

# APLICAÇÃO DE IDENTIFICAÇÃO CAIXA CINZA E ESTIMAÇÃO RECURSIVA NA DETECÇÃO DE FALHA DE UM MOTOR CC SEM ESCOVAS (BLDC)

JOÃO PAULO S. GONÇALVES\*, VICTOR SUGUIITI TANAKA\*, MATEUS GIESBRECHT\*

\**Av. Albert Einstein - 400, Cidade Universitária Zeferino Vaz  
Faculdade de Engenharia Elétrica e Computação (FEEC) - Unicamp  
Campinas, São Paulo, Brasil*

Emails: [jpaulosg@dsif.fee.unicamp.br](mailto:jpaulosg@dsif.fee.unicamp.br), [vstech.tanaka@gmail.com](mailto:vstech.tanaka@gmail.com), [mateus@fee.unicamp.br](mailto:mateus@fee.unicamp.br)

**Abstract**— This article is about the fault detection of a brushless dc motor (BLDC) when one of its power supply phases is lost. The aim is to use the motor mathematical model with recursive estimation algorithms to estimate its physical parameters in the cases where it operates with and without fault. The recursive estimation algorithms are based on the recursive least squares method. From the results obtained in this paper it is concluded that the recursive algorithms are able to detect the fault and the choice of which algorithm to use depends on the application. Besides that, the model, although simple, can be used satisfactorily for fault detection in BLDC machines.

**Keywords**— Fault Detection, Grey Box Identification, Recursive Least Squares, BLDC Motor.

**Resumo**— Neste trabalho se trata sobre a detecção da falha de perda de uma fase de alimentação em um motor de corrente contínua sem escovas (BLDC). O objetivo é utilizar um modelo baseado na física do motor em conjunto com estimadores recursivos para estimar os parâmetros físicos da máquina em operação sem falha e com falha e, a partir da variação dos parâmetros, diagnosticar a presença da falha. Os algoritmos são baseados na forma recursiva do estimador de mínimos quadrados. Ao final conclui-se que os algoritmos são capazes de detectar a falha e que a escolha do algoritmo dependerá da aplicação em questão. Além disso, mostrou-se que o modelo, embora simples, pode ser utilizado satisfatoriamente para detecção da falha de máquinas BLDC.

**Palavras-chave**— Detecção de Falha, Identificação Caixa Cinza, Mínimos Quadrados Recursivo, Motor BLDC.

## 1 Introdução

Com o avanço da tecnologia, os sistemas estão se tornando cada vez mais complexos. Fatores como a automação, a crescente interação homem máquina, redução de custos, eficiência e sustentabilidade estão exigindo sistemas cada vez mais robustos, confiáveis, precisos e eficientes. Devido a isso recorre-se a métodos matemáticos que possam auxiliar na simulação, controle e previsão do comportamento de tais sistemas. Uma das áreas que se utiliza de tais métodos e busca proporcionar maior confiabilidade aos sistemas é o ramo da detecção de falhas. Nesta área estudam-se métodos para prever falhas em sistemas dinâmicos, de modo que essas possam ser previstas rapidamente para que seus efeitos sejam diminuídos ou anulados.

Nas últimas décadas a utilização de modelos matemáticos para diagnóstico e detecção de falhas transformou-se em uma área de estudo muito presente na área de sistemas de controle, pois métodos de identificação de sistemas e filtragem (observadores de estados), controle robusto e o objetivo de desenvolver controladores dinâmicos mais tolerantes a falhas no sistema podem ser aplicados para tais fins. Nas referências (Isermann, 2006) e (Chen and Patton, 1999) é mostrado esta integração entre a teoria de controle automático e a área de detecção de falhas. Os métodos de detecção de falhas baseados em modelos matemáticos tem por objetivo, de forma geral, prever falhas utilizando

o resíduo, que é definido como a diferença entre a saída (ou outra variável) do sistema real e a do modelo estimado, conforme o seu comportamento. Além disso, também são buscados meios de se desenvolver critérios para identificação de falhas que facilitam o diagnóstico e o isolamento da mesma. Geralmente utilizam-se algoritmos recursivos para estimação dos parâmetros do modelo matemático do sistema de forma que possa se identificar a falha online (detectar a falha logo após sua ocorrência). A estimação recursiva para detecção de falhas será o foco deste trabalho utilizando um modelo caixa cinza.

No trabalho se busca apresentar e comparar algoritmos recursivos para detecção de falhas em um motor CC sem escovas (BLDC). A falha tratada é a perda de uma das fases de alimentação do motor (motor trifásico). O procedimento utilizado foi desenvolver um modelo matemático do motor BLDC a partir das relações físicas entre suas grandezas e utilizar algoritmos recursivos para estimar os parâmetros físicos do motor. Este procedimento é conhecido como modelagem e identificação caixa cinza na literatura de identificação de sistemas (Aguirre, 2007). A vantagem da identificação caixa cinza é que ela facilita a escolha da estrutura do modelo e pode ser reproduzida diretamente em qualquer outro sistema com os mesmos princípios físicos (neste caso, outros motores BLDC). Os algoritmos recursivos utilizados são baseados no método de mínimos quadrados e são conhecidos na literatura

tura como mínimo quadrados recursivo com fator de esquecimento exponencial (RLS-Exp) e mínimos quadrados recursivos com reset de covariância (RLS-CR) (Aguirre, 2007), (Ljung and Soderstrom, 1983). Eles foram escolhidos pela simplicidade de implementação e os vários resultados teóricos já existentes sobre os métodos. Buscou-se demonstrar como as variações nos parâmetros podem ser estimadas e analisadas para prever a falha utilizando tais algoritmos. Um critério de erro também foi utilizado para auxiliar na detecção da falha.

O trabalho está dividido da seguinte maneira. Na seção 2 são apresentados os algoritmos recursivos. Na seção 3 é feita a modelagem do BLDC e como o modelo foi utilizado para estimar os parâmetros físicos do motor. Já na seção 4 é apresentada a metodologia experimental e computacional. Na seção 5 são exibidos os resultados das estimativas dos parâmetros juntamente com uma análise estatística do modelo. Na seção 6 apresentam-se as conclusões e pesquisas futuras.

## 2 Estimação de Parâmetros Variantes no Tempo

Nesta seção é apresentado o desenvolvimento dos métodos recursivos utilizados neste trabalho a partir da estimador de mínimos quadrados em batelada.

Em identificação de sistemas dinâmicos lineares, um modelo de regressão linear muito utilizado é o modelo ARX (Auto-regressivo com Entradas Exógenas). A estrutura deste modelo é semelhante a estrutura do modelo caixa cinza da máquina BLDC apresentado na seção 3. Sendo assim, a estimação em batelada do modelo ARX é utilizada como ponto de partida para a dedução dos algoritmos recursivos.

Seja o modelo ARX apresentado na equação (1)

$$y(k) = a_1 y(k-1) + \dots + a_{n_y} y(k-n_y) + b_1 u(k-1) + \dots + b_{n_u} u(k-n_u) + e(k) \quad (1)$$

em que  $y(k)$  e  $u(k)$  são a saída e a entrada no instante  $k = 1, 2, \dots, N$ , sendo  $N$  o número total de amostras,  $a_1, \dots, a_{n_y}$ ,  $b_1, \dots, b_{n_u}$  são os parâmetros a se estimar,  $y(k-1), \dots, y(k-n_y)$ ,  $u(k-1), \dots, u(k-n_u)$  são os regressores e  $e(k)$  é ruído branco. As variáveis  $n_y$  e  $n_u$  representam maior atraso da saída e o maior atraso da entrada. A forma matricial de (1) é mostrada na equação (2) a seguir

$$\mathbf{y} = X\theta + \mathbf{e} \quad (2)$$

em que  $\mathbf{y}$  e  $\mathbf{e} \in \mathbb{R}^N$  são os vetores de saídas e erros concatenados dos instantes 1 a  $N$ ,  $\theta \in \mathbb{R}^{n_y+n_u}$  é

o vetor de parâmetros e  $X \in \mathbb{R}^{N \times n_y+n_u}$  é a matriz de regressores, sendo que cada coluna é um regressor diferente. A estimativa dos parâmetros é dada pela solução do estimador de mínimos quadrados ordinários apresentada em (3).

$$\hat{\theta} = (X^T X)^{-1} X^T \mathbf{y} \quad (3)$$

A solução (3) é uma solução em batelada, pois são usadas todas as  $N$  amostras dos dados. Para estimar parâmetros variantes por este método, seria necessário calcular (3) para todo novo dado disponível. A medida que o número de amostras aumenta, tal fato se torna inviável devido à quantidade de dados a se armazenar e devido ao trabalho computacional elevado necessário para realizar as inversões de matrizes da equação (3). Uma alternativa é utilizar métodos recursivos, contornando assim tais desvantagens. O estimador de mínimos quadrados possui uma forma recursiva que converge para a mesma solução que o estimador em batelada. O algoritmo do estimador de mínimo quadrados recursivo (RLS) é apresentado em (4). A dedução do método pode ser encontrada em (Aguirre, 2007) e também em (Young, 2011).

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \mathbf{g}(k)\varepsilon(k), \quad (4a)$$

$$\varepsilon(k) = y(k) - \mathbf{x}(k)^T \hat{\theta}(k-1), \quad (4b)$$

$$\mathbf{g}(k) = \frac{P(k-1)\mathbf{x}(k)}{1 + \mathbf{x}(k)^T P(k-1)\mathbf{x}(k)}, \quad (4c)$$

$$P(k) = P(k-1) - \mathbf{g}(k)\mathbf{x}(k)^T P(k-1). \quad (4d)$$

em que  $\mathbf{x}(k) = [y(k-1), \dots, y(k-n_y), u(k-1), \dots, u(k-n_u)]^T$  é o vetor de regressores no instante  $k$ ,  $\mathbf{g}(k)$  é o ganho de correção,  $P(k) \in \mathbb{R}^{n \times n}$  é a matriz de covariância da estimação e  $\varepsilon(k)$  é o erro de predição ou inovação.

O algoritmo recursivo (4) é um estimador não polarizado para os parâmetros que possui as mesmas características do estimador em batelada. Caso ocorra uma alteração dos parâmetros do sistema após a convergência do algoritmo, como ocorre no surgimento de falhas em sistemas dinâmicos, a convergência para os novos parâmetros pode demorar a ocorrer. Para isso, pode-se usar artifícios para fazer com que o algoritmo seja mais suscetível a variações de parâmetros. Dois destes são: resetar a matriz de covariância de estimação ou mudar a memória do estimador utilizando uma ponderação exponencial nos dados passados.

O método de resetar a covariância do RLS é baseado no fato que normalmente a convergência inicial do algoritmo RLS (4) é rápida. Quando se inicializa o RLS normalmente se escolhem os valores iniciais dos parâmetros  $\theta_0$  igual a zero e a matriz de covariância inicial  $P_0$  com diagonais em um

valor elevado (ex.  $10^6$ ). Com isso a variação dos parâmetros nas iterações iniciais é grande, permitindo uma rápida convergência. Tal fato pode ser aproveitado de maneira que, dado um critério de mudança, geralmente baseado nos resíduos de estimação (erro de estimação), pode-se resetar  $P(k)$  (covariância atual) para um valor elevado e permitir ao algoritmo que convirja novamente para os novos parâmetros. As principais desvantagens do método são a necessidade da definição de um critério de mudança e o novo valor da covariância, já que eles vão depender da aplicação. Não é recomendado utilizar valores muito elevados como na inicialização, pois isto irá gerar picos elevados na estimativa. Neste trabalho eles foram escolhidos de forma *ad hoc*. O critério de mudança foi baseado na média quadrática dos resíduos por janela deslizante. A covariância foi resetada para um valor não muito alto, mas que garantisse a convergência do algoritmo. Estes fatos são detalhados na seção de metodologia na parte computacional.

O outro método é o RLS com fator de esquecimento exponencial (RLS-Exp). Tal método é muito utilizado devido a sua simplicidade. Ele se baseia no princípio de que dados passados são esquecidos exponencialmente, ou seja, o algoritmo dá mais valor as estimativas geradas por dados mais recentes e descarta a influência de dados mais antigos. O algoritmo é apresentado em (5). Sua dedução e análise de características podem ser encontradas de forma objetiva em (Young, 2011).

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \mathbf{g}(k)\varepsilon(k), \quad (5a)$$

$$\varepsilon(k) = y(k) - \mathbf{x}(k)^T \hat{\theta}(k-1), \quad (5b)$$

$$\mathbf{g}(k) = \frac{P(k-1)\mathbf{x}(k)}{\lambda(k) + \mathbf{x}(k)^T P(k-1)\mathbf{x}(k)} \quad (5c)$$

$$P(k)^* = P(k-1) - \mathbf{g}(k)\mathbf{x}(k)^T P(k-1), \quad (5d)$$

$$P(k) = \frac{1}{\lambda(k)} P(k)^*. \quad (5e)$$

A nova variável  $\lambda(k)$  é o fator de esquecimento e  $k$  explicita que seu valor pode ser constante ou variável no tempo. Valores comuns para  $\lambda(k)$  em regime estacionário ( $k = \infty$ ) variam entre 0.950 e 0.999.

O RLS-Exp também possui algumas desvantagens. A primeira é que devido ao fator de esquecimento  $\lambda$ , o resultado da estimação não converge exatamente para o mesmo resultado da estimação em batelada, mas converge próximo o suficiente. A segunda desvantagem é que  $\lambda$  não pode ser escolhido muito baixo, pois isso deixaria o algoritmo muito sensível a variações causadas pelos ruídos de medição levando a estimativas instáveis. Logo, este é o motivo pelo qual valor estacionário de  $\lambda$  é normalmente escolhido próximo de 1. A terceira desvantagem é que o esquecimento exponencial pode deixar a convergência

inicial lenta se ele for escolhido constante. Na referência (Young, 2011) é proposta a utilização de um  $\lambda$  variável no tempo, em que o fator começa com um valor baixo e converge para o valor estacionário desejado. O método é apresentado em (6). A ideia é que  $\lambda$  comece com um valor inicial  $\lambda_0$  (6c) e convirja para o  $\lambda_\infty$  desejado. Com isso, a influência dos dados iniciais são esquecidas rapidamente, não atrapalhando tanto a convergência do RLS.

$$\lambda(k) = 1 - \gamma(k) \quad (6a)$$

$$\gamma(k) = \frac{1 - \lambda_\infty}{1 - \lambda_\infty^{k+1}} \quad (6b)$$

$$\lambda_0 = \frac{\lambda_\infty}{1 - \lambda_\infty} \quad (6c)$$

Existem outros métodos de estimação recursiva para sistemas lineares. As referências (Young, 2011) e (Ljung and Soderstrom, 1983) são clássicos na área e trazem alguns algoritmos diferentes daqueles apresentados nesta seção.

Sendo assim, neste trabalho serão usados tanto os RLS com resete de covariância (RLS-CR) quanto o RLS-Exp. Um dos objetivos do trabalho é comparar os resultados obtidos por cada um dos algoritmos e observar se há vantagens em utilizar um algoritmo em relação ao outro.

Na próxima seção será tratada a modelagem do motor cc sem escovas (BLDC) para se mostrar como chegar a um modelo caixa cinza que possa ser utilizado para estimar seus parâmetros.

### 3 Modelagem do BLDC

Nesta seção o modelo do motor BLDC é deduzido de forma breve, levando em conta apenas os aspectos relevantes. A dedução é baseada em (da Silva, 2017) e se encontra mais detalhada nessa referência.

O BLDC possui três enrolamentos defasados de 120 graus elétricos no estator, identificados como fases A, B e C, os quais foram ligados em estrela para realização deste trabalho. A tensão em cada fase do motor é dada pela equação (7)

$$V = e_f + Ri_a + L \frac{di_a}{dt}. \quad (7)$$

em que  $V$  é a tensão na fase,  $e_f$  a tensão induzida na fase,  $R$  é a resistência de armadura,  $L$  a soma das indutâncias de magnetização e dispersão e  $i_a$  a corrente de armadura.

A força eletromotriz induzida é dada pela equação (8),

$$e_{fA} = e_{fB} = e_f = k_e \omega_m \quad (8)$$

em que  $k_e$  é a constante elétrica em  $[Vs/rad]$  e  $\omega_m$  a velocidade em  $[rad/s]$ .

Substituindo (8) em (7), pode-se reescrever (7) conforme apresentado em (9). A equação (9) será uma das relações utilizadas para estimar os parâmetros do motor.

$$\frac{di_a}{dt} = -\frac{R}{L}i_a - \frac{k_e}{L}\omega_m + \frac{1}{L}V. \quad (9)$$

A segunda relação utilizada para estimar os parâmetros restantes é obtida através do torque resultante sobre o eixo do motor, que conforme a segunda lei de Newton é dado por (10),

$$\frac{d\omega_m}{dt} = \frac{1}{J}T_e - \frac{k_f}{J}\omega_m - \frac{1}{J}T_L \quad (10)$$

sendo que  $T_e$  é o torque eletromagnético gerado pelo motor,  $J$  o momento de inércia do eixo,  $T_L$  o torque gerado pela carga e  $k_f$  a constante de atrito viscoso (aproximação linear para o atrito viscoso com o ar).

Utilizando ainda a relação para o torque eletromagnético (11),

$$T_e = k_t i_a \quad (11)$$

substituindo (11) em (10) e considerando carga nula, conforme a condição de operação utilizada nos ensaios estudados neste trabalho, chega-se a (12).

$$\frac{d\omega_m}{dt} = \frac{k_t}{J}i_a - \frac{k_f}{J}\omega_m \quad (12)$$

A equação (12) é a segunda relação utilizada para estimar os parâmetros do motor. No entanto, ela cai em um problema de identificabilidade, em que se necessita estimar 3 parâmetros, mas se possui apenas dois parâmetros gerais, que são os termos acompanhando a corrente e a velocidade. Tal problema pode ser contornado partindo da hipótese que o motor não possui perdas, logo a potência elétrica e mecânica são iguais. Com isso, pode-se demonstrar que  $k_e$  e  $k_t$  são iguais, sendo necessário estimar apenas um dos parâmetros.

$$\frac{dy(t)}{dt} = \frac{y(k+1) - y(k)}{\Delta_t}. \quad (13)$$

O resultado da discretização é apresentado em (14) e (15).

$$i_a(k) = \theta_1 i_a(k-1) + \theta_2 \omega_m(k-1) + \theta_3 V(k-1) \quad (14a)$$

$$\theta_1 = \left(1 - \frac{R\Delta_t}{L}\right) \quad (14b)$$

$$\theta_2 = -\frac{k_e\Delta_t}{L} \quad (14c)$$

$$\theta_3 = \frac{\Delta_t}{L}. \quad (14d)$$

$$\omega_m(k) = \theta_4 \omega_m(k-1) + \theta_5 i_a(k-1) \quad (15a)$$

$$\theta_4 = \left(1 - \frac{k_f\Delta_t}{J}\right) \quad (15b)$$

$$\theta_5 = \frac{k_t\Delta_t}{J}. \quad (15c)$$

Com as equações discretizadas é possível a aplicação direta dos algoritmos de estimação de parâmetros apresentados na seção 2, considerando como saídas a corrente e a velocidade no instante  $k$  e as variáveis atrasadas como os regressores.

## 4 Metodologia

### 4.1 Metodologia Experimental

Nesta seção são discutidos os pontos relevantes dos experimentos realizados. Detalhes da implementação podem ser encontrados em (da Silva, 2017). Os dados utilizados para estimação advêm das atividades realizadas por um dos autores deste trabalho conforme a referência (Tanaka, 2017).

Os dados foram coletados utilizando o software Labview e um DAQ modelo NI USB-6008. Os sensores para medição de tensão e corrente foram LV-20P e LA-55P. Um sensor hall foi utilizado para medir a velocidade. Uma placa para condicionamento de sinais foi projetada pelo autor de (da Silva, 2017) para captar os sinais de corrente e tensão de linha do motor. O acionamento do motor é feito por instrumentos virtuais desenvolvidos no Labview. Um esquemático da aquisição e condicionamento de dados é mostrado na Figura 1. A Figura 2 mostra a bancada experimental localizada na FEEC.

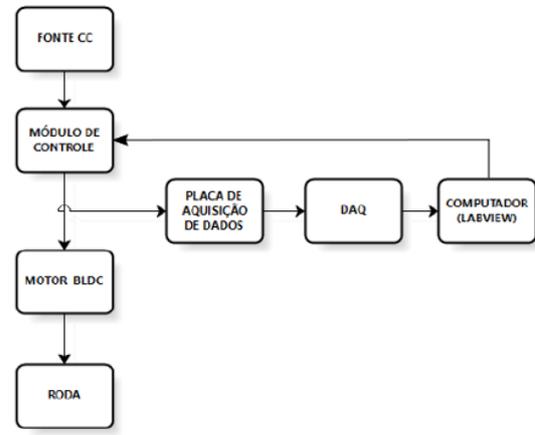


Figura 1: Esquemático de aquisição e condicionamento de dados do BLDC



Figura 2: Bancada Experimental FEEC

A falha foi simulada retirando uma das fases do motor BLDC, o qual estava ligado em estrela. No experimento coletou-se as seguintes variáveis: a tensão entre duas fases (tensão de linha), a velocidade  $\omega_m$  e a corrente de armadura  $i_a$  de uma das fases que não fosse a fase de falha. A tensão de fase  $V$  foi obtida dividindo a tensão de linha por  $\sqrt{3}$ . Os valores médios da tensão e da corrente medidos foram utilizados para estimação. Utilizou-se uma taxa de amostragem de 5Hz (período de amostragem de 0.2 s), a qual mostrou-se suficiente para o trabalho. Os testes no motor foram realizados após o mesmo estar cerca de 20 min ligado para estabilização de sua temperatura. As entradas em cada uma das fases foram do tipo sinal binário pseudo aleatório PRBS. Foram realizado três ciclos periódicos de falha (retirou-se a fase por 3 vezes) com cerca de 5 min cada, sendo que apenas o primeiro foi utilizado para estimação. A Figura 2 mostra o primeiro ciclo de falha para cada um dos sinais medidos. A falha ocorre aproximadamente na amostra 1550.

#### 4.2 Metodologia Computacional

As estimativas em bateladas para os parâmetros durante as operações sem e com falha foram obtidas através do algoritmo de mínimos quadrados utilizando o primeiro ciclo do conjunto de dados e considerando os seguinte intervalos: amostra 1 a 1600 para estimativas de parâmetros da máquina sem falha e amostra 1700 a 3100 com falha. Com estas estimativas gerou-se o intervalo apresentado no resultados para a estimativa em batelada. Na estimação recursiva utilizou-se todo o intervalo de 1 a 3100 amostras para detectar a transição da operação para falha.

Os algoritmos recursivos foram inicializados todos com parâmetros iniciais  $\theta_0$  iguais a zero e covariância inicial  $P_0$  com diagonal principal igual a 100. No algoritmo RLS-CR a covariância é resetada na transição para uma covariância com diagonal principal igual a 1. Tal valor foi escolhido de maneira que se diminuíssem os picos de

transição na estimação pelo RLS-CR e se mantivesse uma taxa de convergência inicial aceitável. No algoritmo RLS-Exp utilizou-se um fator de esquecimento variável no tempo, conforme apresentando na seção 2. O valor estacionário do fator de esquecimento  $\lambda_\infty$  foi escolhido igual a 0.999. Valores abaixo deste ( $<0.990$ ) geraram estimativas muito ruidosas.

O critério para resetar a covariância no RLS-CR foi baseado nos resíduos obtidos pelo RLS normal. O critério foi calcular o valor médio quadrático dos resíduos por janela deslizante (a cada instante de tempo coloca-se a amostra atual e tira a última amostra da janela) considerando uma janela de 300 amostras. O critério é apresentado na seção de resultados. O valor quadrático médio dos resíduos também pode ser estimado de forma recursiva utilizando diretamente as estimativas do algoritmos RLS-CR e RLS-Exp, já que sua forma não se altera a ponto de comprometer a detecção da falha ou o reset da covariância. Para resetar a covariância do RLS-CR foi escolhido uma valor limite do erro quadrático médio por janela da estimativa da corrente, sendo que esse valor limite foi escolhido para ser 4 vezes maior que o valor do critério quando o motor está sem falha (aproximadamente 0.005). Logo, quando o valor do critério fosse  $4*0.005$ , resetava-se a covariância. O reset da covariância se deu na amostra 1690.

## 5 Resultados

### 5.1 Detecção da Falha

Nesta seção são apresentados a análise do modelo desenvolvido de forma estatística, ou seja, analisando os resíduos para os resultados das estimativas em batelada para operação sem falha e com falha do motor. Também é apresentado o critério utilizado para detectar a falha.

Nas Figuras 3 e 4 são mostrado os resíduos das estimativas em batelada para operação do motor sem falha e com falha, considerando as equações discretizadas. A única característica mais aparente é um aumento da variância do erro de estimativa para o caso da máquina em operação de falha.

Uma análise da ACF (função de autocorrelação) dos resíduos sem falha, Figura 5, demonstra que as estimativas podem ser polarizadas e talvez seja necessário modelar o ruído como um processo ARMA (resultando em um modelo ARMAX). A ACF para operação com falha é muito similar a ACF apresentada na 5. No entanto, para análise da falha no motor, a polarização não é tão crítica. Percebe-se que a ACF também não é um parâmetro para detectar a falha do motor.

Sendo assim, outro critério foi utilizado para detectar a falha. Através dos resíduos gerados pela estimativa da corrente e da tensão pela

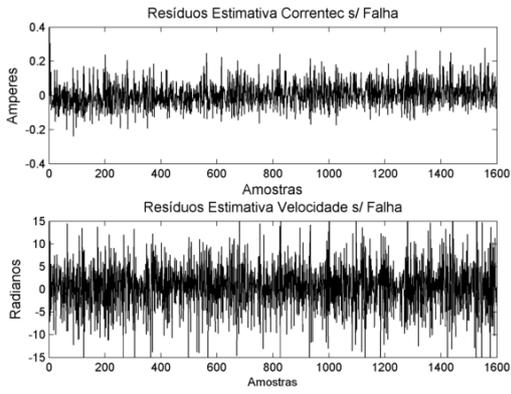


Figura 3: Resíduos estimativas em batelada para a corrente e velocidade operação sem falha

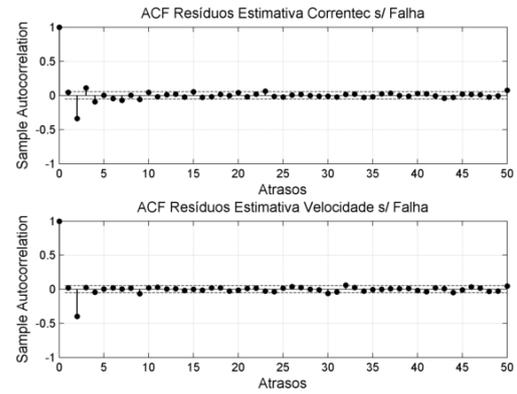


Figura 5: Resíduos estimativas em batelada para a corrente e velocidade operação sem falha

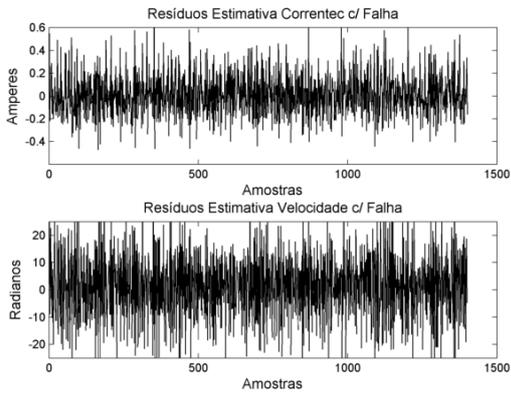


Figura 4: Resíduos estimativas em batelada para a corrente e velocidade operação com falha

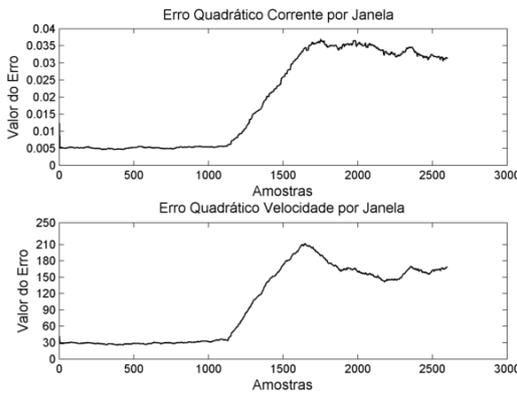


Figura 6: Erro quadrático médio por janela (300 amostras) deslizante do resíduo da estimativa de corrente e velocidade

aplicação do algoritmo RLS normal (4), foi calculado o erro quadrático médio por janela, com uma janela de 300 amostras. Como apresentado na seção 4.2, este critério também foi utilizado para resetar a covariância do RLS-CR. Na Figura 6 o critério é exibido para a estimativa de corrente e de velocidade.

## 5.2 Estimação dos Parâmetros

Esta seção tem por objetivo demonstrar como os algoritmos RLS-CR e RLS-Exp convergem dos valores sem falha (estimativas em batelada) para os valores com falha na transição da condição de operação da máquina. Tal fato é importante, pois podem-se usar as estimativas dos parâmetros para isolar a falha em meio a outras falhas e também para projeto de controladores que consigam compensar a falha. Aqui vale ressaltar a seguinte consideração. A falha introduzida no motor (perda de uma fase) não causa diretamente uma variação física nos parâmetros da máquina. No entanto, o algoritmo captará variações nos parâmetros como um todo indicando uma alteração dinâmica no sistema. Tal fato está ligado diretamente ao modelo matemático, sendo que na perda

de uma fase, o motor estará operando em outro ponto de operação que não é causado diretamente pela variação de um parâmetro, no entanto o estimador tentará adequar as estimativas dos parâmetros aos dados com o intuito de diminuir o erro entre a saída estimada e os dados medidos.

Ao todo 7 parâmetros foram estimados sendo eles a resistência elétrica de armadura  $R$ , a indutância de armadura  $L$ , o momento de inércia do eixo do motor  $J$ , a constante elétrica  $k_e$ , a constante de atrito viscoso  $k_f$ , a constante de tempo elétrica do motor  $\tau_e$  e a constante de tempo mecânica  $\tau_m$ . Os resultados das estimativas para a  $R$ ,  $L$ ,  $k_e$ ,  $k_f$  e  $\tau_e$  são apresentados nas Figuras 7, 8, 9, 10, 11 respectivamente. As estimativas de  $J$  e  $\tau_m$  não variaram na operação de sem falha para falha.

Alguns fatos podem ser analisados pelos resultados obtidos. O primeiro é que basicamente os parâmetros  $J$  e  $\tau_m$  não mudam de forma significativa quando ocorre a falha. A estimativa desses parâmetros não é um bom indicativo para a falha que foi introduzida no experimento. Este resultado de certa forma é esperado, já que a perda de uma fase não interfere diretamente na equação

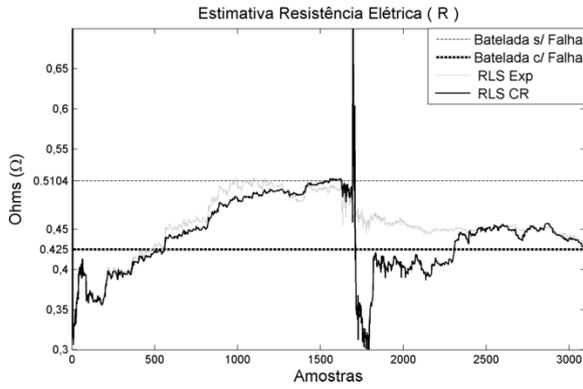


Figura 7: Resultado estimativa resistência elétrica  $R$

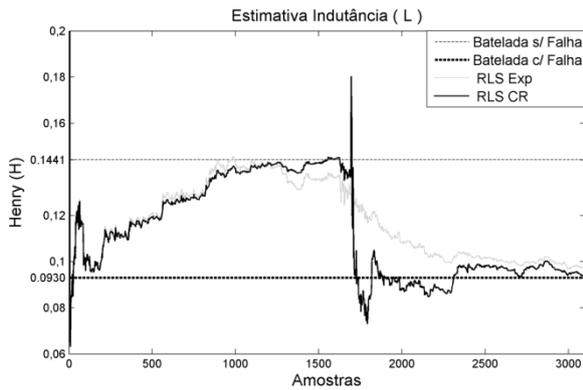


Figura 8: Resultado estimativa indutância  $L$

(12). Entretanto, outros parâmetros tais como  $R$  e  $L$ , apresentam valores muito diferentes nas condições com e sem falha, sendo sua estimativa um indicativo da ocorrência do problema. Isto é esperado uma vez que a falha introduzida é de natureza elétrica e tem impacto direto na equação diferencial (9).

Em relação aos algoritmos, alguns pontos podem ser notados. O algoritmo RLS-CR converge mais rápido que o RLS-Exp. Isto ocorre devido a covariância do RLS-Exp não mudar bruscamente no momento da falha como ocorre no RLS-CR. Uma das desvantagens do RLS-CR são os picos de estimação no momento da transição, como na Figura 7. O RLS-Exp, embora mais lento, possui a vantagem de sua implementação ser mais simples, possuindo apenas um parâmetro de sintonia ( $\lambda$ ) e um custo computacional mais baixo, devido ser necessário também computar o critério de falha do RLS-CR recursivamente.

Em termos gerais, os dois algoritmos conseguem realizar um trabalho satisfatório. O RLS-CR pode ser utilizado quando se possui mais informações sobre o critério de falha e quando há maneiras de lidar com os picos das estimativas. Se o objetivo for apenas identificar e isolar a falha provavelmente o RLS-CR pode trazer resultados melhores. No entanto, se a aplicação está voltada para controle robusto a falhas, ou não possui mui-

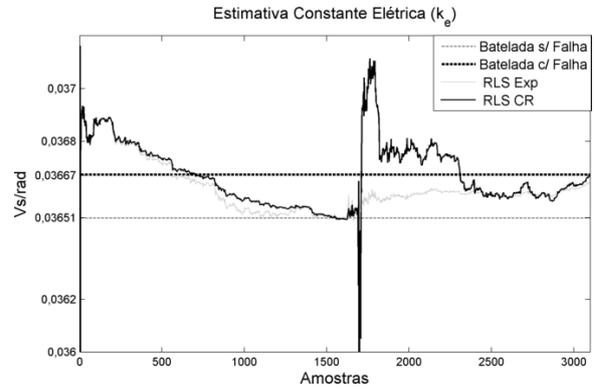


Figura 9: Resultado estimativa constante elétrica  $k_e$

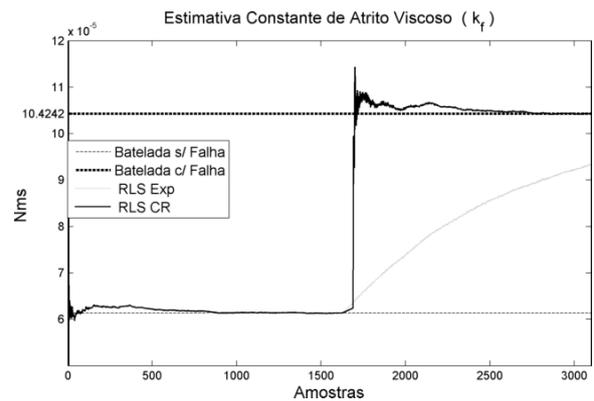


Figura 10: Resultado estimativa constante de atrito viscoso  $k_f$

tas informações a priori, o RLS-Exp é mais indicado devido ao fato de possuir um menor custo computacional, uma transição mais suave nas variações dos parâmetros (picos elevados na estimação levarão a ações de controle agressivas) e uma maior facilidade de implementação.

## 6 Conclusão

O trabalho apresentou a aplicação de algoritmos de estimação recursivos para detecção da falha de falta de uma fase em um motor BLDC utilizando um modelo caixa cinza. O objetivo era demonstrar a implementação de dois algoritmos baseados no algoritmo de mínimo quadrados analisando suas características e também a qualidade do modelo caixa cinza para estimação e previsão da falha. Com as ferramentas e o modelo em mãos, um critério para detecção de falha pelo resíduo das estimativas foi apresentado. Além disso foi demonstrado como os algoritmos recursivos conseguem detectar as variações nos parâmetros físicos da máquina. Conclui-se que, de certa forma, os dois métodos conseguem detectar a falha, mas a escolha para aplicação dependerá do problema em questão. Vale ressaltar que o modelo utilizado é um modelo de certa forma muito

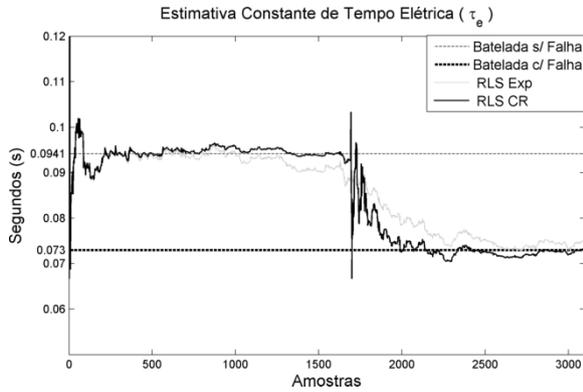


Figura 11: Resultado estimativa constante de tempo elétrica  $\tau_e$

simplificado da máquina BLDC e foi utilizado majoritariamente para demonstrar o comportamento dos algoritmos e demonstrar algumas das vantagens de uma modelagem caixa cinza.

Em pesquisas futuras se buscará melhorar as estimativas dos parâmetros retirando a polarização para analisar se haverá algum ganho de desempenho. Também serão testados os algoritmos em conjunto com outras falhas para se desenvolver critérios de detecção e diferenciação de falhas pelas estimativas dos parâmetros. Além disso, serão aplicados outros algoritmos tais como o filtro de Kalman estendido (Aguirre, 2007) e o método da filtragem de variáveis de estado por mínimos quadrados recursivos (Padilla et al., 2016). Outro ponto a ser tratado futuramente é utilizar um modelo matemático mais fiel ao comportamento da máquina BLDC com objetivo de tornar a identificação, isolamento e controle das falhas mais robusto.

## 7 Agradecimentos

Os autores agradecem a CAPES e FAPESP, pelo apoio financeiro que possibilitou a realização deste trabalho.

## Referências

- Aguirre, L. A. (2007). *Introdução à identificação de sistemas - Técnicas lineares e não lineares aplicadas a sistemas*, Vol. 3, UFMG. ISBN: 9788570415844.
- Chen, J. and Patton, R. J. (1999). *Robust Model-Based Fault Diagnosis for Dynamic Systems*, The Kluwer International Series on Asian Studies in Computer and Information Science, Springer.
- da Silva, R. D. (2017). Identificação de Parâmetros e Projeto do Sistema de Controle de Velocidade de Motores de Corrente Contínua Sem Escovas BLDC. Trabalho de Conclusão

de Curso (Bacharel em Engenharia de Controle e Automação), UNESP (Universidade Estadual Paulista), Sorocaba, Brasil.

- Isermann, R. (2006). *Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance*, Springer.
- Ljung, L. and Soderstrom, T. (1983). *Theory and Practice of Recursive Identification*, The MIT Press.
- Padilla, A., Garnier, H., Young, P. C. and Yuz, J. (2016). Real-time identification of linear continuous-time systems with slowly time-varying parameters, *2016 IEEE 55th Conference on Decision and Control (CDC)*, pp. 3769–3774.
- Tanaka, V. S. (2017). Análise e diagnóstico de falha em motor cc sem escovas (bldc). Projeto de Iniciação Científica processo 2017/08236-4 FAPESP. FEEC (Faculdade de Engenharia Elétrica e Computação), UNICAMP (Universidade Estadual de Campinas), Campinas, Brasil.
- Young, P. (2011). *Recursive Estimation and Time-Series Analysis: An Introduction for the Student and Practitioner*, 2 edn, Springer. ISBN: 978-3642219801.