

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

Rodrigo Baleeiro Silva, rodrigobaleeiro@femc.edu.br¹

Jonatas Souza, jonsouza_cea@hotmail.com²

Renato Dourado Maia, renato@femc.edu.br³

Marcos Flávio Silveira Vasconcelos D'Angelo, marcos.dangelo@unimontes.br⁴

¹Faculdade de Ciência e Tecnologia de Montes Claros, Praça da Tecnologia, 77 - São João, Montes Claros.

¹Universidade Estadual de Montes Claros, Avenida Dr. Ruy Braga, S/N - Vila Mauriceia, Montes Claros.

²Faculdade de Ciência e Tecnologia de Montes Claros, Praça da Tecnologia, 77 - São João, Montes Claros.

³Faculdade de Ciência e Tecnologia de Montes Claros, Praça da Tecnologia, 77 - São João, Montes Claros.

³Universidade Estadual de Montes Claros, Avenida Dr. Ruy Braga, S/N - Vila Mauriceia, Montes Claros.

³Universidade Federal de Minas Gerais, Avenida Universitária, 1000, Montes Claros.

⁴Universidade Estadual de Montes Claros, Avenida Dr. Ruy Braga, S/N - Vila Mauriceia, Montes Claros.

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 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

1. Introdução

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 [1] demonstrou o uso de um sistema adaptativo para diagnosticar falhas em um caça F16 com um controle quadrático híbrido. [13] inseriram um *feedback* em controladores LQR e LQG para minimizar as perturbações externas e aumentar a robustez contornando um modelo preditivo. Exemplifica-se assim o controle de processos de voo, onde 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 sistemas 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) [17]. 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 quem 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 [23]. 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 [13].

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 [21]. 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 [6], modelos preditivos, modelos baseados em redes neurais com realimentação da saída como em [10]. Em relação aos trabalhos com Drones os principais desenvolvimentos são vistos em [7], [22], [12], [4]. Em [11], 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 [5] 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.

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 [13] 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 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.




Figure 1: Movimento de Atitude do Quadrimotor

Fonte: [19]

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.




Figure 2: Bases para o Momento de Inércia
Fonte: [2]

Como mostrado na figura 2 drone é essencialmente simétrico em torno de todos os três eixos, por conseguinte [2] 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:

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

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

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

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

Nas equações 1, 2, 3 e 4, é notável as doze variáveis de estados que representam o espaço de estados do drone, e que 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 = Altitude 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.

Table 1: Parâmetros do Quadrimotor real

| Descrição do parâmetro | Parâmetro | Valor |
|---------------------------------------|----------------|--------------------------|
| Massa do quadrimotor | m | 2.24 kg |
| Aceleração da gravidade | g | 9.81 m/s ² |
| Momento de Inércia em torno do eixo x | J _x | 0.0363 Kg.m ² |
| Momento de Inércia em torno do eixo y | J _y | 0.0363 Kg.m ² |
| Momento de Inércia em torno do eixo z | J _z | 0.0615 Kg.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 :

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

Assim, a implementação de um controlador LQR é baseado em determinar uma lei de controle $u = (t)$ que minimize a uma função quadrática $J = f(x, u)$ onde [18] diz que a equação 6 é:

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

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:

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

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

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

Tanto que P satisfaça a equação de Ricatti 9:

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

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

$$J \doteq \int_0^{\infty} (x(t)'Q + K'RK)x(t)dt == x(\infty)Px(\infty) + x(0)'Px(0) \qquad (10)$$

Portanto, considerando um sistema com realimentação estável, tem-se $x(\infty) \rightarrow 0$, concluindo a equação 11:

$$J = x(0)'Px(0) \qquad (11)$$

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 [23] 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. Para [12] Nas últimas décadas foram propostos na literatura, diversos tipos de métodos e técnicas para diagnósticos de falhas, desde métodos baseados em modelos, até os modernos em que são usados dados do processo com emprego de algoritmos da área de inteligência artificial.

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. [23]. 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, onde 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 [15].

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 [23].

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, dendrito, corpo celular e ramificações que são capazes de conduzir o cérebro a um processamento paralelo e contínuo, [16] basearam e propuseram o primeiro neurônio artificial, este foi chamado de MPC. A figura 3 mostra o funcionamento deste modelo proposto.




Figure 3: Neurônio Artificial
Fonte: [16]

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 [3]. 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 onde os pesos determinam a importância deste sinal de entrada, assim de acordo com [3], 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. [20] 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 [14]. A disposição das camadas de uma rede Perceptron Múltiplas Camadas é mostrada na figura 4.

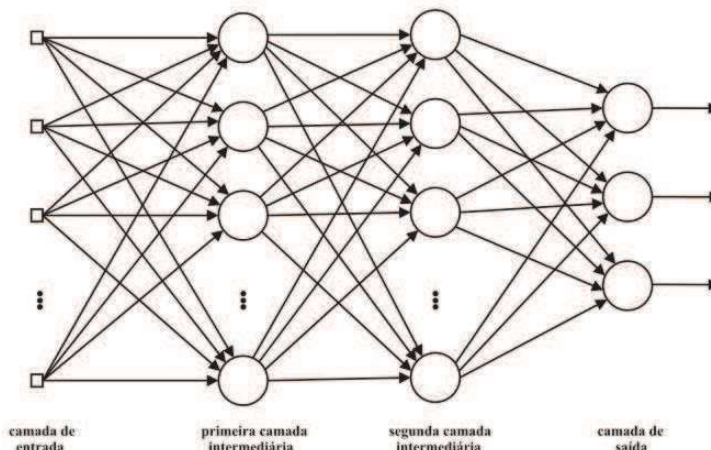


Figure 4: Rede PMC
Fonte: [9]

Como as redes de uma só camada resolvem apenas problemas linearmente separáveis, adotou-se então camadas intermediárias nas redes utilizadas.[8] 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 sigmoideal, a tangente hiperbólica e a função identidade. Assim este acrescentamento dá a rede PMC funções para modelar qualquer tipo de sistema.

6. 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 [17] 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. Na figura 5 é ilustrado o princípio do SRCS em um sistema proposto neste trabalho, levando em conta a dinâmica de um voo, seu controle, as falhas e a detecção proposta.

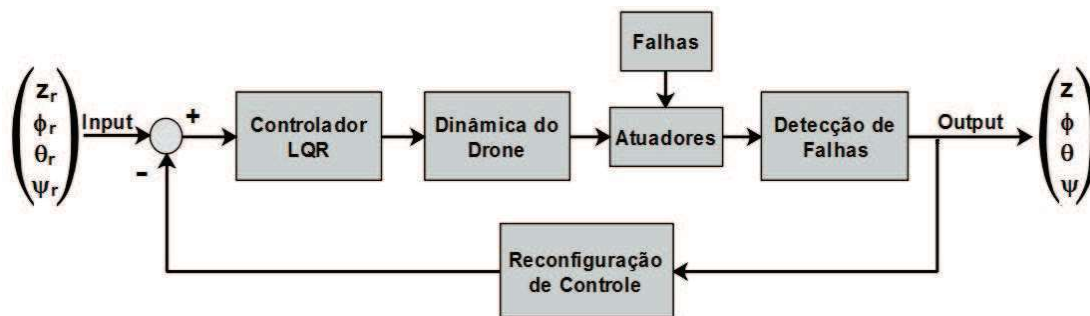


Figure 5: Princípio do Controle com SRCS

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 [13].

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 [13]. Existem trabalhos com uso regras simbólicas e conjuntos fuzzy para realização da reconfiguração de controle. Já [1] 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.

7. 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 6 com as três variáveis altura (h), posição leste (Pe) e posição norte (Pn), mostrando o sistema com falha sem a adição do sistema de reconfiguração 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.



Figure 6: Simulação de falha

Observando os gráficos da 6 nota-se que as falhas inseridas possuem um valor de entrada temporal, os quais são mostrados na tabela 2.

Table 2: Relação de tempo x falha

| Tempo | Falha em percentual de perda de potência em um dos motores |
|----------|--|
| Até 15s | 0% |
| 15 - 30s | 20 % |
| 30 -50s | 40% |
| 50 - 80s | 80% |

Após induzir essas falhas através do modelo matemático gerou-se o treinamento da rede neural (MLP) para utilização na classificação de falhas que será auxiliadora 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 7.

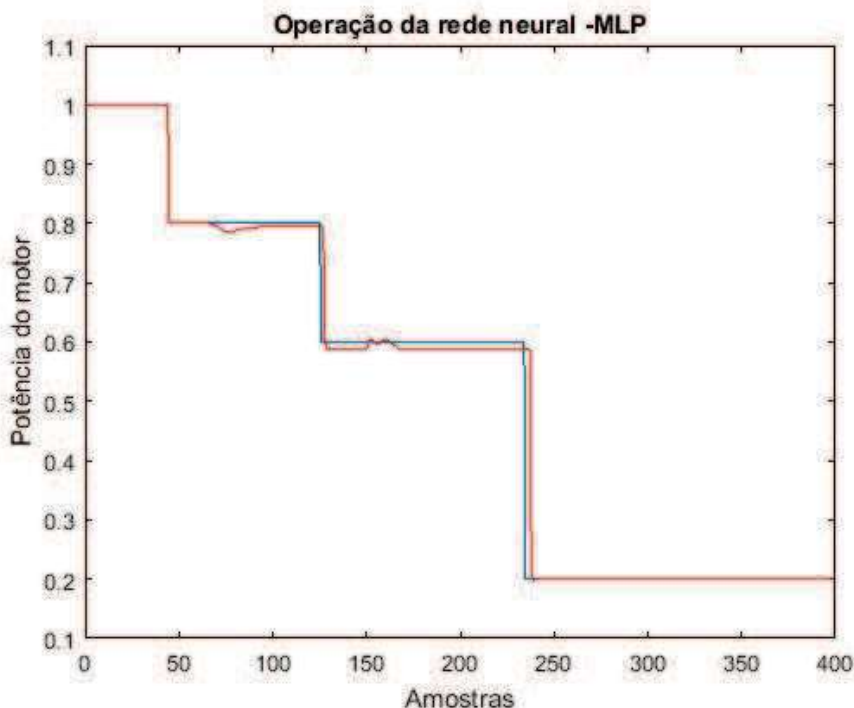


Figure 7: Operação do classificador de falhas

Na figura 7 a linha em azul refere-se a amostra que foi utilizada para treinamento, já na linha vermelha é a operação da rede neural para classificação da falha. Nota-se que para um limiar de erro aceitável o classificar consegue separar as ocorrências de falha no motor do quadrimotor.

Após tal etapa de classificação gerou-se modelos de controladores para as situações abordadas na tabela 2. Assim modelou-se os controladores conforme a tabela 3, em que para cada controlador obtém-se também um novo ponto de operação em uma nova matriz de parâmetros para o sistema LQR.

Table 3: Controladores ativos

| Controlador | Falha em percentual de perda de potência |
|-------------|--|
| 1 | (Operação normal) |
| 2 | (Falha de 20%) |
| 3 | (Falha de 40%) |
| 4 | (Falha de 80%) |

A figura 8 representa o sistema após a adição do sistema de reconfiguração de controle auxiliado pelo classificador de falhas.




Figure 8: Operação do sistema de reconfiguração de controle

Ao analisar os gráficos da figura 8 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.

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.

8. Conclusões e perspectivas futuras

Além de proporcionar um estudo sobre reconfiguração de sistema de controle e classificadores este trabalho conseguiu atingir seu objetivo principal que era a proposta de controlar a altura de voo do drone quadrimotor quando há falhas parciais em um dos motores. Conforme análise dos resultados para falhas de vinte por cento e sessenta por cento na potência de um dos motores o sistema de reconfiguração reagiu bem evitando erros significativos entre o valor desejado e o real da altura. Já com a falha de oitenta por cento houve um erro significativo que está relacionado as características físicas do modelo.

Futuramente, pretende-se expandir o estudo para acrescentar novas pesquisas que abordem lógicas de chaveamento de controladores para evitar erros expressivos no controle da altura quando o drone estiver submetido a falhas com intensidades de perda de potência maiores de sessenta por cento.

References

- [1] Ahmed-Zaid, F., Ioannou, P., Gousman, K. and Rooney, R., 1991. “Accommodation of failures in the f-16 aircraft using adaptive control”. *IEEE Control Systems*, Vol. 11, No. 1, pp. 73–78.
- [2] Beard, R., 2008. *Quadrotor Dynamics and Control*. Brigham Young University.
- [3] Braga, A.d.P., Carvalho, A. and Ludermir, T.B., 2000. *Redes neurais artificiais: teoria e aplicações*. Livros Técnicos e Científicos.
- [4] Cao, W., Mecrow, B.C., Atkinson, G.J., Bennett, J.W. and Atkinson, D.J., 2012. “Overview of electric motor technologies used for more electric aircraft (mea)”. *IEEE Transactions on Industrial Electronics*, Vol. 59, No. 9, pp. 3523–3531.
- [5] Chen, F., Jiang, R., Wen, C. and Su, R., 2015. “Self-repairing control of a helicopter with input time delay via adaptive global sliding mode control and quantum logic”. *Information Sciences*, Vol. 316, pp. 123–131.
- [6] Coza, C., Nicol, C., Macnab, C. and Ramirez-Serrano, A., 2011. “Adaptive fuzzy control for a quadrotor helicopter robust to wind buffeting”. *Journal of Intelligent & Fuzzy Systems*, Vol. 22, No. 5, 6, pp. 267–283.
- [7] Cui, Y.j., Zhu, H.y. and Li, Y.l., 2013. “Flight control system faults analysis based on grey relation method [jj]”. *Journal of Sichuan Ordnance*, Vol. 5, p. 013.
- [8] Cybenko, G., Allen, T. and Polito, J., 1988. “Practical parallel union-find algorithms for transitive closure and clustering”. *International journal of parallel programming*, Vol. 17, No. 5, pp. 403–423.
- [9] da Silva Júnior, E.M., 2016. “Estimativa de volume de madeira de árvores de eucalipto utilizando redes neurais artificiais do tipo rbf”.
- [10] Dierks, T. and Jagannathan, S., 2010. “Output feedback control of a quadrotor uav using neural networks”. *IEEE transactions on neural networks*, Vol. 21, No. 1, pp. 50–66.
- [11] Efe, M.Ö., 2011. “Neural network assisted computationally simple pi d control of a quadrotor uav”. *IEEE Transactions on Industrial Informatics*, Vol. 7, No. 2, pp. 354–361.
- [12] George, V., Frank, L., Michael, R., Andrew, H. and Biqing, W., 2006. *Intelligent fault diagnosis and prognosis for engineering systems*. John Wiley & Sons, Inc.
- [13] Hajiyeve, C. and Caliskan, F., 2013. *Fault diagnosis and reconfiguration in flight control systems*, Vol. 2. Springer Science & Business Media.
- [14] Haykin, S., 1999. “Adaptive filters”. *Signal Processing Magazine*, Vol. 6.
- [15] Inacio, M.J., 2014. “Diagnóstico de falhas baseado em sistema inteligente evolutivo”.
- [16] McCulloch, W.S. and Pitts, W., 1943. “A logical calculus of the ideas immanent in nervous activity”. *The bulletin of mathematical biophysics*, Vol. 5, No. 4, pp. 115–133.
- [17] Montoya, J., Wood, Z. and Rathinam, S., 2011. “Runway scheduling using generalized dynamic programming”. In *AIAA GNC Conference*.
- [18] Ogata, K., 2003. *Ingeniería de control moderna*. Pearson Educación.
- [19] Perlman, A., 2016. “How to fly a quadcopter – the ultimate guide”.
- [20] Rosenblatt, F., 1958. “The perceptron: a probabilistic model for information storage and organization in the brain.” *Psychological review*, Vol. 65, No. 6, p. 386.
- [21] Rubertus, D.P., 1983. “Self-repairing flight control systems overview”. pp. 1280–1286.
- [22] Shen, Q., Jiang, B. and Cocquempot, V., 2013. “Fuzzy logic system-based adaptive fault-tolerant control for near-space vehicle attitude dynamics with actuator faults”. *IEEE Transactions on Fuzzy Systems*, Vol. 21, No. 2, pp. 289–300.
- [23] Venkatasubramanian, V., Rengaswamy, R., Yin, K. and Kavuri, S.N., 2003. “A review of process fault detection and diagnosis: Part i: Quantitative model-based methods”. *Computers & chemical engineering*, Vol. 27, No. 3, pp. 293–311.

9. AVISO DE RESPONSABILIDADE

Os autores são os únicos responsáveis pelo material impresso incluído neste artigo.