

5

RECONFIGURAÇÃO DE CONTROLE EM UM DRONE QUADRIMOTOR AUXILIADA POR UM CLASSIFICADOR DE FALHAS

Rodrigo Baleeiro Silva ¹, Jônatas Souza ² Renato Dourado Maia ³,

Resumo

As tarefas de classificação de falhas e reconfiguração de controle em processos ou sistemas são áreas em que a pesquisa está em crescente desenvolvimento, e essa expansão pode ser associada a sua característica preventiva que junto a um controle robusto previne perdas tanto materiais quanto humanas. Nesse contexto, este trabalho apresenta uma nova proposta de abordagem adaptativa para classificação de falhas e reconfiguração ativa de controle em sistemas dinâmicos, baseada em duas etapas: na primeira etapa a abordagem proposta utiliza métodos clássicos para classificação de falhas, na segunda etapa propõe-se variações em reconfiguração de controle em sistemas dinâmicos a partir de dados de identificação da falha. Para verificar a eficiência da abordagem, ela foi aplicada em um modelo de drone quadrimotor com falha em um dos motores, contextualizada como a queda de potência neste. Dessa forma, os resultados obtidos, através da simulação no software Matlab, pelo sistema de reconfiguração são comparados com controladores utilizados apenas em operação normal, com uma ênfase na variável altura. De modo geral, a abordagem proposta obteve bons resultados, o que sugere que a mesma é promissora para realizar as tarefas de classificação de falhas e reconfiguração de controle de sistemas dinâmicos.

Palavras-chave: Reconfiguração de sistema de controle, classificação de falhas, Drone quadrimotor, Redes Neurais Artificiais

Abstract

The tasks of fault classification and reconfiguration of control in processes or systems are areas in which research is in increasing development, and this expansion can be associated with its preventive characteristic that together with a robust control prevents both material and human losses. In this context, this work presents a new proposal of adaptive approach for classification of failures and active reconfiguration of control in dynamic systems, based on two steps: In the first step, the proposed approach uses

¹Faculdade de Ciência e Tecnologia de Montes Claros, Praça da Tecnologia, 77 - São João, Montes Claros, E-mail: rodrigobaleeiros@yahoo.com.br

²Faculdade de Ciência e Tecnologia de Montes Claros, Praça da Tecnologia, 77 - São João, Montes Claros, E-mail: jonsouza_cea@hotmail.com

³Faculdade de Ciência e Tecnologia de Montes Claros, Praça da Tecnologia, 77 - São João, Montes Claros, E-mail: renato@femc.edu.br

classic methods for classifying failures; in the second stage, it proposes variations in control reconfiguration in dynamic systems from data of fault identification. To verify the efficiency of the approach, it was applied in a four-engine drone model with failure in one of the engines, contextualized as the power outage in this. Thus, the results obtained, through simulation without Matlab software, by rewriting system are compared with controllers used only in normal operation, with an emphasis on varying height. In general, the proposed approach has obtained good results, suggesting that it is promising to perform the tasks of classification of failures and reconfiguration of control of dynamic systems.

Keywords: Control System Reconfiguration, Fault Classification, Four-Drone Drone, Artificial neural networks.

1 Introdução

Este trabalho trata de uma versão estendida do artigo Reconfiguração de Controle Em Um Drone Quadrimotor Auxiliado por Um Classificador De Falhas, aceito e publicado na 7ª Conferência Sul em Modelagem Computacional (7º MCSul).

A nova versão aborda uma nova proposta de classificação, com o uso de uma nova função, que se adequa as projeções não lineares, tendo sua fundamentação teórica detalhada, além de gerar resultados de uma forma mais rápida e com custo computacional menor. Propõe-se também novos resultados acerca da reconfiguração de controle, que são renovados pelo chaveamento via método *fuzzy*, e finalizando com a validação do classificador, incluindo testes de regressão, métricas e matriz de confusão.

O surgimento de novos processos cada vez mais complexos impõem grandes desafios para o seu gerenciamento e manutenção, pois toda essa complexidade também é descrita em termos de projeto, execução e demais passos tomados. Trabalhos como o de (AHMED-ZAID et al., 1991) demonstrou o uso de um sistema adaptativo para diagnosticar falhas em um caça F16 com um controle quadrático híbrido. (HAJIYEV; CALISKAN, 2013) inseriram um *feedback* em controladores LQR (*Linear Quadratic Regulator*) e LQG (*Linear Quadratic Gaussian Regulator*) para minimizar as perturbações externas e aumentar a robustez contornando um modelo preditivo. Exemplifica-se assim o controle de processos de voo, em que o controle, detecção de falhas provenientes de erros físicos ou de *software* fosse feito apenas pelo operador humano, a probabilidade de acidentes seria alta, pois mesmo que a criatividade humana seja de um nível altíssimo, a sua precisão é falha, e processos repetitivos tornam essa característica ainda mais evidente.

O problema de diagnóstico de falha e reconfiguração de controle de sistemas é um ramo em desenvolvimento contínuo na engenharia, e o assunto torna-se maior devido à necessidade de sistemas de navegação cada vez mais sofisticados como em controles, como de sis-

temas de veículos aeroespaciais. Estes em sua maioria são tratados como sistemas especialistas, sua aplicação pode ser vista nos projetos de Redesign em Tempo Real e Técnicas de Busca em Tempo Real inseridos de forma ponta a ponta nos sistemas da *National Aeronautics and Space Administration* (NASA) (MONTROYA; WOOD; RATHINAM, 2011). Existe também esse controle em atuadores automáticos, focados em garantir a segurança sem perder a viabilidade dos projetos.

Nos casos de processos com alto grau de complexidade, torna-se complexo para operadores humanos diagnosticar uma situação anormal em tempo efetivo, ocasionando tomadas de decisões erradas. Estudos estatísticos na área industrial mostram que aproximadamente setenta por cento dos acidentes são causados por erro humano, o que acarreta não só perda econômica, mas diminuição de segurança e danos ambientais (VENKATASUBRAMANIAN et al., 2003).

Os controladores robustos devem funcionar na presença de efeitos indesejáveis, por isso um sistema que controle e reconfigure-se deve ser adaptável, havendo até alterações nas leis de controles para recuperar o curso normal causado pelas falhas, além de que essa adaptação deve ser feita em um tempo aceitável, essas necessidades deram base ao conceito de Auto Reparação de Controle de Voo em Tempo Real, o *Self-Repairing Real-time Flight Control Systems*, ou SRFC (HAJIYEV; CALISKAN, 2013).

O SRFC é um conceito baseado em detectar, isolar e recuperar falhas ou elementos em sistemas de voo, os controles que utilizam o SRFC operam através de monitoramento, detecção, diagnóstico e reconfiguração (RUBERTUS, 1983). O SRFC se divide em duas partes distintas: A detecção de falha e isolamento (FDI) e a reconfiguração das leis de controle. O diagnóstico de falhas é uma tarefa importante no sistema, pois se as falhas não forem listadas corretamente podem ocasionar graves consequências na reconfiguração de controle.

Durante as últimas décadas foram propostos diversos métodos e técnicas de diagnóstico de

falha, com métodos que partem dos clássicos baseados em modelos, até os mais modernos, baseados em dados do processo com emprego de inteligência computacional.

Assim, projetos que fazem uso da tecnologia *Fuzzy* como nos estudos de (COZA et al., 2011), modelos preditivos, modelos baseados em redes neurais com realimentação da saída como em (DIERKS; JAGANNATHAN, 2010).

Em relação aos trabalhos com Drones os principais desenvolvimentos são vistos em (CUI; ZHU; LI, 2013), (SHEN; JIANG; COCQUEMPOT, 2013), (GEORGE et al., 2006), (CAO et al., 2012). Em (EFE, 2011), foi usado uma rede neural auxiliada de um controle PID que auxilia na minimização dos efeitos causados pelos distúrbios. Apesar disso os trabalhos baseados na reconfiguração de controle são mais escassos, listando (CHEN et al., 2015) como o sistema mais interessante, que faz uso de lógica quântica para produzir a reconfiguração de controle.

Logo, em um controle de voo as falhas irão influenciar diretamente a estabilidade, o desempenho, a segurança e a confiabilidade do sistema em questão. Porque, as hélices que elevam o drone estão conectadas aos motores, caso haja falhas nestes motores, tanto a altura como os ângulos que promovem a estabilidade do drone são afetados, assim neste trabalho foi projetado um sistema adaptativo, fazendo uso de redes neurais para a classificação de falhas e da redundância de controle para reconfigurar o sistema, aliviando ou rejeitando as falhas.

Este trabalho tem como objetivo principal propor uma abordagem para classificar falhas e reconfigurar sistema de controle de processos dinâmicos. Para tanto, a abordagem proposta reconfigura o sistema de controle de forma adaptativa de um Drone quadrimotor quando submetido a falhas em um dos motores. Os objetivos específicos deste projeto são: Estudar e conhecer as metodologias utilizadas para a detecção e classificação de falhas existentes na literatura. Evidenciar a estabilidade gerada pela reconfiguração do sistema de controle para amenização do voo após possíveis falhas em um Drone (quadrimotor). Avaliar a

metodologia proposta através de uma comparação de resultados de sistema de controle padrão com um sistema de reconfiguração proposto, com uma ênfase na variável altura e na detecção de falha de um dos motores do Drone.

Para coseguir obter os objetivos citados são necessários os seguintes estudos e implementações que serão demonstrados nas seguintes seções. Na seção 2 descreve a importância e modelo matemático do drone, já na seção 3 mostra o controlador que será utilizado no sistema. A seção 4 discute sobre a classificação do nível de falha no motor do Drone. Observa-se também que a seção 5 discute sobre redes neurais para atuar como classificador de falhas e na seção 6 tem o objetivo de validar o classificador. A reconfiguração do sistema de controle é tratada na seção 7. Dessa forma, chega-se nos resultados das simulações implementadas no matlab na seção 8 e conclui-se todo projeto na seção 9.

2 O Drone

Drones, em geral, são objetos voadores que se parecem com mini-helicópteros e são aplicados em diversas áreas como doméstica, comercial, militar e industrial. A palavra drone não é de origem brasileira. Ela é oriunda da língua inglesa e nem sequer é o nome técnico deste tipo de equipamento. Drone é mais uma palavra comercial ou apelido para estes objetos voadores. Em inglês, esta palavra quer dizer zumbido ou zangão. De acordo com (HAJIYEV; CALISKAN, 2013) o sistema de controle do quadrimotor é considerado um processo complexo comparado com outros objetos em movimento que não realizam o voo, visto que a aeronave realiza movimentos tridimensionais e atuam em ambientes com muitas perturbações externas e, além disso, há necessidade de garantir que todas etapas do voo como decolagem, manobras e pouso sejam normalmente realizadas com segurança e até perfeição, dependendo da sua especificação de utilização.

Utilizou-se neste trabalho a modelagem que permitirá a elaboração do sistema de controle

do drone, além disso viabilizará a simulação de todo o sistema. Na modelagem de um drone, é comum se aproveitar das convenções utilizadas para as orientações do veículo em relação ao seu centro de gravidade.

A Figura 1 demonstra os ângulos que são de suma importância para a implementação das técnicas de controle, pois ao exercer variações nestas atitudes tem-se uma projeção da propulsão de cada hélice para uma direção, assim viabilizando o deslocamento do drone nos eixos X e Y.




Figura 1: Movimentos do Quadrimotor.
Fonte: (PERLMAN, 2016)

Possuindo o conhecimentos das angulações e movimentos os quais o drone exerce pode-se fazer uso dos modelos de Newton-Euler, que descrevem uma dinâmica genérica para um corpo rígido de seis graus de liberdade referenciados ao seu corpo como centro de gravidade, gerando matrizes para os sistemas terra-corpo e para os esforços do conjunto de atuadores. Os momentos de inércia para o drone são calculados assumindo um centro da densa esférica, com massa M e raio R, e pontos de massa m localizados a uma distância de L a partir do centro, como na figura 2.

Como mostrado na Figura 2, um drone é essencialmente simétrico em torno de todos os três eixos, por conseguinte (BEARD, 2008) propõe que as equações finais que demonstram o modelo matemático para o drone quadrimotor pode ser descrito como mostram as Equações 1, 2, 3 e 4:




Figura 2: Bases para o Momento de Inércia.
Fonte: (BEARD, 2008)

$$\begin{pmatrix} \dot{p}_n \\ \dot{p}_e \\ \dot{h} \end{pmatrix} = \begin{pmatrix} c\theta c\psi & s\phi s\theta c\psi - c\phi s\psi & c\phi s\theta c\psi + s\phi s\psi \\ c\theta c\psi & s\phi s\theta c\psi + c\phi s\psi & c\phi s\theta c\psi - s\phi s\psi \\ s\theta & -s\phi c\theta & -c\phi c\theta \end{pmatrix} \begin{pmatrix} u \\ v \\ w \end{pmatrix} \quad (1)$$

$$\begin{pmatrix} \dot{u} \\ \dot{v} \\ \dot{w} \end{pmatrix} = \begin{pmatrix} rv - qw \\ pw - ru \\ qu - pv \end{pmatrix} + \begin{pmatrix} -g\sin(\theta) \\ g\cos(\theta)\sin(\phi) \\ g\cos(\theta)\cos(\phi) \end{pmatrix} + m^{-1} \begin{pmatrix} 0 \\ 0 \\ -F \end{pmatrix} \quad (2)$$

$$\begin{pmatrix} \dot{\phi} \\ \dot{\theta} \\ \dot{\psi} \end{pmatrix} = \begin{pmatrix} 1 & \sin\phi \tan\theta & \cos\phi \tan\theta \\ 0 & \cos\phi & -\sin\phi \\ 0 & \frac{\sin\phi}{\cos\theta} & \frac{\cos\phi}{\cos\theta} \end{pmatrix} \begin{pmatrix} p \\ q \\ r \end{pmatrix} \quad (3)$$

$$\begin{pmatrix} \dot{p} \\ \dot{q} \\ \dot{r} \end{pmatrix} = \begin{pmatrix} \frac{J_y - J_z}{J_x} qr \\ \frac{J_z - J_x}{J_y} pr \\ \frac{J_x - J_y}{J_z} pq \end{pmatrix} + \begin{pmatrix} \frac{1}{J_x} \tau_\phi \\ \frac{1}{J_y} \tau_\theta \\ \frac{1}{J_z} \tau_\psi \end{pmatrix} \quad (4)$$

Nas equações 1, 2, 3 e 4, é notável as doze variáveis de estados que representam o espaço de estados do drone, essas são descritas por:

- p_n = Posição inercial sentido norte: posição linear em X em relação ao sistema Terra: X;
- p_e = Posição inercial sentido leste: posição linear em Y em relação ao sistema Terra: Y;
- h = Altura do drone: posição Linear em Z em relação ao sistema Terra: Z;
- u = Velocidade Linear em X expresso no sistema Corpo;
- v = Velocidade Linear em Y expresso no sistema Corpo;
- w = Velocidade Linear em Z expresso no sistema Corpo;
- ϕ = Ângulo de *roll* (Rolagem) em relação ao sistema Terra;
- θ = Ângulo de *pitch* (Arfagem) em relação ao sistema Terra;
- Ψ = Ângulo de *yaw* (Guinada) em relação ao sistema Terra;

p = Velocidade angular de *pitch* expresso no sistema Corpo;
 q = Velocidade angular de *roll* expresso no sistema Corpo;
 r = Velocidade angular de *yaw* expresso no sistema Corpo.

Com as Equações 1, 2, 3 e 4 foram encontradas quatro matrizes após substituição dos dados reais de acordo com a tabela 1 e o processo de linearização.

Tabela 1: Parâmetros do Quadrimotor real.

Descrição	Parâmetro	Valor
Massa	m	2.24kg
Aceleração	g	9.81m/s ²
Inércia no eixo x	J_x	0.0363Kg.m ²
Inércia no eixo y	J_y	0.0363Kg.m ²
Inércia no eixo z	J_z	0.0615Kg.m ²

Com a inclusão dos dados reais em relação a um modelo de drone quadrimotor conclui-se as quatro matrizes, que colocadas no espaço de estado representam o modelo proposto.

3 O Controle Robusto: Controlador LQR

O Regulador Linear Quadrático, ou somente LQR, é uma tecnologia de uso ótimo e robusto, de fácil implementação aliado a um bom desempenho. É usado amplamente em diversos tipos de processos, como o da robótica até aos processos químicos. Considerando um sistema invariante no tempo, descrito como mostra a Equação 5 :

$$\dot{X} = Ax(t) + Bu(t)y = Cx(t) \quad (5)$$

Assim, a implementação de um controlador LQR é baseado em determinar uma lei de controle $u = (t)$ que minimize a uma função quadrática $j = f(x, u)$ em que (OGATA, 2003) diz que a Equação 6 é:

$$J \doteq \int_0^{\infty} (x(t)'Qx(t) + u(t)'Ru(t))dt \quad (6)$$

Onde as matrizes de ponderação denominadas por $Q = Q' > 0$ e $R = R' > 0$. Assim as variáveis de controle podem estar presentes na constante de realimentação de estados, dadas pela Equação 7:

$$u(t) = -Kx(t) \quad (7)$$

A solução para $u(t)$ que torne o problema ótimo quadrático é expressa pela Equação 8:

$$u(t) = -Kx(t) = -(R)^{-1}B'Px(t) \quad (8)$$

Tanto que P satisfaça a Equação de Ricatti 9:

$$A'P + PA - PB(R)^{-1}B'P + Q = 0 \quad (9)$$

Com isso a função custo para a condição inicial pode ser obtida através do cálculo da Equação 6 é dada pela Equação 10 e pela Equação 11:

$$J \doteq \int_0^{\infty} (x(t)'Q + K'RK)x(t)dt = \quad (10)$$

$$= x(\infty)Px(\infty) + x(0)'Px(0) \quad (11)$$

Portanto, considerando um sistema com realimentação estável, tem-se $x(\infty) \rightarrow 0$, concluindo a Equação 12:

$$J = x(0)'Px(0) \quad (12)$$

Isso assumindo que o sistema em questão seja controlável e observável.

4 Classificação de Falhas

Em qualquer tipo de gerenciamento de processos, máquinas e equipamentos em diversas áreas é fundamental a chamada tarefa de detecção e classificação de falhas. Pode-se diferenciá-las, pois a detecção baseia-se simplesmente em possuir a informação se existe falha ou não, e a classificação além de mostrar a falha existente, deve também possuir informação dos valores da falha, e em sistemas com sensores redundantes deve-se possuir também a indicação do local de falha.

De acordo com (VENKATASUBRAMANIAN et al., 2003) o processo de detecção de

falhas é de suma importância em diversos processos, pois falhas não diagnosticadas corretamente podem ocasionar consequências graves em aspectos socioeconômicos, ambientais e de segurança. Dessa forma, um sistema que possa detectar fielmente as falhas existentes com rapidez e precisão possuem real importância em áreas como militar, medicinal, aeroespacial e industrial, dentre outras.

Assim, de modo geral um sistema de classificação de falhas é um sistema capaz de detectar, isolar e identificar a falha. Este classificador deve, então, receber tanto as informações de controle quanto as informações do estado atual do processo em questão. Os sistemas também devem lidar com falhas que estão fora do escopo do diagnóstico como incertezas estruturais e ruídos de medição. Em um projeto de um sistema de classificação de falhas são desejadas características como a rapidez de diagnosticar uma falha, a robustez a *outliers* e ruídos, a isolabilidade de diferentes falhas e a adaptabilidade de mudanças nos processos, e em alguns destes há a necessidade da identificação de novidade, que em caso de falhas deve afirmar se ela é conhecida ou nova, além de outros ligados aos requisitos computacionais e de modelagem (VENKATASUBRAMANIAN et al., 2003). Muitos dos requisitos desejados são contraditórios, como um diagnóstico rápido e confiável, e dificilmente todas elas são satisfeitas para apenas um sistema, mas conhecer todas essas características é de suma importância para avaliação do sistema, que em métodos de comparação pode gerar um processo mais confiável.

Diferentes tipos de diagnósticos de falhas são encontrados na literatura, em que a principal diferença entre eles está na forma em que os dados do processo são utilizados para a classificação, em que basicamente são divididos entre métodos baseados em modelos e métodos baseados no histórico do processo. Métodos baseado em modelos utilizam um conjunto de relações matemáticas que representam o processo físico, além do conhecimento prévio do processo, seja qualitativo ou quantitativo. Em contraste a esses métodos têm-se os

métodos de diagnósticos de falhas que utilizam grandes quantidades de dados do processo para extrair o conhecimento. Estes dados são obtidos a partir de variáveis de entrada e de saída medidas por sensores. Neste tipo de método, que tende ao uso de inteligência computacional, possui ramos nas redes neurais artificiais, em redes *neurofuzzy*, redes *Bayesianas* e sistemas imunes artificiais (INACIO, 2014).

Com diferentes tipos de sistemas aplicados, nota-se então que um único método não pode ser adequado para atender todos os requisitos desse sistema, assim a qualidade do sistema de qualquer um dos métodos depende da qualidade da informação fornecida. Como é visto em várias áreas, uma forma de melhorar o sistema de diagnóstico de falhas é integrando características de métodos distintos, superando as limitações de cada um (VENKATASUBRAMANIAN et al., 2003).

5 Redes Neurais

Com base nos estudos da funcionalidade de um neurônio biológico, em questões técnicas da biologia celular, percebeu-se que com o axônio, dentrito, corpo celular e ramificações que são capazes de conduzir o cérebro a um processamento paralelo e contínuo, (MCCULLOCH; PITTS, 1943) basearam e propuseram o primeiro neurônio artificial, este foi chamado de MPC. A Figura 3 mostra o funcionamento deste modelo proposto.

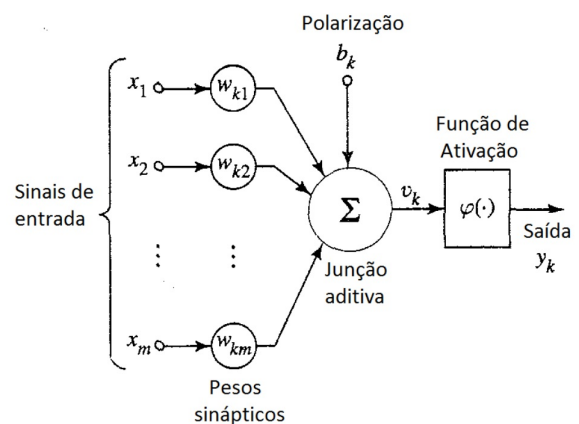


Figura 3: Neurônio Artificial.
Fonte: (MCCULLOCH; PITTS, 1943)

No neurônio biológico informação é processada, passando através do axônio até os dendritos dos neurônios seguintes. O ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro é conhecido como sinapse. As sinapses funcionam como válvulas e a variação no fluxo do impulsos promovida por elas é que confere ao neurônio a capacidade de adaptação (BRAGA; CARVALHO; LUDERMIR, 2000). Já o modelo de neurônio artificial possui n entradas, especificadas como x_1, x_2, x_m que representam os dendritos e a saída y para representar o axônio. Para dar ao neurônio artificial a características adaptativa deve-se proporcionar as mesmas características das sinapses biológicas, assim nas entradas existem os pesos sinápticos w_1, w_2, w_m em que os pesos determinam a importância deste sinal de entrada. De acordo com (BRAGA; CARVALHO; LUDERMIR, 2000), o corpo do neurônio é emulado por um mecanismo simples que realiza a soma dos valores $x_i w_i$ recebidos pelo neurônio (soma ponderada) e decide se ele deve disparar ou não, comparando a soma obtida ao limiar de excitação do neurônio.

A partir desse primeiro trabalho inicial outros projetos seguiram o mesmo preceito, desenvolvendo as redes neurais para o patamar existente hoje, com diversas modalidades de redes. (ROSENBLATT, 1958) propôs um neurônio artificial denominado de *perceptron* composto basicamente das mesmas unidades básicas de um MPC e com uma regra de aprendizado. Este novo neurônio composto de apenas uma camada e com implementação de funções de ativações lineares, o que o limita a resolver problemas linearmente separáveis, e mesmo que a rede possua mais camadas mas suas funções de ativações sejam lineares, estas redes são equivalentes as redes de apenas uma camada. Assim, o *perceptron* mesmo possuindo um grande avanço para a época é inviável para diversos sistemas práticos, e nesse pensamento que deu-se início a criação da rede *Perceptron Múltiplas Camadas*.

5.1 *Perceptron Múltiplas Camadas*

Este tipo de rede, também chamada de PMC, ou MLP do inglês *Multi Layer Perceptron*, é composta por um conjunto de unidades sensoriais como neurônios de entrada, uma ou mais camadas intermediárias, também chamadas de ocultas, e uma camada de saída (HAYKIN, 1999). A disposição das camadas de uma rede *Perceptron Múltiplas Camadas* é mostrada na Figura 4.




Figura 4: Rede PMC.

Fonte: (Júnior, 2016)

Como as redes de uma só camada resolvem apenas problemas linearmente separáveis, adotou-se então camadas intermediárias nas redes utilizadas. (CYBENKO; ALLEN; POLITO, 1988) diz que uma rede neural intermediária pode aprender qualquer função contínua, e uma rede com duas ou mais camadas intermediária permite a aproximação de qualquer função. Mas mesmo após a inserção de camadas intermediárias a rede ainda necessita de funções de ativação não lineares e diferenciáveis para permitir o treinamento. As funções de ativação mais comuns usadas são a sigmoide, a tangente hiperbólica e a função identidade. Assim este acrescentamento dá a rede PMC funções para modelar qualquer tipo de sistema.

5.2 A Classificação com *Feedforward Neural Network*

Uma rede *Feedforward*, também chamada de FF, consistem em uma série de camadas.

A primeira camada possui ligação com a entrada da rede e com as demais camadas, com as camadas escondidas também participando dos nós. Esse tipo de rede, mesmo possuindo arquitetura simples pode ser usada para qualquer tipo de mapeamento entre entrada e saída, uma camada escondida e um número de neurônios suficientes já são capazes de resolver problemas com um número finito de dados.

Quando se trata do uso de redes neurais a atenção maior deve ser voltada para a inicialização e ao ajuste dos pesos. O método *feedforward* pode ter uma taxa de convergência maior que em outros métodos quando se alia esse método a algoritmos de aprendizagem que evitem o *overfitting*. O método *backpropagation*, por exemplo, é sensível a mínimos locais, o que presume em ajustes profundos nos coeficientes de aprendizagem (SHANG; WAH, 1996). Assume-se então o método avançado de otimização chamado de *Levenberg-Marquardt backpropagation*.

5.3 O Treinamento com *Levenberg-Marquardt*

o Método de *Levenberg-Marquardt* é um método usado na otimização em diversas áreas, primeiramente desenvolvido por *Kenneth Levenberg* e aprimorado por *Donald Marquardt* (LEVENBERG, 1944)(MARQUARDT, 1963). No contexto da classificação, essa função de treinamento atualiza os valores dos pesos e polarização com o *backpropagation*, podendo usufruir de questões como o valor de inicialização, fatores de aumento ou diminuição e metas de desempenho. O uso do método *Levenberg-Marquardt* foi projetado para elevar a velocidade do treinamento para segunda ordem, mas sem a necessidade de fazer os cálculos da matriz de Hessian, limitando-se apenas aos cálculos das primeiras derivadas dos erros em relação aos erros através do *backpropagation*, o que bem menos complexo que o cálculo da matriz de Hessian (HAGAN; MENHAJ, 1994). Como faz uso do Jacobi-ano para os cálculos, pressupondo a média ou soma dos erros quadrados o treinamento deve-se atentar as funções de desempenho.

6 A Validação de Classificadores

Ao fazer o uso de algoritmos de aprendizado, normalmente supervisionados, existe a necessidade de visualizar o desempenho final, isto é feito por modelos que gerem e demonstram os resultados, tem-se os exemplos da matriz de confusão, valor de acurácia, além da visualização da regressão, compreendendo o treino, validação, teste e índice de acurácia.

A matriz de confusão (KOHAVI; PROVOST, 1998), possui colunas que representam as instâncias de cada classe prevista no treino, enquanto as linhas da matriz representam as classes reais, e recebe este nome pois é usada para visualizar se está existindo confusão entre as classes do treino (TECNOLOGIA, 2015).

A regressão linear é usada para a estimação do valor esperado de uma variável com o uso dos valores de outras variáveis. Esse modelo é considerado um dos primeiros a usar a forma regressiva de análise aprofundada e criteriosa, e largamente usada em aplicações práticas. O modelo é em diversas vezes ajustados por meio dos mínimos quadrados, como também de outras maneiras, como a minimização desses ajustes (REIS, 1994).

7 Reconfiguração de Controle

Em caso de falha de um elemento de controle a reconfiguração é proposta como automática, que se caracteriza como reconfiguração ou reestruturação do sistema, de tal maneira que o sistema se recupere a uma condição segura e posteriormente possa ser controlado manualmente para uma parada segura. Esse tipo de reconfiguração é demonstrado por (MONTROYA; WOOD; RATHINAM, 2011) em que é proposto um erro em uma aeronave e o controle automático deve tomar as melhores decisões inseridas anteriormente para que a aeronave se recupere a condição inicial de queda até que possa ser novamente pilotada, e em caso de falhas graves e sem condições de permanecer em voo, possa tornar a aterrissagem possível e de forma segura. Isso só é possível se o controle e sensores estejam em

operacional normal.

Um sistema que possua reparação automática de controle, ou auto reparação, SRCS do termo em inglês, *Self-Repairing Control System*, consiste na detecção das falhas, diagnóstico e etapas de reconfiguração do sistema. Isso implica na detecção e tentativa de classificação, isolamento e quantificação da falha, para medir o impacto mediante o processo.

Portanto, após a detecção e diagnóstico da falha e de seu impacto ao sistema dinâmico, a reconfiguração do sistema de controle é iniciada para que a falha seja atenuada e assim a condição inicial de queda seja superada e o voo ou aterrissagem sejam seguros. A característica primária de qualquer sistema de reconfiguração é a detecção de variações bruscas no sistema, seja nos sensores, atuadores, na superfície de controle ou qualquer parte do processo que possa ser considerado uma falha, por isso a detecção da falha é o primeiro passo pra ação corretiva. Assim, é requerido que seja rápido com atraso mínimo de detecção, e, portanto sensíveis à falha, garantindo que alarmes falsos sejam minimizados, mas que também sejam robustos a erros de modelagem e a existência de redundância.

Partindo do pressuposto de que um observador ou filtro seja criado para que seja insensível a alguma falha hipotética, pode-se assim explorar a falha para estabelecer como o algoritmo de decisão atuará, pois a detecção e decisão baseiam-se na sensibilidade do observador e do filtro. Se a falha for detectada e permanecer nesse estado o sistema então pode passar para o próximo passo e ser capaz de reconfigurar os seus componentes, substituindo ou isolando esse sistema ou subsistema do restante do processo. Essa reconfiguração pode ser feita através de *backup* de configurações normais, ou reconfiguração das entradas de controle (HAJIYEV; CALISKAN, 2013).

As leis que regem as técnicas de reconfiguração de controle formam a parte mais importante de um sistema que utiliza a auto reparação. Os controladores têm de possuir autoridade, que pode ser definida como a capacidade

de substituir o piloto quando o sistema considera que é necessário, para que o processo continue normal. Nas técnicas de reconfiguração é de uso o termo *Fly-By-Wire* (FBW) significa plena autoridade, é usado em processos onde o controlador automático pode assumir todo o controle para recuperar o sistema de falhas impostas, além de fazer isso em um tempo aceitável.

Existem várias técnicas de reconfiguração para sistemas na literatura, das mais conhecidas pode-se exemplificar a técnica *Pseudo-Inverse*, que se baseia na reconstrução do comando quando as forças e movimentos são classificados como falhos, assim utilizando a matriz de eficácia e é feito o inverso para tentar voltar à operação normal, entretanto depende da matriz de entrada que deve ser conhecida perfeitamente. Há também as técnicas baseadas no controle adaptativo que inclui *self-repairing*, modelo de referência, controle adaptativo e controle preditivo. Usa-se o feedback incluso a controladores robustos como LQR e LQG, maximizando a robustez e minimizando as perturbações externas (HAJIYEV; CALISKAN, 2013). Existem trabalhos com uso regras simbólicas e conjuntos *fuzzy* para realização da reconfiguração de controle. Já (AHMED-ZAID et al., 1991) utilizou do Sistema adaptativo para diagnosticar falhas em um caça baseado em *Gain Sheduling*, com o adicionamento de um controle quadrático híbrido adaptativo. Neste trabalho é proposto um sistema de reconfiguração de controle ativo baseado na realimentação das detecções de falhas nos atuadores do drone.

8 Discussão e Resultados

Os experimentos para este trabalho foram realizados no *software* MatLab[®], principalmente nos ambientes *simulink*, para redes neurais e sistemas *neurofuzzy*. Inicialmente foi proposto controle do sistema com a inserção de falhas, como resultados tem-se a Figura 5 com as três variáveis altura (h), posição leste (Pe) e posição norte (Pn), mostrando o sistema com falha sem a adição do sistema de reconfi-

guração de controle. Nota-se que inicialmente as três variáveis estavam em “um” metro e foi colocado um novo *setpoint* com valor igual a “quatro” metros.




Figura 5: Simulação de falha.

Observando os Gráficos da 5 nota-se que as falhas inseridas possuem um valor de entrada temporal, os quais são mostrados na Tabela 2.

Após induzir essas falhas através do modelo matemático equacionado por (BEARD, 2008), baseado na segunda lei de Newton, gerou-se o treinamento da rede neural (MLP) com a nova função *feedforward* do *software*, para utilização na classificação de falhas que será auxilia-

Tabela 2: Relação de tempo x falha.

Tempo	Percentual de Falha
Até 15s	0%
15 - 30s	20 %
30 -50s	40%
50 - 80s	80%

dora na reconfiguração do sistema de controle. Dessa forma, considerando “1” para potência máxima e “0” para potência mínima gerou-se o seguinte classificador, como visto na Figura 6.

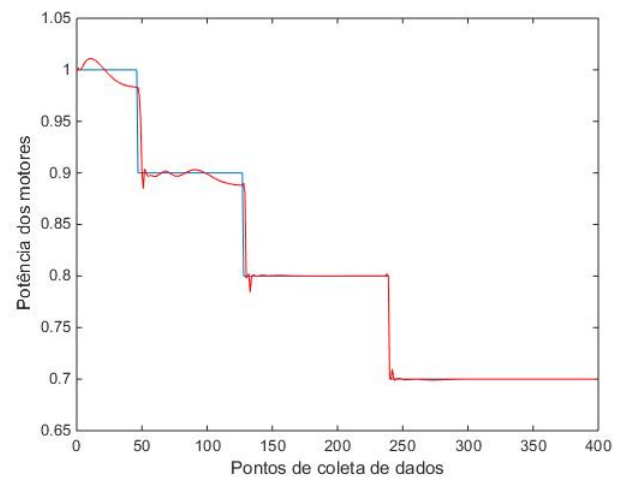


Figura 6: Operação do Classificador de Falhas

Na Figura 6 a linha que descreve os degraus (em azul) refere-se a amostra que foi utilizada para treinamento, já na outra linha (vermelha) é a operação da rede neural para classificação da falha. Nota-se que para um limiar de erro aceitável o classificador consegue separar as ocorrências de falha no motor do quadrimotor.

Quando a nova função é comparada a função antiga usada há uma grande diferença no desempenho. Algumas informações podem ser vistas na Figura 7.

Observa-se que o número de interações usadas diminuiu drasticamente, usando apenas 1,45% do anterior, em um tempo mínimo, com melhor performance e gerando um resultado semelhante. Essa função também viabiliza a regressão, detalhada nas Figuras 8 e 9

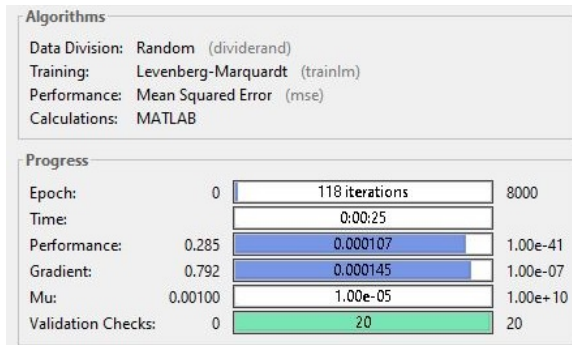


Figura 7: Classificação no software .



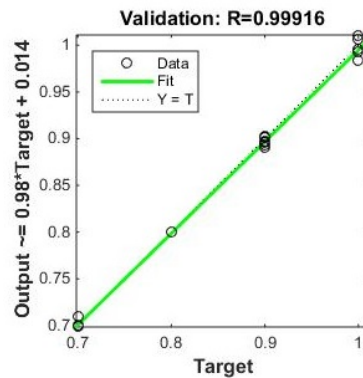


Figura 9: Validação e AI.




Figura 8: Treino e Teste.

As Figuras 8 e 9 demonstram a regressão viabilizada, e os valores dos 4 momentos estão acima dos 0.99, o que demonstra que a função foi projetada de uma maneira correta para o treinamento da rede e do sistema.

Além disso, no Primeiro Apêndice encontra-se os resultados da matriz de confusão. Avaliando o classificador através da matriz de confusão na Figura 15 observa a taxa de acerto do classificador 80,1 % como pode ser visto no ultimo quadro da diagonal principal. Pode-se observar outras duas métricas conforme Tabela 3.

Tabela 3: Métricas do Classificador.

Métrica	Percentual
Acurácia	(80,11 %)
Frequência de Erro	(19,89%)

O bom valor da acurácia a baixa taxa de erro mostra que o sistema de classificação de falhas consegue identificar bem as falhas de potência gerada por um dos motores.

Após tal etapa de classificação com o uso da nova ferramenta, gerou-se modelos de controladores para as situações abordadas na Tabela 2. Assim, modelou-se os controladores conforme a Tabela 4, em que para cada controlador obtém-se também um novo ponto de operação em um nova matriz de parâmetros para o sistema LQR.

A estrutura do sistema de reconfiguração baseado na retroação no sistema é fundamentado no modelo proposto pela Figura 10:

Tabela 4: Controladores ativos.

Controlador	Percentual de Falha
1	(Operação normal)
2	(Falha de 20%)
3	(Falha de 40%)
4	(Falha de 80%)

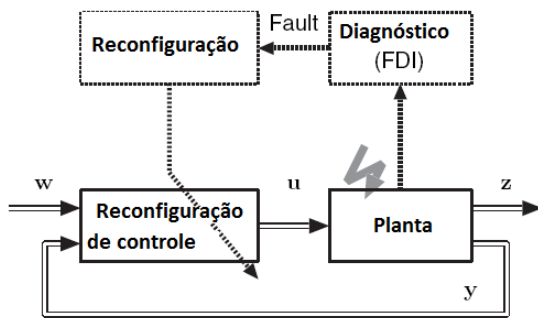


Figura 10: Princípio do Controle proposto.

Contudo, dentro do bloco de controle há um sistema de reconfiguração baseado na lógica *fuzzy* em que foi utilizado a função Gauseana, demonstrada na Figura 11, que fará o chaveamento do controlador mediante as falhas encontradas




Figura 11: Chaveamento por Lógica *Fuzzy*.

A Figura 11 mostra como acontece o chaveamento entre os controladores mediante as falhas, podem ser vistas as marcações denominadas de C1, C2, C3 e C4, que indicam os quatro controladores apresentado. Assim, o sistema de reconfiguração proposto está completo. A Figura 12 representa o sistema após a adição do sistema de reconfiguração de controle auxi-

liado pelo classificador de falhas.




Figura 12: Reconfiguração de Controle.

Ao analisar os Gráficos da Figura 12 observa-se que a variável altura consegue ser controlada com maior eficiência em relação as demais. Apenas quando a falha é de maior intensidade no momento do tempo em cinquenta segundos, por características físicas, afeta de forma drástica o voo do quadrimotor, visto que o mesmo tem que permanecer no ar com basicamente três motores com eficiência máxima e um com apenas vinte por cento de eficiência.

Para uma melhor avaliação da variável altura e do sistema de reconfiguração observa-se nas Figuras 13 e 14 o sistema que é representado por quadrados (Figura 14) como sendo a metodologia proposta e o representado por círculos (Figura 13) o sistema de controle sem reconfiguração de controle para um cenário em que a falha aumenta gradativamente conforme a Tabela 5.




Figura 13: Sistema sem Reconfiguração de Controle.




Figura 14: Sistema com a Reconfiguração de Controle.

A Tabela 5 demonstra o crescimento gradual do percentual de falha.

Tabela 5: Cenário de falhas.

Tempo (segundos)	Perda potência (%)
0 - 15	0
15 - 35	10
35 - 55	20
55 - 75	30
75 - 95	40
95 - 115	50
115 - 135	60
135 - 155	70
155 - 175	80
175 - 195	90
195 - 215	100

Como a proposta deste trabalho é reconfigurar o quadrimotor através do classificador de falhas para evitar perdas com a queda do quadrimotor, pode-se considerar um bom resultado, porém com algumas limitações que são geradas dos dados de um sistema real.

9 Conclusões e Perspectivas futuras

Este trabalho teve como objetivo principal propor uma abordagem para classificação de falhas e reconfiguração de controle em sistemas dinâmicos de forma adaptativa, ou seja, a metodologia proposta reconfigura o sistema de controle de um Drone quadrimotor após a detecção do nível de falha em perda de potência em um dos motores. Assim, após a classificação da falha realizada por uma rede neural, o sistema realiza o chaveamento do controlador mais adequado para a situação classificada através da lógica *fuzzy*.

Os resultados da operação da RNA demonstraram que o sistema teve um bom desempenho para classificar a queda de potência parcial em um dos motores do Quadrimotor. Além disso, como o sistema de reconfiguração necessitou de tais resultados do classificador de falhas para reagir e amenizar os efeitos das falhas, observa-se que os dois sistemas integrados reagiram bem, mantendo o Quadrimotor

por um tempo maior em relação à abordagem sem sistema de reconfiguração.

Ao finalizar o projeto, concluíram-se os objetivos específicos que foram estudar e conhecer as metodologias utilizadas para a detecção e classificação de falhas existentes na literatura e, através de uma análise gráfica evidenciar a estabilidade gerada pela reconfiguração do sistema de controle para amenização do voo após possíveis falhas em um motor do Drone (quadrimotor).

A contribuição deste trabalho foi propor uma nova abordagem de reconfiguração de controle adaptativa, tendo em vista a variável altura como principal. Dessa forma, a abordagem proposta é mais uma opção de sistema de reconfiguração de controle baseado em detecção de falhas em atuadores de VANTs. Analisando os resultados da abordagem proposta na classificação de falhas e na reconfiguração, percebe-se que abordagem proposta é promissora para detecção, classificação e reconfiguração de sistemas dinâmicos.

Futuramente pretendem-se aplicar e avaliar o comportamento e a eficiência da abordagem proposta em um sistema físico do Drone e, além disso, aspira-se à inserção de falhas em mais de um dos motores simultaneamente e falhas também causadas por sensores.

Referências

- AHMED-ZAID, F. et al. Accommodation of failures in the f-16 aircraft using adaptive control. *IEEE Control Systems*, IEEE, v. 11, n. 1, p. 73–78, 1991.
- BEARD, R. *Quadrotor Dynamics and Control*. [S.l.]: Brigham Young University, 2008.
- BRAGA, A. d. P.; CARVALHO, A.; LUDERMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. [S.l.]: Livros Técnicos e Científicos, 2000.
- CAO, W. et al. Overview of electric motor technologies used for more electric aircraft (mea). *IEEE Transactions on Industrial Electronics*, IEEE, v. 59, n. 9, p. 3523–3531, 2012.
- CHEN, F. et al. Self-repairing control of a helicopter with input time delay via adaptive global sliding mode control and quantum logic. *Information Sciences*, Elsevier, v. 316, p. 123–131, 2015.
- COZA, C. et al. Adaptive fuzzy control for a quadrotor helicopter robust to wind buffeting. *Journal of Intelligent & Fuzzy Systems*, IOS Press, v. 22, n. 5, 6, p. 267–283, 2011.
- CUI, Y.-j.; ZHU, H.-y.; LI, Y.-l. Flight control system faults analysis based on grey relation method [j]. *Journal of Sichuan Ordnance*, v. 5, p. 013, 2013.
- CYBENKO, G.; ALLEN, T.; POLITO, J. Practical parallel union-find algorithms for transitive closure and clustering. *International journal of parallel programming*, Springer, v. 17, n. 5, p. 403–423, 1988.
- DIERKS, T.; JAGANNATHAN, S. Output feedback control of a quadrotor uav using neural networks. *IEEE transactions on neural networks*, IEEE, v. 21, n. 1, p. 50–66, 2010.
- EFE, M. Ö. Neural network assisted computationally simple pi d control of a quadrotor uav. *IEEE Transactions on Industrial Informatics*, IEEE, v. 7, n. 2, p. 354–361, 2011.
- GEORGE, V. et al. *Intelligent fault diagnosis and prognosis for engineering systems*. [S.l.]: John Wiley & Sons, Inc, 2006.
- HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. *IEEE transactions on Neural Networks*, IEEE, v. 5, n. 6, p. 989–993, 1994.
- HAJIYEV, C.; CALISKAN, F. *Fault diagnosis and reconfiguration in flight control systems*. [S.l.]: Springer Science & Business Media, 2013. v. 2.
- HAYKIN, S. Adaptive filters. *Signal Processing Magazine*, Citeseer, v. 6, 1999.
- INACIO, M. J. *Diagnóstico de falhas baseado em sistema inteligente evolutivo*. [S.l.]: Universidade Federal de Minas Gerais, 2014.

- JÚNIOR, E. M. da S. *Estimativa de volume de madeira de árvores de eucalipto utilizando redes neurais artificiais do tipo RBF*. [S.l.]: Universidade Federak de Montes Claros, 2016.
- KOHAVI, R.; PROVOST, F. Confusion matrix. *Machine learning*, v. 30, n. 2-3, p. 271–274, 1998.
- LEVENBERG, K. A method for the solution of certain non-linear problems in least squares. *Quarterly of applied mathematics*, v. 2, n. 2, p. 164–168, 1944.
- MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters. *Journal of the society for Industrial and Applied Mathematics*, SIAM, v. 11, n. 2, p. 431–441, 1963.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943.
- MONTOYA, J.; WOOD, Z.; RATHINAM, S. Runway scheduling using generalized dynamic programming. In: *AIAA GNC Conference*. [S.l.: s.n.], 2011.
- OGATA, K. *Ingeniería de control moderna*. [S.l.]: Pearson Educación, 2003.
- PERLMAN, A. How to fly a quadcopter – the ultimate guide. 2016.
- REIS, E. *Estatística Descritiva (6ª ed.)*. [S.l.]: Sílabo, 1994.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, American Psychological Association, v. 65, n. 6, p. 386, 1958.
- RUBERTUS, D. P. Self-repairing flight control systems overview. p. 1280–1286, 1983.
- SHANG, Y.; WAH, B. W. Global optimization for neural network training. *Computer*, IEEE, v. 29, n. 3, p. 45–54, 1996.
- SHEN, Q.; JIANG, B.; COCQUEMPOT, V. Fuzzy logic system-based adaptive fault-tolerant control for near-space vehicle attitude dynamics with actuator faults. *IEEE Transactions on Fuzzy Systems*, IEEE, v. 21, n. 2, p. 289–300, 2013.
- TECNOLOGIA, R. B. de W. *Matriz de Confusão Revista Brasileira de Web: Tecnologia*. Disponível em: <<http://www.revistabw.com.br/revistabw/matriz-de-confusao/>>. Acesso em 05 de Marco de 2017.: [s.n.], 2015.
- VENKATASUBRAMANIAN, V. et al. A review of process fault detection and diagnosis: Part i: Quantitative model-based methods. *Computers & chemical engineering*, Elsevier, v. 27, n. 3, p. 293–311, 2003.

A Primeiro Apêndice




Figura 15: Matriz de confusão