



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA

Caroline Mateus de Oliveira

**Utilização de técnicas de inferência Neuro-Fuzzy para
modelagem de um multicóptero**

Uberlândia-MG

2019

Caroline Mateus de Oliveira

**Utilização de técnicas de inferência Neuro-Fuzzy para
modelagem de um multicóptero**

Monografia apresentada ao Curso de
Graduação em Engenharia Aeronáutica da
Universidade Federal de Uberlândia, como
parte dos requisitos para a obtenção do título
de **BACHAREL EM ENGENHARIA
AERONÁUTICA.**

Orientador: Prof. Msc. Felipe Machini
Malachias Marques

Uberlândia-MG

2019

TERMO DE APROVAÇÃO

Caroline Mateus de Oliveira

Utilização de técnicas de inferência Neuro-Fuzzy para modelagem de um multicóptero

Projeto de Conclusão de Curso apresentado ao Curso de Engenharia Aeronáutica da Universidade Federal de Uberlândia como requisito à obtenção do título de Bacharel em Engenharia Aeronáutica, pela seguinte banca examinadora:

Aprovado em: ____ de _____ de _____.

Msc. Felipe Machini Malachias Marques

Orientador

Universidade Federal de Uberlândia, UFU.

Prof. Dr. Tobias de Souza Moraes

Universidade Federal de Uberlândia, UFU.

Msc. Vitor Taha Sant'Ana

Universidade Federal de Uberlândia, UFU.

“Não importa o quanto a vida possa ser ruim, sempre existe algo que você pode fazer, e triunfar. Enquanto há vida, há esperança.” – Stephen Hawking

AGRADECIMENTOS

Agradeço a minha mãe Joana Darc Mateus, ao meu pai Mauro Sérgio de Oliveira e ao meu irmão Luís Felipe Mateus de Oliveira por todo apoio, paciência, compreensão, apoio financeiro e por sempre acreditarem em mim e no meu potencial me dando todo incentivo e oportunidades de amadurecimento. Agradeço pelos valores ensinados, por todo carinho e amor que recebi e por estarem ao meu lado em todos os momentos de minha vida.

A todos os meus amigos e familiares que direta ou indiretamente contribuíram para minha formação, com conselhos, palavras de conforto e ajudas quando precisei.

Ao Prof Msc. Felipe Machini Malachias Marques e ao Msc. Vitor Taha Sant’Ana pela oportunidade de realizar um trabalho de tamanha importância para o desenvolvimento da pesquisa e pela paciência e disponibilidade de desenvolvermos juntos esse projeto.

Agradeço a banca examinadora pela disponibilidade e paciência, e aos quais admiro pelo trabalho que exercem com dedicação e amor.

Por fim, agradeço a Universidade Federal de Uberlândia e a Faculdade de Engenharia Mecânica por toda infraestrutura e oportunidade de aprendizado fornecida.

OLIVIERA, M. C. **Utilização de técnicas de inferência Neuro-Fuzzy para modelagem de um multicóptero.** 2019. Pág 46. Projeto de conclusão de Curso. Universidade Federal de Uberlândia. Uberlândia, Brasil.

RESUMO

A crescente frota de VANTs em todo o mundo tem aumentado a necessidade de se melhorar a tecnologia e as técnicas de controle dessas aeronaves. Sendo assim, a utilização de métodos para estimar as características de voo das aeronaves torna-se uma ferramenta útil para obter um modelo mais realista e auxiliar no projeto de controladores. Este trabalho apresenta a modelagem da força vertical de um multicóptero pelo método neuro-fuzzy baseado em dados coletados em voo. O método utiliza uma base de regras para estimar as forças verticais através do parâmetro de comando PWM dos motores. Com esses parâmetros definidos, foi possível obter um modelo representativo do sistema e testar um controlador baseado na técnica PID para controle de altitude.

Palavras-chave: Neuro-fuzzy, multicóptero, VANTs, PID.

OLIVIERA, M. C. **Use of Neuro-Fuzzy inference techniques for modeling a multicopter.** 2019. Pag 46. Graduation Project. Federal University of Uberlândia. Uberlândia, Brazil.

ABSTRACT

A growing rate of UAVs around the world has increased the need to improve technology and control techniques of these aircraft. Thus, the use of methods to estimate aircraft flight characteristics becomes a useful tool to obtain a more realistic model and assist in the design of controllers. This paper presents a modeling of the vertical force of a multicopter by the neuro-fuzzy method based on the data collected in flight. The method uses a rule base for estimation as vertical forces through the motor PWM command parameter. With these parameters set, it was possible to obtain a representative system model and test a driver based on the PID technique for altitude control.

Key-Words: Neuro-fuzzy, multicopter, UAVs, PID.

LISTA DE FIGURAS

Figura 1 - Representação dos eixos de referência e dos ângulos de Euler do multicóptero (Machini, 2018).....	6
Figura 2 - Exemplificação do funcionamento do sistema motopropulsivo. (Conroy, 2014).	7
Figura 3 - Representação da arquitetura de uma rede neural artificial multicamadas (Silva, 2006)	9
Figura 4 - Esquema de um neurônio i da camada I (Silva, 2006)	9
Figura 5 - Princípio do controle indireto adaptativo (Landau et al., 2011).....	11
Figura 6 - Representação da arquitetura de um sistema com base de Regras Fuzzy (Jafelice, 2003).	13
Figura 7 - Formas usais para a função de pertinência (Pacheco, 2015).....	14
Figura 8 - Ilustração do método de Mamdani (Jafelice, 2003).....	15
Figura 9 - Ilustração do método de Takagi-Sugeno (Jafelice, 2003).....	16
Figura 10 - Representação de um sistema neuro-fuzzy (Pereira B. L., 2017)	18
Figura 11 - Sinal PWM e força em z em função do tempo. (Taha, Machini, Pereira, & Finzi, 2019).....	21
Figura 12a - Sinal de resposta em frequência da entrada com filtro e sem filtro. .	21
Figura 12b - Sinal de resposta em frequência da saída com filtro e sem filtro.	22
Figura 13 - Coerência do sinal de entrada com relação ao sinal de saída em função da frequência.....	23
Figura 14 - Sistema Neuro-Fuzzy do modelo.	23
Figura 15 - Função de pertinência.	24
Figura 16 - Evolução de C_f no processo de otimização em função das iterações.	25
Figura 17 - Representação do modelo físico do multicóptero. Fonte: autora.	26
Figura 18 - Diagrama de blocos do controlador PID e da planta do sistema.....	28

Figura 19 - Sinal real e sinal estimado pelo neuro-fuzzy em função do tempo. (Taha, Machini, Pereira, & Finzi, 2019).....	29
Figura 20 - Root Locus do sistema.	30
Figura 21 - Resposta do sistema ao comando PID com um degrau de entrada. ...	31
Figura 22 - Resposta do sistema Neuro-Fuzzy ao comando PID com um degrau de entrada.	32

SUMÁRIO

1 INTRODUÇÃO	1
2 OBJETIVOS	3
3 JUSTIFICATIVA	4
4 FUNDAMENTAÇÃO TEÓRICA.....	5
4.1 MECÂNICA DO VOO	5
4.2 REDES NEURAIS.....	8
4.2.1 CONCEITOS GERAIS	8
4.2.2 TREINAMENTO DA REDE NEURAL	10
4.2.3 APLICAÇÃO DE REDES NEURAIS EM SISTEMAS DE CONTROLE ADAPTATIVOS.....	11
4.3 TEORIA DOS CONJUNTOS FUZZY	12
4.4 SISTEMA NEURO-FUZZY	16
4.5 CONTROLADOR PROPORCIONAL INTEGRAL DERIVATIVO (PID)	18
5 METODOLOGIA E DESENVOLVIMENTO.....	20
5.1 COLETA E ANÁLISE DOS DADOS	20
5.2 OBTENÇÃO DO MODELO NEURO-FUZZY	23
5.3 MODELO E CONTROLE DINÂMICO DO SISTEMA.....	26
6 RESULTADOS E DISCUSSÕES	29
6.1 ESTIMATIVA DOS PARÂMETROS UTILIZANDO O MÉTODO NEURO-FUZZY.....	29
6.2 CONTROLE DO SISTEMA DINÂMICO.....	30
7 CONCLUSÕES E TRABALHOS FUTUROS	33
REFERÊNCIAS BIBLIOGRÁFICAS.....	35

1 INTRODUÇÃO

Os veículos aéreos não tripulados (VANT) vêm se tornando, ao longo dos anos, cada vez mais populares pela sua versatilidade em diferentes áreas de atuação e missões, causando um grande impacto na indústria da aviação. De acordo com a Circular de Informações Aeronáuticas AIC N2/10, do Departamento de Controle do Espaço Aéreo (DECEA), “os VANTs são veículos aéreos projetados para operar sem piloto a bordo, que possua uma carga útil embarcada e que não seja utilizado para fins meramente recreativas. Nesta definição incluem-se todos os aviões, helicópteros e dirigíveis controláveis nos três eixos, excluindo-se, portanto, os balões tradicionais e aeromodelos.” (DECEA). São utilizados em todo o mundo em missões militares e civis, como, busca e salvamento, operações militares, combate a incêndios, atividades de lazer como fotografias, entre outra vasta gama de aplicações (Valavanis, 2007).

Os VANTs foram introduzidos pela primeira vez durante a Primeira Guerra Mundial (1917) pelo exército americano que criaram um torpedo que se guiava autonomamente a um alvo definido. Porém foi considerado um sistema sem confiabilidade e impreciso. Mas foi durante a Segunda Guerra Mundial (1940) que o governo americano voltou a investir no projeto se inspirando em uma bomba criada pela Alemanha chamada *buzz bomb*. Este novo projeto de VANT obteve um resultado considerável, apesar de voar apenas em linha reta e com velocidade constante. Então, foi usado para reconhecimento de terrenos, ataque, espionagem e para enviar mensagens. (Torres & Tommaselli, 2017)

No Brasil, os VANTs são utilizados em grande parte (40%) na indústria agropecuária, sendo utilizado em funções de reconhecimento de todos os tipos de plantações, fotogrametria, entre outros métodos. Hoje mais de 40 países vem trabalhando no desenvolvimento desses veículos para diferentes mercados e missões. (Jorge & Inamasu, 2014).

Devido ao crescimento da demanda de VANTs no mundo todo, a tecnologia para o desenvolvimento de novas técnicas de controle e modelagem vem se tornando cada vez mais estudadas. Uma modelagem mais precisa, pode aumentar a aplicabilidade e

segurança desses veículos, além de melhorar sua performance. Sendo assim, é esperado que dentro de alguns anos a tecnologia de tais veículos e sua utilidade se modernize cada vez mais.

2 OBJETIVOS

O principal objetivo desse projeto é estimar os parâmetros de coeficientes de forças e momentos através da técnica neuro-fuzzy fazendo o uso do multicóptero e utilizando dados experimentais e numéricos e a modelagem do sistema dinâmico do mesmo.

Os objetivos específicos do projeto são:

- Coleta de dados;
- Analisar e tratar os sinais e entrada;
- Determinar incertezas relacionadas aos parâmetros;
- Estabelecer a confiabilidade do modelo;
- Propor um modelo dinâmico representativo;
- Validar o modelo com a comparação de modelos já conhecidos.

3 JUSTIFICATIVA

Ao longo dos anos, vêm se tornando popular o uso de veículos não tripulados para diferentes missões militares e civis. Sendo assim, veículos não tripulados autônomos também se tornam cada vez mais comum e necessário. Porém há a pouco estudo de metodologia para a modelagem dinâmica de tais veículos, como o multicóptero. Trata-se da inexistência de soluções analíticas ótimas considerando as características de não linearidade da planta.

As técnicas de inteligência artificial vêm se destacando devido a sua versatilidade e sua ótima adaptação a sistemas dinâmicos que contém uma grande quantidade de variáveis e parâmetros que são difíceis de serem estimados. Na literatura há pouca referência sobre como esses parâmetros podem ser estimados com um determinado nível de confiabilidade. Há estudos, como feito por (Conroy, 2014), que estima através de um teste estático os coeficientes desejados.

Neste contexto, o trabalho se justifica no desenvolvimento de novas estratégias para estimar parâmetros de voo a partir de um sinal de entrada utilizando uma técnica de estimativa a partir de uma função de pertinência e uma base de regras, a qual forma a técnica Neuro-Fuzzy. Tal técnica também será utilizada para se obter o sistema dinâmico do multicóptero. A partir disso, será possível fazer uma comparação entre o controlador PID esperado para um sistema linear simplificado e o controlador obtido pela modelagem do sistema dinâmico. A modelagem do sistema foi realizada de forma experimentalmente e a comparação entre os controladores PID de forma simulada, tendo então dados reais conclusivos.

Assim, será possível obter uma nova fonte de referência sobre o assunto tendo em vista o crescimento no setor tecnológico de aeronaves não tripuladas e sua versatilidade em diferentes missões.

4 FUNDAMENTAÇÃO TEÓRICA

Para que o leitor obtenha um aproveitamento sobre o desenvolvimento e resultados desse trabalho, é necessário o entendimento de alguns conceitos e aplicações desenvolvidas sobre o assunto. Os temas que serão abordados no trabalho terão ênfase em mecânica do voo do multicóptero, redes neurais, teoria dos conjuntos fuzzy e sistema neuro-fuzzy.

4.1 MECÂNICA DO VOO

Antes de iniciar o trabalho de estimativa de parâmetros pelo método Neuro-Fuzzy e para se fazer o controlador, é necessário obter o modelo do multicóptero. Sendo assim, é necessário fazer algumas considerações sobre a estrutura. Assim como outras aeronaves convencionais, o multicóptero pode ser modelado como um corpo rígido. Seu movimento é livre em todas as dimensões, podendo transladar nos eixos x , y e z , e rotacionar ao redor dos eixos, obtendo os movimentos de roll (ϕ), pitch (θ) e yaw (ψ), respectivamente. Sendo assim, o sistema possui 6 graus de liberdade (GDL).

A figura 1 representa com clareza os eixos de movimento do multicóptero. É possível notar que há dois sistemas de referência para os eixos: (x_B, y_B, z_B) que é o sistema de referência fixo no corpo, denominado BCS, e o sistema de referência (x_E, y_E, z_E) que é o sistema de coordenadas inercial (ICS). Na figura também está representado os ângulos de Euler do movimento rotacional.




Figura 1 - Representação dos eixos de referência e dos ângulos de Euler do multicóptero
(Machini, 2018)

A partir dos graus de liberdade citados anteriormente, é possível definir as equações de velocidade, posição e forças (Machini, 2018). Para tal, utiliza-se as variáveis como mostrado nas equações (1), (2) e (3).

$$\vec{v} = \begin{pmatrix} U \\ V \\ W \\ P \\ Q \\ R \end{pmatrix} = \begin{pmatrix} \text{velocidade longitudinal} \\ \text{velocidade lateral} \\ \text{velocidade vertical} \\ \text{velocidade angular de rolagem} \\ \text{velocidade angular de arfagem} \\ \text{velocidade angular de guinada} \end{pmatrix} \quad (1)$$

$$\vec{\eta} = \begin{pmatrix} X_E \\ Y_E \\ Z_{E,h} \\ \Phi \\ \Theta \\ \Psi \end{pmatrix} = \begin{pmatrix} \text{posição x do eixo inercial da Terra} \\ \text{posição y do eixo inercial da Terra} \\ \text{posição z do eixo inercial da Terra, altitude} \\ \text{ângulo de rolagem} \\ \text{ângulo de arfagem} \\ \text{ângulo de guinada} \end{pmatrix} \quad (2)$$

$$\begin{pmatrix} X \\ Y \\ Z \\ L \\ M \\ N \end{pmatrix} = \begin{pmatrix} \text{força longitudinal} \\ \text{força lateral} \\ \text{força vertical} \\ \text{momento de rolagem} \\ \text{momento de arfagem} \\ \text{momento de guinada} \end{pmatrix} \quad (3)$$

Os multicopteros utilizam sistema motopropulsivo que produz a tração necessária para um equilíbrio das forças peso e arrasto do veículo. Considera-se então que o multicoptero possui um sistema motopropulsivo que permite uma inclinação longitudinal e lateral. Sendo assim, assume-se que cada rotor é independente. As forças externas atuantes sobre o veículo de estudo que serão consideradas são a força peso, a força de arrasto e a força de tração produzida pelos quatro rotores do multicoptero.

O multicoptero funciona através de um sistema elétrico que gera um sinal PWM de entrada, chamado na figura 2 por μ . Tal sinal aciona os rotores que produz uma rotação Ω suficiente para que suas hélices gerem a força de tração T necessária.




Figura 2 - Exemplificação do funcionamento do sistema motopropulsivo. (Conroy, 2014).

O motor produz uma potência P_W que através da hélice produz uma tração T que atua sempre na direção Z_B . Toda a manipulação matemática e formulações físicas necessárias para o desenvolvimento da equação 4 está presente em (Machini, 2018). Sendo assim, é possível definir a força de tração como

$$T = k\Omega^2 \quad (4)$$

Onde, k é uma constante que correlaciona a força de empuxo com a rotação do motor.

A força de arrasto está concentrada no CG do multicoptero e é dada da forma de uma constante k_d multiplicada pela velocidade do sistema, como demonstrado na equação 5.

$$F_D^{BCS} = -k_d \vec{v} = \begin{pmatrix} -k_{dx}u \\ -k_{dy}v \\ -k_{dz}w \end{pmatrix} \quad (5)$$

Para uma modelagem mais precisa do sistema, deve-se levar em consideração também os momentos gerados sobre a estrutura pelas forças que atuam sobre a aeronave e seu movimento. Sendo assim, a aeronave irá sofrer momento em seu CG. Tal momento é causado por um torque devido a variação de empuxo, ao efeito giroscópio e um torque devido a arrasto da hélice. Tais equações estão demonstradas em (Machini, 2018).

A modelagem do sistema em estudo será realizada considerando apenas o eixo z do referencial do corpo, e, portanto, apenas a força de tração será necessária para tal abordagem.

4.2 REDES NEURAIS

4.2.1 CONCEITOS GERAIS

Uma estrutura matemática constituída por um número finito de unidades individualizadas, designadas de neurônios, organizados em camadas é conhecida como uma rede neural artificial, RNA (Silva, 2006). Uma das aplicações da rede neural, entre outras, é para o reconhecimento de padrões e para a obtenção de modelos para sistemas estáticos e dinâmicos, como estrutura matemática de controladores. Essa estrutura de rede neural apresenta características que são adequadas a uma série de problemas pois possui capacidade de se ajustar e se adaptar ao problema em questão.

Na figura 3 pode-se observar a representação da arquitetura da estrutura da rede neural com múltiplas camadas. Na camada de entrada da estrutura tem-se m neurônios que fornecem uma variável X para todos os neurônios da camada intermediária que, por sua vez, subtrai o vetor X de um vetor armazenado. A saída dessa camada é enviada a uma camada de soma. É realizado um somatório do produto entre um vetor peso e o vetor da saída da camada anterior. Este número de observações varia de acordo com o número

de saídas desejadas. Na camada de saída, é então gerado um vetor Y que se trata da divisão de cada resultado da camada de soma pelo somatório de todas as unidades de soma (Specht, 1991).

Já a figura 4 esquematiza um neurônio i de uma camada I . A saída a_i^I de cada neurônio i da camada I , é responsável por prover à estrutura matemática a característica desejada de não linearidade.




Figura 3 - Representação da arquitetura de uma rede neural artificial multicamadas (Silva, 2006)




Figura 4 - Esquema de um neurônio i da camada I (Silva, 2006)

A equação 6 descreve tal variável, sendo que σ é a função de ativação da rede neural, e a saída é limitada no intervalo $[-1,1]$. Parâmetros como w_{ij}^l e b_i^l são, respectivamente, o peso sináptico e o valor do bias associado a neurônio i . Ambos são determinados durante o processo de treinamento da rede neural (Pereira B. , 2017). As funções de ativação de σ usualmente utilizadas são degrau, linear, sigmoide ou tangente hiperbólica.

$$i_i^l = \sum_{j=1}^{n_{l-1}} w_{ij}^l a_j^{l-1} + b_i^l$$

$$a_i^l = \sigma_i^l(i_i^l) \tag{6}$$

Após estabelecer os números de camadas e de neurônios em cada camada, é realizado o treinamento da rede neural e, portanto os valores de w_{ij}^l e b_i^l são determinados, de forma que levam a um melhor desempenho da rede.

4.2.2 TREINAMENTO DA REDE NEURAL

Tal treinamento é executado através de métodos como a evolução diferencial e os algoritmos genéticos, métodos heurísticos passam a ser utilizados para tal função, a qual baseia-se na minimização da função custo Cf , que pode ser vista pela equação 7, em que $y(k)$, $k=1,...,Nd$; sendo Nd número de elementos da sequência $y(k)$, que é o conjunto de dados utilizados para o treinamento da rede; e $\hat{y}(k)$, $k=1,...,Nd$ são os valores obtidos na saída.

$$Cf = \sum_{k=1}^{Nd} [y(k) - \hat{y}(k)]^2 \tag{7}$$

Tal treinamento pode ser realizado de forma off-line, ou chamado de treinamento em grupo, e de forma on-line, ou tempo real. O treinamento off-line é usado quando o sistema é invariante no tempo, onde pode-se extrair todos os dados e valores iniciais dos

parâmetros da rede. Assim, o valor de Nd deve permitir uma grande variedade de informação sendo na casa de centenas. Deve ser feito a otimização com um número de iterações suficientes para minimizar o valor de Cf , tendo que ser treinado para diferentes valores de entrada e saída para se certificar que o método está generalizado.

O treinamento on-line é utilizado em sistemas variantes no tempo. O número de iterações também deverá ser no mínimo na casa de centenas para garantir uma rápida adaptação da rede ao sistema. Para sistemas não-lineares, o treinamento on-line pode causar o esquecimento da rede acerca de características globais, fazendo com que esta funcione apenas para pontos com características locais.

4.2.3 APLICAÇÃO DE REDES NEURAIS EM SISTEMAS DE CONTROLE ADAPTATIVOS

Há basicamente duas formas de trabalhar aplicando redes neurais em sistemas de controle adaptativos: controle direto e indireto adaptativos (Haykin, 2008).

Em métodos de controle indireto adaptativo, a obtenção dos pesos e bias da rede neural está ligado a estimação da dinâmica da planta. É utilizado um procedimento subdividido em 2 passos.




Figura 5 - Princípio do controle indireto adaptativo (Landau et al., 2011)

Na figura 5 é apresentado um esquema de controle direto adaptativo que se baseia na observação de que a diferença entre a saída da planta e a saída do modelo de referência, chamada subsequente de erro planta-modelo é uma medida comparativa entre o desempenho real e o desejado. Sendo assim, o método de adaptação para ajustar diretamente em tempo real os parâmetros do controlador adaptativo, utiliza essa informação juntamente a outras para forçar o erro planta-modelo para zero (Landau et al, 2011).

O modelo da planta é utilizado para se obter as estimativas da saída do sistema em função da entrada imposta no mesmo. Assim, a partir dessa, é possível projetar um controlador adaptativo que obtêm o conjunto de ações de controle capaz de garantir que o sistema controlado atinja o desempenho que se espera. O equacionamento e planta para encontrar o erro e projetar o controlador adaptativo pode ser encontrado em (Landau et al, 2011).

Neste trabalho será realizado apenas um controlador PID para um sistema linear simplificado e para o modelo dinâmico obtido pela técnica Neuro-Fuzzy. Porém, é possível obter um modelo adaptativo utilizando o método descrito anteriormente.

4.3 TEORIA DOS CONJUNTOS FUZZY

A lógica fuzzy foi introduzida por (Zadeh, 1965) e estende a lógica tradicional de controle clássico (Gomide, 2015). Essa lógica introduz o conceito da verdade parcial, que permite uma pertinência simultânea e parcial em vários conjuntos a invés de uma inclusão total em um conjunto definido. Assim, a função de pertinência é a curva que define o grau, de zero a um, com que cada ponto no espaço de saída é mapeado no conjunto fuzzy.

Nos conjuntos fuzzy são usadas as operações padrões de intersecção (operador *e*, união (operador *ou*) e complementar de subconjuntos fuzzy (operador *não*). Dados dois ou mais conjuntos fuzzy, estas operações conectam esses conjuntos de modo a produzir um único subconjunto fuzzy. Zadeh (Zadeh, 1965) propôs que alguns elementos

poderiam ser mais pertinentes do que outros, assim, existe um fator de pertinência que varia de $[0,1]$.

Para definir a metodologia dos controladores fuzzy ou de sistemas baseados em regras fuzzy, é fundamental definir esses conceitos. Esses sistemas são construídos em quatro etapas, como mostrado na figura 6 e explicado a seguir.




Figura 6 - Representação da arquitetura de um sistema com base de Regras Fuzzy (Jafelice, 2003).

A primeira é a fuzzificação dos dados de entrada e suas funções de pertinência, ou seja, a tradução das entradas do sistema em conjuntos fuzzy em seus respectivos domínios. Assim, são construídas as funções de pertinências para cada entrada. A figura 7 mostra as funções de pertinência mais utilizadas, sendo que, neste trabalho, serão usadas as funções Gaussianas.




Figura 7 - Formas usais para a função de pertinência (Pacheco, 2015).

A segunda etapa é a elaboração das bases de regras, que são um conjunto de regras linguísticas do tipo Se/Então, que descreve a relação entre as variáveis de entrada e saída.

A terceira etapa é a inferência, que é o mecanismo pelo qual as informações da etapa anterior são avaliadas matematicamente. Há duas possibilidades de métodos de inferência possíveis:

- O método de Mamdani que agrega as regras da base de regras em operadores Ou/E. A figura 8 exemplifica a saída z do sistema de inferência Mamdani gerada a partir das entradas x e y e das regras de composição de max-min. Neste método é utilizado uma integração da área abaixo da curva delimitada pelo grau de pertinência (Andrade & Jacques, 2008).

$$z = \frac{\int uC(u)du}{\int C(u)du} \quad (8)$$




Figura 8 - Ilustração do método de Mamdani (Jafelice, 2003).

- O método de Takagi-Sugeno é similar ao método de Mamdani, porém apresenta uma modelagem diferenciada da função z, assim como demonstrado na figura 9, sendo que nesse método é feita uma média ponderada onde o grau de pertinência representa o peso da média (Takagi & Sugeno, 1985).

$$z = \frac{\sum_{i=1}^k c_i(u) f_i}{\sum_{i=1}^k c_i(u)} \quad (9)$$




Figura 9 - Ilustração do método de Takagi-Sugeno (Jafelice, 2003).

A última etapa é a defuzzificação, que consiste em transformar o valor fuzzy de saída em um valor numérico pertencente ao conjunto dos números reais, ou seja, num valor *crisp*, utilizando um dos métodos anteriores. O método de Mamdani é menos utilizado pois o custo computacional é mais alto devido ao somatório de todas as integrais de área. Portanto, neste trabalho, será utilizado o método de Takagi-Sugeno.

4.4 SISTEMA NEURO-FUZZY

O sistema neuro-fuzzy usa um algoritmo de estratégias de aprendizado derivado do comportamento de redes neurais para encontrar os parâmetros determinados pelos conjuntos fuzzy. As redes neurais utilizando de estruturas chamadas nó neural que são processadores simples que captam as informações exteriores ou de outros nós e tomam

decisões sobre elas e passa o resultado ao próximo nó. Quanto mais nós são implementados a estrutura, maior a capacidade de tomar decisões complexas.

A arquitetura ANFIS (Jang, 1992) possui cinco camadas de neurônios, como esquematizada na figura 10. O sistema de inferência (SI) embutido no ANFIS é do tipo Takagi-Sugeno, proposto por (Takagi & Sugeno, 1985) as funções de pertinência das variáveis consequentes são funções das variáveis de entrada.

As camadas de neurônios do ANFIS, como pode ser notado na figura 10, pode ser vista detalhada em Jang (Jang, 1992). A camada do tipo adaptativa se comporta de forma que se adapta aos novos parâmetros de entrada, não precisando de ajuste manual. Já a camada não adaptativa apenas copia os dados da camada anterior e devem ser ajustados manualmente.

Resumidamente tem-se que a **camada 1** é do tipo adaptativa, onde os parâmetros são chamados de antecedentes; **camada 2** é do tipo não adaptativa, portanto possui parâmetros a serem ajustados; **camada 3** é também não adaptativa, onde é calculada em cada nó a razão entre a aplicabilidade da i -ésima regra e o somatório das aplicabilidades de todo o sistema de regras; **camada 4** é do tipo adaptativa com função de ativação; e a **camada 5** é do tipo não adaptativa e é composta por apenas um nó que calcula a saída final, como a soma de todos os sinais de entrada vindos da camada 4.




Figura 10 - Representação de um sistema neuro-fuzzy (Pereira B. L., 2017)

Ao final desse processo, o ANFIS equivale a um sistema de informação, com a mesma vantagem de incorporar ao seu processo o conhecimento aproximado de um especialista.

4.5 CONTROLADOR PROPORCIONAL INTEGRAL DERIVATIVO (PID)

Controlador proporcional integral derivativo é uma técnica de controle que une 3 ações distintas: proporcional, integral e derivativa. É um controlador baseado na resposta da modelagem matemática de uma malha de processo a ser controlada. São encontrados em controladores eletrônicos com microprocessadores, chamados de *single-loop* e em softwares de controladores programáveis, entre outros equipamentos de controle.

A primeira ação do PID, produz um sinal de saída que é proporcional à amplitude do erro $e(t)$, onde K_p é sua constante de proporcionalidade. Esse método possui a vantagem de eliminar as oscilações do sinal de saída do sistema. Porém, possui um erro de *off-set* inversamente proporcional a K_p , que pode ser compensado no método de controle integral.

$$P_{saída} = K_p e(t) \quad (10)$$

A segunda ação do PID produz um sinal de saída que é proporcional ao erro acumulado (proporcional a magnitude e a duração do erro). Isso corrige o erro de *off-set* gerado pela ação anterior e acelera a resposta do sistema, chegando, portanto, mais rapidamente ao valor de referência.

$$I_{saída} = K_i \int_0^t e(\tau) d\tau \quad (11)$$

A última ação produz um sinal de saída proporcional a variação do erro. Essa ação fornece uma correção antecipada do erro, diminuindo o tempo de resposta do sistema e melhorando a estabilidade. Porém isso não deve ser utilizada em processos que o sistema

deve responder rapidamente a uma perturbação, nem em processos que apresentam muito ruído no sinal medido porque essa ação atua em intervalos de regulares e, se aplicado em processos onde há perturbações súbitas, leva o sistema a instabilidade.

$$D_{saída} = K_d \frac{de(t)}{dt} \quad (12)$$

Há quatro modos de controle distintos que pode ser aplicado em controladores. São a combinação de cada uma das ações possíveis, podendo ser um controlador do tipo P, PI, PD ou PID. Para saber qual controlador deve ser aplicado o sistema deve ser analisado e suas características juntamente com as características de cada controlador. (Wescott, 2000)

5 METODOLOGIA E DESENVOLVIMENTO

A partir da pesquisa bibliográfica realizada no capítulo anterior, o trabalho começou a ser desenvolvido em duas partes. A primeira parte tem como metodologia: a coleta dos dados de um voo do multicóptero; o tratamento dos dados estatisticamente; a obtenção da correlação do sinal; e a aplicação das técnicas Neuro-Fuzzy para estimar o coeficiente de força.

Após esse processo, é desenvolvida a segunda parte. Trata-se de obter o modelo dinâmico do multicóptero, obter a função de transferência e a planta do modelo, propor um controlador PID e por fim obter uma base de regras os ganhos do controlador levando em conta o modelo de planta obtido.

5.1 COLETA E ANÁLISE DOS DADOS

Foi realizado um voo com o multicóptero e foram coletados dados para o sinal de entrada dos motores (PWM) e os dados da aceleração no eixo vertical (aceleração em z). Após a coleta dos dados, a análise foi feita utilizando um código de análise no *software* Matlab®.

Devido a presença de ruídos no sinal, foi necessário fazer o tratamento do sinal utilizando um filtro para melhoria da correlação entre o sinal de entrada e saída. O processo de filtragem utilizado foi o filtro de Savitzky-Golay que suaviza os dados a partir da interpolação polinomial a partir de um ponto central. Os coeficientes do filtro são gerados a partir de um ajuste linear não ponderado de mínimos quadrados. (Nishida, 2017).

Na figura 11 está demonstrado a variação do sinal de entrada (PWM) e o sinal de saída (aceleração em z) com relação ao tempo. Tais sinais foram filtrados retirando a parte ruidosa.

As figuras 12a e 12b mostram o sinal de resposta em frequência da entrada e da saída, respectivamente, com filtro e sem filtro. Pode-se notar que o filtro atenuou bem o sinal, tornando-o mais limpo e menos ruidoso reduzindo sua banda de frequência.




Figura 11 - Sinal PWM e força em z em função do tempo. (Taha, Machini, Pereira, & Finzi, 2019)




Figura 12a - Sinal de resposta em frequência da entrada com filtro e sem filtro.




Figura 12b - Sinal de resposta em frequência da saída com filtro e sem filtro.

A partir da filtragem, a correlação do sinal e todos os procedimentos seguintes foram feitos utilizando o sinal filtrado de entrada e saída. Logo, para ser feito o cálculo da correlação do sinal de entrada e saída, é necessário calcular a função de coerência dos sinais. Foi realizado um cálculo para amostragem dos sinais com 15 amostras e um intervalo de tempo de 6,3 *ms*.

A função de coerência é calculada a partir das densidades espectrais que são funções de correspondência diretas G_{xx} , G_{yy} e indiretas G_{xy} , G_{yx} . Essas funções são multiplicações dos vetores de entrada e saída, onde X representa a entrada e Y representa a saída.

Essa função determina qual a coerência entre os sinais. A coerência que foi obtida pelos sinais de entrada e saída filtrados está demonstrada na figura 13. Pode-se notar uma baixa correlação, isso mostra que a forma como a coerência foi calculada não é a melhor forma para este caso. A melhor forma de calcular a correlação seria pela fórmula de Person, como pode ser notado em (Sant'ana, 2019).




Figura 13 - Coerência do sinal de entrada com relação ao sinal de saída em função da frequência.

5.2 OBTENÇÃO DO MODELO NEURO-FUZZY

O modelo Neuro-Fuzzy foi obtido posteriormente a análise de dados com a implementação offline. Para isso foi definido a entrada e saída do modelo do sistema Neuro-Fuzzy. A figura 14 ilustra o funcionamento ANFIS para o modelo em estudo. Como variável de entrada obteve-se o parâmetro PWM relacionado a rotação do motor e como parâmetro de saída a aceleração no eixo vertical z.




Figura 14 - Sistema Neuro-Fuzzy do modelo.

Após definir o modelo de entrada, é calculada a função de pertinência que correlaciona com a base de regras determinada. Ela é do formato Se/Então, a qual é determinada da seguinte forma:

- Se PWM é MUITO PEQUENO, então Fz é MUITO PEQUENO;
- Se PWM é PEQUENO, então Fz é PEQUENO;
- Se PWM é MÉDIO, então Fz é MÉDIO;
- Se PWM é GRANDE, então Fz é GRANDE;
- Se PWM é MUITO GRANDE, então Fz é MUITO GRANDE;
- Se PWM é MÁXIMO, então Fz é MÁXIMO.

A figura 15 está demonstrada a função de pertinência referente ao modelo Neuro-Fuzzy. Pode-se notar que há 6 curvas gaussianas que são referentes a quantidade de subconjuntos que a entrada foi dividida. As funções de pertinência foram definidas como muito pequeno, pequeno, médio, grande, muito grande e máximo.




Figura 15 - Função de pertinência.

Para se obter o modelo, o treinamento do sistema neuro-fuzzy é feito encontrando os pesos dos consequentes do sistema e a simulação é feita para cada possível solução encontrada a partir da evolução diferencial, esta busca minimizar a função custo (Cf).

Em que, nessa função, PWM_{ref} é a rotação do motor de referência e ΔPWM_{ref} é a variação da rotação de referência; as variáveis λ_1 , λ_2 e λ_3 são constantes impostas relacionadas ao sistema e as propriedades de minimização. Na figura 16 está demonstrado a função custo Cf em função das iterações do algoritmo de evolução diferencial. Foram totalizadas 315 iterações.




Figura 16 - Evolução de Cf no processo de otimização em função das iterações.

Conforme apresentado na figura 16 a função custo é minimizada após 200 iterações quando a função custo se torna constante.

5.3 MODELO E CONTROLE DINÂMICO DO SISTEMA

Para se obter o modelo dinâmico do sistema, foi considerado um modelo simplificado do multicóptero. O modelo dinâmico proposto está representado na figura 17. São consideradas a rotação do motor PWM , peso W e arrasto D .




Figura 17 - Representação do modelo físico do multicóptero. Fonte: autora.

O multicóptero pode ser descrito como um sistema SISO (*single-input, single-output*). Isso significa que o sistema possui suas variáveis desacopladas e pode ser modelado com uma variável de entrada e uma variável de saída. (Berto & Henz, 2017).

A rotação do motor ΔPWM é proporcional a velocidade de rotação das hélices ao quadrado multiplicado por uma constante k e a quantidade de motores n ; a força de arrasto é linearmente definida por uma constante k_d multiplicada pela velocidade vertical $\dot{h}$; a força peso está relacionada com a massa do multicóptero que é m e a aceleração da gravidade g .

Os valores das constantes de força de tração e de arrasto foram tirados de parâmetros pré-determinados na literatura e estão apresentados na tabela 1.

PARÂMETROS DO QUAD-ROTOR	
k	$8,901 \cdot 10^{-6} \text{ [N} \cdot \text{s}^2]$
k_d	$4,8 \cdot 10^{-3} \text{ [N} \cdot \text{s}^2]$

m	1,14 [kg]
n	4
g	9,81 [m/s ²]

Tabela 1 - Parâmetros do quadrrirrotor.

$$\Delta PWM = k \cdot \Omega^2 \cdot n \quad (13)$$

$$D = k_d \cdot \dot{h} \quad (14)$$

$$W = m \cdot g \quad (15)$$

As equações 13, 14 e 15 representam as forças atuantes sobre o corpo de forma simplificada e linear. Para modelar o sistema do multicóptero, considera-se o modelo em equilíbrio, isso quer dizer que a força peso W se iguala a força de tração relacionada a rotação do motor. Assim, utiliza-se como base a segunda lei de Newton $\sum F = m \cdot \ddot{h}$. Sendo assim, partimos para a equação do movimento do multicóptero que se torna:

$$m \cdot \ddot{h} + k_d \cdot \dot{h} + W = PWM + \Delta PWM$$

$$m \cdot \ddot{h} + k_d \cdot \dot{h} = \Delta PWM \quad (16)$$

Portanto, determina-se que PWM é a variável de entrada e y , deslocamento vertical, é a variável de saída do sistema. A partir disso, aplica-se a transformada de Laplace para obter o modelo no domínio s . As variáveis obtidas após a transformada passam a ser a variação PWM no domínio e a altura do sistema.

$$m \cdot s^2 \cdot H(s) - k_d \cdot s \cdot H(s) = \Delta PWM(s) \quad (17)$$

A partir da equação 17, pode-se obter a função de transferência do modelo entre a força de tração das hélices e a posição de altura h , que é a função $G(s) = \frac{1}{m \cdot s^2 - k_d \cdot s}$. A partir dessa função de transferência é possível projetar o controlador PID que, através da informação de saída esperada, calcula o ganho necessário para que a rotação ω das hélices seja suficiente para alcançar a altura pré-programada.

A figura 18 representa em diagrama de blocos do controlador PID do modelo do multicóptero. O controlador PID do sistema é composto por um ganho proporcional k_p , um integrador k_i e um derivativo k_d . A união desses 3 ganhos faz com que o erro do sistema seja minimizado pela ação proporcional, zerado pela ação integral e é obtido mais rapidamente devido a ação derivativa.




Figura 18 - Diagrama de blocos do controlador PID e da planta do sistema.

Como última etapa do trabalho, foi feito o controle do sistema considerando como variável de entrada a rotação do motor ω encontrada no Neuro-Fuzzy. Assim, no tópico seguinte, será comparado o controle PID para um valor de entrada PWM como determinado pela equação 19 e o valor de entrada PWM determinado pela técnica Neuro-Fuzzy.

6 RESULTADOS E DISCUSSÕES

6.1 ESTIMATIVA DOS PARÂMETROS UTILIZANDO O MÉTODO NEURO-FUZZY

Após o treinamento neuro-fuzzy, foi obtido como sinal de saída a força do sistema no eixo vertical relacionada ao sinal de rotação do motor. A figura 19 mostra uma comparação do sinal estimado da força e o sinal obtido pelo neuro-fuzzy em função do tempo.




Figura 19 - Sinal real e sinal estimado pelo neuro-fuzzy em função do tempo. (Taha, Machini, Pereira, & Finzi, 2019)

Pode-se notar que o sinal obtido pelo neuro-fuzzy é coerente com o sinal estimado experimentalmente, comprovando a eficiência do método. Porém, em alguns locais, há uma certa discrepância no sinal. Nota-se que entre 10 e 15 segundos há o maior erro entre os sinais, chegando a um erro de aproximadamente 0,1.

Isso pode ser explicado pois, nesse determinado momento, há uma inflexão da curva de forma que o método Neuro-Fuzzy não consegue se aproximar dos valores

experimentais. Além disso nota-se baixa correlação entre os sinais de entrada e saída nessa região.

6.2 CONTROLE DO SISTEMA DINÂMICO

A figura 20 mostra o gráfico de Root Locus para o sistema modelado. O sistema possui duas raízes instáveis, o que era esperado, pois, o multicóptero, possui a característica de ser um veículo para diferentes missões e, por vezes, sendo necessário sua mudança de rota e agilidade em voo.




Figura 20 - Root Locus do sistema.

Para a modelagem do controle, aplicou-se um degrau e aumentou o tempo de resposta para que o sistema oscile o menos possível. Na figura 21 está indicada a resposta do sistema para essa condição. Foi calculado para o controlador as seguintes constantes:

coeficiente proporcional $P = 7,715 \cdot 10^{-3}$; coeficiente integrativo $I = 6,299 \cdot 10^{-3}$; coeficiente derivativo $D = 2,281 \cdot 10^{-3}$; coeficiente de filtro $N = 2,137$.




Figura 21 - Resposta do sistema ao comando PID com um degrau de entrada.

Para a modelagem do controle utilizando a estimativa neuro-fuzzy, foi necessário fazer a conversão no código de força para PWM. Tal conversão foi feita utilizando a equação 18 onde $F_o = m \cdot g$ é a força de equilíbrio e a constante é um valor obtido experimentalmente que equivale ao valor PWM quando $\Delta F = 0$.

$$\Delta PWM = \frac{F \cdot 5978}{F_o} \quad (18)$$

Sendo assim, foi possível obter a figura 22 que indica a resposta do sistema quando é dada uma entrada degrau e aplicando um controlador PID. Para o controlador da estimativa fuzzy, foi considerado os mesmos coeficientes anteriores de proporcionalidade, integrativo e derivativo.




Figura 22 - Resposta do sistema Neuro-Fuzzy ao comando PID com um degrau de entrada.

É possível notar que, ao comparar a resposta do controlador para o sistema simples da figura 21 e o controlador para o sistema modelado com as técnicas Neuro-Fuzzy da figura 22 há uma grande diferença na resposta. Essa grande diferença entre as respostas pode ser explicada devido a disparidade dos modelos, sendo que o primeiro foi feito aproximações, simplificações e é considerado linear. Já o segundo é feito com a estimativa Neuro-Fuzzy baseado em dados experimentais obtidos em voo, e, portanto, garante um modelo mais realístico.

7 CONCLUSÕES E TRABALHOS FUTUROS

O trabalho apresenta uma coleta e análise dos dados, aplicações do método Neuro-Fuzzy para estimar o coeficiente de força da aceleração vertical e, por fim, a comparação simulada do controlador PID para um sistema linear simplificado e para o sistema modelado dinamicamente pelo Neuro-Fuzzy.

O primeiro resultado que pode ser citado é a aplicação da resposta em frequência do sinal adquirido experimentalmente. É possível notar que há uma elevada taxa de ruído no sinal de entrada (PWM) e no sinal de saída (aceleração em z). Isso pode ser explicado pela presença de forças externas ou falha na aquisição de dados. Para minimizar o erro dos ruídos foi aplicado um filtro, Savitzky-Golay, que minimizou o ruído de forma considerável.

Para a aplicação do método Neuro-Fuzzy fez-se a modelagem do sistema e a comparação do sinal obtido experimentalmente com o sinal estimado pelo método. Foi possível notar que os dois sinais são coerentes e próximos, e, portanto, verifica-se a eficácia de se utilizar neuro-fuzzy para a estimativa dos parâmetros.

Após o processo do neuro-fuzzy, o sistema foi modelado dinamicamente e foi possível simular o controle do sistema utilizando PID para o sistema simples e, após, para o sistema com a saída estimada pelo neuro-fuzzy. Ao fazer a comparação da resposta para os dois sistemas, foi possível notar que o sistema neuro-fuzzy apresenta uma característica de “queda” antes do sinal atingir o valor de degrau. A disparidade entre os dois resultados mostra que quando o controlador é aplicado em um sistema real, a resposta é totalmente diferente do esperado pelo modelo simplificado.

Como trabalhos futuros, seria de grande interesse acadêmico o estudo de técnicas para melhoria do sinal coletado, assim como técnicas para melhorar a filtragem do sinal e a coerência do mesmo. Estimar uma margem de confiabilidade entre a estimativa Neuro-Fuzzy e o sistema real poderia aumentar a aplicabilidade do método.

Também seria de grande importância científica o estudo do controlador PID utilizando técnicas de regras de base e Neuro-Fuzzy para o treinamento o modelo para

encontrar uma base de regras para o ganho para que ele se adapte em função das condições de operação do sistema.

REFERÊNCIAS BIBLIOGRÁFICAS

- Andrade, M., & Jacques, M. A. (2008). Estudo comparativo de controladores de Mamdani e Sugeno para controle de tráfego em interseções isoladas. *Transportes*, volume XVI, número 2, dezembro, p 24-31.
- Bernardes, R. (2019). *Sistemas Neuro-Fuzzy Aplicados no Controle de uma aeronave de asa fixa*. Uberlândia, MG, Brasil: Monografica de defesa de Projeto de Conclusão de Curso.
- Berto, P. H., & Henz, R. M. (2017). *Controle multivariável via desacopladores e projeto no espaço de estados: extensão de Benchmark em planta industrial de quatro tanques*. Brasília: Engenharia Mecatrônica, Universidade de Brasília.
- Conroy, J. K. (2014). *Characterization and enhancement of micro brushless DC motor response*. Baltimore, Maryland, United States: SPIE Defense + Security.
- DECEA, D. d. (s.d.). Veículos Aéreos Não Tripulados. *IAC N 21/10*.
- Gomide, F. A. (2015). *Conceitos Fundamentais da Teoria de Conjuntos Fuzzy, Lógica Fuzzy e Aplicações*. Campinas: Unicamp.
- Haykin, S. (2008). *Redes neurais: Principios e Prática*. 2 ed. Bookman, Canada.
- Jafelice, R. S. (2003). *Modelagem Fuzzy para Dinâmica de Transferência de Soropositivos para HIV em Doenças Plenamente Manifesta*. Campinas, SP, Brasil.
- Jang, J. R. (1992). *Fuzzy Controller Design without Domain Experts*. . Berkeley: IEEE International Conference on Fuzzy Systems.
- Jorge, L. A., & Inamasu, R. Y. (2014). *Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão*. São Carlos, SP: Embrapa Instrumentação.
- Landau et al, I. D. (2011). *Adaptive Control: Algorithms, Analysis and Applications* 34p. Springs EUA.
- Machini, F. M. (2018). *Modeling, Simulation and Control of a Generic Tilting Rotor Multi-Copter*. Uberlândia, MG, Brazil: Master's thesis, Federal University of Uberlândia.

- Nishida, E. N. (2017). *Propriedade da Filtragem de Savitzky-Golay Aplicadas na Identificação de Complexos QRS em Sinais de Eletrocardiograma*. Itajubá: Universidade Federal de Itajubá.
- Pereira, B. (2017). *Aplicação de Sistemas Neuro-Fuzzy e Evolução Diferencial na Modelagem e Controle de Veículo de Duas Rodas*. Uberlândia, MG, Brasil: Dissertação, Universidade Federal de Uberlândia.
- Pereira, B. L. (2017). *Aplicação de Sistemas Neuro-Fuzzy e Evolução Diferencial na Modelagem e Controle de Veículo de Duas Rodas*. Uberlândia, MG, Brasil: Dissertação de mestrado - Mestrado Acadêmico em Engenharia Mecânica.
- Sant'ana, V. T. (2019). *Aerodynamic Modeling Using Neuro-Fuzzy for a Scaled Model of Cessna*. Uberlândia: Dissertação Mestrado - Universidade Federal de Uberlândia .
- Silva, G. V. (2006). *Controle nao linear*. Lisboa: Edição digital 3ed.
- Specht, D. F. (1991). A generalized regression neural network . *IEEE Transactions on Neural Network*, Piscataway, v.2, n. 6, 569-576.
- Taha, V. S., Machini, F. M., Pereira, B. L., & Finzi, R. M. (2019). Multi-CopterForcesandMomentsCoefficientEstimationUsingAdaptive NeuralFuzzyInferenceSystems. *25° ABCM International Congress of Mechanical Engineering*, p. 10.
- Takagi, T., & Sugeno, M. (1985). Fuzzy Identification of Systems and Its Applications to Modeling and Control. *IEEE Transactions on Systems, Man, and Cybernetics* v.15 Japan, 116-132.
- Torres, F. M., & Tommaselli, A. M. (2017). *A lightweight UAV-Based laser scanning system for forest application*. Presidente Prudente, São Paulo, Brasil: Unesp.
- Valavanis, K. (2007). *Advances in Unmanned Aerial Vehicles*. Dordrecht, Netherlands: Springer.
- Wescott, T. (2000). *PID without a PhD*. India: EE Times.
- Zadeh, l. A. (1965). *Fuzzy sets. Information and control*, vol 8. .