interpretabilidade [8], [9].

O nível de complexidade e incerteza associados a problemas práticos tem motivado o desenvolvimento de sistemas *fuzzy* tipo-2 no contexto evolutivo com aplicações em diversas áreas de estudo [10]. Uma vez que grande parte dos métodos de

projeto e análise de sistemas *fuzzy* tipo-2 utilizam apenas informações linguísticas do especialista [7] e, considerando o crescente volume de dados e informações pertinentes a sistemas dinâmicos, propostas de metodologias para projeto de sistemas *fuzzy* tipo-2 evolutivos, levando em consideração o processamento de dados experimentais incertos, é um campo de pesquisa ainda em aberto [11], [12].

Em problemas práticos, é comum a distorção das informações contidas em dados experimentais, obtidos por meio de sensores, devido à presença de ruídos [13]. Neste sentido, algoritmos de aprendizagem eficientes e com melhor desempenho, desenvolvidos para aplicações neste contexto, são bastante procurados. O filtro de Kalman, desde que foi proposto em 1960, constitui uma das principais ferramentas matemáticas utilizadas no processamento de dados experimentais ruidosos [14], [15]. Diante disso, este artigo consiste no projeto de filtros de Kalman usando modelos *fuzzy* Takagi-Sugeno tipo-2 evolutivos considerando o processamento intervalar e espectral de dados experimentais incertos por meio de uma formulação multivariável e recursiva do método de Análise Espectral Singular.

A metodologia proposta neste artigo consiste em duas etapas. Na primeira etapa é realizada a estimação paramétrica inicial do modelo do filtro de Kalman *fuzzy* tipo-2 evolutivo e sua estrutura é atualizada, recursivamente, de acordo com a dinâmica inerente aos dados experimentais. Na segunda etapa, a atualização recursiva do filtro de Kalman *fuzzy* tipo-2 evolutivo, a parametrização da proposição do antecedente é realizada por meio do particionamento evolutivo dos dados experimentais através de uma formulação *fuzzy* tipo-2 do algoritmo *evolving* Takagi-Sugeno (eTS), proposta neste artigo, e a parametrização da proposição do consequente é realizada por meio de uma formulação *fuzzy* tipo-2 recursiva do algoritmo *Observer/Kalman Filter Identification* (OKID), proposta em [16], a qual é baseada nas componentes espectrais não-observáveis extraídas a partir dos dados experimentais.

II. METODOLOGIA PROPOSTA: FILTRAGEM DE KALMAN Fuzzy TIPO-2 EVOLUTIVA

Nesta seção, a metodologia proposta para o projeto do Filtro de Kalman *Fuzzy* Tipo-2 Evolutivo, a partir de componentes espectrais não-observáveis extraídas de dados experimentais incertos, é apresentada.

A. Pré-Processamento de Dados por Análise Espectral Singular Multivariável

A Análise Espectral Singular (AES) é uma técnica de processamento de dados que tem por objetivo a decomposição de séries temporais originais em componentes espectrais não-observáveis interpretáveis [17]. Uma formulação recursiva multivariável do algoritmo AES é proposta, a qual é descrita a seguir.

1) *Estimação Inicial das Componentes Espectrais Não-Observáveis*: Considerando a janela inicial de dados experimentais multivariável \mathbf{y} referente a p séries temporais, com N amostras, dada por:

$$\mathbf{y} = [\mathbf{y}_1 \quad \mathbf{y}_2 \quad \dots \quad \mathbf{y}_N], \quad \mathbf{y} \in \mathbb{R}^{p \times N} \quad (1)$$

onde $\mathbf{y}_k \in \mathbb{R}^p$, tal que $k = 1, \dots, N$, é o vetor composto pelas observações da série temporal p na amostra k . Uma matriz trajetória \mathcal{H} é construída considerando as p dimensões de \mathbf{y} como segue:

$$\mathcal{H} = \begin{bmatrix} \mathbf{y}_1 & \mathbf{y}_2 & \mathbf{y}_3 & \dots & \mathbf{y}_\rho \\ \mathbf{y}_2 & \mathbf{y}_3 & \mathbf{y}_4 & \dots & \mathbf{y}_{\rho+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{y}_\delta & \mathbf{y}_{\delta+1} & \mathbf{y}_{\delta+2} & \dots & \mathbf{y}_N \end{bmatrix}, \quad \mathcal{H} \in \mathbb{R}^{p\delta \times \rho} \quad (2)$$

onde $2 \leq \delta \leq N - 1$ é um parâmetro definido pelo usuário e $\rho = N - \delta + 1$. Uma matriz de covariância \mathcal{S} é calculada como segue:

$$\mathcal{S} = \mathcal{H}\mathcal{H}^T, \quad \mathcal{S} \in \mathbb{R}^{p\delta \times p\delta} \quad (3)$$

A Decomposição em Valores Singulares (SVD) da matriz \mathcal{S} é equivalente à SVD de \mathcal{H} e resulta em uma coleção de δ autovalores ($\sigma^1 \geq \sigma^2 \geq \dots \geq \sigma^\delta \geq 0$) e δ autovetores ($\phi^1, \phi^2, \dots, \phi^\delta$). A SVD de \mathcal{H} resulta em:

$$\mathcal{H} = \mathcal{H}^1 + \mathcal{H}^2 + \dots + \mathcal{H}^d \quad (4)$$

onde $d = \max\{\varrho, \text{tal que } \sigma^\varrho > 0\}$ e a matriz $\mathcal{H}^\varrho|_{\varrho=1, \dots, d}$ é obtida por:

$$\mathcal{H}^\varrho = \sqrt{\sigma^\varrho} \phi^\varrho \mathbf{V}^{\varrho T}, \quad \mathcal{H}^\varrho \in \mathbb{R}^{\delta \times \rho} \quad (5)$$

onde

$$\mathbf{V}^\varrho = \frac{\mathcal{H}^T \phi^\varrho}{\sqrt{\sigma^\varrho}}, \quad \varrho = 1, \dots, d \quad (6)$$

As matrizes $\mathcal{H}^\varrho|_{\varrho=1, \dots, d}$, obtidas a partir da Equação (5), são reagrupadas em ξ termos disjuntos, tal que $\xi \leq d$, como segue:

$$\mathcal{H} = \mathcal{I}^1 + \mathcal{I}^2 + \dots + \mathcal{I}^\xi \quad (7)$$

onde $\mathcal{I}^j|_{j=1, \dots, \xi}$ são os termos resultantes após o reagrupamento das matrizes $\mathcal{H}^\varrho|_{\varrho=1, \dots, d}$ e ξ corresponde ao número de

componentes espectrais não-observáveis extraídas dos dados experimentais, o qual é um parâmetro definido pelo usuário. Considerando $\delta^* = \min(\delta, \rho)$ e $\rho^* = \max(\delta, \rho)$, o vetor α^j que contém as ξ componentes espectrais não-observáveis referentes às p séries temporais de dados experimentais é obtido de $\mathcal{I}^j|_{j=1, \dots, \xi}$, da seguinte forma:

$$\alpha_k^j = \begin{cases} \frac{1}{k} \sum_{\nu=1}^{k+1} \mathcal{I}_{\nu, k-\nu+1}^j & 1 \leq k \leq \delta^* \\ \frac{1}{\delta^*} \sum_{\nu=1}^{\delta^*} \mathcal{I}_{\nu, k-\nu+1}^j & \delta^* \leq k \leq \rho^* \\ \frac{1}{N-k+1} \sum_{\nu=k-\rho^*+1}^{N-\rho^*+1} \mathcal{I}_{\nu, k-\nu+1}^j & \rho^* < k \leq N \end{cases} \quad (8)$$

2) *Atualização Recursiva das Componentes Espectrais Não-Observáveis*: Após a inicialização do algoritmo de análise espectral singular recursiva multivariável, conforme descrito na Seção II-A1, as componentes espectrais não-observáveis são atualizadas em $k = N + 1, N + 2, \dots$ conforme formulado a seguir. A variável ρ é atualizada da seguinte forma:

$$\rho = k - \delta + 1 \quad (9)$$

e a matriz de covariância \mathcal{S}_k é atualizada para o instante de tempo k como segue:

$$\mathcal{S}_k = \mathcal{S}_{k-1} + \Upsilon_k, \quad \mathcal{S}_k \in \mathbb{R}^{p\delta \times p\delta} \quad (10)$$

onde $\Upsilon_k = \psi_k \psi_k^T \in \mathbb{R}^{p\delta \times p\delta}$ com $\psi_k = [\mathbf{y}_\rho, \mathbf{y}_{\rho+1}, \dots, \mathbf{y}_k]^T$. O conjunto de autovalores $\sigma_k^1, \sigma_k^2, \dots, \sigma_k^\delta$ e seus respectivos autovetores $\phi_k^1, \phi_k^2, \dots, \phi_k^\delta$ são atualizados no instante de tempo k a partir da aplicação do procedimento de SVD para atualização da matriz de covariância \mathcal{S}_k , tal que \mathbf{y}_k pode ser reescrito como segue:

$$\mathbf{y}_k = \mathbf{h}_k^1 + \mathbf{h}_k^2 + \dots + \mathbf{h}_k^d \quad (11)$$

onde $\mathbf{h}_k^\varrho = \kappa_k^\varrho \psi_k^T \phi_k^\varrho$, $\varrho = 1, \dots, d$, tal que κ_k^ϱ corresponde ao último elemento do autovetor ϕ_k^ϱ . Os termos $\mathbf{h}_k^\varrho|_{\varrho=1, \dots, d}$ são reagrupados em ξ termos disjuntos $\mathcal{I}_k^j|_{j=1, \dots, \xi}$, como segue:

$$\mathbf{y}_k = \mathcal{I}_k^1 + \mathcal{I}_k^2 + \dots + \mathcal{I}_k^\xi \quad (12)$$

onde $\mathcal{I}_k^j = \alpha_k^j$, com $j = 1, \dots, \xi$ e $k = N + 1, N + 2, \dots$

B. Estimação Paramétrica do Filtro de Kalman Fuzzy Tipo-2 Evolutivo

O filtro de Kalman *fuzzy* tipo-2 evolutivo apresenta a $i|_{i=1, 2, \dots, L}$ -ésima regra *fuzzy*, como segue:

$$R^{(i)} : \quad \text{SE } \mathcal{Z}_k \text{ É } \widetilde{W}^i$$

$$\text{ENTÃO } \begin{cases} \widetilde{\mathbf{x}}_{k+1}^i = \widetilde{\mathbf{A}}_k^i \widetilde{\mathbf{x}}_k^i + \widetilde{\mathbf{B}}_k^i \mathbf{u}_k + \widetilde{\mathbf{K}}_k^i \widetilde{\boldsymbol{\epsilon}}_k^i \\ \widetilde{\mathbf{y}}_k^i = \widetilde{\mathbf{C}}_k^i \widetilde{\mathbf{x}}_k^i + \widetilde{\mathbf{D}}_k^i \mathbf{u}_k \end{cases} \quad (13)$$

onde a proposição do antecedente é definida pelos seguintes termos:

- $\mathcal{Z}_k \in \mathbb{R}^{r \times N}$ é a variável linguística da proposição do antecedente com r séries temporais e N amostras;
- \tilde{W}^i é o conjunto *fuzzy* tipo-2 intervalar correspondente a i -ésima regra;

e a proposição do consequente é definida por um submodelo no espaço de estados como segue:

- $\tilde{\mathbf{x}}_k^i = [\tilde{x}_{1k}^i \dots \tilde{x}_{nk}^i]^T \in \mathbb{R}^n$ representa o vetor de estados intervalar estimado com n -ésima ordem;
- $\tilde{\mathbf{y}}_k^i = [\tilde{y}_{1k}^i \dots \tilde{y}_{pk}^i]^T \in \mathbb{R}^p$ é o vetor de saídas local intervalar estimado;
- $\mathbf{u}_k = [u_{1k} \dots u_{mk}]^T \in \mathbb{R}^m$ é o sinal de entrada;
- $\mathbf{A}_k^i \in \mathbb{R}^{n \times n}$, $\mathbf{B}_k^i \in \mathbb{R}^{n \times m}$, $\mathbf{C}_k^i \in \mathbb{R}^{p \times n}$, $\mathbf{D}_k^i \in \mathbb{R}^{p \times m}$ e $\mathbf{K}_k^i \in \mathbb{R}^{n \times p}$ são, respectivamente, matriz de estados, matriz de entrada, matriz de saída, matriz de transmissão direta e matriz de ganho de Kalman, os quais são parâmetros intervalares;
- $\tilde{\boldsymbol{\epsilon}}_k^i = [\underline{\boldsymbol{\epsilon}}_k \quad \bar{\boldsymbol{\epsilon}}_k]$ é o vetor de erro residual, o qual serve como mecanismo de ajuste para a estimação dos ganhos de Kalman do filtro de Kalman *fuzzy* tipo-2 evolutivo.

1) *Estimação Inicial da Proposição do Antecedente do Filtro de Kalman Fuzzy Tipo-2 Evolutivo*: A proposição do antecedente do filtro de Kalman *fuzzy* tipo-2 evolutivo proposto é inicialmente estimada pelo algoritmo de agrupamento Gustafson-Kessel tipo-2 intervalar, conforme descrito a seguir. Seja os dados experimentais $\mathcal{Z} \in \mathbb{R}^{p \times N}$, a primeira etapa do algoritmo de agrupamento Gustafson-Kessel tipo-2 intervalar é o cálculo dos protótipos dos *clusters* $\tilde{\mathbf{v}}^{i(l)}$, com base na matriz de partição inicial aleatória $\tilde{\mathbf{U}}^{(0)} \in \mathbb{R}^{L \times N}$, como segue:

$$\tilde{\mathbf{v}}^{i(l)} = \frac{\sum_{k=1}^N \left(\tilde{\mu}_{\tilde{W}^i}^i(\mathcal{Z}_k)^{(l-1)} \right)^{\tilde{m}} \mathcal{Z}_k}{\sum_{k=1}^N \left(\tilde{\mu}_{\tilde{W}^i}^i(\mathcal{Z}_k)^{(l-1)} \right)^{\tilde{m}}}, \quad 1 \leq i \leq L \quad (14)$$

onde \mathcal{Z}_k corresponde aos dados experimentais no instante k , L é o número inicial de agrupamentos, tal que $1 < L < N$, $\tilde{\mu}_{\tilde{W}^i}^i(\mathcal{Z}_k)$ é o grau de pertinência intervalar da amostra \mathcal{Z}_k no i -ésimo agrupamento e $\tilde{m} = [\underline{m}, \bar{m}]$ é o expoente de ponderação intervalar, tal que \underline{m} e \bar{m} correspondem, respectivamente, ao expoente de ponderação das funções de pertinência superior e inferior do conjunto *fuzzy* tipo-2 intervalar \tilde{W}^i . As matrizes de covariância $\tilde{\mathbf{F}}^i$ são calculadas para cada agrupamento, como segue:

$$\tilde{\mathbf{F}}^i = \frac{\sum_{k=1}^N \left(\tilde{\mu}_{\tilde{W}^i}^i(\mathcal{Z}_k)^{(l-1)} \right)^{\tilde{m}} (\mathcal{Z}_k - \tilde{\mathbf{v}}^{i(l)}) (\mathcal{Z}_k - \tilde{\mathbf{v}}^{i(l)})^T}{\sum_{k=1}^N \left(\tilde{\mu}_{\tilde{W}^i}^i(\mathcal{Z}_k)^{(l-1)} \right)^{\tilde{m}}}, \quad 1 \leq i \leq L, \quad 1 \leq k \leq N$$

A partir das matrizes de covariância $\tilde{\mathbf{F}}^i$, as distâncias $\tilde{D}_{k\tilde{\mathbf{F}}^i}^i$ são calculadas por:

$$\tilde{D}_{k\tilde{\mathbf{F}}^i}^i = \sqrt{(\mathcal{Z}_k - \tilde{\mathbf{v}}^{i(l)})^T \left[\det(\tilde{\mathbf{F}}^i)^{1/n} (\tilde{\mathbf{F}}^i)^{-1} \right] (\mathcal{Z}_k - \tilde{\mathbf{v}}^{i(l)})} \quad (16)$$

O termo $\left[\det(\tilde{\mathbf{F}}^i)^{1/n} (\tilde{\mathbf{F}}^i)^{-1} \right]$ na Equação (16) corresponde à matriz de norma induzida $\mathbf{A}^i |_{i=1, \dots, L}$ relacionada a cada agrupamento, a qual permite adaptar o formato dos agrupamentos à estrutura topológica dos dados experimentais [18]. A matriz de partição $\tilde{\mathbf{U}}^{(l)}$ é atualizada como segue:

Se $\tilde{D}_{k\tilde{\mathbf{F}}^i}^i > 0$ para $1 \leq i \leq L$, $1 \leq k \leq N$

$$\tilde{\mu}_{\tilde{W}^i}^{i(l)}(\mathcal{Z}_k) = \left[\underline{\mu}_{\tilde{W}^i}^i(\mathcal{Z}_k), \bar{\mu}_{\tilde{W}^i}^i(\mathcal{Z}_k) \right] \quad (17)$$

onde

$$\underline{\mu}_{\tilde{W}^i}^{i(l)}(\mathcal{Z}_k) = \min \left[\frac{1}{\sum_{j=1}^L \left(\underline{D}_{k\tilde{\mathbf{F}}^j}^j / \underline{D}_{k\tilde{\mathbf{F}}^i}^i \right)^{2/(\underline{m}-1)}}, \frac{1}{\sum_{j=1}^L \left(\bar{D}_{k\tilde{\mathbf{F}}^j}^j / \bar{D}_{k\tilde{\mathbf{F}}^i}^i \right)^{2/(\bar{m}-1)}} \right] \quad (18)$$

$$\bar{\mu}_{\tilde{W}^i}^{i(l)}(\mathcal{Z}_k) = \max \left[\frac{1}{\sum_{j=1}^L \left(\underline{D}_{k\tilde{\mathbf{F}}^j}^j / \underline{D}_{k\tilde{\mathbf{F}}^i}^i \right)^{2/(\underline{m}-1)}}, \frac{1}{\sum_{j=1}^L \left(\bar{D}_{k\tilde{\mathbf{F}}^j}^j / \bar{D}_{k\tilde{\mathbf{F}}^i}^i \right)^{2/(\bar{m}-1)}} \right] \quad (19)$$

caso contrário $\tilde{\mu}_{\tilde{W}^i}^{i(l)}(\mathcal{Z}_k) = [0, 0]$. Estas etapas são repetidas iterativamente para $l = 1, 2, \dots$, até que a seguinte condição seja satisfeita:

$$\left\| \tilde{\mathbf{U}}^{(l)} - \tilde{\mathbf{U}}^{(l-1)} \right\| < \mathcal{E} \quad (20)$$

onde \mathcal{E} é a tolerância para finalização do algoritmo.

2) *Atualização Evolutiva da Proposição do Antecedente do Filtro de Kalman Fuzzy Tipo-2 Evolutivo*: A partição do universo de discurso da variável linguística \mathcal{Z}_k é atualizada por uma formulação *fuzzy* tipo-2 intervalar do algoritmo de agrupamento *evolving* Takagi-Sugeno (eTS), a qual é proposta neste artigo, a fim de adaptar a estrutura do filtro de Kalman *fuzzy* tipo-2 evolutivo à dinâmica inerente aos dados (15) experimentais. O algoritmo é baseado na densidade $D_k(z_k^j)$ da

amostra \mathbf{z}_k dos dados experimentais, para a j -ésima dimensão, a qual é calculada por [19]:

$$D_k(z_k^j) = \frac{k-1}{(k-1)(\delta_k+1) + \sigma_k - 2\rho_k} \quad (21)$$

onde

$$\delta_k = \sum_{j=1}^{o+1} (z_k^j)^2 \quad (22)$$

$$\sigma_k = \sigma_{k-1} + \sum_{j=1}^{o+1} (z_{k-1}^j)^2 \quad (23)$$

$$\rho_k = \sum_{j=1}^{o+1} z_k^j \alpha_k \quad (24)$$

$$\alpha_k = \alpha_{k-1} + z_{k-1}^j \quad (25)$$

tal que $D_1(z_1^j) = 1$, $\alpha_1 = 0$ e $\sigma_1 = 0$. A densidade dos protótipos dos agrupamentos $D_k(z^{i*})$, $i = 1, \dots, L$, é atualizada, de forma recursiva, como segue:

$$D_k(z^{i*}) = (k-1) + (k-2) \left(\frac{1}{D_{k-1}(z^{i*})} - 1 \right) + \sum_{j=1}^{o+1} (z_k^j - z_{k-1}^j)^2 \quad (26)$$

O mecanismo de adaptação é baseado na comparação entre a densidade de uma nova amostra a partir dos dados experimentais e a densidade de todos os protótipos dos agrupamentos existentes. Assim, a cada instante de tempo k , algumas condições são avaliadas para avaliar a qualidade do particionamento e, assim, adaptar a estrutura do filtro de Kalman *fuzzy* tipo-2 evolutivo de acordo com a variabilidade dos dados experimentais. Tais condições são descritas a seguir [20]:

- A **Condição A** seleciona uma amostra como novo protótipo de agrupamento, a qual é descrita por:

$$D_k(z_k^j) > \max_{i=1}^L D(z^{i*}) \text{ OU } D_k(z_k^j) < \min_{i=1}^L D(z^{i*}) \quad (27)$$

Se a condição A é satisfeita, então um novo agrupamento é definido ($L \leftarrow L+1$; $z^{i*} \leftarrow z_k^j$; $D(z^{i*}) = D_k(z_k^j)$);

- A **Condição B** evita a redundância e sobreposição de regras *fuzzy*, a qual é descrita por:

$$\text{SE } \tilde{\mu}_{\tilde{W}_k^i}(z_k^j) > e^{-1}, \quad i = 1, \dots, L-1 \\ \text{ENTÃO } L \leftarrow L-1 \quad (28)$$

- A **Condição C** garante que a base de regras tenha apenas regras *fuzzy* com algum nível de contribuição, e elimina regras com baixo nível de utilidade U_k^i , a qual é calculada por:

$$U_k^i = \frac{\sum_{l=1}^k \tilde{\mu}_{\tilde{W}_k^i}(z_l^j)}{k - I^{i*}} \quad (29)$$

onde I^{i*} é o instante de tempo em que a i -ésima regra *fuzzy* é criada. Portanto, a Condição C é dada por:

$$\text{SE } U_k^i < \eta, \quad i = 1, \dots, L, \quad \text{ENTÃO } L \leftarrow L-1 \quad (30)$$

tal que $\eta = [0.01 \ 0.3]$.

3) **Estimação Inicial da Proposição do Consequente do Filtro de Kalman Fuzzy Tipo-2 Evolutivo:** Para a estimação paramétrica inicial da proposição do consequente do filtro de Kalman *fuzzy* tipo-2 evolutivo foi utilizada uma formulação *fuzzy* tipo-2 intervalar do algoritmo OKID (*Observer/Kalman Filter Identification*) [21]. Este algoritmo é baseado nos valores de pertinência intervalares obtidos inicialmente pelo algoritmo de agrupamento *fuzzy* tipo-2 Gustafson-Kessel, conforme descrito na Seção II-B1, e nas componentes espectrais não-observáveis extraídas dos dados experimentais. Seja o conjunto de dados experimentais \mathbf{Z} , tal que $\mathbf{Z}_k = [\mathbf{u}_k \ \boldsymbol{\alpha}_k^*]^T$, onde $\boldsymbol{\alpha}_k^*$ corresponde às componentes espectrais mais significativas extraídas a partir dos dados experimentais, uma matriz de regressores Λ is calculada por:

$$\Lambda = \begin{bmatrix} \mathbf{u}_q & \mathbf{u}_{q+1} & \cdots & \mathbf{u}_{N_b-1} \\ \mathbf{Z}_{q-1} & \mathbf{Z}_q & \cdots & \mathbf{Z}_{N_b-2} \\ \mathbf{Z}_{q-2} & \mathbf{Z}_{q-1} & \cdots & \mathbf{Z}_{N_b-3} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{Z}_0 & \mathbf{Z}_1 & \cdots & \mathbf{Z}_{N_b-q-1} \end{bmatrix}_{[(m+p)q+m] \times N_b} \quad (31)$$

onde q é o número de parâmetros Markov definidos pelo usuário. A partir da matriz de regressores dada na Equação 31, o vetor composto pelos parâmetros do observador Markov $\tilde{\mathbf{Y}}^i$ é obtido pela seguinte equação:

$$\tilde{\mathbf{y}}^T = \sum_{i=1}^L \tilde{\Gamma}^i \Lambda^T \tilde{\mathbf{Y}}^{iT} \quad (32)$$

onde

$$\tilde{\Gamma}^i = \begin{bmatrix} \tilde{\mu}_{\tilde{W}_k^i}(\mathbf{Z}_q) & 0 & \cdots & 0 \\ 0 & \tilde{\mu}_{\tilde{W}_k^i}(\mathbf{Z}_{q+1}) & \cdots & 0 \\ 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \tilde{\mu}_{\tilde{W}_k^i}(\mathbf{Z}_{N-1}) \end{bmatrix} \quad (33)$$

é a matriz diagonal de ponderação da i -ésima regra *fuzzy* obtida a partir do algoritmo de agrupamento *fuzzy* tipo-2 intervalar Gustafson-Kessel e

$$\tilde{\mathbf{Y}}^i = \begin{bmatrix} \tilde{\mathbf{D}}_k^i & \tilde{\mathbf{C}}_k^i \tilde{\mathbf{B}}_k^i & \tilde{\mathbf{C}}_k^i \tilde{\mathbf{A}}_k^i \tilde{\mathbf{B}}_k^i & \cdots & \tilde{\mathbf{C}}_k^i \tilde{\mathbf{A}}_k^{i(q-1)} \tilde{\mathbf{B}}_k^i \end{bmatrix} \\ \tilde{\mathbf{Y}}^i = \begin{bmatrix} \tilde{\mathbf{Y}}_0^i & \tilde{\mathbf{Y}}_1^i & \tilde{\mathbf{Y}}_2^i & \cdots & \tilde{\mathbf{Y}}_q^i \end{bmatrix} \quad (34)$$

é o vetor com os parâmetros de Markov do observador, e $\tilde{\mathbf{A}}_k^i = [\tilde{\mathbf{A}}_k^i + \tilde{\mathbf{K}}_k^i \tilde{\mathbf{C}}_k^i]$ e $\tilde{\mathbf{B}}_k^i = [\tilde{\mathbf{B}}_k^i + \tilde{\mathbf{K}}_k^i \tilde{\mathbf{D}}_k^i, -\tilde{\mathbf{K}}_k^i]$ correspondem às matrizes de estados e entradas acopladas, uma vez que possuem informações do comportamento dinâmico inerente

aos dados experimentais e do ganho de Kalman intervalar. Usando a abordagem local na Equação (32), tem-se:

$$\Lambda \tilde{\Gamma}^i \mathbf{y}^T = \Lambda \tilde{\Gamma}^i \Lambda^T \tilde{\mathbf{Y}}^{iT} \quad (35)$$

onde $\mathbf{y} = [\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_N] \in \mathbb{R}^{p \times N}$ corresponde à janela inicial de dados experimentais reais. Considerando $\tilde{\mathbf{U}}^i = \Lambda \tilde{\Gamma}^i \Lambda^T$ e $\tilde{\mathbf{N}}^i = \Lambda \tilde{\Gamma}^i \mathbf{y}^T$, a Equação (35) é reescrita como segue:

$$\tilde{\mathbf{U}}^i \tilde{\mathbf{Y}}^{iT} = \tilde{\mathbf{N}}^i \quad (36)$$

A Equação (36) é solucionada aplicando o método de fatoração QR no termo $\tilde{\mathbf{U}}^i$, resultado em [22]:

$$\tilde{\mathbf{Q}}^i \tilde{\mathbf{R}}^i \tilde{\mathbf{Y}}^{iT} = \tilde{\mathbf{N}}^i \quad (37)$$

onde $\tilde{\mathbf{Q}}^i$ possui colunas ortonormais, isto é $(\tilde{\mathbf{Q}}^i)^{-1} = (\tilde{\mathbf{Q}}^i)^T$, e $\tilde{\mathbf{R}}^i$ é triangular superior cujos elementos da diagonal principal são diferentes de zero. Os parâmetros de Markov do observador $\tilde{\mathbf{Y}}^i$ são obtidos por substituição retroativa a partir da Equação (37), uma vez que a matriz $\tilde{\mathbf{R}}^i$ é triangular superior. Assim, os parâmetros de Markov do ganho do observador e os parâmetros de Markov do sistema são extraídos de $\tilde{\mathbf{Y}}^i$, como segue:

$$\tilde{\mathbf{Y}}_0^i = \tilde{\mathbf{D}}_k^i \quad (38)$$

$$\tilde{\mathbf{Y}}_j^i = \tilde{\mathbf{C}}_k^i \tilde{\mathbf{A}}^{i(j-1)} \tilde{\mathbf{B}}_k^i \quad (39)$$

$$= \left[\tilde{\mathbf{C}}_k^i \left(\tilde{\mathbf{A}}_k^i + \tilde{\mathbf{K}}_k^i \tilde{\mathbf{C}}_k^i \right)^{(j-1)} \left(\tilde{\mathbf{B}}_k^i + \tilde{\mathbf{K}}_k^i \tilde{\mathbf{D}}_k^i \right), \right. \\ \left. - \tilde{\mathbf{C}}_k^i \left(\tilde{\mathbf{A}}_k^i + \tilde{\mathbf{K}}_k^i \tilde{\mathbf{C}}_k^i \right)^{(j-1)} \tilde{\mathbf{K}}_k^i \right] \quad (40)$$

$$= \left[\tilde{\mathbf{Y}}_j^{i(1)}, -\tilde{\mathbf{Y}}_j^{i(2)} \right], \quad j = 1, 2, 3, \dots \quad (41)$$

Os parâmetros de Markov do sistema $\tilde{\mathbf{Y}}_j^i$ são usados para construir a matriz de Hankel $\tilde{\mathbf{H}}^i(j-1) \in \mathbb{R}^{\gamma p \times \beta m}$, como segue:

$$\tilde{\mathbf{H}}^i(j-1) = \begin{bmatrix} \tilde{\mathbf{Y}}_j^i & \tilde{\mathbf{Y}}_{j+1}^i & \dots & \tilde{\mathbf{Y}}_{j+\beta-1}^i \\ \tilde{\mathbf{Y}}_{j+1}^i & \tilde{\mathbf{Y}}_{j+2}^i & \dots & \tilde{\mathbf{Y}}_{j+\beta}^i \\ \vdots & \vdots & \ddots & \vdots \\ \tilde{\mathbf{Y}}_{j+\gamma-1}^i & \tilde{\mathbf{Y}}_{j+\gamma}^i & \dots & \tilde{\mathbf{Y}}_{j+\gamma+\beta-2}^i \end{bmatrix} \quad (42)$$

onde γ e β são inteiros definidos pelo usuário. Considerando $j = 1$ e aplicando o procedimento de Decomposição em Valores Singulares em $\tilde{\mathbf{H}}^i(0)$, tem-se:

$$\tilde{\mathbf{H}}^i(0) = \tilde{\mathbf{\Xi}}^i \tilde{\mathbf{\Sigma}}^i \tilde{\mathbf{\Psi}}^{iT} \quad (43)$$

onde $\tilde{\mathbf{\Xi}}^i \in \mathbb{R}^{\gamma p \times \gamma p}$ e $\tilde{\mathbf{\Psi}}^i \in \mathbb{R}^{\beta m \times \beta m}$ são matrizes ortogonais e $\tilde{\mathbf{\Sigma}}^i \in \mathbb{R}^{\gamma p \times \beta m}$ é composta por n valores singulares significativos, o que corresponde a ordem mínima do filtro de Kalman fuzzy tipo-2 evolutivo.

A matriz de observabilidade $\tilde{\mathbf{P}}_\gamma^i$ e a matriz de controlabilidade $\tilde{\mathbf{Q}}_\beta^i$ são calculadas, como segue:

$$\tilde{\mathbf{P}}_\gamma^i = \tilde{\mathbf{\Xi}}_n^i \left(\tilde{\mathbf{\Sigma}}_n^i \right)^{1/2} \quad (44)$$

$$\tilde{\mathbf{Q}}_\beta^i = \left(\tilde{\mathbf{\Sigma}}_n^i \right)^{1/2} \tilde{\mathbf{\Psi}}_n^{iT} \quad (45)$$

onde

$$\tilde{\mathbf{P}}_\gamma^i = \left[\tilde{\mathbf{C}}_k^i \ \tilde{\mathbf{C}}_k^i \tilde{\mathbf{A}}_k^i \ \tilde{\mathbf{C}}_k^i \tilde{\mathbf{A}}_k^{i2} \ \dots \ \tilde{\mathbf{C}}_k^i \tilde{\mathbf{A}}_k^{i\gamma-1} \right]^T \quad (46)$$

$$\tilde{\mathbf{Q}}_\beta^i = \left[\tilde{\mathbf{B}}_k^i \ \tilde{\mathbf{A}}_k^i \tilde{\mathbf{B}}_k^i \ \tilde{\mathbf{A}}_k^{i2} \tilde{\mathbf{B}}_k^i \ \dots \ \tilde{\mathbf{A}}_k^{i\beta-1} \tilde{\mathbf{B}}_k^i \right] \quad (47)$$

Por fim, as matrizes definidas na proposição do consequente do filtro de Kalman fuzzy tipo-2 evolutivo são dadas por:

$$\tilde{\mathbf{A}}_k^i = \left(\tilde{\mathbf{\Sigma}}_n^i \right)^{-1/2} \tilde{\mathbf{\Xi}}_n^{iT} \tilde{\mathbf{H}}_n^i(1) \tilde{\mathbf{\Psi}}_n^{iT} \left(\tilde{\mathbf{\Sigma}}_n^i \right)^{-1/2} \quad (48)$$

$$\tilde{\mathbf{B}}_k^i = \text{primeiras } m \text{ colunas de } \tilde{\mathbf{Q}}_\beta^i \quad (49)$$

$$\tilde{\mathbf{C}}_k^i = \text{primeiras } p \text{ linhas de } \tilde{\mathbf{P}}_\gamma^i \quad (50)$$

$$\tilde{\mathbf{D}}_k^i = \tilde{\mathbf{Y}}_0^i \quad (51)$$

A matriz de ganho de Kalman intervalar $\tilde{\mathbf{K}}_k^i$, na i -ésima regra, é dada por:

$$\tilde{\mathbf{Y}}_j^{i\circ} = -\tilde{\mathbf{P}}_\gamma^i \tilde{\mathbf{K}}_k^i \quad (52)$$

onde $\tilde{\mathbf{K}}_k^i$ é a matriz de ganho de Kalman intervalar. Usando a abordagem local na Equação (52), tem-se:

$$\tilde{\mathbf{P}}_\gamma^{iT} \tilde{\mathbf{\Gamma}}^i \tilde{\mathbf{Y}}_j^{i\circ} = -\tilde{\mathbf{P}}_\gamma^{iT} \tilde{\mathbf{\Gamma}}^i \tilde{\mathbf{P}}_\gamma^i \tilde{\mathbf{K}}_k^i \quad (53)$$

A matriz de ganho de Kalman intervalar $\tilde{\mathbf{K}}_k^i$ é obtida usando fatoração QR no lado direito de Equação (53).

4) *Atualização Recursiva da Proposição do Consequente do Filtro de Kalman Fuzzy Tipo-2 Evolutivo:* Após a estimação inicial do filtro de Kalman fuzzy tipo-2 evolutivo, os filtros de Kalman, definidos na proposição do consequente do sistema de inferência, são atualizados recursivamente nos instantes de tempo $k = N + 1, k = N + 2, \dots$, a cada nova amostra do conjunto de dados experimentais. Considerando o vetor de regressores, no instante k , dado por:

$$\boldsymbol{\lambda}_k = [\mathbf{u}_{k+1} \ \mathbf{Z}_k \ \mathbf{Z}_{k-1} \ \dots \ \mathbf{Z}_{k-q}]^T \quad (54)$$

os parâmetros de Markov do observador intervalares $\tilde{\mathbf{Y}}_k^i$ são obtidos pela atualização recursiva de (36), como segue:

$$\tilde{\mathbf{U}}_k^i = \tilde{\mathbf{U}}_{k-1}^i + \tilde{\mu}_{\tilde{W}^i}^i(\mathbf{Z}_k) \boldsymbol{\lambda}_k \boldsymbol{\lambda}_k^T \quad (55)$$

$$\tilde{\mathbf{N}}_k^i = \tilde{\mathbf{N}}_{k-1}^i + \tilde{\mu}_{\tilde{W}^i}^i(\mathbf{Z}_k) \boldsymbol{\lambda}_k \mathbf{y}_k^T \quad (56)$$

Uma vez que $\tilde{\mathbf{U}}_k^i$ e $\tilde{\mathbf{N}}_k^i$ foram atualizados e aplicando-se fatoração QR em $\tilde{\mathbf{U}}_k^i$, os parâmetros de Markov do observador

$\tilde{\mathbf{Y}}_k^i$ são atualizados e a proposição do conseqüente é atualizada executando-se as Equações (37)-(51). De forma similar, a matriz de ganho de Kalman intervalar $\tilde{\mathbf{K}}_k^i$ é obtida pela atualização recursiva da Equação (52), como segue:

$$\tilde{\mathbf{A}}_k^i = \tilde{\mathbf{A}}_{k-1}^i + \tilde{\mu}_{\tilde{W}^i}(\mathbf{Z}_k) \lambda_k \lambda_k^T \quad (57)$$

$$\tilde{\mathbf{N}}_k^i = \tilde{\mathbf{N}}_{k-1}^i + \tilde{\mu}_{\tilde{W}^i}(\mathbf{Z}_k) \lambda_k \lambda_k^T \quad (58)$$

Uma vez que $\tilde{\mathbf{A}}_k^i$ e $\tilde{\mathbf{N}}_k^i$ foram atualizados e aplicando-se o método de fatoração QR em $\tilde{\mathbf{A}}_k^i$, a matriz de ganho de Kalman *fuzzy* intervalar é atualizada a cada instante de tempo k . No sentido de ilustrar as etapas sequenciais dos aspectos computacionais para o projeto do filtro de Kalman *fuzzy* tipo-2 evolutivo, para melhor compreensão dos leitores, um fluxograma da metodologia proposta é mostrado na Figura 1.

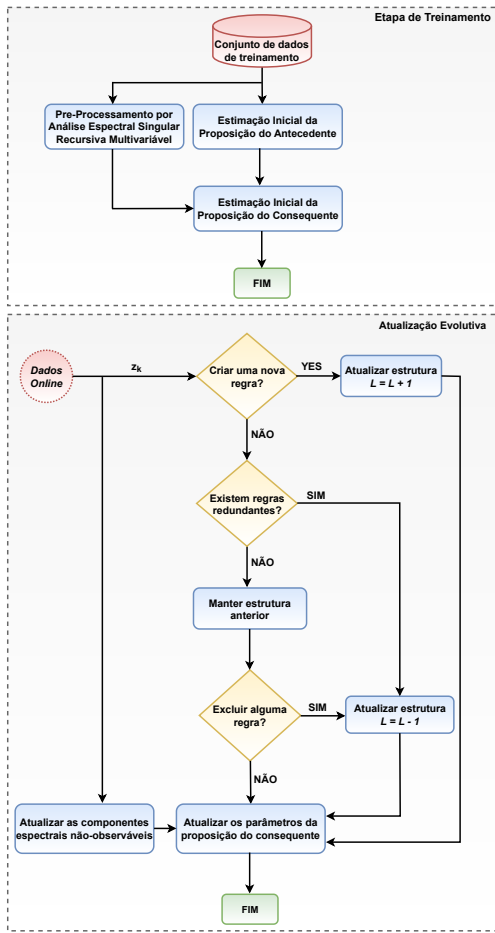


Fig. 1. Fluxograma da metodologia proposta correspondente aos aspectos computacionais para projeto do filtro de Kalman *fuzzy* tipo-2 evolutivo.

III. RESULTADOS EXPERIMENTAIS

O filtro de Kalman *fuzzy* tipo-2 evolutivo proposto neste artigo foi aplicado ao problema de rastreamento de um helicóptero 2DoF, o qual é mostrado na Figura 2. O helicóptero 2DoF é um sistema dinâmico MIMO (*Multiple Input and*

Multiple Output) com duas variáveis de entrada (tensão de controle do ângulo de elevação $u_\theta \in [-15V, +15V]$ e tensão de controle do ângulo de azimute $u_\vartheta \in [-24V, +24V]$) e duas variáveis de saída (ângulo de elevação $y_\theta \in [-360^\circ, +360^\circ]$ e ângulo de azimute $y_\vartheta \in [-40^\circ, +40^\circ]$). Os dados experimentais, com comprimento total de 751 amostras, relacionados às variáveis de entrada u_θ e u_ϑ e às variáveis de saída y_θ e y_ϑ do helicóptero 2DoF, são mostradas nas Figuras 3-4, respectivamente. Considerando as primeiras 300 amostras




Fig. 2. Helicóptero 2DoF.




Fig. 3. Variáveis de entrada ao helicóptero 2DoF: (a) Tensão de controle do ângulo de elevação u_θ , (b) Tensão de controle do ângulo de azimute u_ϑ .

dos dados experimentais de entrada e saída do helicóptero 2DoF, o filtro de Kalman *fuzzy* tipo-2 evolutivo foi inicialmente estimado, considerando $\mathbf{Z} = [y_\theta \ y_\vartheta]^T$ na Equação (13). A análise espectral singular recursiva multivariável foi capaz de obter as componentes espectrais relacionados aos




Fig. 4. Variáveis de saída do helicóptero 2DoF: (a) Ângulo de elevação y_θ , (b) Ângulo de azimute y_ϕ .

dados experimentais de entrada e saída do helicóptero 2DoF. O número de componentes espectrais não-observáveis foi definido de acordo com a métrica VAF (*Variance Accounted For*), dentro de um intervalo de 2 a 10 componentes. O número adequado de componentes espectrais não-observáveis foi de $\xi = 2$ para implementação da metodologia proposta, com valor de VAF de 99,99% de eficiência para representação dos dados experimentais.

A partição inicial do universo de discurso de \mathcal{Z} foi realizada pela formulação *fuzzy* tipo-2 do algoritmo de agrupamento Gustafson-Kessel, conforme descrito na Seção II-B1, durante a etapa de treinamento, considerando os seguintes parâmetros: $L = 3$, expoente de ponderação $\tilde{m} = [1.7 \ 2.2]$ e $\mathcal{E} = 10^{-4}$. O algoritmo OKID *fuzzy* tipo-2 intervalar foi utilizado para obter a estimação inicial da proposição do consequente do filtro de Kalman *fuzzy* tipo-2 evolutivo, conforme descrito na Seção II-B3, considerando os seguintes parâmetros: número de parâmetros de Markov $q = 1$ e dimensões da matriz de Hankel $\gamma = 30$ e $\beta = 30$.

A partir da amostra 301, as partições de \mathcal{Z} relacionadas às variáveis de saída do helicóptero 2DoF foram atualizadas pela formulação *fuzzy* tipo-2 intervalar do algoritmo de agrupamento *evolving* Takagi-Sugeno, conforme descrito na Seção II-B2, de modo que a proposição do antecedente e o número de regras *fuzzy* puderam ser estimadas a cada instante de tempo k durante a etapa de atualização recursiva do filtro de Kalman *fuzzy* tipo-2 evolutivo. Para a implementação do algoritmo de agrupamento *evolving* Takagi-Sugeno tipo-2, o valor de $\eta = 0,01$ (Condição C) foi adotado. O algoritmo OKID *fuzzy* tipo-2 intervalar foi implementado para atualização recursiva da proposição do consequente do filtro de Kalman *fuzzy* tipo-2 evolutivo, conforme a Equação (13), considerando como critério de ponderação as partições atualizadas dos dados experimentais, bem como as componentes espectrais não-observáveis. A região de confiança, conforme mostrado nas Figuras 5-6, durante a etapa recursiva do filtro de Kalman *fuzzy*

tipo-2 evolutivo, ilustra a eficiência da metodologia proposta para o rastreamento dos dados experimentais do ângulo de elevação y_θ e do ângulo de azimute y_ϕ do helicóptero 2DoF. O




Fig. 5. Região de confiança para o rastreamento dos dados experimentais do ângulo de elevação y_θ do helicóptero 2DoF, obtida durante a etapa recursiva do filtro de Kalman *fuzzy* tipo-2 evolutivo.

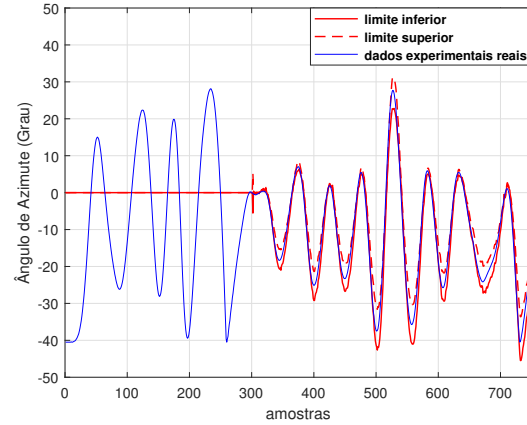


Fig. 6. Região de confiança para o rastreamento dos dados experimentais do ângulo de azimute y_ϕ do helicóptero 2DoF, obtida durante a etapa recursiva do filtro de Kalman *fuzzy* tipo-2 evolutivo.

número regras *fuzzy* variante no tempo do sistema de inferência do filtro de Kalman *fuzzy* tipo-2 evolutivo, de acordo com as flutuações dinâmicas dos dados experimentais do helicóptero 2DoF, é ilustrado na Fig. 7.

A fim de avaliar a eficiência da metodologia proposta neste artigo, foi realizada uma análise comparativa com a abordagem em [23], considerando a métrica *Variance Accounted For* (VAF %), a qual é dada por:

$$VAF (\%) = \left[1 - \frac{\text{var}(\mathbf{y} - \hat{\mathbf{y}})}{\text{var}(\mathbf{y})} \right] \times 100 \quad (59)$$

onde $\hat{\mathbf{y}}$ corresponde ao valor estimado do valor real \mathbf{y} e $\text{var}(\cdot)$ é a variância do sinal. A eficiência do filtro de Kalman *fuzzy* tipo-2 evolutivo, comparada com a abordagem em [23],




Fig. 7. Variação do número de regras *fuzzy* do filtro de Kalman *fuzzy* tipo-2 evolutivo para o rastreamento dinâmico do helicóptero 2DoF.

TABLE I
ANÁLISE COMPARATIVA ENTRE A METODOLOGIA PROPOSTA E A
ABORDAGEM EM [23] PARA RASTREAMENTO DO HELICÓPTERO 2DOF.

	Saída	Metodologia		
		Proposta	[23]	[24]
VAF (%)	Elevação θ	99.9874	97.17	-
	Azimute ϑ	99.5963	98.06	-
RMSE (%)	Elevação θ	0.00156	-	0.0067
	Azimute ϑ	0.00762	-	0.0136

é apresentada na Tabela I. A partir da análise comparativa percebe-se o melhor desempenho da metodologia proposta, uma vez que esta possibilita a adaptação da estrutura do modelo do filtro de Kalman conforme a dinâmica descrita pelos dados experimentais.

IV. CONCLUSÕES

Neste artigo, uma abordagem para o projeto de filtros de Kalman *fuzzy* tipo-2 evolutivos, baseada na decomposição espectral de dados experimentais, foi apresentada. A metodologia adotada permite atualizar de forma evolutiva os parâmetros do modelo do filtro em tempo real de modo a adaptá-lo às alterações dinâmicas apresentadas pelo conjunto de dados, bem como permite o processamento das incertezas inerentes às regiões de operação intervalares, estabelecendo uma região de confiança de possíveis soluções como saída do sistema de inferência do filtro de Kalman *fuzzy* tipo-2 evolutivo. A eficiência da metodologia proposta foi ilustrada a partir do rastreamento intervalar de um helicóptero 2DoF. O escopo futuro deste trabalho está relacionado à implementação da metodologia proposta com a ordem do modelo no espaço de estados variante no tempo usando estratégias de processamento paralelo, a fim de minimizar o custo computacional do algoritmo e, assim, garantir alta velocidade de processamento.

AGRADECIMENTOS

Os autores agradecem à CAPES pelo apoio financeiro e ao Programa de Pós-Graduação em Engenharia de Eletricidade

da Universidade Federal do Maranhão (PPGEE/UFMA) pelo suporte ao desenvolvimento desta pesquisa.

REFERENCES

- [1] J. Rabcan, V. Levashenko, E. Zaitseva, and M. Kvassay, "EEG signal classification based on fuzzy classifiers," *IEEE Transactions on Industrial Informatics*, vol. 18, no. 2, pp. 757–766, feb 2022.
- [2] D. C. dos Santos Gomes and G. L. de Oliveira Serra, "Machine learning model for computational tracking and forecasting the COVID-19 dynamic propagation," *IEEE Journal of Biomedical and Health Informatics*, vol. 25, no. 3, pp. 615–622, mar 2021.
- [3] Y. Guo, L. Jiao, R. Qu, Z. Sun, S. Wang, S. Wang, and F. Liu, "Adaptive fuzzy learning superpixel representation for PolSAR image classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1–18, 2022.
- [4] L. Song, X. Liu, S. Chen, S. Liu, X. Liu, K. Muhammad, and S. Bhattacharyya, "A deep fuzzy model for diagnosis of COVID-19 from CT images," *Applied Soft Computing*, vol. 122, p. 108883, jun 2022.
- [5] Z. You, H. Yan, H. Zhang, S. Chen, and M. Wang, "Fuzzy-dependent-switching control of nonlinear systems with aperiodic sampling," *IEEE Transactions on Fuzzy Systems*, vol. 29, no. 11, pp. 3349–3359, nov 2021.
- [6] H. Zarei, A. Khastan, and R. Rodríguez-López, "Suboptimal control of linear fuzzy systems," *Fuzzy Sets and Systems*, may 2022.
- [7] H. H. Y. Saad, N. A. M. Isa, and M. M. Ahmed, "A structural evolving approach for fuzzy systems," *IEEE Transactions on Fuzzy Systems*, vol. 28, no. 2, pp. 273–287, feb 2020.
- [8] G. L. O. Serra, Ed., *Frontiers in Advanced Control Systems*. InTech, jul 2012.
- [9] C. Y. Teh, Y. W. Kerk, K. M. Tay, and C. P. Lim, "On modelling of data-driven monotone zero-order TSK fuzzy inference systems using a system identification framework," *IEEE Transactions on Fuzzy Systems*, pp. 1–1, 2018.
- [10] W.-C. Su, C.-F. Juang, and C.-M. Hsu, "Multiobjective evolutionary interpretable type-2 fuzzy systems with structure and parameter learning for hexapod robot control," *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 52, no. 5, pp. 3066–3078, may 2022.
- [11] C. Chen, J. Huang, D. Wu, and X. Tu, "Interval type-2 fuzzy disturbance observer-based t-s fuzzy control for a pneumatic flexible joint," *IEEE Transactions on Industrial Electronics*, vol. 69, no. 6, pp. 5962–5972, jun 2022.
- [12] O. Baskov, "Dual type-2 fuzzy cones and their application in multicriteria choice," *Fuzzy Sets and Systems*, feb 2022.
- [13] F. Cady, *The Data Science Handbook*. Wiley, Feb. 2017.
- [14] R. E. Kalman, "A new approach to linear filtering and prediction problems," *Journal of Basic Engineering*, vol. 82, no. 1, pp. 35–45, mar 1960.
- [15] G. L. O. Serra, Ed., *Kalman Filters - Theory for Advanced Applications*. InTech, feb 2018.
- [16] D. C. dos Santos Gomes, "Metodologia para filtragem de kalman fuzzy tipo-2 intervalar baseada em modelagem computacional das componentes espectrais não-observáveis de dados experimentais." Universidade Federal do Maranhão, Tech. Rep., 2021.
- [17] N. Golyandina and A. Zhigljavsky, *Singular Spectrum Analysis for Time Series*. Springer Berlin Heidelberg, 2013.
- [18] R. Babuska, *Fuzzy Modeling for Control*. Springer, 1998.
- [19] P. Agelov, D. P. Filev, and N. Kasabov, *Evolving Intelligent Systems: Methodology and Applications*. IEEE COMPUTER SOC PR, 2010.
- [20] P. Angelov, *Autonomous Learning Systems: From Data Streams to Knowledge in Real-Time*. Wiley, 2013.
- [21] J. N. Juang, *Applied System Identification*. Prentice Hall, 1994.
- [22] C. T. Chen, *Linear System Theory and Design*. Oxford University Press, 1999.
- [23] L. M. M. Torres and G. Serra, "State-space recursive fuzzy modeling approach based on evolving data clustering," *Journal of Control, Automation and Electrical Systems*, vol. 29, no. 4, pp. 426–440, jun 2018.
- [24] M. C. Maya-Rodríguez, M. A. Lopez-Pacheco, Y. Lozano-Hernandez, V. G. Sanchez-Meza, L. A. Cantera-Cantera, and R. Tolentino-Eslava, "Integration of CNN in a dynamic model-based controller for control of a 2dof helicopter with tail rotor perturbations," *IEEE Access*, vol. 10, pp. 73 474–73 483, 2022.