

Controle preditivo em motor de indução trifásico com uso de filtros lms para estimação de espectro de frequência à baixas frequências de excitação**Predictive control in three-phase induction motor using lms filters for estimation of frequency spectrum at low excitation frequencies**

DOI:10.34117/bjdv6n4-206

Recebimento dos originais: 10/03/2020

Aceitação para publicação: 14/04/2020

David Augusto Ribeiro

Mestrando em Engenharia de Sistemas e Automação pela Universidade Federal de Lavras
Instituição: Universidade Federal de Lavras
Endereço: Câmpus Universitário, Caixa Postal 3037, CEP:37200-000, Lavras - MG - Brasil
E-mail: david.augusto.ribeiro@gmail.com

Juliano Coelho Pereira

Pós Graduação em Gestão da Automação Industrial pelo Centro Universitário Internacional
Instituição: Universidade Federal de Lavras
Endereço: Câmpus Universitário, Caixa Postal 3037, CEP:37200-000, Lavras - MG - Brasil
E-mail: julianopereira@ufla.br

Diego Cardoso Fuzatto

Mestrando em Engenharia de Sistemas e Automação pela Universidade Federal de Lavras
Instituição: Universidade Federal de Lavras
Endereço: Câmpus Universitário, Caixa Postal 3037, CEP:37200-000, Lavras - MG - Brasil
E-mail: diego.fuzatto@ufla.br

RESUMO

Motores de indução tornaram-se extremamente eficientes em diversos processos industriais. Assim, observa-se a necessidade de maior atenção perante suas possíveis falhas, que podem ser estatísticas, rotóricas e mecânicas. Os motores em questão estão sujeitos a todo instante a um dos tipos de falhas, sendo assim, as manutenções preditivas são extremamente essenciais para evitar, tanto as perdas em processos produtivos, quanto em perdas financeiras. Um dos maiores problemas em máquinas rotativas é o defeito de desbalanceamento de massa. Esse defeito implica em esforço excessivo nos mancais causando redução de sua vida útil, sendo assim, é crucial a detecção automática destas falhas e com alto desempenho. Este trabalho tem por objetivo detectar falhas induzidas de desbalanceamento de polias conectadas ao eixo de motores de indução por análise de vibração. Utiliza-se filtros LMS para eliminação de ruídos nos estágios iniciais de acionamento do motor. A detecção de falhas, em todos os casos analisados, foi determinada com desempenho considerável em análises off-line.

Palavras chave: Motores de indução trifásico. Desbalanceamento. Análise de vibração. Ruído. Filtros LMS.

ABSTRACT

Induction motors have become extremely efficient in many industrial processes. Thus, there is a need for greater attention in view of its possible flaws, which can be statoric, rotoric and mechanical. The engines in question are subject at all times to one of the types of failures, therefore, predictive maintenance is extremely essential to avoid both losses in production processes and financial losses. One of the biggest problems in rotating machines is the defect in mass unbalance. This defect implies

excessive effort in the bearings causing a reduction in their useful life, therefore, the automatic detection of these failures and with high performance is crucial. This work aims to detect induced failures of unbalance of pulleys connected to the axis of induction motors by vibration analysis. LMS filters are used to eliminate noise in the initial stages of engine activation. Failure detection, in all cases analyzed, was determined with considerable performance in offline analyzes.

Keywords: Three-phase induction motors. Unbalance. Vibration analysis. Noise. LMS filters.

1 INTRODUÇÃO

Os processos industriais estão cada vez mais competitivos e exigentes, admitem cada vez menos erros em seus processos de execução da produção para garantirem qualidade e quantidade de produto, afinal, cada falha gera uma parada de processo e cada parada de processo traz desconforto para o cliente, perda de dinheiro, dentre diversos outros fatores empresariais. Os motores de indução trifásicos são muito utilizados em diversos processos industriais e podem gerar quebras nas linhas de produção, devido a diversos fatores.

Segundo Pinheiro (2011), os motores de indução trifásicos podem ter vários tipos de problemas, tais como: erros de projetos, sendo ele sub ou superdimensionado; materiais com defeitos: os motores podem possuir parte de seus componentes comprometidos, danificados ou desgastados; processamento e fabricação deficiente: motores fabricados de forma errada, se tornando impróprio para utilização; instalações equivocadas: instalações dos motores feitas sem alinhamento, em locais impróprios; condições de serviço: as condições sendo ruins, por exemplo, em local com alta umidade, excesso de poeiras limalhas, coisas que comprometem a vida útil do motor: manutenção deficiente: tópico essencial, onde não é dada a devida atenção às manutenções de motores, aumentando assim o índice de falhas; operação imprópria: maneira de utilizar os motores errada.

Diante do exposto é evidente a importância de sistemas automáticos de monitoramento de falhas em motores de indução objetivando detectar e classificar os eventos e, posteriormente, determinar as causas e consequências das falhas. Grande parte das indústrias utilizam Motores de Indução Trifásico (MIT) em seu processo produtivo, o que o torna equipamento de vital importância no processo produtivo industrial, uma vez que sua falha implica na parada da produção, bem como em encargos financeiros também decorrentes de sua manutenção corretiva. Sendo assim, faz-se necessário um sistema que tenha capacidade de prever por meio de análise de sinais em tempo real possíveis falhas que possam decorrer durante o trabalho executado por esses motores.

O uso de filtros LMS vem a ser uma abordagem e tem como finalidade a retirada os ruídos que não constituem os sinais considerados como padrões desejados do sistema, e assim possibilita um controle do motor em todas as fases de sua execução, desde baixas até altas frequências. Porém, nota-se que, mesmo com acionamento efetuado por inversores de frequência que permitem um torque controlado e eliminação de picos de corrente partida, ainda há geração de ruídos dos mais diversos

durante o acionamento, o que prejudica uma análise preditiva em tempo real para baixas taxas frequências de excitação do motor. Deste modo: é possível projetar um sistema que venha permitir a detecção de falhas no motor, mesmo nos instantes iniciais de sua partida?

Os filtros adaptativos têm sido largamente citados na literatura, uma vez que possuem a capacidade de adaptar seus coeficientes nas iterações realizadas. Sendo assim, abdica-se da necessidade de desenvolvimento de filtros específicos para cada faixa de frequência, ou para sistemas estacionários. Como comumente utiliza-se sistemas que mudam dinamicamente seus dados de entrada, necessita-se cada vez mais de tecnologias que deem suporte aos mais variados tipos de sistemas. A escolha do modelo LMS se dá em virtude de sua: alta robustez, facilidade de implementação, baixo custo computacional e possibilidade de alta estabilidade quando combinado com filtros IRR ou FIR. Há uma vasta literatura a respeito do filtro LMS em si, porém não lida diretamente com sistemas de Motores Indutivos Trifásicos, nem tampouco, para faixa de baixas frequências de acionamento, sendo mais encontrado estudos a respeito de tratamento e eliminação de ruídos em voz, e pesquisas com análise de espectro de sinais ECG na área médica.

O trabalho objetivou desenvolver um sistema de controle que seja capaz de analisar os sinais de vibração de um motor, e assim, por meio de processamento digital, eliminar os ruídos decorrentes do processo de excitação em baixas frequências. Apresenta-se a elaboração de um sistema em modo *off-line* que adquire dados brutos de aceleração da vibração de um *Motor de Indução Trifásico (MIT) B3D W22 IR2* como entrada, por meio de *sensores acelerômetros NI9234*, baseado na comunicação do sistema físico com software de aquisição de dados *LabView® 2019*. O sistema é capaz de retirar os ruídos provenientes de ressonância gerados no sistema em função das componentes de vibração natural dos materiais. O filtro utilizado é o *LMS (Least Mean Square)*, no qual utiliza vetor de gradientes de pesos para atualizar os coeficientes do filtro ao longo da execução, de modo a minimizar o erro de filtragem ao longo do tempo de análise do sinal.

2 IDENTIFICAÇÃO DE FALHAS

2.1 DESBALANCEAMENTO

Tendo em vista as dificuldades geradas em virtude de paradas de processo industrial devido às falhas, observa-se a necessidade de uma análise aprofundada dos processos, ou parte deles, para que sejam previstas e evitadas as falhas onde as mesmas serão corrigidas preditivamente após análise, ou seja, antes mesmo que a falha ocorra (SPAMER, 2009).

Segundo Oliveira, Carvalho e Moraes (2016), o defeito de desbalanceamento de massa gera um aumento de vibração na frequência de rotação proporcionando demasiados esforços nos mancais dos rotores. Os rotores são componentes de máquinas que operam em uma dada rotação em torno de

um eixo de rotação (ER). Alguns exemplos de rotores desbalanceados estão presentes no cotidiano, como em ventiladores vibrando excessivamente por conta de desbalanceamento e também em volantes de veículos vibrando devido ao desbalanceamento presente nas rodas.

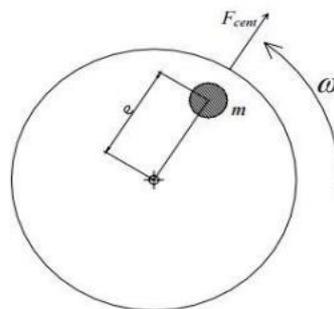
Conforme Sousa (2005), o defeito de desbalanceamento se dá devido a uma distribuição não uniforme da massa do rotor em torno do eixo de rotação. Essas imperfeições na distribuição da massa podem ser causadas por diversas razões, como por exemplos, imperfeições geométricas devido às tolerâncias de fabricação, assimetrias, desgastes e deformações permanentes devidos a efeitos térmicos ou esforços. Os erros de massa, também chamados de pontos pesados, que ocorrem ao longo de um rotor desbalanceado provocam a mudança da posição do centro de gravidade da seção transversal onde contém o erro. O somatório desses desvios dos centros de gravidade resulta no afastamento do eixo principal de inércia (EPI) do eixo de rotação, quebrando assim a condição ideal de coincidência entre esses dois eixos.

Com o movimento do rotor, forças centrífugas são geradas por causa dos pontos pesados presentes. A magnitude dessas forças depende do valor da massa excêntrica, da respectiva distância para o eixo de rotação e da velocidade angular do rotor em radianos por segundos, como mostra a Equação 1 (SOUZA, 2005).

$$F_{cent} = m \cdot e \cdot \omega^2 \quad (1)$$

Onde F_{cent} é a força centrífuga; m é a massa excêntrica; e é a distância da massa em relação ao eixo de rotação; e ω a velocidade angular [rad/s]. A representação gráfica de uma dessas forças analisada separadamente é mostrada através da figura 1.

Figura 1 – Representação gráfica do desbalanceamento de massa



Fonte: Souza (2005)

A combinação de todas as forças centrífugas atuando em um rotor geram resultantes nos mancais cujos módulos e direções dependem das posições em que se encontram os pontos pesados

no rotor (AZEVEDO, 2017). A principal característica do defeito do desbalanceamento é de que ele sempre ocorre na frequência de rotação do rotor. Isso se deve ao fato das resultantes nos mancais girarem solidárias ao rotor (SOUSA, 2005).

2.2 RECONHECIMENTO DE PADRÕES

Reconhecimento de padrões é uma área da ciência cujo objetivo é a classificação de objetos em um número de classes. Dependendo da aplicação, estes objetos podem ser imagens, formas de onda de sinal ou qualquer tipo de medições que necessitam serem distinguidas. O reconhecimento de padrões é uma habilidade extremamente desenvolvida nos seres humanos e em alguns animais. O ser humano é hábil em reconhecer faces, vozes, caligrafias e, até mesmo, estados de humor de pessoas conhecidas (THEODORIDIS; KOUTOUMBAS, 1999).

Entende-se por padrão, as propriedades que possibilitam o agrupamento de objetos semelhantes dentro de uma determinada classe mediante a interpretação de dados de entrada. Entende-se por classe um conjunto de atributos comuns do objeto de estudo. Assim, reconhecimento de padrões pode ser definido como sendo um procedimento em que se busca a identificação de certas estruturas nos dados de entrada em comparação a estruturas conhecidas e sua posterior classificação dentro de classes (TOU; GONZALEZ, 1981).

A ideia é que o grau de associação seja maior entre dados da mesma categoria e menor entre dados de estruturas diferentes. Os dados de entrada são geralmente provenientes de sensores e selecionados segundo o conteúdo de informações relevantes para a decisão. Em geral, os dados passam por um processo de redução de dimensionalidade para que possam ser usados por um classificador, que o designará a classe que melhor o representa (MARQUES, 1999).

Um sistema para reconhecimento de padrões engloba três grandes etapas: representação dos dados de entrada e sua mensuração, extração das características e finalmente identificação e classificação do objeto em estudo. Classificação pressupõe a designação de um objeto a uma determinada classe. O classificador “aprende” a distinguir dentre as classes, aquela à qual o objeto pertence. Padrões de uma mesma classe aglomeram-se em agrupamentos. A figura 2 apresenta uma estrutura típica de um sistema de reconhecimento de padrões (TODESCO, 1995).

Figura 2 - Esquema geral de um sistema de reconhecimento de padrões



Fonte: Todesco (1995)

O sistema ilustrado na figura 2 consiste de sensores e um procedimento de aquisição e tratamento de dados, um algoritmo de extração de características, e um algoritmo de classificação. Complementarmente, é usual que alguns dados que já tenham sido classificados estejam disponíveis para realizar ajustes no sistema. Esse conjunto de dados é chamado de conjunto de treinamento (TODESCO, 1995).

Sobre o classificador escolhido, a matriz de confusão oferece uma medida efetiva do modelo de classificação ao mostrar o número de classificações corretas versus as classificações incorretas para cada classe, sobre um conjunto de n exemplos. Cada coluna da matriz representa as amostras de uma classe prevista, enquanto as linhas representam os casos de uma classe estimada pelo modelo (POZO, 2006).

A matriz de confusão de um classificador ideal possui todos os elementos fora da diagonal iguais a zero uma vez que ele não comete erros. A matriz de confusão possibilita analisar a porcentagem de assiduidade das diversas amostras associadas a uma classe, assim como permite o entendimento e a quantificação das amostras classificadas de forma incorreta (P-N. TAN et al., 2006).

2.3 FILTROS ADAPTATIVOS

O processamento normalmente executado em sinais discretos é a operação conhecida como filtragem. Filtrar um sinal significa selecionar desse sinal, quais frequências são desejadas e quais são indesejadas.

Filtros adaptativos são filtros que mudam e atualizam suas especificações automaticamente a partir da aplicação à qual estão sendo usados, não precisando de nenhuma intervenção do projetista ou usuário. Isso significa que um filtro adaptativo pode mudar sua própria resposta ao impulso (BARBOSA, 2016). Existem diversos algoritmos que servem para atualizar os parâmetros do filtro e um dos mais usados é o LMS que foi utilizado nesse trabalho.

Segundo Haykin (1991), em 1959 Widrow e Hoff derivaram um algoritmo cujo nome era *Least Mean Square* (LMS) em seus estudos de reconhecimento de padrões e até agora é um dos melhores algoritmos de filtragem adaptativa. Este algoritmo é amplamente utilizado para diferentes aplicações, como equalização de canal e cancelamento de eco. Esse algoritmo ajusta os coeficientes de $w(n)$ - *função matemática de pesos* - de um filtro para que se reduza o erro quadrático médio entre o sinal desejado e a saída do filtro. O algoritmo LMS é um tipo de filtro adaptativo conhecido como algoritmo estocástico baseado em gradiente, pois ele utiliza o vetor de gradiente de pesos para convergir para uma solução *Wiener* otimizada.

Pode-se dividir os filtros adaptativos em quatro categorias que apresentam algoritmos de implementação similares, porém suas configurações diferem. As partes gerais desses sistemas são:

uma entrada $x(n)$, um resultado desejado $d(n)$, uma saída $y(n)$, uma função de transferência $w(n)$ e um sinal de erro $e(n)$, que vem da diferença entre uma primeira saída $u(n)$ e a saída real do sistema $y(n)$ (DRUMRIGHT, 1998).

O algoritmo adaptativo dos Mínimos Quadrados (LMS) é o mais utilizado dentre os filtros adaptativos. Os principais motivos da sua vasta utilização são: baixa complexidade computacional, prova de convergência em ambiente estacionário e comportamento estável quando implementado com aritmética de precisão finita. Processamentos digitais de sinais são usualmente utilizados para aplicações como filtragem de ruídos, identificação de sistemas e previsões. Entretanto, os modelos convencionais de processamentos digitais, por vezes, não apresentam um resultado rápido e acurado (BARBOSA, 2016).

Em todo sistema de comunicação o ponto crucial é o transporte do sinal de informação de um ponto onde se localiza o transmissor a outro ponto remoto, onde se localiza o receptor de destino. Até meados da década de 60, devido à natureza analógica dos sinais de informação, esses sinais eram convertidos em formas de onda de corrente ou tensão, e tratados por elementos de circuito (HAYKIN, 1991).

Quando lidamos com filtros, os classificadores são ferramentas de suma importância em redes neurais artificiais. Em controle preditivo, classificadores são utilizados para “treinar” redes que possam aprender sobre suas classes, sendo assim utilizado para reconhecer um padrão de sinal divergente do desejado. As redes neurais artificiais oferecem melhores abordagens para problemas que requeiram: reconhecimentos de padrões; classificação de padrões; associação de padrões; identificação; resistência ao ruído; aproximação de funções e aprendizado (BOHR; BOHR; BRUNAK, 1988).

2.4 METODOLOGIA

2.4.1 Aquisição de Dados

Para se medir a vibração causada pelo desbalanceamento é necessário um sistema de aquisição de dados. Esse sistema é composto por sensores de vibração, como acelerômetros, condicionador de sinais, placa de aquisição A/D e um computador com *software* de aquisição de sinais instalado. A aquisição de dados foi realizada em um motor de indução trifásico de 1 CV, 220 V, 3420 rpm e 60 Hz, comandado por um inversor de frequência *WEG CFW 500* e instalado sobre uma base metálica, conforme figura 3.

O desbalanceamento foi provocado na polia conectada ao eixo do MIT utilizando-se três porcas cujas massas são: 2,122g (porca 1); 4,750g (porca 2); e 6,872g (porca 3). Todas as porcas foram fixadas através de uma fita *hellerman* de 0,234g. As porcas foram posicionadas em dois pontos

diferentes para variar distância da massa em relação ao eixo de rotação, conforme equação 1, visto no item 2.1 sobre desbalanceamento. A figura 3 mostra a configuração de instalação do motor na bancada, bem como o posicionamento do conjunto. A figura 4 mostra as diferentes posições das porcas. A posição mais perto do centro da polia foi nomeada de “*posição 1*” e a outra foi nomeada de “*posição 2*”. Variou-se a frequência de operação do MIT em 20 Hz, 25 Hz, 30Hz, 35 Hz e 40 Hz a fim de verificar o comportamento do sistema em diferentes frequências de operação.

Figura 3 - Instalação do motor de indução trifásico



Fonte: Do Autor (2019)

O desbalanceamento foi provocado na polia conectada ao eixo do MIT utilizando-se três porcas cujas massas são: 2,122g (porca 1); 4,750g (porca 2); e 6,872g (porca 3). Todas as porcas foram fixadas através de uma fita *hellerman* de 0,234g. As porcas foram posicionadas em dois pontos diferentes para variar distância da massa em relação ao eixo de rotação, conforme equação 1 vista anteriormente.

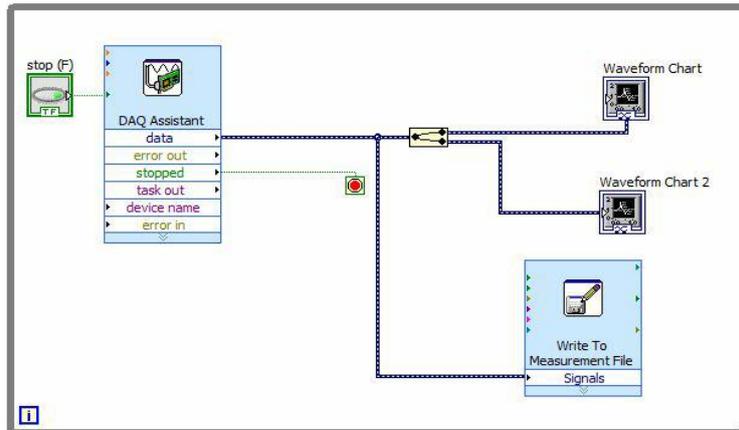
Figura 4 – Posicionamentos das porcas na polia do MIT



Fonte: Do Autor (2019)

O experimento foi desenvolvido segundo o esquemático no *software LabView*® 2019, conforme observa-se na figura 5.

Figura 5 - Sistema de aquisição de dados em LabView



Fonte: Do Autor (2019)

A coleta de dados experimentais foi realizada por meio de dois acelerômetros da *National Instruments*: acelerômetro 1, instalado na carcaça do motor e acelerômetro 2, instalado na base onde o motor foi fixado, conforme figura 6.

Figura 6 - Posição dos acelerômetros instalados



Fonte: Do Autor (2019)

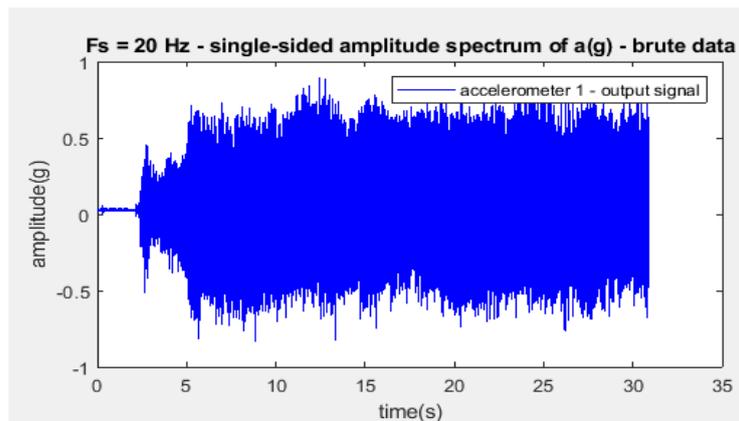
O objetivo da utilização de dois acelerômetros foi comparar a existência de diferenças consideráveis nas medições, devido à posição dos mesmos. Em um ambiente industrial, as dificuldades em se posicionar os acelerômetros devido à maneira como o motor foi instalado pode existir, então considera-se as duas maneiras para chegar mais perto do real, independentemente de como o motor se encontra instalado, a medição poderá ser feita.

2.4.2 Sistema de Monitoramento

O monitoramento de falhas, em geral, compreende basicamente a obtenção de valores de sensores, e a aplicação de algoritmos para extração de variáveis indicadoras da existência de falhas, e para a detecção e classificação em si. Neste trabalho a obtenção de variáveis indicadoras de falhas foi feita a partir dos seguintes parâmetros, considerando o acelerômetro 1: valor máximo da componente fundamental da FFT (Transformada Rápida de Fourier), valor eficaz do sinal, valor máximo do sinal e valor mínimo do sinal. Desta forma, totalizaram-se quatro parâmetros (características) a serem analisados pelo classificador.

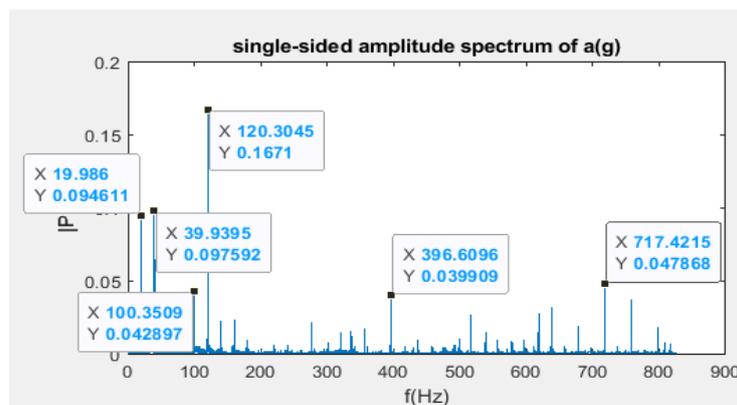
Nesta etapa utilizou-se o *software matlab* ® 2014 para análise dos sinais obtidos. Primeiramente utilizou-se o filtro adaptativo LMS para retirar ruídos nos sinais coletados, uma vez que para excitação em baixas frequências o sistema apresentou instabilidade na detecção dos espectros de frequência do sinal, como pode ser observado nas figuras 7 e 8. O sistema apresenta outras componentes de frequência, bem como ressonância pelo fato da vibração do motor.

Figura 7 – Sinais brutos coletados



Fonte: Do Autor (2019)

Figura 8 – Espectro de Frequência do sinal excitado em 20 Hz.

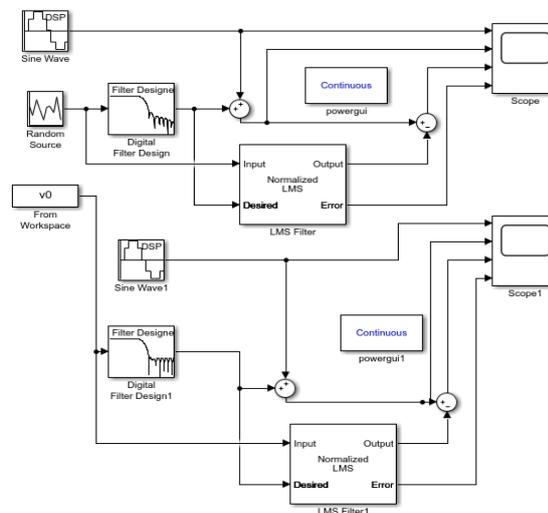


Fonte: Do Autor (2019)

Para filtrar o ruído da entrada melhorando o tratamento dos dados, utilizou-se o *toolbox Simulink matlab* © 2014 para obter o sinal mais próximo do desejado, devido a existência de muitas distorções. O esquemático utilizado é mostrado na figura 9, no qual faz-se o uso de dois modelos, sendo modelo 1 para período de análise de 30 segundos e modelo 2 para período de 60 segundos, na saída no sistema, uma vez que isso facilita a observação do desempenho do filtro para tempos divergentes.

Nesse esquemático utiliza-se excitação de sinal senoidal *sine wave DSP* como sinal desejado. O sinal *random source* é a fonte de ruídos, no quais poluía o sinal de forma a impedir sua identificação. O parâmetro *v0* é a importação dos dados de amplitude em função do tempo da *workspace* do matlab. O bloco *normalized LMS* é um bloco adquirido no Simulink que nos permite configurar internamente com programação e parâmetros desejados de desempenho, nos quais são realizados por tentativa e erro até obtenção de resultados considerados satisfatórios. As junções de soma e subtração são necessárias para manipulação dos sinais como o próprio nome sugere, sendo o *scope* a geração de sinal visual para o usuário que observa e monitora o sistema.

Figura 9 – Esquemático desenvolvido em Simulink



Fonte: Do Autor (2019)

2.4.3 Análise de sinais

Por meio da geração dos sinais, carregados no ambiente *workspace* do *matlab* © 2014, os dados brutos foram convertidos na plataforma *LabView*® 2019 para serem utilizados como entrada do filtro LMS contido na *toolbox Simulink*. É possível verificar 4 seções de processamento de sinais:

- 1) *Signal*;
- 2) *Signal with low frequency noise*;
- 3) *Approximation of input signal*;

4) *Error*.

Em *Signal* há o código do sinal desejado, uma vez que já supomos que conhecemos o comportamento e média de amplitude do sinal que queremos obter.

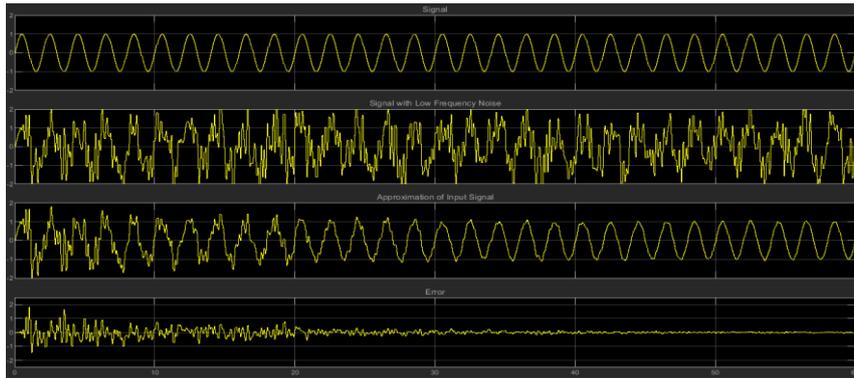
Signal with low frequency noise dá o sinal bruto coletado com os ruídos para baixa frequência de excitação pelo inversor de frequência. São os ruídos decorrentes da vibração dos instantes iniciais de partida do motor, no qual descreve a curva de subida e manutenção de torque nominal para giro do MIT.

Approximation of input signal é a saída do filtro projetado, no qual ao longo do tempo retira os ruídos a cada iteração do gradiente de pesos do algoritmo programado, o que faz com que, em função do tempo o sinal venha tender a estabilizar e identificar as características dos sinal, fazendo com que desde os estágios iniciais de acionamento do motor possibilite uma identificação de falhas de motor que causem alteração na amplitude do espectro de frequência, e/ou amplitude do sinal de excitação, bem como mudanças na fase do sinal.

Error define a taxa de erro em função do tempo para a relação do sinal desejado com o sinal filtrado. É bom salientar que este erro nunca será nulo, uma vez que o filtro permite uma constante aproximação. Portanto, como resultado é interessante que o erro venha a tender a zero, pois assim confirma-se que o algoritmo está retirando os ruídos ao longo do tempo. Se a taxa de erro tender a zero em tempo demasiado longo, é necessário que o projeto seja revisto, uma vez que para esses casos de acionamento precisa-se de sistemas com rápida resposta.

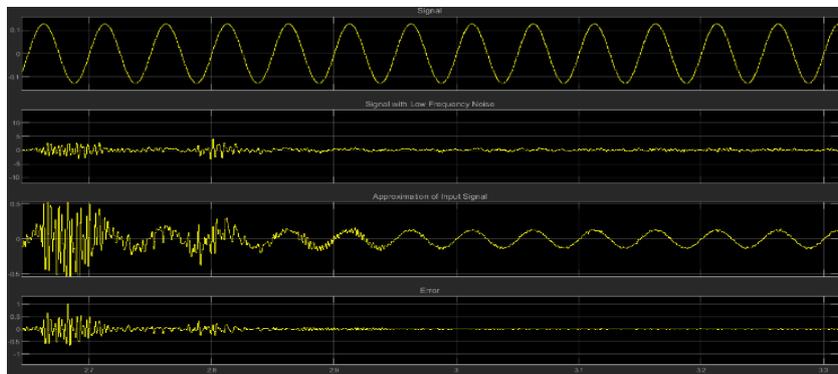
Como verifica-se nas figuras 10 e 11, nota-se que o sinal *Approximation of input* apresenta uma estabilização e capacidade de anulação do ruído logo nos instantes iniciais, o que faz com que o sistema reconheça as informações dos sinais previamente em momento que seria comumente ruidoso. O *Error* do sistema também tende a cair em função do tempo, o que nos garante que as iterações matemáticas convergem para o valor desejado, ou seja, quanto menor o erro, mais ruído foi extraído do sinal poluído. A figura 12 apresenta a matriz de confusão da rede neural MLP. Essa matriz nos mostra o número de classificações corretas versus as classificações incorretas para cada classe analisada. Percebe-se, pela diagonal principal, que não houve confusão quanto à classificação dos dados. Dessa forma obteve-se um empenho de 100% na classificação dos eventos, foi implementada através do software livre *NeuCom Student v0.919* (KASABOV, 2002).

Figura 10 – Filtro LMS para o sistema em range de 60 s



Fonte: Do Autor (2019)

Figura 11 – Filtro LMS para o sistema em range de 30 s



Fonte: Do Autor (2019)

Figura 12 – Matriz de confusão

		Actual Class						
		1	2	3	4	5	6	7
Predicted Class	1	100	0	0	0	0	0	0
	2	0	100	0	0	0	0	0
	3	0	0	100	0	0	0	0
	4	0	0	0	100	0	0	0
	5	0	0	0	0	100	0	0
	6	0	0	0	0	0	100	0
	7	0	0	0	0	0	0	100

Fonte: Do Autor (2019)

3 CONSIDERAÇÕES FINAIS

Modelos como esse são raros na literatura, e conseqüentemente vem agregar à área do conhecimento em processamento de sinais. Um classificador somente é eficiente quando a etapa de pré-processamento e extração de características é bem realizada, pois se houver intersecção entre classes o classificador cometerá erros. Isso nos mostra o quão importante são as fases iniciais de aquisição de dados e tratamentos dos sinais com filtros que possibilitem estabilidade e robustez ao sistema. Portanto um algoritmo de predição só oferecerá resultados satisfatórios se a entrada for confiável do ponto de vista pré-analítico. O escopo do trabalho focou na eliminação dos ruídos, bem como na diminuição do erro em função do tempo com uso de filtro LMS, na finalidade de obter um sistema que seja capaz de prever com robustez e confiabilidade a predição de falhas de motores do tipo MIT. Como observado, o sistema apresentou taxa de erro que convergiram para a zero em função do tempo analisado para baixas frequências de excitação (20 Hz), mostrando que essa categoria de filtros pode ser usada como ferramenta em controle preditivo industriais. Porém, novos estudos são necessários no que tange o tempo de processamento de convergência do algoritmo que poderá ser otimizada em função do tempo de treinamento, e possibilitar ao operador do sistema detectar falhas em menos tempo por meio da análise de sinais, tanto em modo *off-line*, bem como em tempo real.

REFERÊNCIAS

- AZEVEDO, R. S. Desenvolvimento de uma ferramenta virtual para detecção e análise do defeito de desbalanceamento em simulador de máquina rotativa. 80P. Monografia. Universidade de Brasília, UNB, 2017.
- BARBOSA, I. J. T. Aceleração de Algoritmos para Estimativa da Frequência Cardíaca Fetal Utilizando FPGA. Monografia, Universidade de Brasília, UNB, 2016.
- BOHR, H. J.; BOHR, S.; BRUNAK, R.M. Protein secondary structure and homology by neurais networks. FEBS Letters, v.241, n.1, pp. 223-228. 1988.
- DRUMRIGHT, T. Adaptive Filtering. [S.l.], 1998.
- DSP.LMSFILTER. System Object Documentation. [S.l.]. Disponível em: <http://www.mathworks.com/help/dsp/ref/dsp.lmsfilter-class.html>, 2019.
- HAYKIN, S. Adaptive Filter Theory. 2nd Edition. Prentice-Hall Inc., New Jersey, 1991.
- KASABOV, N. Evolving connectionist systems: Methods and Applications in Bioinformatics. Brain Study and Intelligent Machines, Springer Verlag, 2002.
- MARQUES, J. Reconhecimento de padrões métodos estatísticos e neuronais. Portugal: IST Press, 284 p, 1999.

OLIVEIRA, J. P.; CARVALHO, M. O. M. M.; MORAES, M. V. G. Balanceamento de rotores pelo método de otimização four run method accelerated com aplicação em hidrogerador. Revista Interdisciplinar de Pesquisa em Engenharia, v. 2, n. 4, p. 54-73, 2016.

PINHEIRO, H. C. Sistema para Detecção e Diagnóstica de Falhas em Motores Elétricos de Indução Utilizando Lógica Fuzzy. 103 f. Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, Natal, 2011.

POZO, A. T. R. Tópicos Especiais em Inteligência Artificial. 34p. Classificação. pp.13, Universidade Federal do Paraná, UFPR, 2006.

P-N. Tan et al. Introduction to data mining. Noida: Pearson Education India, 165 p., 2006.

SOUSA, W. S. Desenvolvimento de um sistema aplicativo em labview para o monitoramento de máquinas rotativas com um módulo de balanceamento de rotores. 114p. Trabalho de conclusão de curso, Universidade Federal do Pará, Pará, 2005.

SPAMER, F. R. Técnicas Preditivas de Manutenção de Máquinas Rotativas. Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2009.

THEODORIDIS, S.; KOUTOUMBAS, K. Pattern recognition. San Diego: Academic Press, 1999.

TOU, J. T.; GONZALEZ, R. C. Pattern recognition principles. Massachusetts: Addison-Wesley Publishing Company, 399 p, 1981.