

UNIVERSIDADE FEDERAL DE ITAJUBÁ

**PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA**

**Monitoramento de Bombas Submersas, do Tipo
BCSS, Através da Técnica MCSA, para Fins de
Manutenção Preditiva**

Isac Antônio dos Santos Areias

Itajubá, Fevereiro de 2025

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA**

Isac Antônio dos Santos Areias

**Monitoramento de Bombas Submersas, do Tipo
BCSS, Através da Técnica MCSA, para Fins de
Manutenção Preditiva**

**Tese submetida ao Programa de Pós-Graduação em
Engenharia Elétrica como parte dos requisitos para
obtenção do Título de Doutor em Ciências em
Engenharia Elétrica**

Área de Concentração:

Sistemas Elétricos Industriais

Orientador: Prof. Dr. Luiz Eduardo Borges da Silva

**Fevereiro de 2025
Itajubá-MG**

RESUMO

Entre os métodos de elevação artificial empregados em completções submarinas no Brasil, particularmente na produção de óleos pesados e viscosos, o Bombeamento Centrífugo Submerso (BCS) destaca-se por proporcionar um aumento significativo na vazão de produção, podendo alcançar até 100% em comparação com um poço sem esse sistema. No entanto, a falha de uma BCSS (Bomba Centrífuga Submersa Submarina) implica elevados custos operacionais, incluindo intervenções complexas, manutenção dispendiosa e consideráveis perdas financeiras associadas ao lucro cessante. Diante desse cenário, a busca por estratégias que elevem a confiabilidade desses sistemas torna-se fundamental. Visando aprimorar o monitoramento preditivo da *skid*-BCSS/BCSS, este trabalho emprega técnicas de análise da assinatura elétrica, uma abordagem essencial, dado que o acesso físico à máquina em ambiente submarino é extremamente limitado. O estudo propõe a identificação de padrões de falha na assinatura elétrica dos motores responsáveis pelo acionamento da *skid*-BCSS, além da avaliação do potencial de algoritmos de separação de sinais em cenários onde dois motores são alimentados em paralelo por um único cabo. Para lidar com sinais não estacionários, foram aplicadas técnicas avançadas de processamento digital de sinais, incluindo métodos estatísticos. Como parte central do monitoramento, foi desenvolvido um algoritmo Bayesiano de prognóstico, onde os testes foram realizados com sinais de aceleração de um motor de indução trifásico que apresentou uma falha no rolamento, ao decorrer do monitoramento. Os resultados demonstraram que o modelo foi capaz de estimar o tempo restante de vida útil (RUL) do sistema de forma progressivamente mais precisa. Inicialmente, a incerteza nas previsões levou a erros de até 72 horas, os quais foram reduzidos a zero à medida que o momento da falha se aproximava, atingindo sua máxima precisão em um ponto crítico. Embora tenham sido observados pequenos desvios nas últimas estimativas, o impacto prático dessas variações revelou-se insignificante, reforçando a confiabilidade do modelo. Adicionalmente, o algoritmo Bayesiano demonstrou eficácia na identificação da evolução de uma componente espectral do sinal de aceleração associada à degradação do motor, permitindo a correlação entre variações de componente espectral e o desenvolvimento progressivo de falhas no sistema. A técnica de concatenação otimizada de sinais contribuiu para o aprimoramento da resolução espectral, minimizando os problemas decorrentes da perda de estacionariedade dos sinais monitorados. Como continuidade deste estudo, serão realizadas novas análises de prognóstico aplicadas aos sinais elétricos da *skid*-BCSS e da BCSS, com o objetivo de avaliar a antecipação das falhas detectadas pelo modelo em relação a outras técnicas de monitoramento online utilizadas na operação de bombas submersas.

Palavras-chave: MCSA, ESA, RUL, *Skid*-BCSS, Manutenção Preditiva, Inferência Bayesiana.

ABSTRACT

Among the artificial lift methods used in subsea completions in Brazil, particularly in the production of heavy and viscous oils, Electrical Submersible Pumping (ESP) stands out by providing a significant increase in production flow, which can reach up to 100% compared to a well without this system. However, the failure of a Subsea Electrical Submersible Pump (ESP) entails high operational costs, including complex interventions, expensive maintenance, and considerable financial losses associated with lost profits. In this context, the pursuit of strategies to enhance the reliability of these systems becomes essential. Aiming to improve the predictive monitoring of the skid-ESP/ESP system, this work employs Electrical Signature Analysis techniques—an essential approach given the extremely limited physical access to the machine in the subsea environment. This study proposes the identification of fault patterns in the electrical signature of the motors responsible for driving the skid-ESP, as well as the evaluation of the potential of signal separation algorithms in scenarios where two motors are powered in parallel by a single cable. To handle non-stationary signals, advanced digital signal processing techniques were applied, including statistical methods. As a central part of the monitoring strategy, a Bayesian prognostic algorithm was developed. Tests were carried out using acceleration signals from a three-phase induction motor that experienced a bearing failure during monitoring. The results showed that the model was able to estimate the system's remaining useful life (RUL) with increasing accuracy. Initially, uncertainty in the predictions led to errors of up to 72 hours, which were progressively reduced to zero as the moment of failure approached, reaching its highest precision at a critical point. Although small deviations were observed in the final estimates, the practical impact of these variations proved to be negligible, reinforcing the reliability of the model. Additionally, the Bayesian algorithm was effective in identifying the evolution of a spectral component in the acceleration signal associated with motor degradation, enabling the correlation between spectral variations and the progressive development of system faults. The optimized signal concatenation technique contributed to improving spectral resolution, minimizing issues arising from the non-stationarity of the monitored signals. As a continuation of this study, further prognostic analyses will be conducted using electrical signals from the skid-ESP and the ESP, with the objective of evaluating the model's ability to anticipate failures compared to other online monitoring techniques used in the operation of submersible pumps.

Keywords: MCSA, ESA, RUL, Skid-BCSS, Predictive Maintenance, Bayesian Inference.

ÍNDICE DE FIGURAS

- Figura 1 - Elementos principais do motor de BCSS, (2).
- Figura 2 - Exemplo de carta amperimétrica: BCSS operando com gás presente na bomba, (2).
- Figura 3 - Padrão de falha para barras quebradas (11).
- Figura 4 - Padrão de excentricidade estática, (11).
- Figura 5 - Padrão de excentricidade dinâmica, (11).
- Figura 6 - Padrão de excentricidade em baixa frequência, (11).
- Figura 7 - Turbulência ao entorno da componente fundamental no espectro de corrente de uma bomba em cavitação e outra bomba saudável, (12).
- Figura 8 - *Skid*-BCSS (17).
- Figura 9 - Curva de velocidades dos motores de uma *skid*-BCSS.
- Figura 10 - Espectro de corrente de uma *skid*-BCSS.
- Figura 11 - Cinco sinais distintos para a análise no tempo.
- Figura 12 - Cinco sinais distintos para a análise na frequência próximo a fundamental.
- Figura 13 - Mediana do Teste Z para cada um dos 5 sinais
- Figura 14 - Espectros com e sem janelamento.
- Figura 15 - Sinais no tempo com e sem janela.
- Figura 16 - Representação de uma janela retangular nos domínios tempo e frequência (25).
- Figura 17 - Espectros de corrente para 3 tipos de janelas.
- Figura 18 - Diagrama da concatenação otimizada de dois sinais.
- Figura 19 - Espectros para o sinal original e concatenado.
- Figura 20 - Componentes de desequilíbrio rotórico.
- Figura 21 - Fluxograma do algoritmo de prognóstico Bayesiano.
- Figura 22 - Amostragem MCMC.
- Figura 23 - Evolução das componentes espectrais do sinal de vibração.
- Figura 24 - Evolução da componente espectral de 138,5 Hz do sinal de vibração.
- Figura 25 - Amostras iniciais utilizadas na definição do *thresould*.
- Figura 26 - Histograma e distribuição das amostras iniciais.

Figura 27 - Amostras iniciais inseridas no algoritmo MCMC.

Figura 28 - Curva do modelo exponencial (*trueData*) considerando os valores de 'b' e 'a' e dados medidos (*measuData*).

Figura 29 - Trajetória das amostras do algoritmo MCMC, parâmetros 'b' e 's'.

Figura 30 - Histograma das amostras do algoritmo MCMC, parâmetros 'b' e 's'.

Figura 31 - Curvas de degradação, região de cruzamento com o limiar e o histograma de RUL.

Figura 31 - Dados iniciais obtidos pelo sistema de prognóstico.

Figura 33 - Regiões A e B, críticas para o algoritmo de prognóstico.

Figura 34 - Início do prognóstico, com a máquina ainda operando em boas condições.

Figura 35 - Detalhe das curvas do algoritmo no início do prognóstico.

Figura 36 - Algoritmo de prognóstico resumido.

Figura 37 - Evolução do prognóstico na Região A.

Figura 38 - Evolução do prognóstico na Região B.

Figura 39 - Exemplo de cruzamento da curva de degradação com o limiar

Figura 40 - Curvas geradas pelo algoritmo de prognóstico em 10 instantes subsequentes, abrangendo as aquisições de 258 até 267.

Figura 41 - Curvas geradas pelo algoritmo de prognóstico em 10 instantes subsequentes, abrangendo as aquisições de 268 até 277

Figura 42 - Erro de estimativa em horas para os dez instantes.

Figura 43 - Erro de estimativa em termos percentuais do RUL calculado em cada instante.

ÍNDICE DE TABELAS

Tabela 1 – Frequências de vibração característica da BCSS (2).

Tabela 2 – Carta de severidade para barras quebradas, (13).

Tabela 3 – Resultado do algoritmo de prognóstico com a falha na aquisição 362.

LISTA DE ABREVIATURAS E SIGLAS

BCS	Bombeamento Centrífugo Submerso
BCSS	Bomba Centrífuga Submersa Submarina
<i>Skid-BCSS</i>	Bomba Centrífuga Submersa Submarina disposta em um <i>skid</i>
RUL	Tempo restante de vida útil
MCSA	<i>Machine current signature analysis</i>
ESA	<i>Electrical signature analysis</i>
ANM	Árvore de Natal Molhada
RPM	Rotações por minuto
THD	Índice de distorção harmônica
PDF	Função densidade de probabilidade
Db	Decibel
FFT	Transformada Rápida de Fourier
DFT	Transformada Discreta de Fourier
MCMC	Markov Chain Monte Carlo
MH	Algoritmo Metropolis-Hastings

LISTA DE SÍMBOLOS

f_1	Frequência de alimentação em Hz
k	Ordem da harmônica
R	Número de barras do motor
n_{ecc}	Número da ordem da excentricidade
p	Número de polos
n_s	Ordem da harmônica da frequência de alimentação
' f_c '	Frequência característica.
$u(n)$	Sinal original
$w(n)$	Função de janela
$g(n)$	Sinal final
N	Número de amostras
τ	Duração do sinal
$P(\Theta Y)$	Probabilidade condicional
Θ	Parâmetro desconhecido
Y	Variável conhecida
$P(Y \Theta)$	Verossimilhança
$f_{\Theta}(\theta)$	PDF priori do parâmetro do modelo
$f_Y(y)$	PDF priori associada aos dados medidos
X_t	Estado atual
X_{t-1}	Estado imediatamente anterior
Z_i	Nova proposta
$q(\cdot \theta)$	Distribuição auxiliar
' u '	Número aleatório
θ'	Valor proposto
b	Taxa de crescimento da falha
s	Variabilidade dos dados

y_k	Dados medidos
\tilde{y}_k	Previsão do modelo de degradação
jPdf0	Distribuição posterior inicial
jPdf1	Distribuição posterior

SUMÁRIO

RESUMO	i
ABSTRACT	ii
ÍNDICE DE FIGURAS	iii
ÍNDICE DE TABELAS	v
LISTA DE ABREVIATURAS E SIMBOLOS	vi
LISTA DE SÍMBOLOS	vii
SUMÁRIO	ix
1. INTRODUÇÃO	1
1.1. CONSIDERAÇÕES INICIAIS	1
1.2. JUSTIFICATIVA	2
1.3. OBJETIVO E CONTRIBUIÇÕES	4
1.4. METODOLOGIA DE PESQUISA	4
1.5. ORGANIZAÇÃO DO TRABALHO	5
2. REVISÃO BIBLIOGRÁFICA	6
2.1. CARACTERÍSTICAS E PARTICULARIDADES DOS MOTORES UTILIZADOS EM BCSS	6
2.2. FALHAS DA BCSS	9
2.3. DESIGN IMPRÓPRIO DA INSTALAÇÃO (2)	10
2.3.1. Condições do Poço e seus Efeitos na BCSS (2)	11
2.3.2. Problemas Elétricos da BCSS (2)	12
2.3.3. Vibração da BCSS	12
2.4. MÉTODOS DE MONITORAMENTO NÃO INVASIVOS DE BCSS	15
2.4.1. Carta Amperimétrica	17
2.4.2. Análise da Assinatura Elétrica	18
2.5. PADRÕES DE FALHAS EM MCSA	20
2.5.1. Falhas de Barra Quebrada	20
2.5.2. Excentricidade do Entreferro (<i>airgap</i>), (11)	21
2.5.3. Rotação do Eixo	23
2.5.4. Defeitos em Rolamentos	24

2.5.5. Efeitos da Carga – Bomba Centrífuga (11)	24
3. TECNICAS DE PROCESSAMENTO DIGITAL DE SINAIS DEDICADO A ASSINATURA ELÉTRICA DE SKID-BCSS	26
3.1. IMPACTO DA DIFERENÇA DE VELOCIDADE NA IDENTIFICAÇÃO DAS COMPONENTES ESPECTRAIS	31
3.1.1. Aprimoramento da Resolução Espectral: Aumento da Quantidade de Amostras	32
3.1.2. O Problema do Vazamento Espectral e Seus Impactos na Análise	32
3.1.3. Avaliação do Vazamento Espectral Através da Estacionariedade do Sinal	33
3.2. ESTACIONARIEDADE	33
3.2.1. Avaliação do Nível de Estacionariedade	34
3.3. ESTUDO DE JANELAS ESPECTRAIS VOLTADAS À ASSINATURA ELÉTRICA DE SKID-BCSS	38
3.3.1. Impacto do Janelamento no Espectro da Corrente da <i>Skid-BCSS</i>	38
3.3.2. Representação Matemática da Janela Retangular e sua Transformada de Fourier	40
3.3.3. Influência da Escolha da Janela na Resolução Espectral	41
3.3.4. Comparação de Diferentes Tipos de Janelas	42
3.4. CONCATENAÇÃO OTIMIZADA APLICADA EM ASSINATURA ELÉTRICA DE SKID-BCSS	44
3.5. APLICAÇÃO CONJUNTA DAS TÉCNICAS DE JANELAMENTO E CONCATENAÇÃO EM SINAIS DE SKID-BCSS	48
4. ESTIMAÇÃO DA VIDA ÚTIL REMANESCENTE (RUL) POR INFERÊNCIA BAYESIANA	50
4.1. AMOSTRAGEM POR MONTE CARLO VIA CADEIA DE MARKOV (MCMC)	55
4.2. ALGORITMO METROPOLIS-HASTINGS	57
4.3. PROGNÓSTICO VIA INFERÊNCIA BAYESIANA DE COMPONENTES ESPECTRAIS	59
4.3.1. Definição do <i>Threshold</i>	64
4.3.2. Atualização Dinâmica do <i>Threshold</i>	65
4.3.3. Curva de Degradação	66
4.3.4. Amostragem MCMC e o Algoritmo de Prognóstico	66
4.3.5. Construção do <i>Prior</i> e do <i>Likel</i>	71
4.4. RESULTADOS DO PROGNÓSTICO BAYESIANO	75

4.4.1. O Algoritmo de Prognóstico – Região A	82
4.4.2. O Algoritmo de Prognóstico – Região B	85
4.4.3. O Algoritmo de Prognóstico – Região de Falha	88
4.4.4. Resultados Antes do Cruzamento da Curva de Degradação com o Limiar	90
4.4.5. Resultados Após o Cruzamento da Curva de Degradação com o Limiar	94
4.4.5.a. Avaliação Inicial e Comportamento Progressivo do Modelo	94
4.4.5.b. Precisão e Subestimação nas Fases Finais	94
4.4.5.c. Interpretação Detalhada da Figura 41	95
4.4.5.d. Interpretação dos Dados da Tabela 3	96
4.4.5.e. Impactos Operacionais e Relevância dos Resultados	97
CONCLUSÕES	102
REFERÊNCIAS	104

1. INTRODUÇÃO

1.1. CONSIDERAÇÕES INICIAIS

Dentre os métodos de elevação artificial empregados em completações submarinas no Brasil, o *gas lift* tem se consolidado como a tecnologia mais amplamente utilizada. No entanto, quando se trata da produção de óleos pesados e de elevada viscosidade, o Bombeamento Centrífugo Submerso (BCS) destaca-se como uma alternativa altamente eficiente, proporcionando um incremento significativo no potencial de produção. A utilização do BCS pode resultar em um aumento da vazão de até 100% em comparação a um poço que opera sem essa tecnologia, tornando-se uma solução viável para otimizar a extração em determinadas condições operacionais (1). Além disso, o método apresenta uma elevada eficiência energética e, atualmente, corresponde a aproximadamente 10% da produção mundial de petróleo (2).

A implementação do primeiro sistema de BCS Submarino (BCSS), ou seja, um BCS acoplado a uma Árvore de Natal Molhada (ANM), ocorreu em 1994, por iniciativa da PETROBRAS, marcando um avanço tecnológico significativo na indústria de óleo e gás *offshore*. Diante das descobertas de reservatórios de óleo pesado em águas profundas na costa brasileira, bem como da necessidade de viabilizar economicamente a produção em áreas marginais, a PETROBRAS adotou a elevação por BCSS como uma estratégia essencial para a exploração desses campos (3).

O sistema de BCSS apresenta diversas vantagens operacionais e econômicas, entre as quais se destacam (4):

- Antecipação da produção, possibilitada pelo aumento da vazão e da velocidade de extração, otimizando a rentabilidade do campo;
- Maior conhecimento do reservatório, uma vez que a aceleração da produção permite uma melhor compreensão do comportamento do reservatório em menor tempo;
- Viabilização da produção de campos marginais, especialmente aqueles situados a grandes distâncias da costa e em águas profundas, onde métodos convencionais de elevação poderiam ser inviáveis;
- Aumento do fator de recuperação, uma vez que o sistema de bombeamento reduz as pressões de abandono, possibilitando a extração de volumes adicionais de óleo;

- Redução de investimentos em infraestrutura, já que o BCSS permite a utilização de um número menor de poços, além de viabilizar o escoamento da produção a longas distâncias utilizando instalações existentes;
- Maior estabilidade operacional, pois o controle preciso da vazão reduz as flutuações naturais do poço, garantindo uma produção mais constante e previsível;
- Possibilidade de extração de óleos pesados e de alta viscosidade, que, em muitos casos, não poderiam ser economicamente extraídos por outros métodos de elevação.

Apesar das vantagens, a tecnologia de BCSS ainda apresenta desafios significativos, especialmente no que diz respeito à confiabilidade e à durabilidade, que são inferiores às do *gas lift*. Estatísticas operacionais da PETROBRAS indicam que os intervalos médios entre intervenções para reparos e substituições de BCSS variam entre 2 e 2,5 anos, o que representa um fator crítico para a viabilidade econômica da operação. Quando uma BCSS falha, a interrupção da produção resulta em perdas financeiras expressivas, uma vez que o tempo necessário para mobilizar uma sonda, realizar a intervenção e concluir o reparo pode levar, em média, 25 dias, com custos diários que podem atingir até US\$ 400.000 (3).

Diante do impacto financeiro associado às falhas da BCSS, torna-se imprescindível o desenvolvimento de estratégias eficazes de monitoramento da condição operacional desses sistemas. Para isso, estudos vêm sendo conduzidos com o objetivo de aprimorar a confiabilidade e a longevidade da BCSS e do *skid-BCSS*, configuração na qual duas BCSS são instaladas em um equipamento alojador (*skid*). O aprimoramento das técnicas de monitoramento preditivo e diagnóstico de falhas visa minimizar as paradas não programadas e otimizar a gestão da manutenção, contribuindo para a viabilidade econômica e operacional dessa tecnologia em ambientes *offshore*.

1.2. JUSTIFICATIVA

Considerando os elevados custos diários associados às intervenções de manutenção corretiva, bem como as significativas perdas financeiras decorrentes da interrupção da produção (lucro cessante), torna-se essencial o desenvolvimento de sistemas de *skid-BCSS/BCSS* mais potentes, confiáveis e duráveis. Essa necessidade se intensifica diante da perspectiva de depleção de poços na Bacia de Campos, bem como da crescente exploração de reservatórios mais distantes, em lâminas d'água cada vez mais profundas, e com óleos de maior viscosidade.

Diante desse cenário desafiador, torna-se imperativo o aprimoramento das estratégias de monitoramento preditivo desses sistemas, justificando, assim, investimentos contínuos em pesquisa e desenvolvimento nessa área.

Entre as abordagens promissoras para esse fim, destaca-se a Análise da Assinatura Elétrica, tecnologia que constitui o foco deste estudo. A principal vantagem dessa metodologia reside na possibilidade de monitoramento remoto, sem necessidade de acesso direto ao equipamento submarino. Como a BCSS está instalada em um ambiente de difícil acesso, a Análise da Assinatura Elétrica apresenta-se como uma solução naturalmente adequada, pois permite a avaliação contínua das condições operacionais da máquina a partir da superfície, utilizando os sinais elétricos disponíveis na saída do conversor de frequência.

Assim, considerando as particularidades e desafios encontrados em sistemas de bombeamento submarino, torna-se essencial o desenvolvimento de pesquisas que permitam avaliar sua capacidade de detecção de falhas e sua precocidade na identificação de anomalias operacionais. A redução de custos pode ser obtida com a mitigação de falhas inesperadas com o monitoramento contínuo proposto neste trabalho, garantindo maior previsibilidade e segurança às operações de extração de petróleo em ambientes *offshore*.

1.3. OBJETIVO E CONTRIBUIÇÕES

O presente estudo tem como principal contribuição o desenvolvimento de uma tecnologia de monitoramento baseado em prognóstico. Essa abordagem busca viabilizar a avaliação contínua das condições operacionais do sistema, permitindo a identificação precoce de falhas e aprimorando a confiabilidade do equipamento.

Este trabalho propõe alcançar os seguintes itens específicos:

- A identificação e validação de padrões de falha na assinatura elétrica dos motores de acionamento da *skid-BCSS*;
- A avaliação do desempenho de algoritmos de separação de sinais para casos em que dois motores são alimentados em paralelo pelo mesmo cabo elétrico (*skid-BCSS*);
- O tratamento de sinais não estacionários por meio de técnicas de processamento digital de sinais, incluindo abordagens estatísticas para aprimorar a precisão das análises;

- O desenvolvimento de uma ferramenta de prognóstico baseada em um algoritmo Bayesiano espectral, permitindo a estimativa do estado atual e futuro da *skid*-BCSS.

O objetivo deste trabalho reside na aplicação da tecnologia de monitoramento on-line por assinatura elétrica, para estimativa do estado operacional da *skid*-BCSS. Essa ferramenta fornecerá informações essenciais para a análise de falhas, auxiliando na tomada de decisões estratégicas para otimizar a manutenção preditiva e garantir um regime de funcionamento que favoreça a estabilidade e a eficiência operacional da bomba. Outro objetivo é o desenvolvimento da ferramenta de prognóstico Bayesiano, capaz de receber dados de monitoramento on-line.

1.4. METODOLOGIA DE PESQUISA

A metodologia adotada neste estudo envolve uma abordagem estruturada e fundamentada em múltiplas etapas de pesquisa e desenvolvimento, conforme descrito a seguir:

- Revisão bibliográfica: Levantamento das principais técnicas de monitoramento aplicáveis à BCSS, bem como das características construtivas e operacionais desses sistemas.
- Pesquisa e análise de ferramentas de processamento de sinais: Investigação das metodologias que podem auxiliar na Análise da Assinatura Elétrica de *skid*-BCSS, incluindo critérios para avaliação da estacionariedade dos sinais e a aplicação de técnicas de janelamento para aprimoramento espectral.
- Desenvolvimento de uma ferramenta de análise espectral: Implementação de um método para aprimorar a resolução espectral por meio da concatenação de sinais, minimizando as limitações impostas pela perda de estacionariedade.
- Aplicação de técnicas de janelamento e concatenação de sinais: Teste e validação dessas técnicas em dados reais de *skid*-BCSS para garantir sua efetividade na extração de informações relevantes.
- Desenvolvimento de uma ferramenta de prognóstico baseada em um algoritmo Bayesiano espectral: Implementação de um modelo capaz de prever a degradação do sistema ao longo do tempo, integrando informações obtidas a partir da assinatura elétrica.

- Aplicação do algoritmo Bayesiano espectral em um conjunto de sinais de vibração: Teste do modelo em dados experimentais, avaliando sua capacidade de prever falhas com antecedência e fornecer estimativas confiáveis do tempo restante de vida útil (RUL) do equipamento.

Essa abordagem metodológica permite consolidar a aplicação da tecnologia de assinatura elétrica no monitoramento de *skid*-BCSS, oferecendo uma alternativa robusta e eficiente para a detecção e prognóstico de falhas, contribuindo diretamente para o aumento da confiabilidade e disponibilidade desses sistemas em ambientes submarinos.

1.5. ORGANIZAÇÃO DO TRABALHO

O **Capítulo 2** apresenta uma revisão bibliográfica abrangente sobre as características construtivas da BCSS, abordando os principais tipos de falhas associadas a esse sistema e os métodos de monitoramento não invasivos empregados para sua detecção e diagnóstico.

No **Capítulo 3**, são exploradas técnicas de processamento digital de sinais aplicadas à análise da assinatura elétrica da *skid*-BCSS, com foco na identificação de anomalias e degradação do sistema.

O **Capítulo 4** é dedicado à estimação da vida útil remanescente (RUL) por inferência Bayesiana, detalhando os fundamentos teóricos, a modelagem estatística e a aplicação prática desse método para previsão da degradação.

Por fim, o **Capítulo 5** apresenta as conclusões do estudo.

2. REVISÃO BIBLIOGRÁFICA

2.1. CARACTERÍSTICAS E PARTICULARIDADES DOS MOTORES UTILIZADOS EM BCSS

O sistema de Bombeamento Centrífugo Submerso Submarino (BCSS) tem sido amplamente utilizado ao longo das últimas cinco décadas para a extração de grandes volumes de fluidos em condições em que outros métodos de elevação artificial seriam inviáveis. Esse é o caso, por exemplo, da produção de óleos pesados e de alta viscosidade, onde alternativas

como o *gas lift* apresentam limitações operacionais significativas. A eficiência desse sistema decorre, em grande parte, das características construtivas e operacionais do motor que aciona a bomba, as quais diferem substancialmente dos motores de indução trifásicos convencionais utilizados em aplicações industriais, (5).

A Figura 1 apresenta o diagrama esquemático de um motor de acionamento de uma BCSS, que é um motor trifásico de dois polos projetado para operar em condições extremamente desafiadoras dentro do poço de petróleo. Suas características peculiares, quando comparadas a motores convencionais, incluem (2):

- Elevada razão entre comprimento e diâmetro: Diferentemente dos motores tradicionais, cujo dimensionamento pode ser ajustado tanto pelo aumento do diâmetro quanto do comprimento, os motores de BCSS operam dentro de um espaço confinado dentro do poço. Como resultado, qualquer incremento de potência deve ser realizado exclusivamente pelo aumento do comprimento, mantendo o diâmetro o mais reduzido possível.
- Resfriamento por convecção forçada: A dissipação térmica ocorre unicamente pela transferência de calor do motor para o fluido circundante, que se desloca em contato direto com a carcaça do motor. Essa característica elimina a necessidade de sistemas adicionais de resfriamento, mas exige um projeto otimizado para garantir a eficiência térmica.
- Densidade de corrente elevada: Devido às diferenças entre a capacidade térmica do ar e a dos líquidos, a densidade de corrente suportada pelo motor de BCSS pode ser até dez vezes superior à de motores convencionais, sem que isso resulte em sobreaquecimento significativo.
- Baixa inércia e rápida aceleração: O motor da BCSS apresenta uma inércia extremamente reduzida, permitindo que ele atinja sua velocidade operacional em um tempo inferior a 0,2 segundos durante a partida direta.
- Operação em longas distâncias e queda de tensão: Como a BCSS se encontra a elevadas distâncias da superfície, a alimentação elétrica ocorre por meio de cabos submarinos de grande extensão. Isso torna o sistema suscetível a quedas significativas de tensão, que devem ser levadas em consideração no projeto elétrico e na seleção dos conversores de frequência.

- Projeto modular com múltiplos rotores: Diferentemente de motores convencionais, que possuem um único rotor, os motores de BCSS são compostos por dezenas de rotores dispostos ao longo do eixo. Caso fosse utilizado apenas um rotor, a combinação de comprimento elevado e alta velocidade de rotação tornaria o sistema extremamente instável do ponto de vista radial, especialmente devido à ausência de mancais intermediários.
- Uso de mancais radiais distribuídos ao longo do eixo: A vibração radial do motor é um dos desafios mais críticos no funcionamento da BCSS. Para mitigar esse problema, são empregados mancais radiais de deslizamento ao longo de toda a extensão do eixo. Essa configuração reduz significativamente os níveis de vibração e contribui para a estabilidade operacional da bomba.
- Núcleo do estator com material não magnético nos rolamentos: Para minimizar o impacto do campo magnético girante sobre os mancais, o trecho do núcleo do estator que envolve os rolamentos é construído com materiais não magnéticos. Isso reduz as forças magnéticas que atuam nos mancais, prolongando sua vida útil e reduzindo o desgaste mecânico.
- Rolamentos axiais para compensação de carga: Nas extremidades do motor, são instalados rolamentos axiais especializados, projetados para compensar as cargas axiais do eixo e do rotor. Essa configuração é essencial para garantir um funcionamento eficiente e prolongar a durabilidade do equipamento.
- Preenchimento interno com óleo de alta pureza: Todo o interior do motor da BCSS é preenchido com um óleo altamente refinado, cuja densidade varia entre 0,8 e 0,83 g/ml. Esse óleo desempenha múltiplas funções, tais como:
 - Garantir a rigidez dielétrica necessária para o isolamento entre as partes energizadas do motor, evitando falhas elétricas;
 - Proporcionar lubrificação eficiente dos mancais, reduzindo o atrito e prolongando a vida útil dos componentes mecânicos;
 - Atuar como meio de transferência térmica, facilitando a dissipação do calor gerado internamente para a carcaça do motor e, conseqüentemente, para o fluido de produção.

Dessa forma, o motor da BCSS representa uma solução altamente especializada e projetada para operar em condições extremas, garantindo a viabilidade da extração de óleo pesado e de alta viscosidade em águas profundas. Suas características construtivas refletem a necessidade de alta confiabilidade, resistência térmica e estabilidade mecânica, assegurando o desempenho contínuo do sistema e minimizando a necessidade de intervenções corretivas que podem ser extremamente dispendiosas.




Figura 1 - Elementos principais do motor de BCSS, (2).

2.2. FALHAS DA BCSS

As falhas que ocorrem no sistema de Bombeamento Centrífugo Submerso Submarino (BCSS) são frequentemente de natureza elétrica, uma vez que o motor elétrico é o componente mais sensível e vulnerável desse sistema. No entanto, muitas dessas falhas elétricas têm origem em problemas mecânicos, o que torna essencial uma análise precisa para determinar as causas primárias das falhas e implementar ações corretivas adequadas.

A análise de falhas é, portanto, uma ferramenta fundamental para prolongar a vida útil da BCSS, permitindo a identificação antecipada de anomalias e a adoção de medidas preventivas. As falhas podem ter diferentes origens, estando relacionadas a fatores como:

- Condições adversas do poço (corrosão, abrasão por partículas sólidas, formação de gás e temperatura elevada);
- Design inadequado da instalação, que pode resultar em operação fora da faixa ideal de vazão e em esforços mecânicos excessivos nos componentes internos;
- Problemas elétricos, como desbalanceamento de fase, sobretensões e falhas de isolamento nos cabos de alimentação;
- Níveis elevados de vibração, que afetam o desempenho dos mancais, do motor e da bomba, podendo levar a falhas prematuras do sistema.

Dentre esses fatores, a vibração excessiva merece uma atenção especial, pois é uma característica inerente a máquinas rotativas de alta velocidade e pode acelerar significativamente o processo de degradação da BCSS.

2.3. DESIGN IMPRÓPRIO DA INSTALAÇÃO (2)

Um dimensionamento adequado da BCSS é um dos requisitos mais importantes para garantir sua longevidade e desempenho confiável. Quando o sistema é projetado corretamente, os componentes operam dentro das faixas recomendadas de vazão e carga, minimizando desgastes e riscos de falha prematura.

Quando a BCSS opera fora da faixa ideal de vazão, diversos problemas podem surgir, como:

- Redução da eficiência hidráulica da bomba;

- Aumento do desgaste mecânico dos mancais e rotores;
- Sobrecarga térmica no motor elétrico;
- Ocorrência de cavitação e vibrações excessivas no sistema.

Para garantir um design adequado, é essencial que os dados da produtividade do poço sejam confiáveis e que as propriedades do fluido bombeado sejam corretamente especificadas. Caso o projeto original apresente limitações operacionais, uma solução viável é o uso de conversores de frequência. Esses dispositivos permitem ajustar a velocidade de rotação da bomba, possibilitando que a vazão seja mantida dentro dos níveis ideais sem comprometer a integridade do sistema.

2.3.1. Condições do Poço e seus Efeitos na BCSS (2)

As condições do poço exercem um impacto direto sobre a vida útil e a confiabilidade da BCSS. Os principais fatores ambientais que afetam o desempenho do sistema incluem:

- Corrosão: A corrosão é um dos problemas mais graves em sistemas de bombeamento submerso, pois atinge todas as partes metálicas da BCSS, sendo particularmente prejudicial para:
 - A carcaça do motor, comprometendo sua integridade estrutural;
 - A carcaça da bomba, afetando a eficiência da transferência de calor e acelerando o desgaste mecânico dos componentes internos.
- Incrustações nas Superfícies Metálicas: A formação de depósitos sólidos na superfície do motor e da bomba pode provocar falhas severas, tais como:
 - Redução da dissipação térmica do motor, aumentando sua temperatura e podendo levar à queima do enrolamento;
 - Obstrução dos canais de passagem de fluido na bomba, resultando em uma queda progressiva na vazão até o bloqueio completo do fluxo.
- Presença de Areia e Elementos Abrasivos: A entrada de partículas abrasivas no fluido bombeado representa um grande risco para a integridade mecânica da BCSS. Esses elementos podem causar desgaste acelerado e erosão em:
 - Estágios da bomba e seus rotores;
 - Separadores rotativos de gás;
 - Mancais radiais e axiais, cuja degradação pode levar à falha total do sistema.

- Temperatura Elevada do Poço: A operação em temperaturas excessivamente altas pode comprometer a resistência térmica dos isolamentos elétricos do motor, levando à degradação prematura dos materiais dielétricos e, conseqüentemente, à queima do motor.
- Formação de Gás no Fluido Bombeado: O gás dissolvido no fluido pode causar problemas graves, tais como:
 - Desestabilização da operação da bomba, podendo levar a bloqueios de gás e perda da capacidade de bombeamento;
 - Comprometimento do isolamento elétrico dos cabos de alimentação, reduzindo sua rigidez dielétrica e aumentando os riscos de falha elétrica.
- Alta Viscosidade do Fluido: A presença de óleos de alta viscosidade no poço impacta diretamente:
 - A eficiência hidráulica da bomba, aumentando o esforço mecânico necessário para movimentar o fluido;
 - O aquecimento do motor, devido ao aumento do torque e da corrente elétrica requerida para manter a rotação.

2.3.2. Problemas Elétricos da BCSS (2)

Embora a maioria das falhas elétricas tenha origem em problemas mecânicos ou ambientais, falhas estritamente elétricas também podem ocorrer e comprometer o funcionamento da BCSS. Como o sistema elétrico opera em série, qualquer anomalia em um de seus componentes pode levar à falha total do motor e da bomba.

Os principais problemas elétricos incluem:

- Desbalanceamento de fase, que pode causar aumento de temperatura nos enrolamentos e sobrecarga do motor;
- Sobreensões e transientes elétricos, que podem resultar em degradação do isolamento e curto-circuito nos cabos e enrolamentos;
- Descargas atmosféricas e picos de tensão, que podem provocar falhas catastróficas no motor e no sistema de alimentação elétrica.

2.3.3. Vibração da BCSS

A vibração é uma característica inerente a sistemas de bombeamento de alta rotação e pode comprometer a integridade estrutural da BCSS. Ela se propaga pelo sistema através do eixo e pode causar falhas prematuras em diversos componentes.

As principais causas de vibração incluem, (6):

- Desbalanceamento de massa nos elementos rotativos, provocado por:
 - Irregularidades na distribuição de densidade do material;
 - Configuração assimétrica das partes móveis;
 - Excentricidade no eixo e nos mancais.
- Vibrações de origem hidráulica, resultantes de:
 - Operação fora da faixa de vazão recomendada;
 - Presença de gases no fluido bombeado;
 - Bombeamento de fluidos de elevada viscosidade.
- Instabilidade nos mancais de deslizamento, quando sujeitos a cargas muito baixas, levando à formação de vórtices no óleo lubrificante.
- Mancais mal fixados, que podem girar junto com o eixo, comprometendo a estabilidade do sistema.
- Atrito mecânico entre partes estacionárias e girantes, induzindo vibrações indesejadas.
- Oscilações elétricas, resultantes de falhas no sistema de alimentação ou do dimensionamento inadequado do conversor de potência afetam a estabilidade do fornecimento de energia ao motor, podendo gerar esforços mecânicos irregulares e comprometer a integridade do equipamento. Dentre os principais fatores que intensificam esse fenômeno, destacam-se:
 - Conversor de frequência com filtro harmônico subdimensionado: A insuficiência do filtro harmônico pode resultar na injeção de componentes harmônicas indesejadas na rede elétrica, levando a distorções na forma de onda da tensão e corrente. Esse fenômeno pode gerar esforços torcionais irregulares

no motor da BCSS, amplificando as vibrações e aumentando o desgaste de componentes mecânicos.

- Transposição insuficiente de fases no cabo umbilical: A ausência de uma transposição adequada entre as fases do cabo umbilical pode causar um desequilíbrio na distribuição de corrente elétrica, resultando em um desbalanceamento na alimentação do motor. Esse desbalanceamento induz esforços eletromecânicos assimétricos, intensificando as vibrações e potencialmente reduzindo a vida útil do sistema.
- Conversor de frequência com quantidade insuficiente de células: Um conversor operando com um número reduzido de células pode apresentar um nível elevado de componentes harmônicas na tensão e na corrente elétrica. Esse efeito contribui para o aumento das componentes de sequência negativa, que geram pares de forças alternadas no rotor do motor. Como consequência, ocorre um incremento nas vibrações e uma maior solitação dos rolamentos e demais elementos mecânicos da BCSS, podendo levar a falhas prematuras.

A identificação dessas anomalias pode ser feita através da análise da frequência das vibrações, permitindo correlacioná-las com falhas específicas. A Tabela 1 apresenta as frequências típicas associadas a cada tipo de falha da BCSS, (2).

Tabela 1 – Frequências de vibração característica da BCSS (2).

Componente da BCSS	Frequências Típicas	Possíveis causas
Rotor e eixo	1 ou 2 X RPM	Eixo empenado
Todas as partes girantes	1 X RPM	Desbalanço hidráulico ou de massa, ou rotor excêntrico
Acoplamento, eixo, mancais	1 a 2 X RPM (3 X RPM)	Desalinhamento do acoplamento e/ou do rolamento do eixo
Mancal de deslizamento radial	$< \frac{1}{2} X$ RPM	Vórtices no óleo com o mancal operando em baixa carga
Mancal axial	$> 5 X$ RPM	Atrito excessivo, lubrificação insuficiente, montagem com folga insuficiente
Atrito mecânico	$\frac{1}{3}$ a $\frac{1}{2} X$ RPM	Contato entre as superfícies das partes fixas e girantes
Casquilho do mancal de deslizamento radial	$\frac{1}{2} X$ RPM	Rotação do casquilho junto com o eixo
Motor	1 X RPM	Rotor excêntrico

A vibração na Bomba Centrífuga Submersa Submarina (BCSS) é um fenômeno complexo que pode resultar da atuação de um único tipo de vibração ou de uma combinação de múltiplos fatores. A presença de vibração excessiva pode comprometer a estabilidade operacional da bomba, acelerando o desgaste dos componentes e reduzindo sua vida útil. Os principais tipos de vibração que podem ocorrer na BCSS são os seguintes:

- **Vibração Axial:** Essa vibração ocorre ao longo do eixo da bomba e pode ser particularmente prejudicial aos componentes que suportam cargas axiais. O rolamento axial da bomba, do motor e do protetor são os elementos mais impactados, pois são responsáveis por absorver as forças geradas nessa direção. O aumento da vibração axial pode indicar desalinhamentos, problemas de carga ou desgaste excessivo dos componentes internos.
- **Vibração Radial:** Este tipo de vibração é especialmente crítico devido à sensibilidade do longo eixo da BCSS à estabilidade radial. Como a bomba opera a elevadas rotações,

qualquer desvio na estabilidade pode resultar no contato inadequado dos mancais radiais com o eixo, gerando desgaste acelerado e, conseqüentemente, falha prematura do sistema. Se não controlada, a vibração radial pode levar ao colapso estrutural da bomba e à interrupção total do funcionamento do equipamento.

- Vibração Torsional: Esse tipo de vibração ocorre devido à torção do eixo da bomba, sendo mais comum durante as partidas do motor e em situações de variação brusca de carga. Quando a bomba opera próxima ao limite da capacidade de carga do eixo, a incidência de vibração torsional pode levar à sua ruptura ou torção excessiva, comprometendo a operação do equipamento. Esse tipo de falha é crítico, pois pode resultar na necessidade de substituição completa do eixo e de outros componentes associados.

2.4. MÉTODOS DE MONITORAMENTO NÃO INVASIVOS DE BCSS

O correto dimensionamento e instalação da BCSS são fatores essenciais para garantir seu desempenho adequado. No entanto, mesmo em condições ideais de projeto, a vida útil do equipamento será determinada em grande parte pela maneira como ele é operado e monitorado ao longo do tempo. Para maximizar a eficiência da bomba e prevenir falhas inesperadas, é fundamental a implementação de técnicas de monitoramento contínuo, permitindo a identificação precoce de problemas e possibilitando ações corretivas antes que danos severos ocorram.

Os sistemas de monitoramento modernos utilizam instrumentação permanentemente instalada ao longo da estrutura da BCSS para coletar e analisar dados operacionais em tempo real. Os principais parâmetros monitorados são, (7):

- Pressão: Permite avaliar a condição do reservatório e o desempenho da bomba;
- Temperatura: Indica possíveis sobrecargas térmicas e problemas de dissipação de calor;
- Fluxo: Ajuda a monitorar a eficiência da extração e detectar obstruções ou vazamentos;
- Vibração: Fornece informações sobre possíveis desalinhamentos, desgaste de componentes e presença de cargas excessivas.

Apesar de o sinal de vibração ser coletado, ele é utilizado apenas como tendências (nível RMS da aceleração) e indica apenas o início de possíveis problemas quando o nível de vibração excede o nível de alarme. Portanto, a causa da falha não pode ser determinada sem o emprego

de um sistema adicional de análise de vibrações. Além disso, o monitoramento de vibrações é inviável de ser implementado devido à profundidade, temperatura e pressão do poço. Outro problema nesta análise é a necessidade do posicionamento preciso do sensor de vibração, visto que o nível de vibração sofre grandes variações com o deslocamento do posicionamento do sensor ao longo da carcaça do motor (2,8).

Diante dessas dificuldades, um método alternativo e não invasivo para monitoramento da BCSS é a análise do sinal de corrente e tensão do motor. Esse método apresenta vantagens como, (7):

- Baixo custo, pois não requer a instalação de sensores dentro do poço;
- Maior praticidade, pois os sensores são instalados na superfície, conectados apenas na alimentação elétrica do motor;
- Monitoramento contínuo, sem necessidade de interrupção da operação da bomba para a aquisição dos dados.

Este tipo de análise possibilita a identificação de padrões de consumo de energia e variações no funcionamento da BCSS, fornecendo indícios indiretos sobre o estado mecânico e operacional da bomba.

2.4.1. Carta Amperimétrica

Os problemas operacionais que afetam a BCSS frequentemente resultam em falhas elétricas, tornando o monitoramento contínuo da corrente de alimentação uma ferramenta indispensável para garantir a integridade do equipamento. A variação da corrente elétrica pode fornecer informações valiosas sobre o estado operacional da bomba, permitindo a detecção precoce de falhas e a adoção de medidas preventivas antes que ocorra um colapso total do sistema.

O monitoramento da corrente pode ser realizado por meio de um gravador de sinal de corrente, que recebe os dados de um transformador de corrente acoplado a uma das fases da alimentação elétrica da BCSS. Esses dados são então analisados para identificar padrões anômalos no consumo de energia, que podem estar associados a problemas como:

- Desgaste de componentes internos;
- Presença de gás na bomba;

- Obstrução ou redução na vazão do fluido bombeado;
- Desbalanceamento ou desalinhamento da bomba e do motor;
- Variações bruscas de carga e torque.

Na análise amperimétrica, o sinal de corrente é registrado ao longo do tempo e representado graficamente em um formato circular, conhecido como carta amperimétrica. Esse gráfico permite visualizar variações no consumo de corrente de forma intuitiva e identificar tendências e padrões repetitivos que possam indicar a ocorrência de falhas, (2).

Por exemplo, a presença de gás na bomba pode ser detectada pela flutuação cíclica da corrente elétrica, conforme ilustrado na Figura 2. Essa flutuação ocorre devido à turbulência provocada pelo gás no fluido bombeado, que gera variações de carga no motor e, conseqüentemente, oscilações na potência requisitada. O resultado dessa condição operacional é uma redução substancial na taxa de produção líquida, prejudicando a eficiência da extração, (2).

A interpretação adequada da carta amperimétrica permite que operadores tomem decisões rápidas e assertivas para corrigir pequenos problemas antes que se agravem. Além disso, essa técnica pode ser integrada a sistemas de monitoramento remoto e inteligência artificial, proporcionando análises automatizadas e preditivas para otimizar a operação da BCSS, (9).

Dessa forma, a análise amperimétrica se apresenta como uma solução eficiente e acessível para o monitoramento de bombas centrífugas submersas, sendo amplamente utilizada na indústria do petróleo para melhorar a confiabilidade, reduzir custos operacionais e maximizar a produção.

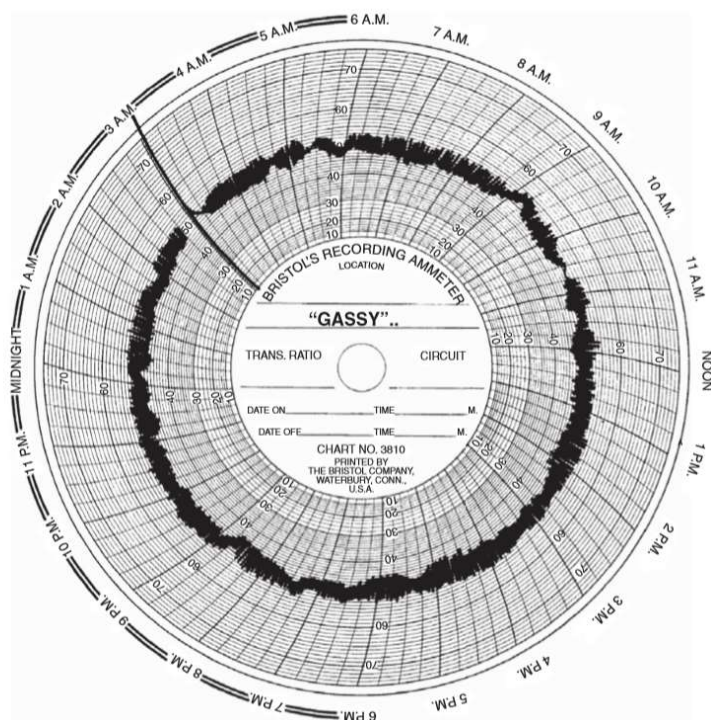


Figura 2 – Exemplo de carta amperimétrica: BCSS operando com gás presente na bomba, (2).

Apesar das vantagens da carta amperimétrica, a mesma se caracteriza por ser um método extremamente duvidoso devido à tendência de erros de diagnóstico. Por exemplo, nessa análise é difícil distinguir quando o eixo da bomba quebra e quando a bomba enche de gás, pois, em ambos os cenários, a carta apresenta picos de corrente reduzidos, (5).

2.1.1. Análise da Assinatura Elétrica

A análise da assinatura elétrica é uma técnica não invasiva de caráter preditivo e possibilita o monitoramento do motor sem interferência no mesmo, utilizando o próprio motor como transdutor. Além do monitoramento de falhas, permite determinar o desempenho do equipamento e é aplicada principalmente em motores de indução trifásico. Essa técnica além de revelar a condição dos componentes elétricos do motor, também exprime a condição dos elementos mecânicos como a dos seus mancais, do alinhamento, da condição do acoplamento e até a da carga.

Através de simples sensores de corrente e tensão, o monitoramento pode ser realizado remotamente, com os mesmos conectados no circuito de alimentação do motor. Em condições

de difícil acesso, podem ser conectados a quilômetros de distância do mesmo sem a necessidade de interromper sua operação e a produção.

A técnica é fundamentada no princípio de que quando ocorre uma determinada falha no motor, ocorrem variações de carga e, conseqüentemente, variações na corrente do motor. Essas variações resultam em modulações da corrente estatórica e, no domínio da frequência, surgem componentes espectrais com frequência característica para cada tipo de falha. (10)

Ao aplicar a transformada de Fourier no sinal de corrente, obtém-se o espectro onde serão monitoradas as componentes com frequência correspondente a cada tipo de falha. A avaliação da severidade da falha é realizada considerando a amplitude da componente espectral e sua evolução no tempo. Para a avaliação da componente, é efetuado a relação entre a amplitude da componente característica da falha e o nível de corrente do motor, garantindo que o indicador seja constante em relação à variação de corrente proveniente da variação de carga.

As principais características da aquisição de sinais voltados a análise da assinatura elétrica são, (11):

- Teorema de Nyquist: um sinal deve ser reconstruído com uma frequência de amostragem que não pode ser inferior ao dobro da componente de frequência máxima do sinal;
- Faixa de frequência: considerando que a resposta em frequência necessária na análise da assinatura de corrente ser de apenas 5 kHz, para satisfazer a condição de Nyquist, os transdutores deverão ter uma resposta mínima de 10 kHz;
- A resolução espectral na análise de assinatura de corrente deve ser suficiente para possibilitar a distinção entre as componentes espectrais, que frequentemente podem estar próximas a harmônicas da rede ou outras componentes.

A análise da assinatura de corrente (MCSA) permite determinar falhas no circuito rotórico, circuito do estator, excentricidades estáticas e dinâmicas, problemas nos mancais, no acoplamento e na carga acoplada. Possibilita também a determinação de parâmetros relacionados a qualidade de energia como desequilíbrio elétrico, harmônicas, índice de distorção harmônica (THD), fator de potência e a potência consumida, (12).

2.2. PADRÕES DE FALHAS EM MCSA

2.2.1. Falhas de barra quebrada

Esse tipo de falha é a mais popular entre os estudos realizados na área da MCSA, pois, as componentes espectrais relacionadas a ela são mais simples de detectar. O monitoramento é efetuado em frequências específicas, sendo as duas principais delas localizadas ao entorno da fundamental de maneira simétrica, como apresentado na Figura 3. As componentes surgem com o desequilíbrio do circuito rotórico provocado pela barra quebrada, resultando na modulação da corrente do motor. A frequência das componentes são proporcionais a frequência da corrente rotórica acrescida pela frequência da componente fundamental, sinal da portadora nessa modulação, (11).

A causa desse tipo de falha é por esforços térmicos e mecânicos, cargas pulsantes, imperfeições no processo de manufatura da gaiola e partidas com carga realizadas com frequência, (11).

A frequência das componentes de barra quebrada é apresentada em (1), sendo a componente da esquerda ($f - 2s$) resultante diretamente da severidade da falha e a da direita ($f + 2s$) resultante do *ripple* de velocidade do motor, (11).

$$f_{bb} = f_1 \cdot (1 \pm k \cdot 2 \cdot s) \quad (1)$$

Onde:

f_1 é a frequência de alimentação em Hz;

k é a ordem da harmônica e igual a 1, 2, 3,

A avaliação da severidade da falha é realizada levando em consideração a carta de severidade apresentada na Tabela 2 (13), onde a diferença é o valor em decibéis da componente de barra quebrada com maior amplitude em relação à amplitude do sinal completo, (11).

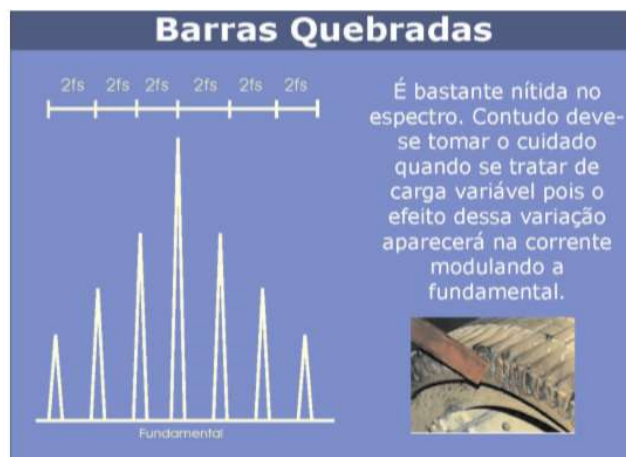


Figura 3: Padrão de falha para barras quebradas (11).

Tabela 2 – Carta de severidade para barras quebradas, (13).

Severidade	Diferença em dB	Condição Rotórica	Ação Recomendada
1	>60	Excelente	Nenhuma
2	54-60	Bom	Nenhuma
3	48-54	Moderado	Verificar tendência
4	42-48	Probabilidade de pontos de alta resistência ou barra quebrada	Estado de atenção
5	36-42	1 ou 2 barras quebradas	Estado de emergência
6	30-36	Múltiplas barras trincadas ou quebradas	Reparo
7	<30	Múltiplas barras trincadas ou quebradas e ou anel de curto	Reparo

2.2.2. Excentricidade do entreferro (*airgap*), (11)

A excentricidade do entreferro é uma condição em que a distância entre a superfície do rotor e a do núcleo do estator não é uniforme, resultando em uma região com entreferro máximo e outra com mínimo. A excentricidade é classificada em estática, Figura 4 (11), quando a posição do *airgap* máximo e mínimo não se deslocam com o funcionamento do motor indica que o núcleo do estator é oval e/ou existe um desalinhamento entre o eixo e o centro do estator. A excentricidade do tipo dinâmica, Figura 5 (11), ocorre quando o entreferro mínimo e máximo se deslocam com a rotação do rotor e é resultante de situações em que o diâmetro externo do rotor não é concêntrico, no empeno térmico do rotor, em defeito no rolamento (do tipo distribuído), desbalanceamento do rotor ou da carga. O motor sempre está sujeito a excentricidade conforme a não idealidade do processo de manufatura do motor, como acontece

na assinatura elétrica de barra quebrada, sendo o nível máximo permitido de 5% estabelecido por alguns fabricantes, enquanto outros permitem até 10%. Observa-se que a excentricidade do entreferro, especificada pelo fabricante, é a excentricidade radial, que se refere a soma da dinâmica e da estática.

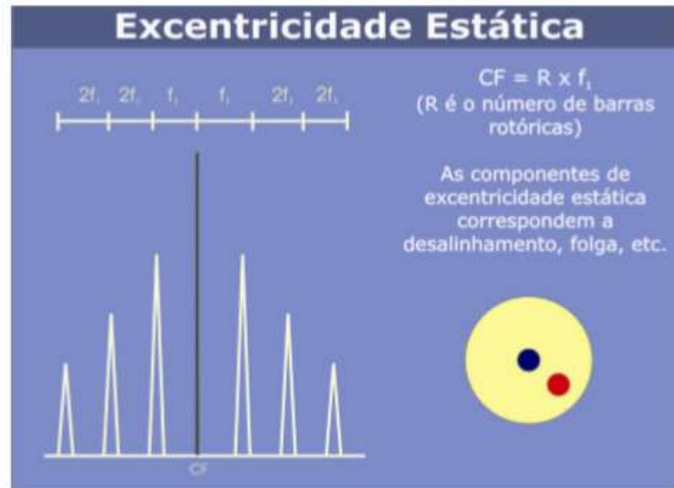


Figura 4: Padrão de excentricidade estática, (11).

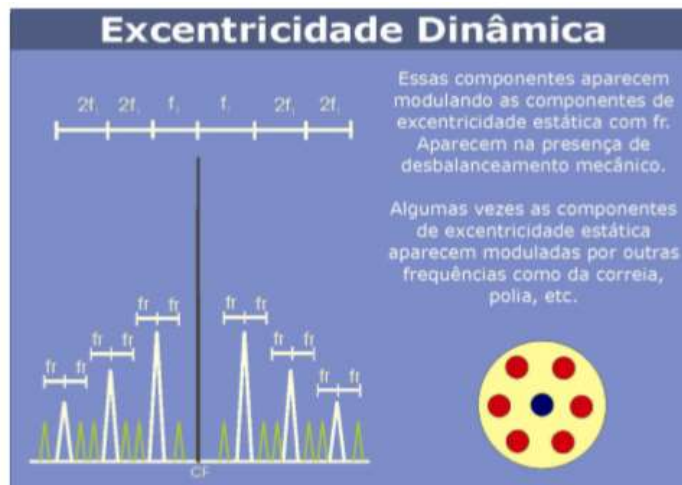


Figura 5: Padrão de excentricidade dinâmica, (11).

A assinatura elétrica da excentricidade do entreferro considera a frequência das bandas laterais do espectro de corrente em torno da frequência de slot, representado por (2). Considerando nesta expressão a ordem de excentricidade nula ($n_{ecc} = 0$) têm-se as frequências características de excentricidade estática.

$$f_{slot / exc} = f_1 \left[(kR \pm n_{ecc}) \left(\frac{1-s}{p/2} \right) \pm n_s \right] \quad (2)$$

Onde:

$$k = 1, 2, 3, \dots;$$

R = número de barras do motor;

$n_{ecc} = 1, 2, 3, 4, 5 \dots$ número da ordem da excentricidade;

p = número de polos;

$n_s = 1, 3, 5, 7, 9 \dots$ ordem da harmônica da frequência de alimentação.

Observa-se na expressão (2) a necessidade de se conhecer aspectos construtivos da máquina como o número de barras do rotor, tornando a análise limitada para casos em que não se obtém essa informação.

2.2.3. Rotação do eixo

Este padrão, Figura 6 (11), é representado pela modulação da frequência fundamental, surgindo como bandas laterais, expresso em (3) e também é conhecido como padrão de excentricidade em baixa frequência. Essa modulação é consequente de defeitos nos elementos móveis do motor, como rolamento, carga e rotor. Assim essa assinatura também traz informação sobre a excentricidade no entreferro sem a necessidade do dado de quantidade de barras do rotor, além de refletir problemas nos rolamentos e na carga.

$$f_{re} = f_1 \left[(1 \pm k) \left(\frac{1-s}{p/2} \right) \right] \quad (3)$$

Onde 's' é escorregamento em p.u.;

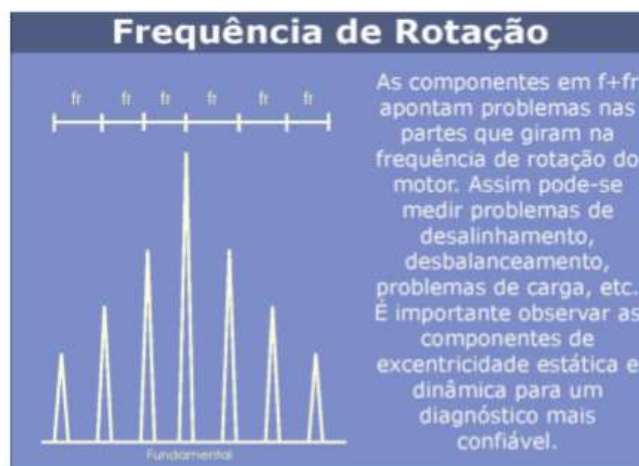


Figura 6 – Padrão de excentricidade em baixa frequência, (11).

2.2.4. Defeitos em Rolamentos

Defeitos em rolamentos provocam variações de torque no motor como o comportamento de cargas impulsivas, resultando em modulações em fase e também sendo detectadas no espectro da corrente estatórica em forma de pares de componentes ao entrono da frequência de alimentação (4), (14).

$$f_b = f_1 \pm kf_c \quad (4)$$

Onde ‘ f_c ’ é a frequência característica do rolamento em Hz.

As frequências características (f_c) são determinadas para cada parte do rolamento e estão relacionadas aos aspectos construtivos do mesmo. (15).

Deve-se ressaltar que a identificação de defeitos em rolamentos através da corrente é significativamente mais difícil do que na vibração do motor (15). Essa dificuldade é em distinguir os padrões de defeitos em rolamentos do ruído e das demais componentes (16).

2.2.5. Efeitos da carga – bomba centrífuga (11)

As oscilações de torque da carga, assim como as falhas mecânicas no motor resultam em variações da corrente do motor, cuja amplitude dependerá primordialmente da inércia do sistema. As alterações periódicas no torque da carga que são proporcionais a velocidade rotórica resultam em modulações na frequência de alimentação.

No caso de a carga ser uma bomba centrífuga, como empregado na BCSS, seus parâmetros como pressão de sucção, pressão de descarga e cavitação irão influenciar na assinatura de corrente do motor e também no seu nível de vibração.

Para a análise de falha das bombas centrífugas as frequências de maior relevância são as relacionadas a rotação da bomba e a de passagem das pás. Sendo para o caso da BCSS, por apresentar uma elevada quantidade de estágios em série, a mais importante sendo o comportamento das saliências próximas da frequência da rede. A frequência de passagem das pás não se destaca no espectro da corrente da BCSS visto que a elevada quantidade de bombas em série provoca o equilíbrio e a mitigação desse fenômeno.

O efeito da elevação da amplitude das componentes de passagem das pás reflete em defeitos no interior da bomba como a deterioração das pás, obstrução do fluxo, variações abruptas de direção do fluxo, rotor posicionado excêntrica na carcaça e folga nos mancais.

Enquanto a análise da frequência de rotação da bomba indica problemas que são relacionados a desalinhamento ou desbalanceamento da bomba.

Quando a bomba opera fora do seu ponto de operação pode ocorrer a cavitação e as consequências no espectro é o aumento da amplitude das componentes situadas na região de turbulência, como exemplificado na Figura 7, além da elevação de componentes de alta frequência.

Com o agravamento da cavitação, as respectivas saliências se pronunciam no espectro, apontando o problema. Assim, é importante que se tenha um espectro de referência do motor e bomba em bom estado para o acompanhamento da evolução dessas componentes, ou seja, o *baseline*.

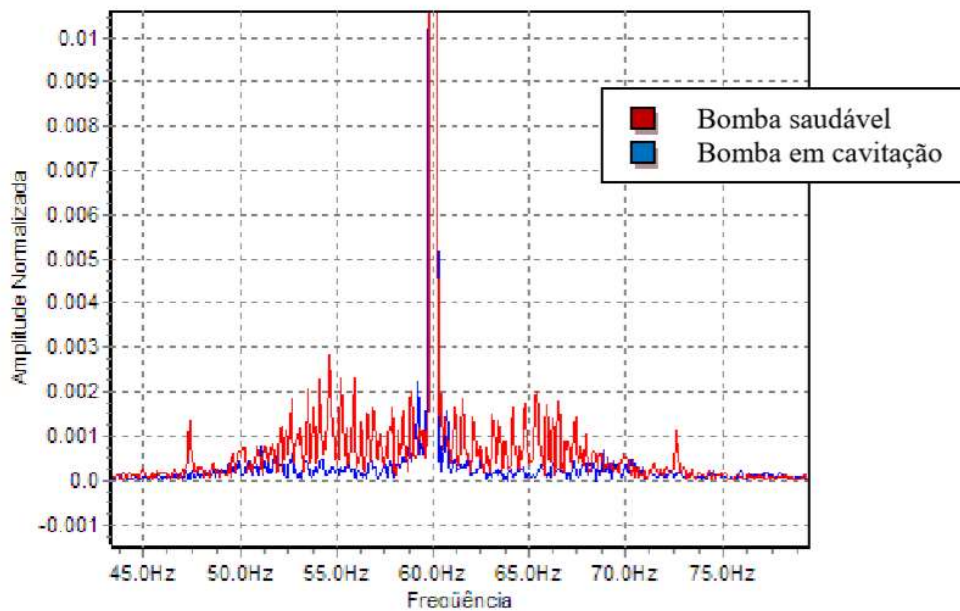


Figura 7 – Turbulência ao entorno da componente fundamental no espectro de corrente de uma bomba em cavitação e outra bomba saudável, (12).

3. TECNICAS DE PROCESSAMENTO DIGITAL DE SINAIS DEDICADO A ASSINATURA ELÉTRICA DE *SKID-BCSS*

A *skid-BCSS* é um sistema composto pelo arranjo de duas bombas centrífugas submersas submarinas (BCSS) acopladas em série, formando um circuito hidráulico interconectado, como ilustrado na Figura 8, (17). Essa configuração é adotada principalmente para aumentar a eficiência do bombeamento em sistemas de extração submarina, garantindo um melhor desempenho em condições de operação que demandam altas pressões diferenciais.

A principal particularidade dessa configuração está relacionada à forma como os motores elétricos das bombas interagem com a alimentação elétrica, influenciando diretamente a assinatura elétrica do sistema. Diferentemente de uma BCSS convencional, onde a corrente elétrica reflete exclusivamente o comportamento de um único motor e sua carga mecânica associada, na *skid-BCSS*, a corrente medida é proveniente da alimentação simultânea de dois motores que operam independentemente, sem compartilharem o mesmo eixo mecânico.

Essa particularidade tem implicações diretas no espectro de corrente, gerando padrões espectrais específicos que devem ser compreendidos para garantir uma análise precisa da assinatura elétrica do sistema.

A análise espectral da corrente elétrica em uma *skid-BCSS* apresenta características distintas quando comparada a um sistema com apenas uma única BCSS. Isso ocorre devido à presença de dois motores operando em velocidades distintas, além da influência das harmônicas da rede elétrica e do chaveamento dos inversores. Essas particularidades resultam na formação de componentes espectrais específicas, que podem ser descritas da seguinte forma:

- Componentes espectrais associadas à velocidade dos motores surgem em pares: Como os dois motores não estão mecanicamente acoplados em um mesmo eixo, cada um opera em uma velocidade ligeiramente diferente, devido a diferença de carga hidráulica, escorregamento do motor e eficiência do sistema de controle. No espectro de corrente, isso se traduz na presença de pares de componentes espectrais com frequências proporcionais às velocidades individuais de cada motor. Essa característica pode ser explorada para diagnosticar assimetrias de carga entre as bombas.

- Influência das harmônicas da rede elétrica e do chaveamento dos inversores:
Como os motores são alimentados pelo mesmo ponto de fornecimento elétrico, as harmônicas da rede, incluindo a componente fundamental, se manifestam de maneira unificada no espectro de corrente. Diferentemente das componentes espectrais associadas às velocidades dos motores, que surgem em pares, as harmônicas e sub-harmônicas do chaveamento dos inversores se apresentam como uma única componente, assim como ocorre na análise espectral de um sistema convencional de uma única BCSS.

Esse comportamento ocorre porque, do ponto de vista elétrico, ambos os motores compartilham o mesmo barramento de alimentação, sendo submetidos às mesmas condições de chaveamento e distorção harmônica. Assim, o espectro de corrente resultante apresenta um padrão híbrido, no qual algumas componentes espectrais surgem duplicadas e outras se manifestam de forma única, dependendo da origem do fenômeno analisado.

Dessa forma, a análise da assinatura elétrica em sistemas *skid*-BCSS apresenta desafios técnicos consideráveis devido à natureza híbrida do espectro de corrente resultante. No entanto, com a aplicação de técnicas avançadas de processamento digital de sinais, é possível extrair informações valiosas para o diagnóstico e prognóstico de falhas, garantindo uma operação mais eficiente e confiável. O desenvolvimento de abordagens que combinem métodos espectrais e análise estatística representa um avanço significativo para o monitoramento preditivo de bombas centrífugas submersas submarinas.




Figura 8 - *Skid-BCSS* (17).

Neste capítulo, será realizada uma abordagem detalhada sobre as assinaturas elétricas características de uma *skid-BCSS*, além da apresentação das técnicas desenvolvidas especificamente para a análise desses sinais. O objetivo principal é fornecer uma compreensão aprofundada da coleta, processamento e interpretação dos sinais de corrente no domínio da frequência, destacando-se a relevância desse tipo de monitoramento para a detecção e diagnóstico de falhas nesse tipo de equipamento.

A análise apresentada baseia-se em um extenso conjunto de dados adquiridos a partir de uma *skid-BCSS* instalada na plataforma P-58 da PETROBRAS. Para garantir uma avaliação confiável e representativa do comportamento operacional do sistema ao longo do tempo, os sinais foram coletados durante um período de 10 meses, totalizando 1600 registros individuais de corrente elétrica.

A coleta dos sinais elétricos foi realizada utilizando o sistema de aquisição Preditor®, um sistema dedicado a análise de assinatura elétrica de motores, pois garante uma elevada resolução de amplitude, elevada resolução espectral (coleta sinais de longa duração) e taxa de amostragem elevada. As principais características da aquisição dos dados, configurada para este trabalho, são:

- Duração de cada aquisição: 22 segundos por registro;
- Taxa de amostragem: 46.875 amostras por segundo (46,875 kHz);

- Resolução de quantização: 24 bits por amostra.

Na Figura 9, são apresentados os níveis de velocidade dos dois motores da *skid-BCSS*, calculados para cada um dos 1600 sinais adquiridos. Um aspecto relevante a ser destacado é que, embora ambos os motores estejam conectados ao mesmo ramal de alimentação elétrica e apresentem características construtivas semelhantes, suas velocidades operacionais não são exatamente idênticas. Observa-se, na análise das curvas de velocidade, uma proximidade entre as frequências de operação, com diferenças variando entre 0,054 Hz e 0,047 Hz.

Essa diferença ocorre devido ao fato de que os motores não estão acoplados mecanicamente por um eixo comum, operando de forma independente um do outro. Assim, sua velocidade de rotação pode ser influenciada por fatores como:

A diferença de velocidade entre os motores das bombas em série da *skid-BCSS* ocorre devido ao fato de serem motores de indução, cuja velocidade não é exatamente síncrona, variando conforme o escorregamento, que, por sua vez, depende diretamente da carga mecânica aplicada. Nesse contexto, a segunda bomba tende a operar com uma velocidade ligeiramente inferior à da primeira, pois está exposta à alta pressão da coluna de produção. Esse fenômeno pode ser explicado por dois efeitos distintos que influenciam a velocidade do motor:

1. Aumento da contrapressão e da carga hidráulica

- A pressão hidrostática da coluna de produção impõe uma resistência significativa ao escoamento do fluido.
- Esse aumento da resistência eleva a carga imposta ao motor da segunda bomba, exigindo um maior torque para manter a rotação.
- Como consequência, o escorregamento do motor tende a aumentar, resultando em uma redução da sua velocidade em relação à primeira bomba.

2. Efeito de vazão estabilizada

- Se a coluna de produção já impõe um fluxo contínuo e estabilizado, o fluido pode estar se movendo de forma mais uniforme, reduzindo a necessidade de aceleração adicional pela segunda bomba.
- Nesse cenário, o motor poderia operar com menor variação de carga, o que poderia reduzir o escorregamento.

- No entanto, esse efeito tende a ser menos significativo do que o impacto do aumento da carga hidráulica devido à contrapressão.

Dessa forma, a segunda bomba opera a uma velocidade ligeiramente menor que a primeira, devido à maior carga imposta pela pressão hidrostática da coluna de produção, que resulta em um escorregamento mais acentuado.

Essa discrepância na velocidade de operação dos motores da *skid*-BCSS tem um impacto direto na assinatura elétrica do sistema, pois resulta na formação de componentes espectrais distintas para cada motor no espectro de corrente elétrica.

A diferença de velocidades entre os dois motores reflete-se na assinatura elétrica do sistema de forma bastante característica. No domínio da frequência, isso implica que as componentes espectrais relacionadas às frequências de rotação dos motores surgirão em pares, correspondendo a cada um dos motores operando em uma velocidade distinta.

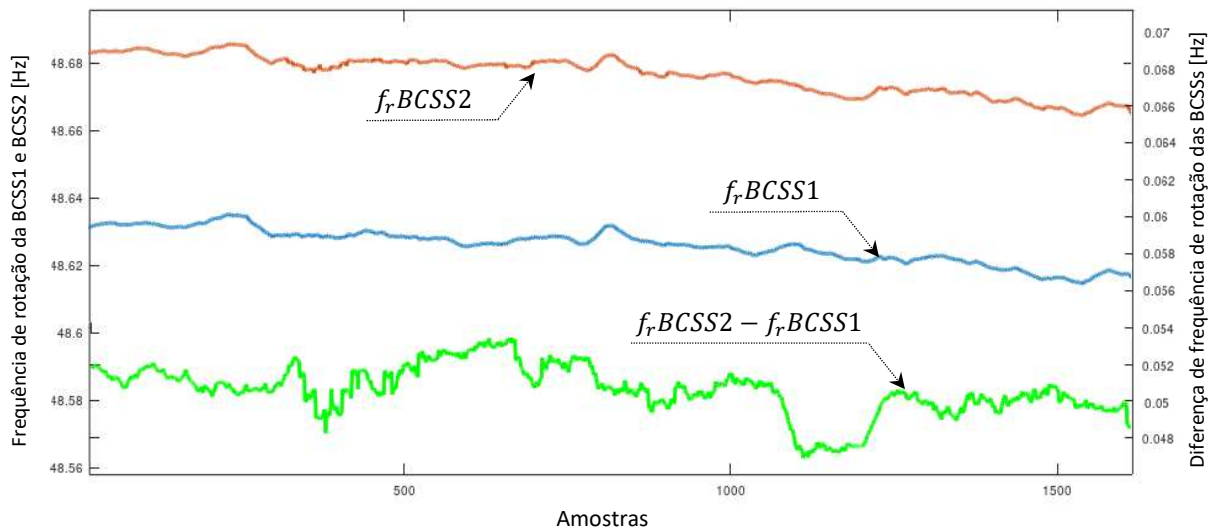


Figura 9 – Curva de velocidades dos motores de uma *skid*-BCSS.

A assinatura elétrica da *skid*-BCSS apresenta particularidades que devem ser compreendidas para uma análise espectral eficiente. No espectro de corrente, ilustrado na Figura 10, podem ser observadas duas componentes espectrais associadas ao desequilíbrio rotórico, cuja frequência f_{bb} é determinada pela equação (1). Esse comportamento ocorre porque a frequência f_{bb} é diretamente proporcional ao escorregamento (s) do motor, um

parâmetro que varia conforme a velocidade de operação. Como os motores da *skid*-BCSS operam a velocidades ligeiramente diferentes, suas assinaturas de desequilíbrio rotórico não se manifestam em um único valor de frequência, mas sim em pares de componentes espectrais, correspondendo a cada um dos motores.

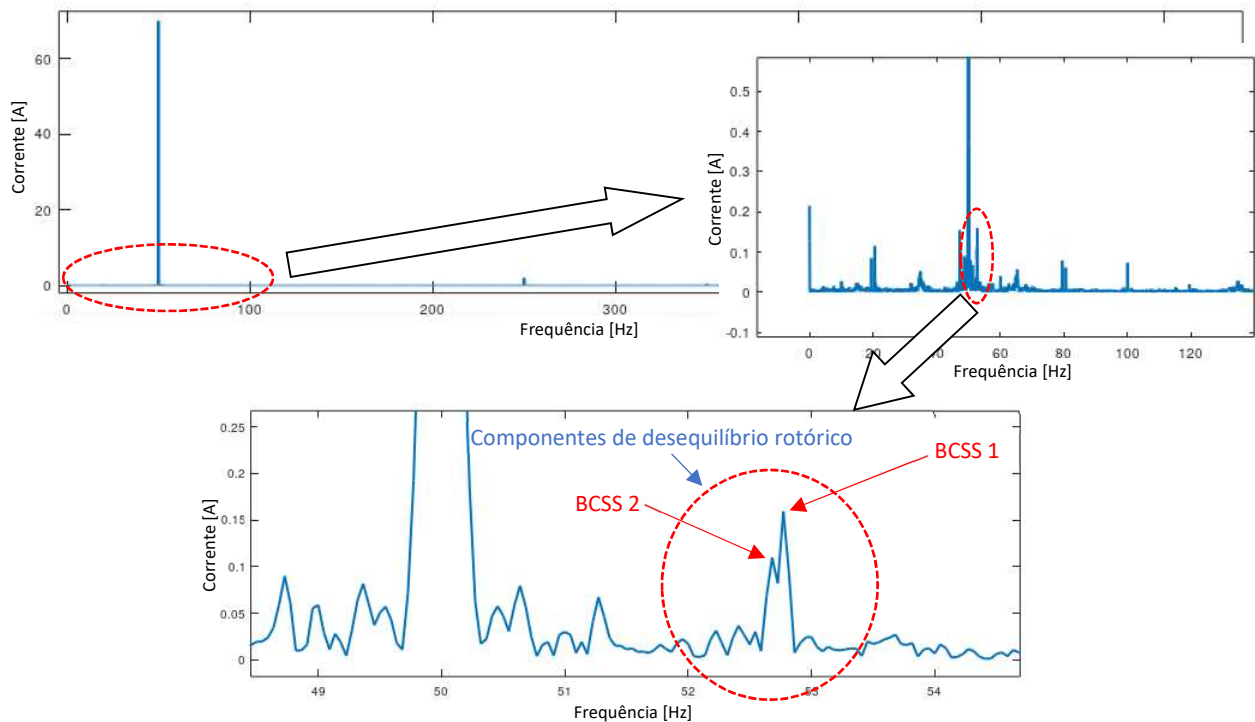


Figura 10 – Espectro de corrente de uma *skid*-BCSS.

3.1. IMPACTO DA DIFERENÇA DE VELOCIDADE NA IDENTIFICAÇÃO DAS COMPONENTES ESPECTRAIS

A separação dessas componentes espectrais no domínio da frequência depende diretamente da diferença de velocidade entre os dois motores. Quanto menor for essa diferença de rotação, mais próximas essas componentes estarão no espectro de corrente, tornando sua separação mais complexa e desafiadora.

Esse fenômeno é especialmente problemático nas regiões espectrais de baixa frequência, pois a proximidade das componentes pode resultar em sobreposição espectral. Dependendo da resolução espectral empregada na análise, os métodos tradicionais de Transformada Rápida de

Fourier (FFT) podem não ser capazes de distinguir adequadamente essas frequências, gerando um espectro com baixa precisão na identificação das assinaturas individuais de cada motor.

Esse desafio evidencia a necessidade de estratégias de aprimoramento da resolução espectral, de forma a permitir a correta identificação das assinaturas elétricas e, conseqüentemente, melhorar a capacidade de monitoramento preditivo da *skid*-BCSS.

3.1.1. Aprimoramento da Resolução Espectral: Aumento da Quantidade de Amostras

A resolução espectral é definida como a capacidade de um sistema de análise espectral de distinguir componentes de frequência próximas. Um dos métodos mais simples e diretos para melhorar essa resolução consiste em aumentar o número de amostras do sinal analisado.

Um dos métodos mais simples e diretos para melhorar a resolução espectral é aumentar o número de amostras do sinal analisado. Esse conceito se baseia no fato de que a resolução espectral é inversamente proporcional ao tempo total de aquisição do sinal. Dessa forma, ao estender a duração da aquisição, a resolução melhora, permitindo distinguir frequências que, em uma janela de tempo menor, poderiam aparecer sobrepostas.

Esse método, no entanto, não pode ser aplicado indefinidamente, pois há um limite prático para o aumento do tempo de aquisição. Se esse tempo for excessivamente elevado, outros efeitos indesejados começam a impactar a análise espectral, sendo um dos principais o vazamento espectral (*spectral leakage*) (18).

3.1.2. O Problema do Vazamento Espectral e Seus Impactos na Análise

O vazamento espectral é um fenômeno que ocorre quando a janela de tempo utilizada na análise não é perfeitamente compatível com a periodicidade das componentes presentes no sinal. Isso resulta na distribuição da energia do sinal por diversas frequências adjacentes, tornando a identificação precisa das componentes espectrais mais difícil e menos confiável.

Esse efeito pode ser visualizado no espectro como o surgimento de "ruído" em torno das componentes espectrais principais, dificultando sua separação e, em alguns casos, mascarando informações essenciais sobre o comportamento do sistema.

A presença de vazamento espectral se torna ainda mais crítica quando a diferença de velocidade entre os motores da *skid-BCSS* é pequena, pois as componentes de desequilíbrio rotórico já se encontram muito próximas e, com o vazamento espectral, podem se fundir em um único espectro distorcido, inviabilizando a análise precisa do fenômeno.

Dessa forma, o aumento do tempo de aquisição deve ser feito com cautela, garantindo um equilíbrio entre melhoria na resolução espectral e minimização dos efeitos de vazamento espectral.

3.1.3. Avaliação do Vazamento Espectral Através da Estacionariedade do Sinal

Uma das maneiras mais eficientes de avaliar se um sinal está sujeito a vazamento espectral é a análise do nível de estacionariedade. A estacionariedade de um sinal refere-se à constância estatística das suas propriedades ao longo do tempo, ou seja, se suas características fundamentais, como média e variância, permanecem inalteradas durante a aquisição.

Caso um sinal apresente variações significativas ao longo do tempo, como mudanças abruptas de amplitude ou oscilações transitórias, o vazamento espectral se tornará mais acentuado. Portanto, a análise da estacionariedade do sinal se torna uma etapa essencial para determinar se um aumento no tempo de aquisição poderá ser benéfico ou se introduzirá mais ruído na análise espectral.

3.2. ESTACIONARIEDADE

Na presente tese, a estacionariedade é uma propriedade fundamental dos sinais analisados, sendo um critério essencial para a avaliação das técnicas de análise aplicadas a sinais elétricos de sistemas S-BCSS. Conforme discutido por Silva (2008) (12), a importância de garantir um elevado grau de estacionariedade reside na possibilidade de obter estimativas mais precisas do espectro de frequência, contribuindo significativamente para a melhoria da análise espectral.

Um sinal é classificado como estacionário quando seu modelo probabilístico se mantém invariante ao longo do tempo. Em outras palavras, seus parâmetros estatísticos, tais como a média, a variância e todos os momentos do processo, devem permanecer constantes. No entanto, diferentes níveis de estacionariedade podem ser observados, uma vez que um

subconjunto de estatísticas pode se manter constante enquanto outro apresenta variações. Além disso, um sinal pode exibir comportamento estacionário apenas por um intervalo específico e, posteriormente, perder essa característica.

Como exemplo, considere-se o sinal de corrente de um motor operando em regime permanente e submetido a uma variação brusca de carga. Durante o regime permanente, o espectro de potência de qualquer segmento do sinal não apresenta alterações significativas em relação ao espectro médio do período analisado. Entretanto, quando se considera o sinal completo, o espectro de potência de determinados segmentos pode diferir substancialmente do espectro médio global, indicando a ocorrência de não-estacionariedade.

Dessa forma, a maioria dos sinais não estacionários pode ser aproximada como estacionária em períodos curtos. Nos processos fracamente estacionários, os momentos de primeira ordem (média) e de segunda ordem (covariância, correlação e espectro de potência) devem permanecer constantes (19).

3.2.1. Avaliação do Nível de Estacionariedade

Dada a relevância da estacionariedade para a aplicação de técnicas de análise espectral, sejam elas paramétricas ou não paramétricas (como a Transformada Discreta de Fourier – DFT), torna-se indispensável a avaliação rigorosa dessa propriedade nos sinais analisados (20). No entanto, garantir a estacionariedade nos sinais medidos não é uma tarefa trivial, pois mesmo em sistemas teoricamente invariantes no tempo, fatores como erros de medição e perturbações no processo podem comprometer essa característica (21).

No contexto da análise de assinaturas elétricas de sistemas S-BCSS, a avaliação da estacionariedade assume um papel central, uma vez que permite identificar quais sinais oferecem melhor representatividade espectral. Neste trabalho, a avaliação da estacionariedade será incorporada às ferramentas propostas.

Conforme exposto por Souza (22), a estacionariedade de um sinal é avaliada em um intervalo finito de tempo. Caso ocorra não-estacionariedade nesse intervalo, o efeito de *leakage* (vazamento espectral) será observado no domínio da frequência (21). Para garantir a estacionariedade, os espectros locais de todos os segmentos do sinal devem ser estatisticamente

equivalentes ao espectro médio global. Tanto os segmentos quanto o espectro médio global devem possuir a mesma duração. Se uma amostra do espectro de um segmento apresentar um desvio significativo em relação à amostra correspondente do espectro médio global, ocorre o erro de *leakage*, indicando que aquele segmento não é estacionário.

A avaliação desse desvio e, conseqüentemente, do nível de estacionariedade, pode ser realizada utilizando métricas estatísticas que quantificam a distância entre os espectros locais e o espectro médio global. Adicionalmente, é possível identificar quais segmentos apresentam não-estacionariedade por meio de testes estatísticos de hipóteses, conforme descrito em (21, 22, 23).

A metodologia para avaliação da estacionariedade de um sinal, seguindo a abordagem de Silva (2008) (12), compreende as seguintes etapas:

1. Definição da segmentação do sinal

- Determina-se o número de segmentos em que o sinal será dividido e a fração de sobreposição entre os segmentos. Deve-se considerar que um maior número de segmentos implica em uma redução na resolução de frequência.

2. Aplicação de janelamento e estimação espectral

- Cada segmento é submetido a uma janela apropriada e, posteriormente, calcula-se seu espectro de potência utilizando a metodologia do periodograma.

3. Construção da matriz espectral e obtenção do espectro médio global

- Os espectros individuais são organizados em uma matriz, onde cada linha representa o espectro de um segmento e cada coluna corresponde a uma frequência específica.
- A amplitude média de cada componente espectral (ou seja, de cada coluna da matriz) é calculada, resultando no espectro médio global.

4. Cálculo da distância estatística entre os espectros individuais e o espectro médio global

- Para cada segmento, determina-se a distância entre seus componentes espectrais e as componentes correspondentes do espectro médio global.
- Conforme proposto por Barbé (21), essa distância será medida por meio da estatística Z , baseada no teste qui-quadrado.

5. Comparação entre sinais em relação ao nível de estacionariedade

- A mediana dos valores da estatística Z é calculada para cada sinal analisado, fornecendo um valor de referência.
- Sinais com menores valores de estatística Z apresentam um maior grau de estacionariedade.

6. Identificação de segmentos com menor grau de estacionariedade

- Para avaliar a estacionariedade de cada segmento individualmente, compara-se seu valor da estatística Z com o valor de referência.
- Caso o módulo do valor da estatística Z de um segmento seja superior ao valor de referência, esse segmento é considerado não-estacionário.

Para ilustrar a aplicação do método de avaliação da estacionariedade, analisam-se cinco sinais distintos, comparando-se seus níveis de estacionariedade e identificando quais apresentam um nível inaceitável dessa característica.

Na Figura 11, são apresentados os cinco sinais no domínio do tempo, servindo de base para a análise da estacionariedade.




Figura 11 - Cinco sinais distintos para a análise no tempo.

Na Figura 12, os mesmos sinais são representados no domínio da frequência. Nota-se que um dos sinais, identificado pela cor preta, apresenta vazamento espectral próximo à componente fundamental (50 Hz). Esse efeito compromete a análise das componentes situadas nessa faixa de frequência, como aquelas associadas ao desequilíbrio rotórico (barra quebrada).

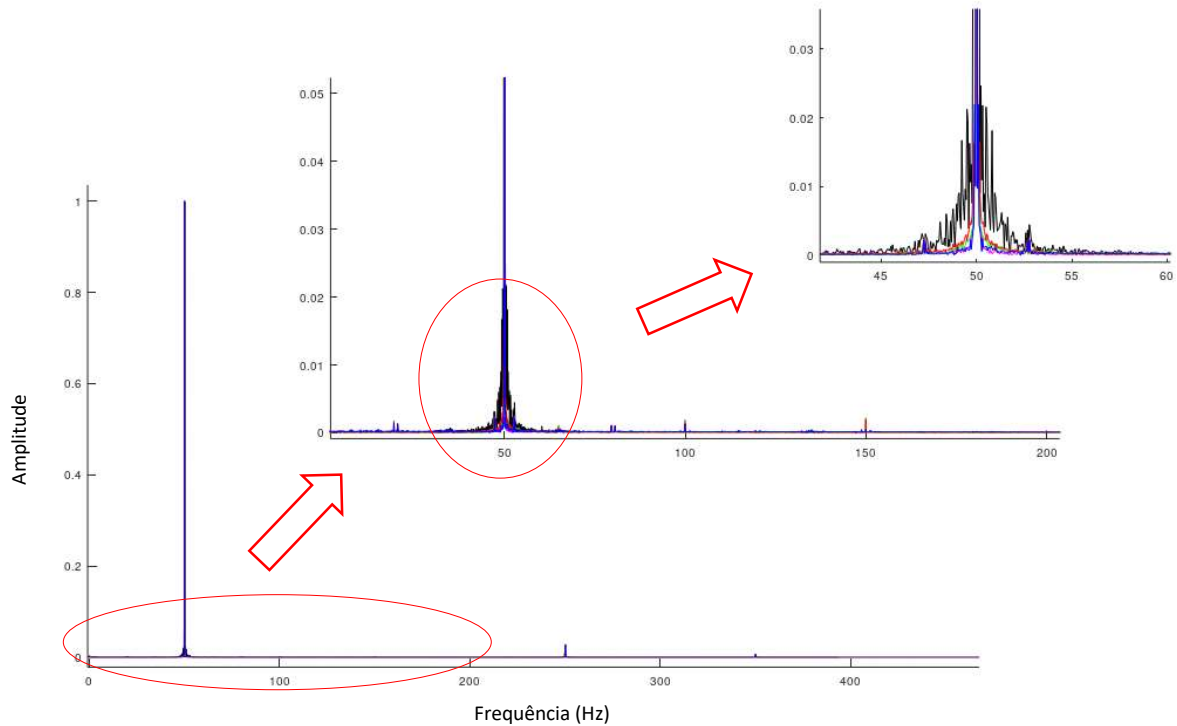


Figura 12 - Cinco sinais distintos para a análise na frequência próximo a fundamental.

Para quantificar a estacionariedade desses sinais, aplicou-se o teste Z, considerando cinco segmentos para cada sinal. As medianas dos valores obtidos são apresentadas na Figura 13. Observa-se que o sinal que apresentou vazamento espectral (sinal preto) também apresentou a maior mediana da estatística Z, superando em mais do que o dobro os valores dos demais sinais. Esse resultado permite concluir que esse sinal possui um nível inferior de estacionariedade.

A aplicação desse teste possibilita a seleção do sinal de melhor qualidade para a análise espectral, permitindo uma avaliação mais precisa de componentes espectrais sensíveis à não-estacionariedade, como as componentes de barra quebrada próximas à fundamental e componentes pares, que dependem da velocidade de cada motor no sistema S-BCSS.




Figura 13 - Mediana do Teste Z para cada um dos 5 sinais

3.3. ESTUDO DE JANELAS ESPECTRAIS VOLTADAS À ASSINATURA ELÉTRICA DE *SKID-BCSS*

A análise espectral é uma ferramenta fundamental para o monitoramento de falhas em sistemas elétricos e mecânicos, permitindo a identificação de padrões característicos na assinatura elétrica de equipamentos industriais, como a *skid-BCSS*. Entretanto, a aplicação da Transformada de Fourier em sinais de duração finita introduz um fenômeno conhecido como *leakage*, que pode comprometer a precisão da análise ao espalhar a energia do sinal por uma ampla faixa de frequências. O *leakage* decorre da descontinuidade nas extremidades do sinal e pode resultar na perda de informações importantes, principalmente em componentes espectrais de baixa amplitude.

Uma técnica amplamente utilizada para mitigar esse problema é o uso de janelas espectrais, que suavizam as bordas do sinal no domínio do tempo, reduzindo a propagação indesejada de energia no domínio da frequência. A escolha da janela adequada impacta diretamente na capacidade de distinguir diferentes componentes espectrais, especialmente quando estas apresentam amplitudes próximas ou estão muito próximas em frequência.

3.3.1. Impacto do Janelamento no Espectro da Corrente da *Skid-BCSS*

A Figura 14 apresenta dois espectros de um sinal de corrente da *skid-BCSS*, comparando o efeito da aplicação de uma janela do tipo Tukey com a ausência de janelamento. Observa-se que, sem o uso de uma janela adequada, ocorre um aumento do *leakage*, tornando difícil a identificação de componentes de menor amplitude. Esse efeito é particularmente prejudicial em

análises de falhas elétricas e mecânicas, onde componentes espectrais de baixa intensidade podem fornecer indícios precoces de degradação.

A Figura 15 ilustra a modificação do sinal no domínio do tempo com e sem janelamento. O processo de aplicação da janela consiste em multiplicar o sinal original $u(n)$ por uma função de janela $w(n)$, resultando no sinal final $g(n)$, conforme representado na equação (5) abaixo, (18):

$$g(n) = u(n) \cdot w(n) \quad (5)$$

Esse processo suaviza as extremidades do sinal, minimizando a descontinuidade ao final da amostragem e, conseqüentemente, reduzindo os efeitos do vazamento espectral.

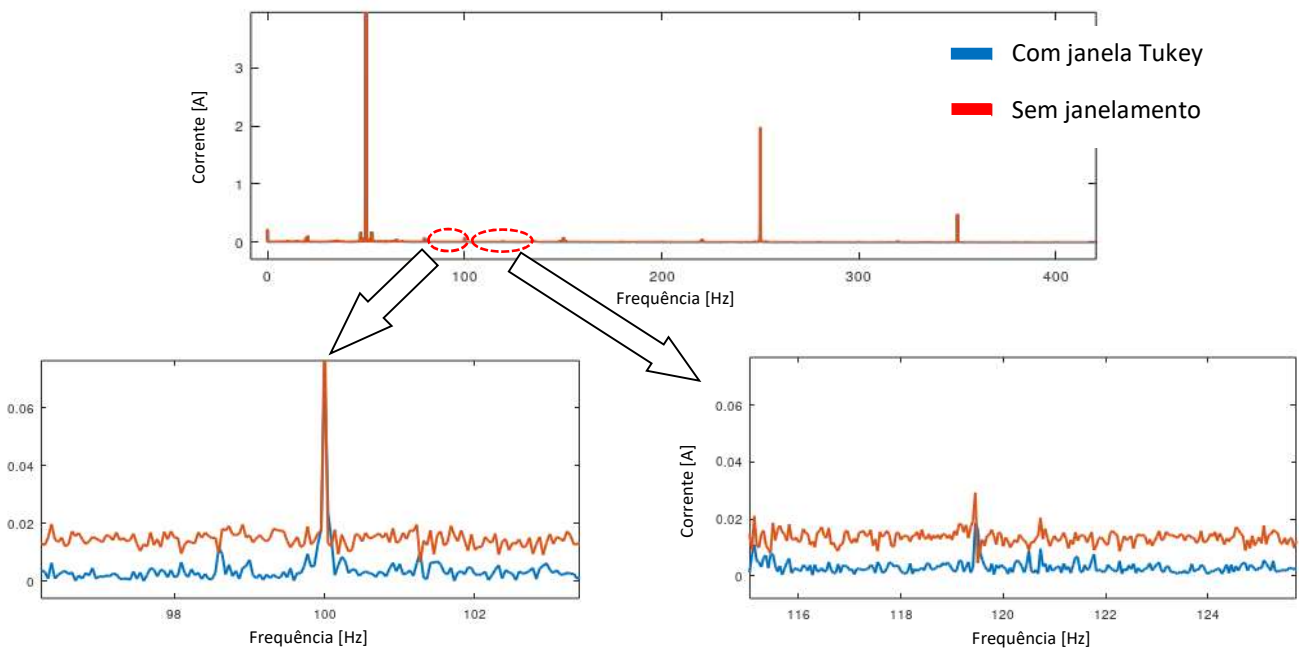


Figura 14 – Espectros com e sem janelamento.

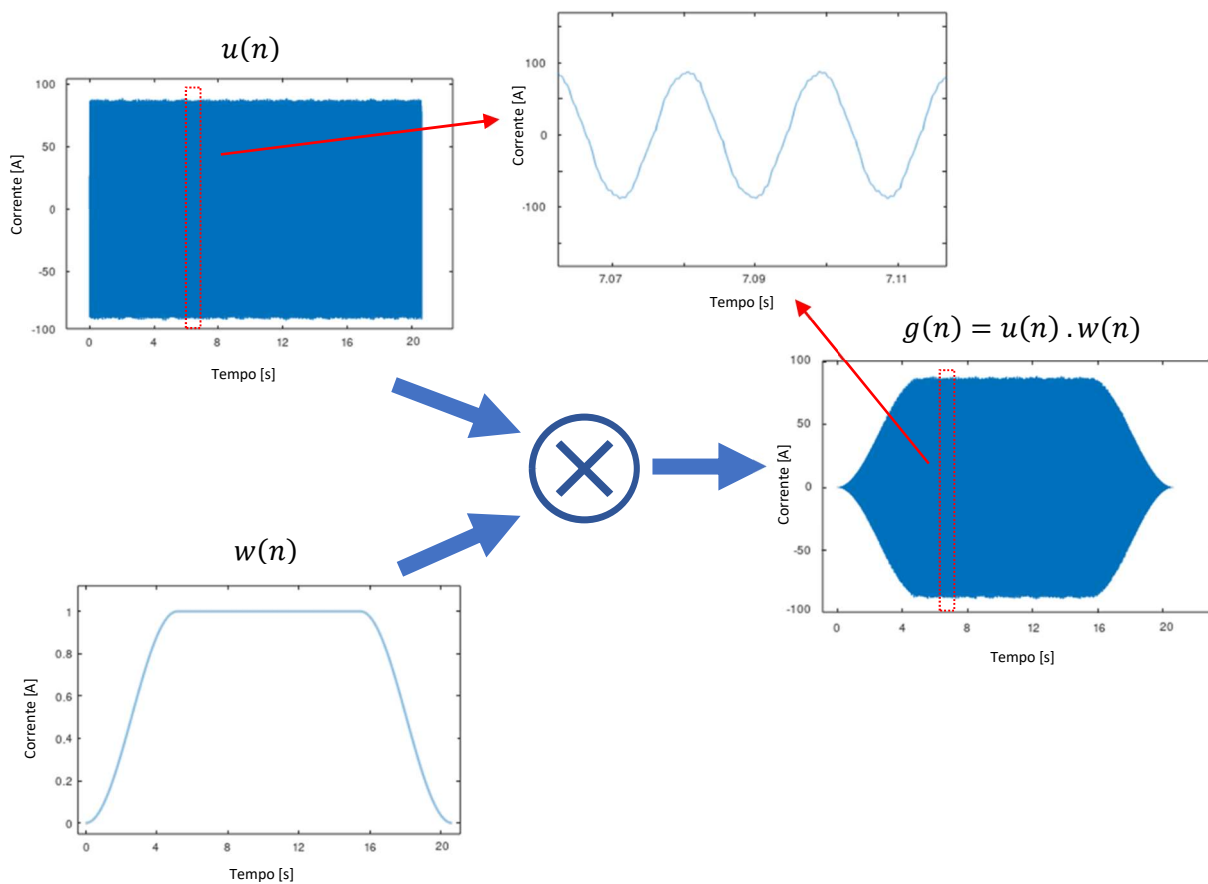


Figura 15 – Sinais no tempo com e sem janela.

3.3.2. Representação Matemática da Janela Retangular e sua Transformada de Fourier

A aplicação de uma janela retangular $w(n)$ no domínio do tempo corresponde à seleção de um número finito de amostras, sem qualquer suavização nas extremidades do sinal. Isso gera uma resposta espectral caracterizada pela função sinc, que apresenta lóbulos secundários significativos, contribuindo para o vazamento espectral. A Figura 16 ilustra a representação de uma janela retangular no domínio do tempo e sua correspondente Transformada de Fourier, evidenciando o espalhamento da energia espectral. Para N representando o número de amostras e τ a duração do sinal, a janela do tipo retangular, $rect(t, \tau)$, é descrita pela equação (6), já a transformada de Fourier é uma função $\tau sinc\left(\frac{\omega t}{2}\right)$.

$$w(n) = \begin{cases} 1 & \text{para } n \in \{0, 1, \dots, N-1\} \\ 0 & \text{para } n \in \{-\infty, \dots, -2, -1\} \cup \{N, N+1, \dots, \infty\} \end{cases} \quad (6)$$




Figura 16 – Representação de uma janela retangular nos domínios tempo e frequência (25).

3.3.3. Influência da Escolha da Janela na Resolução Espectral

A escolha da função janela desempenha um papel crítico na resolução espectral e na capacidade de distinção entre diferentes componentes do sinal. Existem duas situações principais que influenciam essa escolha, (26):

1. Obscurecimento de componentes de baixa amplitude: O vazamento espectral pode mascarar sinais de menor intensidade, dificultando sua detecção. Para minimizar esse efeito, recomenda-se o uso de janelas com alta faixa dinâmica, capazes de reduzir a propagação da energia espectral. Esse tipo de janela é ideal para aplicações em que a amplitude dos componentes espectrais varia significativamente dentro do espectro.
2. Separação de componentes espectrais próximas: Quando duas frequências próximas coexistem no sinal, o vazamento pode tornar impossível a distinção entre elas. Para esses casos, as janelas de alta resolução são mais adequadas, pois apresentam um lóbulo principal mais estreito, permitindo a identificação precisa das componentes espectrais.

A janela retangular, por exemplo, possui elevada resolução, sendo eficaz para separar frequências próximas. No entanto, devido ao seu alto vazamento espectral, ela pode ocultar componentes de menor amplitude. Já a janela Tukey, utilizada na análise da Figura 14, representa um compromisso entre a redução do vazamento e a preservação da resolução espectral.

3.3.4. Comparação de Diferentes Tipos de Janelas

A Figura 17 ilustra os espectros resultantes da aplicação de três diferentes janelas em um sinal de corrente da *skid*-BCSS: Retangular, Tukey e Blackman. A equação da janela retangular já foi apresentada anteriormente, enquanto as janelas Tukey e Blackman são descritas pelas seguintes expressões (7) e (8), respectivamente:

$$w(n) = \begin{cases} \frac{1}{2} \left[1 - \cos\left(\frac{2\pi n}{\alpha N}\right) \right] & \text{para } 0 \leq n < \frac{\alpha N}{2} \\ 1 & \text{para } \frac{\alpha N}{2} \leq n \leq \frac{N}{2} \end{cases} \quad (7)$$

$$w(N - n) = w(n) \quad \text{para } 0 \leq n \leq \frac{N}{2}$$

Onde $\alpha = 0$ resulta em janela retangular e $\alpha = 1$ resulta em uma janela de Hann.

$$w(n) = a_0 - a_1 \cos\left(\frac{2\pi n}{N}\right) + a_2 \cos\left(\frac{4\pi n}{N}\right) \quad (8)$$

Onde $a_0 = 7938/18608$, $a_1 = 9240/18608$ e $a_2 = 1430/18608$.

Observa-se que, na baixa frequência, a janela retangular apresenta um *leakage* elevado, decorrente do vazamento da componente fundamental, dificultando a visualização de componentes de menor amplitude. Entre as janelas Tukey e Blackman, a Tukey mostrou-se mais eficiente na minimização da sobreposição espectral, permitindo a identificação de componentes de desequilíbrio rotórico referentes a cada motor da *skid*-BCSS.

A superioridade da janela Tukey pode ser atribuída à sua construção híbrida, combinando características da janela retangular e de uma função cosseno, proporcionando uma redução significativa do vazamento sem comprometer a resolução espectral.

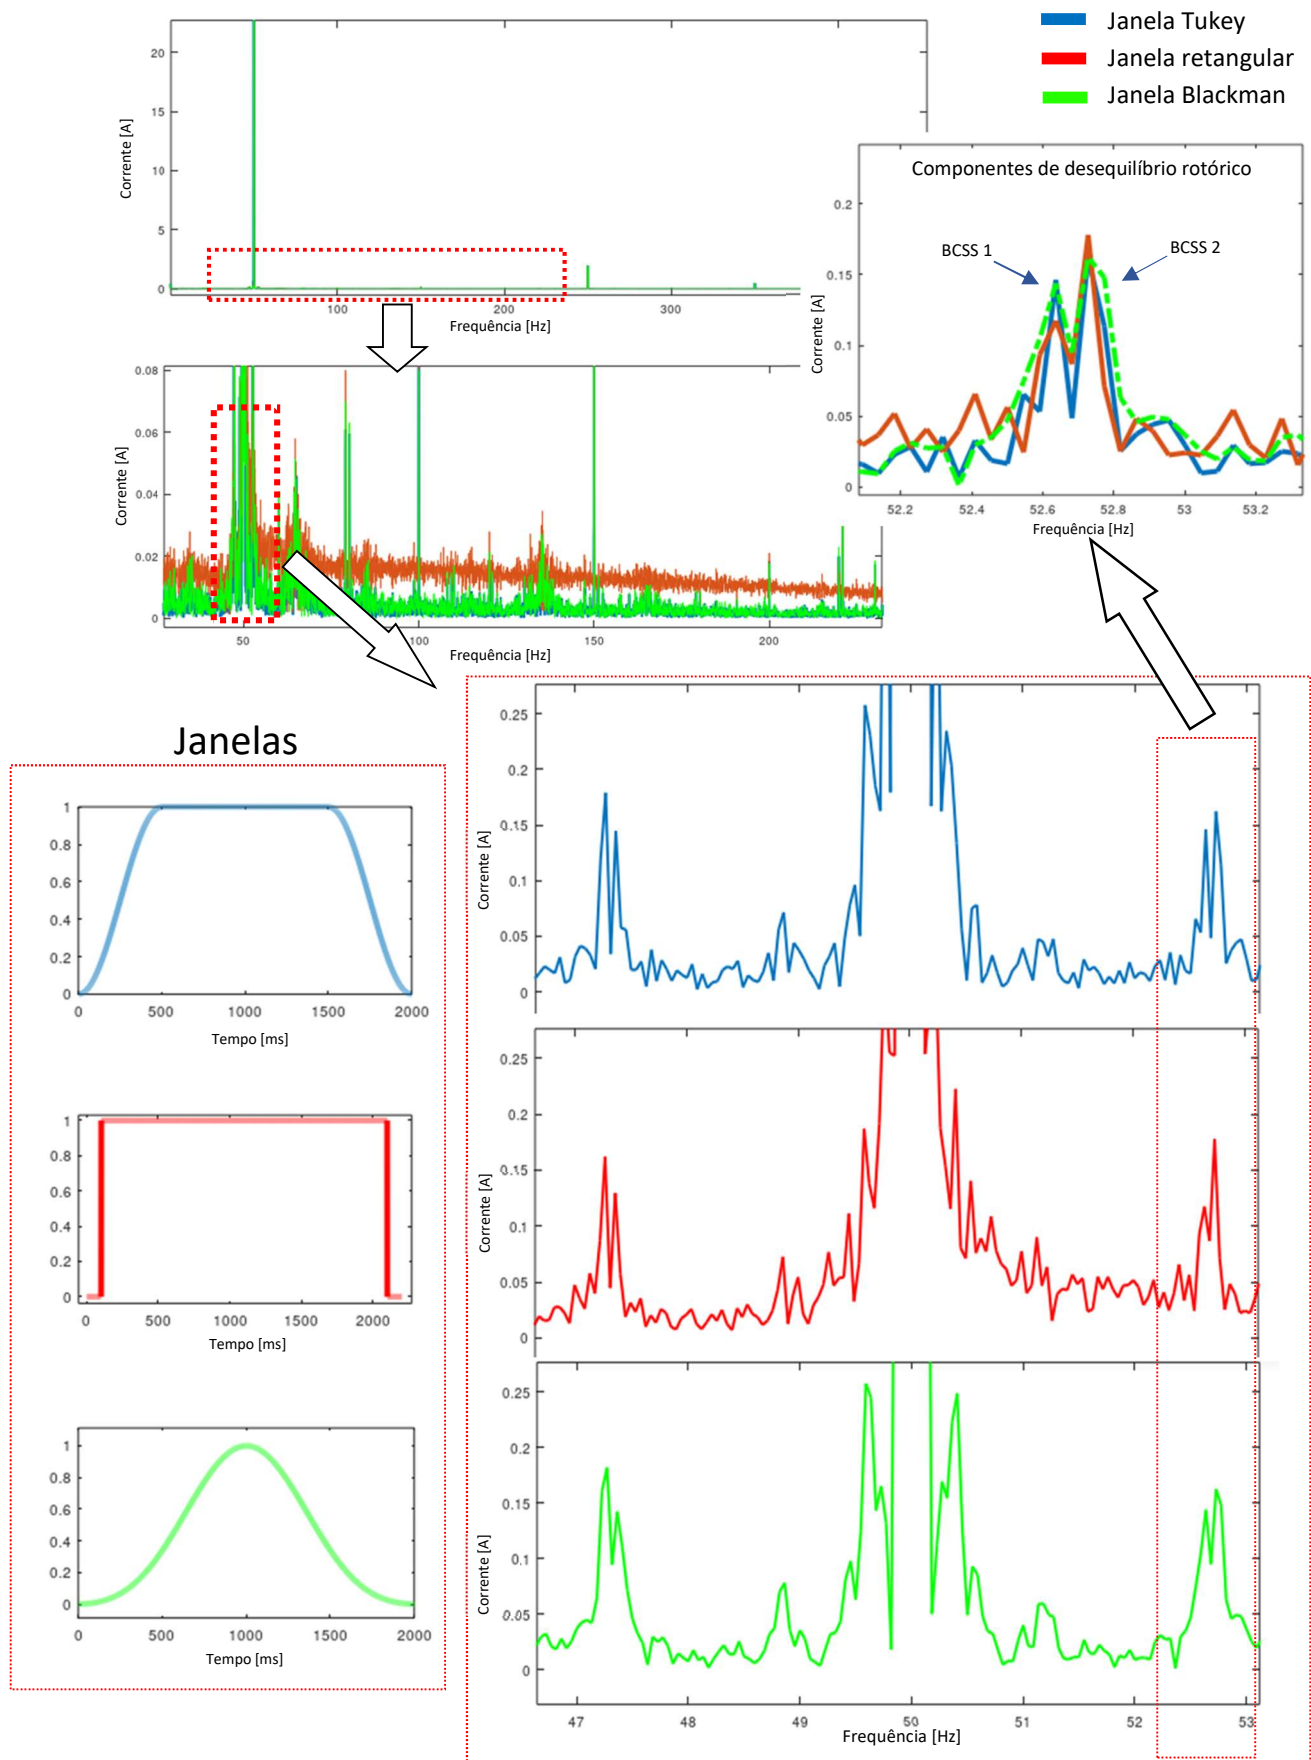


Figura 17 -Espectros de corrente para 3 tipos de janelas.

Considerando as particularidades da assinatura elétrica da *skid*-BCSS, marcada pela presença de componentes espectrais em pares e muito próximas entre si, conclui-se que a janela Tukey representa a melhor escolha para este tipo de análise. Diferentemente da janela Blackman, amplamente utilizada em motores de indução convencionais, a Tukey proporciona uma melhor distinção das frequências sem comprometer a faixa dinâmica, garantindo uma análise mais precisa e objetiva.

3.4. CONCATENAÇÃO OTIMIZADA APLICADA EM ASSINATURA ELÉTRICA DE *SKID*-BCSS

Além da aplicação do janelamento, a concatenação de sinais representa uma abordagem eficaz para aprimorar a resolução espectral em análises de sinais no domínio da frequência. Esse método consiste na junção de dois ou mais sinais adquiridos de forma sequencial. Entretanto, para que essa concatenação seja eficiente, ela deve ser conduzida de maneira otimizada, visando minimizar o *leakage* dentro de uma faixa de frequência de interesse.

O procedimento de concatenação otimizada envolve a remoção de um número específico de amostras iniciais do segundo sinal antes da junção com o primeiro. Dessa forma, diferentes valores de deslocamento são testados, e a resposta espectral do sinal concatenado é analisada em função do nível do *leakage*.

A Figura 18 ilustra esse processo de forma esquemática. Inicialmente, os dois sinais são apresentados separadamente, destacando o ponto de transição entre o final do primeiro e o início do segundo. Em seguida, o método aplicado considera a concatenação completa dos sinais, sem remoção de amostras, e calcula a Transformada Rápida de Fourier (FFT) do sinal resultante. A partir disso, determina-se a média da amplitude das componentes espectrais em uma região de frequência próxima à componente fundamental, estabelecendo assim um primeiro valor de referência para o deslocamento igual a zero.

O procedimento prossegue com a eliminação progressiva de amostras iniciais do segundo sinal, seguido do recálculo da FFT e da média de amplitude das componentes para cada novo deslocamento testado. Esse processo é repetido até a obtenção de uma curva que correlaciona o deslocamento aplicado com o respectivo nível de média de amplitude de componentes. O deslocamento correspondente ao menor valor dessa curva representa a condição ideal de concatenação, ou seja, a quantidade otimizada de amostras que devem ser descartadas do segundo sinal para minimizar o *leakage*.

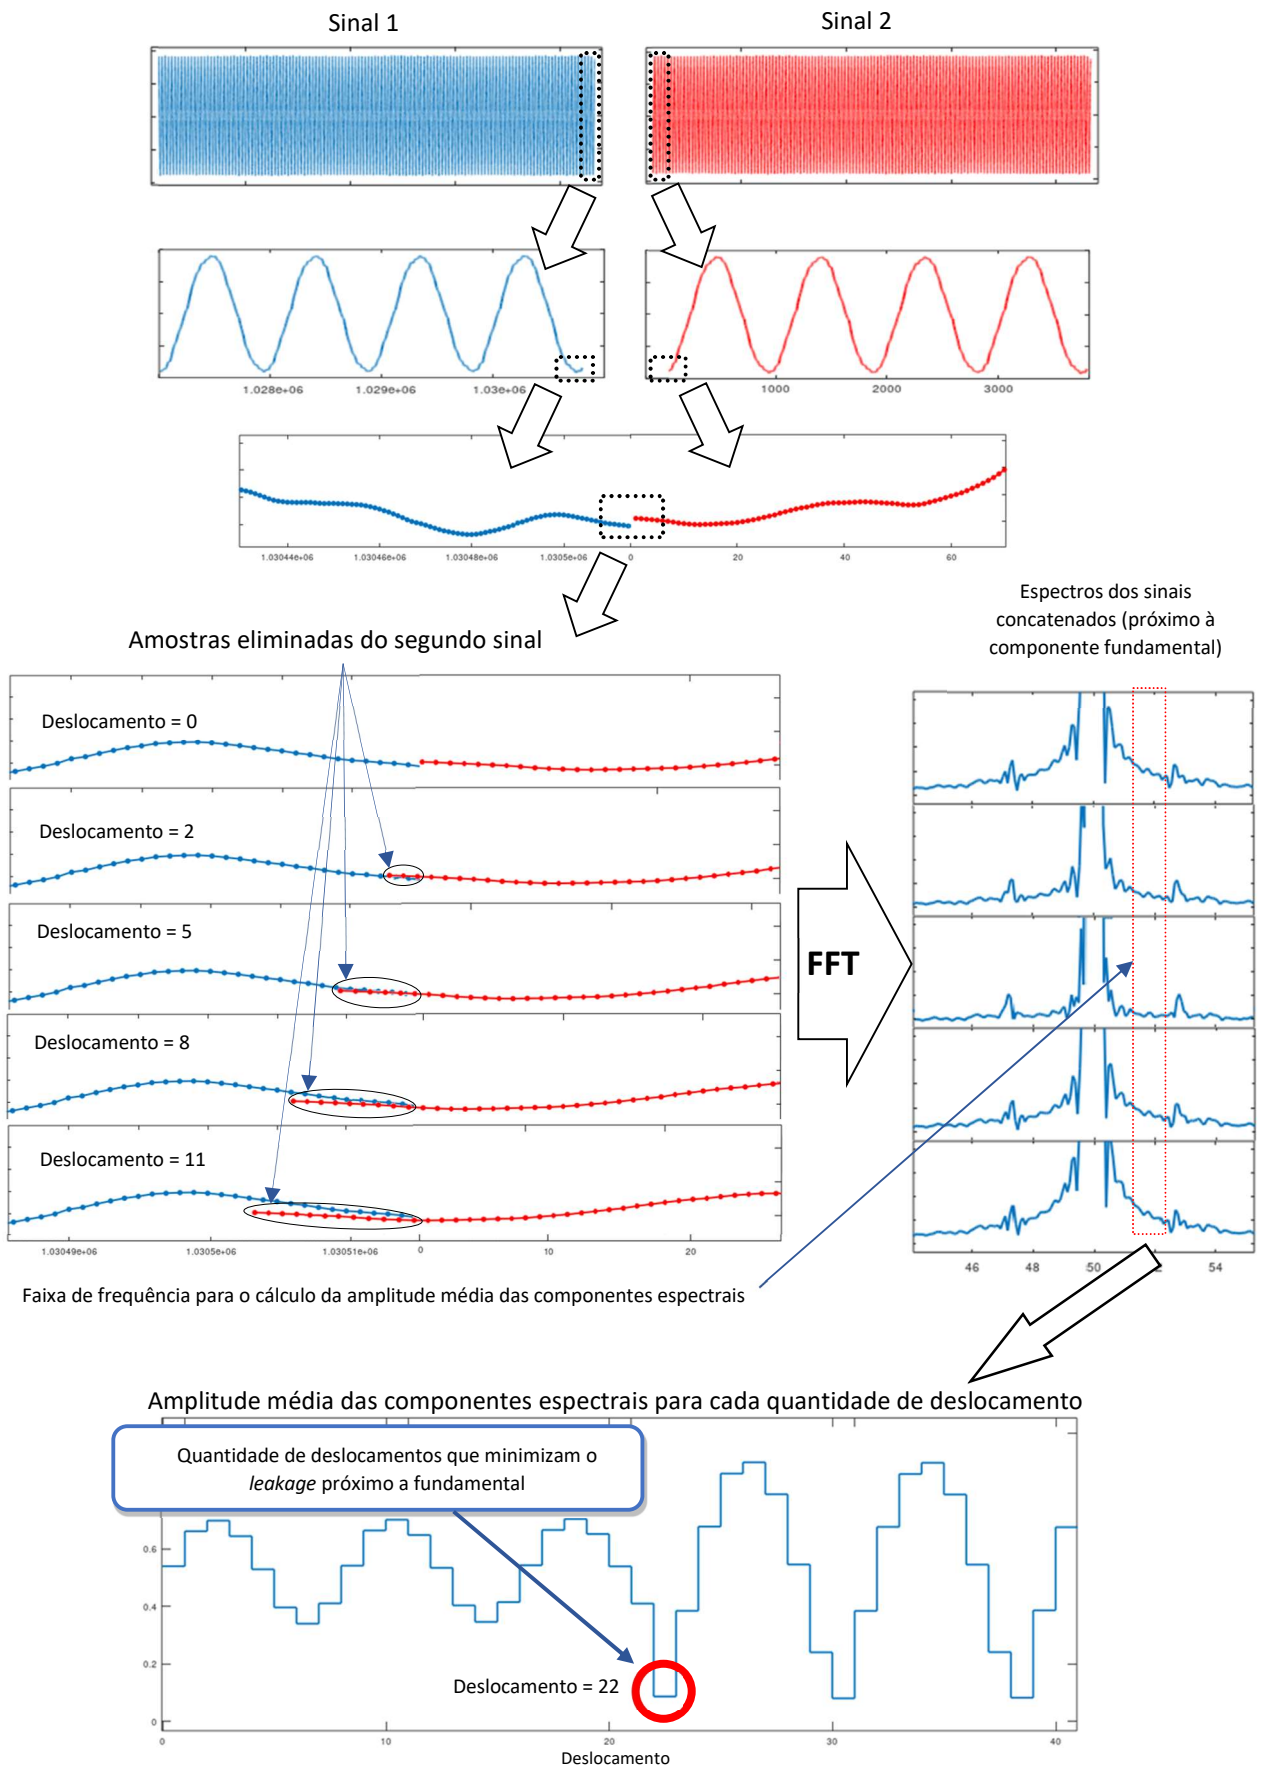


Figura 18 - Diagrama da concatenação otimizada de dois sinais.

Para demonstrar a eficácia desse método na análise de assinaturas elétricas de corrente em sistemas *skid*-BCSS, a Figura 19 apresenta os espectros de dois sinais distintos. O primeiro corresponde a um sinal de 22 segundos de duração, resultando em uma resolução espectral de 0,0454 Hz. O segundo sinal, por sua vez, consiste na concatenação de dois sinais de 22 segundos, sendo que um deles é o primeiro sinal analisado.

Ao comparar os espectros, observa-se um significativo aprimoramento na resolução espectral do sinal concatenado em relação ao sinal original. Esse ganho possibilita a distinção entre componentes espectrais que anteriormente se encontravam sobrepostas, como as associadas ao desequilíbrio rotórico e às frequências de rotação dos diferentes BCSS. Dessa forma, a concatenação otimizada demonstra-se uma ferramenta valiosa para melhorar a precisão da análise espectral em sistemas de monitoramento de máquinas.

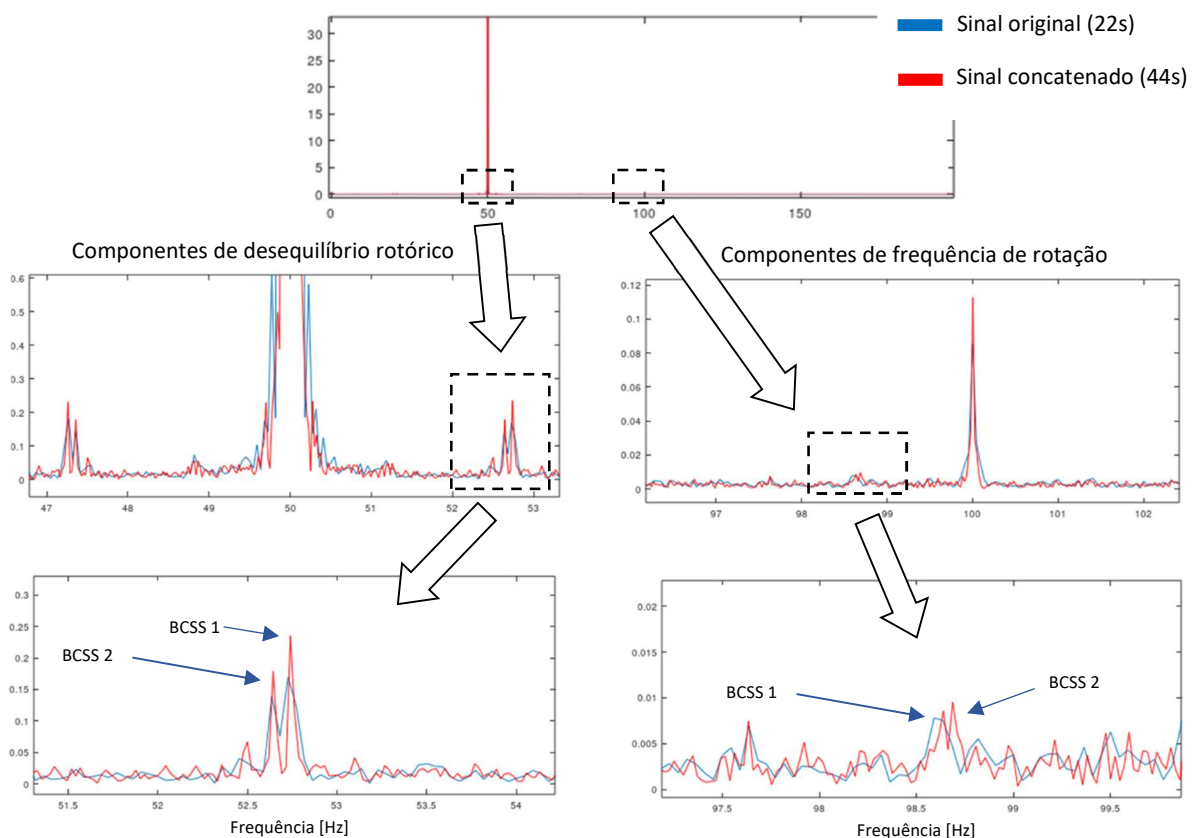


Figura 19 – Espectros para o sinal original e concatenado.

3.5. APLICAÇÃO CONJUNTA DAS TÉCNICAS DE JANELAMENTO E CONCATENAÇÃO EM SINAIS DE *SKID-BCSS*

Nesta seção, apresentam-se os resultados obtidos com a aplicação combinada das técnicas de janelamento e concatenação de sinais em um mesmo conjunto de dados provenientes de um *skid-BCSS*. O procedimento seguiu uma abordagem sequencial, contemplando inicialmente a técnica convencional de análise, seguida pela aplicação de uma janela de Tukey e, por fim, pela concatenação otimizada de sinais.

A Figura 20 ilustra os espectros obtidos por meio dessas diferentes abordagens, sendo eles:

1. Análise Convencional: Utilização da janela de Blackman, técnica frequentemente empregada em análises espectrais convencionais.
2. Janelamento Específico: Aplicação da janela de Tukey, reconhecida por sua adequação à análise de assinaturas elétricas em sistemas *skid-BCSS*.
3. Concatenação Otimizada: Implementação da concatenação otimizada de sinais em conjunto com a janela de Tukey, visando aprimorar a resolução espectral.

A análise comparativa dos espectros apresentados na Figura 20 concentra-se na faixa de frequências associada às componentes de desequilíbrio rotórico. Observa-se que, ao empregar a janela de Blackman (primeiro espectro), as componentes de desequilíbrio rotórico de cada motor do *skid-BCSS* encontram-se sobrepostas, dificultando a distinção entre elas.

Por outro lado, a aplicação da janela de Tukey (segundo espectro) permite uma separação mais evidente dessas componentes, proporcionando uma melhoria na identificação das assinaturas individuais de cada motor. A etapa final, na qual a concatenação otimizada é incorporada em conjunto com a janela de Tukey (terceiro espectro), demonstra um avanço significativo na resolução espectral. Além da distinção mais clara entre as componentes de desequilíbrio rotórico, observa-se uma melhor concentração de energia espectral, resultando em níveis de amplitude mais representativos e menos influenciados pela sobreposição espectral.

Dessa forma, a combinação das técnicas de janelamento e concatenação comprova-se uma abordagem eficiente para aprimorar a análise de assinaturas elétricas em sistemas *skid-BCSS*, permitindo uma avaliação mais precisa dos fenômenos dinâmicos envolvidos.

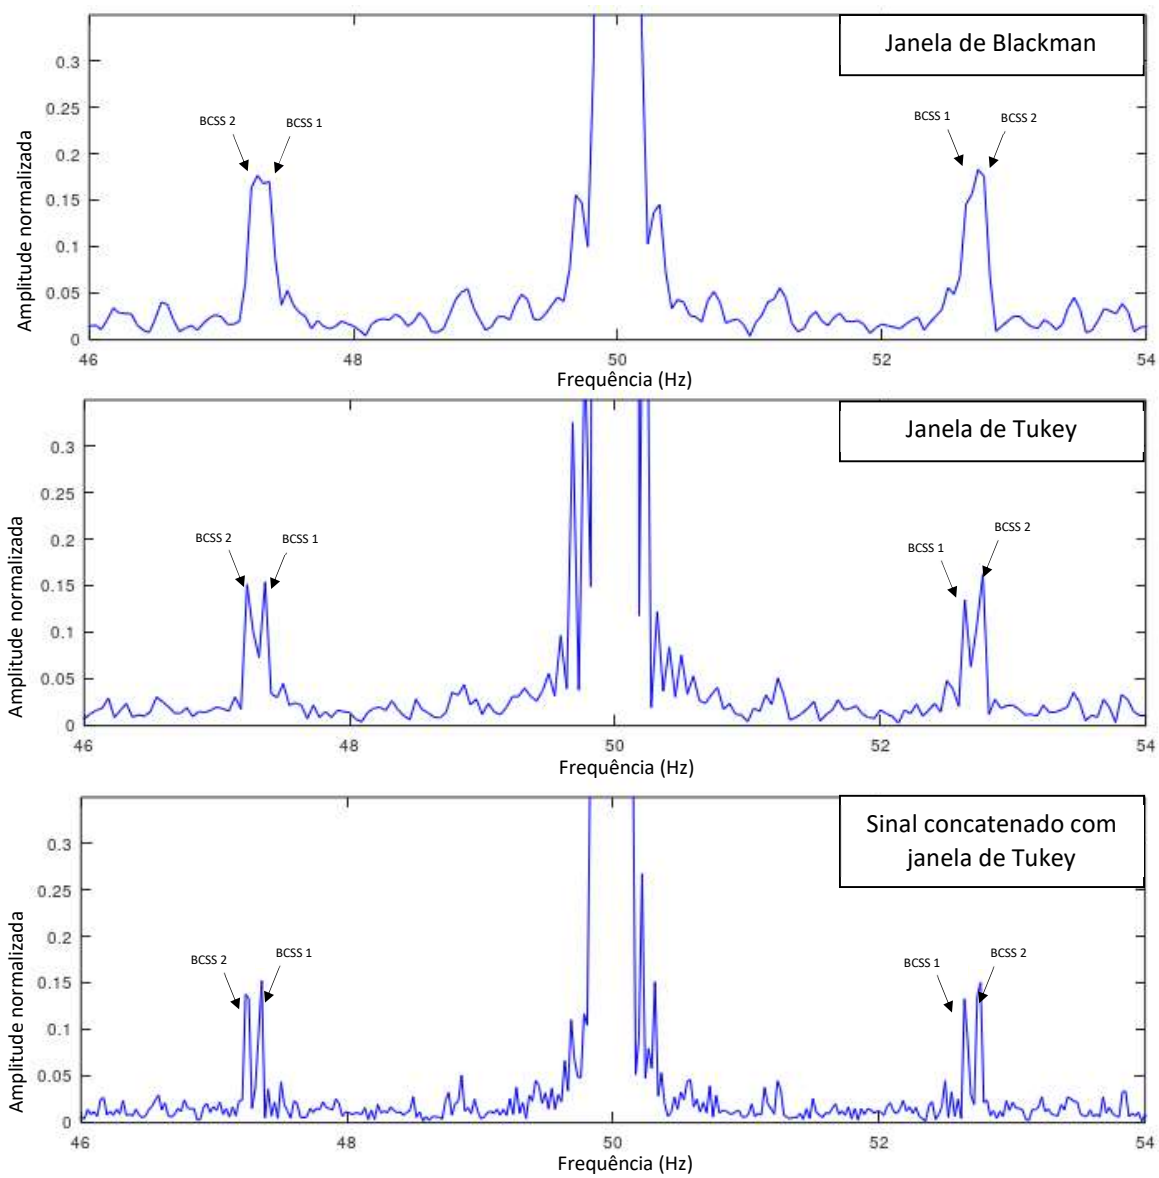


Figura 20 – Componentes de desequilíbrio rotórico.

4. ESTIMAÇÃO DA VIDA ÚTIL REMANESCENTE (RUL) POR INFERÊNCIA BAYESIANA

Nos últimos anos, a manutenção preditiva tem se consolidado como uma abordagem estratégica e imprescindível para garantir eficiência, segurança e redução de custos em sistemas industriais complexos. Diferentemente das abordagens tradicionais, como a manutenção corretiva, que aguarda a ocorrência de falhas, ou a manutenção preventiva, que opera com base em intervalos fixos de tempo, a manutenção preditiva busca antecipar falhas iminentes ao analisar sinais de desgaste ou irregularidades operacionais. Essa metodologia possibilita intervenções no momento oportuno, reduzindo custos associados a paradas não planejadas e evitando substituições desnecessárias de componentes.

Um dos maiores desafios da manutenção preditiva é a estimativa precisa do Tempo Restante de Vida (RUL, do inglês *Remaining Useful Life*) de um equipamento. Essa estimativa permite prever o momento em que um sistema atingirá uma condição crítica de falha, possibilitando um planejamento otimizado das intervenções de manutenção. Para enfrentar esse desafio, foram desenvolvidas ferramentas matemáticas e computacionais avançadas, que utilizam dados coletados em tempo real, como vibração, temperatura e pressão, para modelar o comportamento de sistemas e projetar sua degradação futura.

Entre essas ferramentas, destaca-se o uso de algoritmos de prognóstico baseados no Teorema de Bayes. Este teorema, amplamente reconhecido no campo da probabilidade, possibilita a atualização de estimativas à medida que novas informações são obtidas. Em termos práticos, o Teorema de Bayes fornece uma estrutura matemática para combinar conhecimentos prévios, representados por distribuições *a priori*, com os dados coletados ao longo do monitoramento, representados pela função de verossimilhança. O resultado dessa combinação é a distribuição *a posteriori*, que reflete uma estimativa atualizada e mais precisa dos parâmetros de degradação.

Neste estudo, o Teorema de Bayes é implementado em conjunto com técnicas de amostragem MCMC (Markov Chain Monte Carlo), como o algoritmo Metropolis-Hastings. Essas técnicas possibilitam a realização de inferências probabilísticas em cenários onde as distribuições envolvidas apresentam alta complexidade e não possuem soluções analíticas. O uso do MCMC permite gerar amostras da distribuição *a posteriori*, fornecendo não apenas os

valores estimados dos parâmetros, mas também as incertezas associadas a essas estimativas. Essa abordagem é especialmente relevante em contextos industriais, onde decisões críticas demandam elevado grau de confiabilidade.

Com base nos parâmetros estimados, o modelo de degradação pode ser propagado ao futuro, permitindo a simulação da evolução do sistema até que uma condição de falha seja atingida. Esse processo incorpora incertezas nos parâmetros do modelo e nas condições operacionais, resultando em uma previsão probabilística do RUL. Assim, o algoritmo oferece não apenas uma estimativa pontual do RUL, mas também uma análise detalhada das incertezas envolvidas, garantindo maior precisão no planejamento de manutenção e na gestão de ativos.

A metodologia apresentada foi aplicada à análise de sinais de vibração, amplamente utilizados na detecção de falhas em máquinas rotativas, como motores e bombas. O uso de sinais de vibração foi motivado pela disponibilidade de dados. Além disso, os sinais de assinatura elétrica da *skid*-BCSS/BCSS apresentam comportamento análogo, com características exponenciais de degradação semelhantes às observadas nos sinais de vibração.

O estudo explorou técnicas de processamento de sinais, incluindo o uso de janelas específicas para aprimorar a resolução espectral, bem como métodos probabilísticos para análise preditiva. Os resultados demonstraram que a abordagem proposta é capaz de identificar padrões de degradação e acompanhar a evolução das falhas com alta precisão.

Portanto, a introdução do Teorema de Bayes e de técnicas MCMC no campo da manutenção preditiva representa um avanço significativo, proporcionando uma abordagem robusta e flexível para prognósticos. A integração de dados históricos e informações em tempo real possibilita previsões confiáveis, que incorporam incertezas e oferecem subsídios fundamentais para a tomada de decisão em ambientes industriais, maximizando a confiabilidade operacional e minimizando custos associados à manutenção.

A ideia central do algoritmo de prognóstico deste trabalho é o Teorema de Bayes, que possibilita a atualização de crenças ou estimativas a partir de novas evidências. Esse método considera tanto o conhecimento prévio sobre o sistema, quanto as informações obtidas ao longo do monitoramento. O resultado dessa combinação reflete a estimativa atualizada dos parâmetros do modelo de degradação com base nos dados observados.

No contexto de prognóstico, o algoritmo utiliza técnicas de amostragem MCMC (Markov Chain Monte Carlo), como o Metropolis-Hastings, para realizar inferências sobre os parâmetros do modelo de degradação de forma probabilística.

O algoritmo de prognóstico se baseia no fluxograma da Figura 21 a seguir, onde as etapas são estruturadas para capturar o processo de degradação, estimar parâmetros e prever o Tempo Restante de Vida (RUL) com base no Teorema de Bayes. A primeira etapa consiste em identificar o modelo de degradação, que é selecionado com base nas características do sistema ou equipamento monitorado. O modelo deve representar adequadamente a evolução da falha, como um comportamento linear, exponencial ou logarítmico, considerando as condições operacionais e históricas do equipamento.

Na segunda etapa, são coletados os dados de degradação, que podem incluir variáveis como vibração, temperatura, pressão ou outros indicadores relevantes. Esses dados são essenciais para alimentar o modelo e refletem o comportamento real do equipamento ao longo do tempo.

A terceira etapa é a estimação dos parâmetros do modelo utilizando MCMC (Markov Chain Monte Carlo), com o algoritmo Metropolis-Hastings. Nessa fase, os parâmetros do modelo são ajustados considerando a combinação das distribuições a priori e das observações coletadas, resultando na distribuição a posteriori. Essa abordagem incorpora as incertezas associadas ao processo de degradação, permitindo uma análise probabilística robusta.

Após a estimação, ocorre a propagação do modelo para o futuro, onde o comportamento do sistema é simulado com base nos parâmetros estimados. Essa projeção considera tanto as incertezas dos parâmetros quanto as condições futuras esperadas do equipamento.

Por fim, é realizada a previsão do Tempo Restante de Vida (RUL), que fornece uma estimativa probabilística do tempo até que o equipamento atinja uma condição de falha. Essa etapa é crucial para a tomada de decisões sobre manutenção preditiva, planejamento de reparos e gestão de ativos, maximizando a confiabilidade e a eficiência operacional.

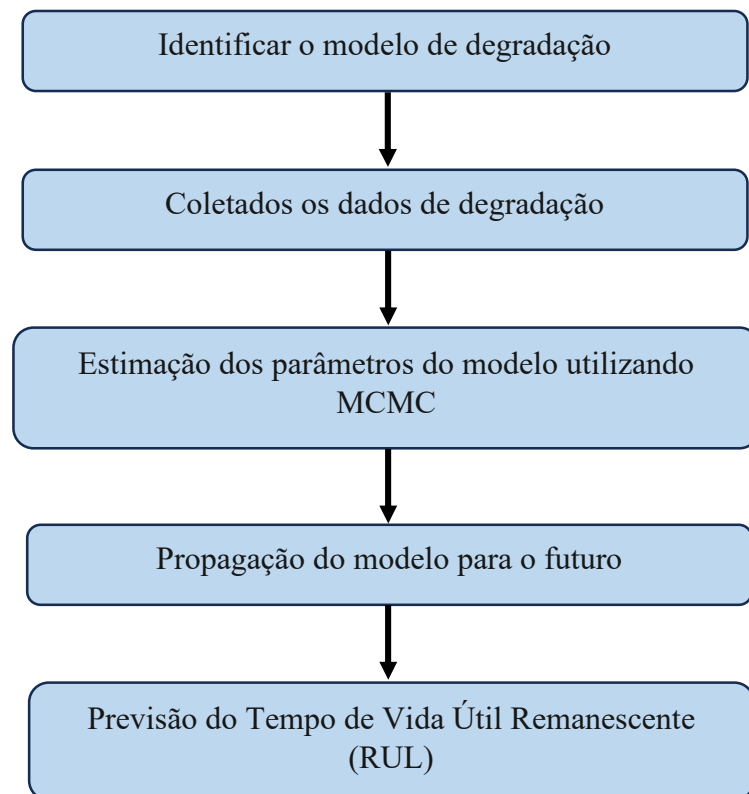


Figura 21 – Fluxograma do algoritmo de prognóstico Bayesiano.

A equação (9) apresentada a seguir expressa o Teorema de Bayes, que estabelece uma relação fundamental na inferência estatística. Nesse contexto, $P(\Theta|Y)$ representa a probabilidade condicional do parâmetro desconhecido Θ , dado que a variável Y é conhecida. Essa probabilidade, denominada distribuição a posteriori, quantifica o grau de confiança na estimativa de Θ após a incorporação das informações fornecidas por Y .

Por outro lado, $P(Y|\Theta)$ corresponde à verossimilhança, que expressa a plausibilidade de observar o valor Y considerando um determinado valor do parâmetro Θ . Em outras palavras, essa função mede o quanto a variável observada Y corrobora uma possível estimativa do parâmetro Θ , (27).

$$P(\Theta|Y) = \frac{P(Y|\Theta)P(\Theta)}{P(Y)} \quad (9)$$

Onde:

- $P(\Theta|Y)$: Probabilidade posterior
 - É a probabilidade de um parâmetro θ dado os dados observados.

- Responde: *Quão provável é este valor do parâmetro, considerando os dados e nosso conhecimento prévio?*
- $P(Y|\theta)$: Verossimilhança
 - Mede o quão bem os dados observados são explicados por um determinado valor de θ .
 - Responde: *Quão provável é observar estes dados, assumindo que θ é o parâmetro verdadeiro?*
- $P(\theta)$: Probabilidade a priori
 - Representa o conhecimento ou crença sobre θ antes de observar os dados.
 - Pode ser baseada em informações anteriores ou ser uniforme (neutra).
- $P(Y)$: Probabilidade marginal (normalização)
 - Garantia de que a soma total das probabilidades do posterior seja 1.

Para a viabilização do uso da ferramenta MCMC (Markov Chain Monte Carlo) é utilizado a densidade de probabilidade no lugar do uso de probabilidades simples, uma vez que as distribuições de probabilidade posterior são frequentemente complexas e não podem ser calculadas analiticamente.

Quando os parâmetros θ pertencem a um espaço contínuo, as probabilidades não podem ser atribuídas a um único ponto, apenas a intervalos. Em vez disso, usamos densidades de probabilidade para representar a "densidade de massa" em torno de um valor. Além disso, a densidade permite reconstruir distribuições completas a partir de amostras geradas pelo MCMC, como histogramas suavizados ou funções kernel.

Trabalhar diretamente com densidades evita a necessidade de normalização explícita. Isso viabiliza o MCMC lidar com distribuições de forma complexa (multimodais, assimétricas) que não são facilmente tratadas com abordagens determinísticas.

O teorema de Bayes pode ser apresentado na forma de função de densidade de probabilidade (PDF), para se obter dos parâmetros do modelo Θ , com descrito na equação (10), (28):

$$f_{\theta}(\theta|Y = y) = \frac{f_Y(y|\theta)f_{\theta}(\theta)}{f_Y(y)} \quad (10)$$

Onde:

$f_{\theta}(\theta)$ - é a PDF priori do parâmetro do modelo θ ;

$f_Y(y)$ - é a PDF priori, associada aos dados medidos;

$f_Y(y|\theta = \theta)$ - é a função verossimilhança, a PDF dos dados medidos 'y' para determinados parâmetros do modelo 'θ';

$f_{\theta}(\theta|Y = y)$ - é a PDF posterior do parâmetro θ , que é atualizado da PDF priori $f_{\theta}(\theta)$ com a função de verossimilhança $f_Y(y|\theta = \theta)$.

4.1. AMOSTRAGEM POR MONTE CARLO VIA CADEIA DE MARKOV (MCMC)

O funcionamento do método MCMC pode ser compreendido de forma mais clara por meio da Figura 22. Esse método utiliza um processo estocástico, representado por uma cadeia de Markov, onde cada estado futuro depende apenas do estado atual. Essa propriedade, conhecida como "memória curta", é formalmente descrita pela seguinte relação probabilística, expressa na equação (11), (29):

$$P(X_t \in A|X_0, \dots, X_{t-1}) = P(X_t \in A|X_{t-1}) \quad (11)$$

onde X_t representa o estado atual, X_{t-1} o estado imediatamente anterior, e 'A' é um subconjunto do espaço de estados.

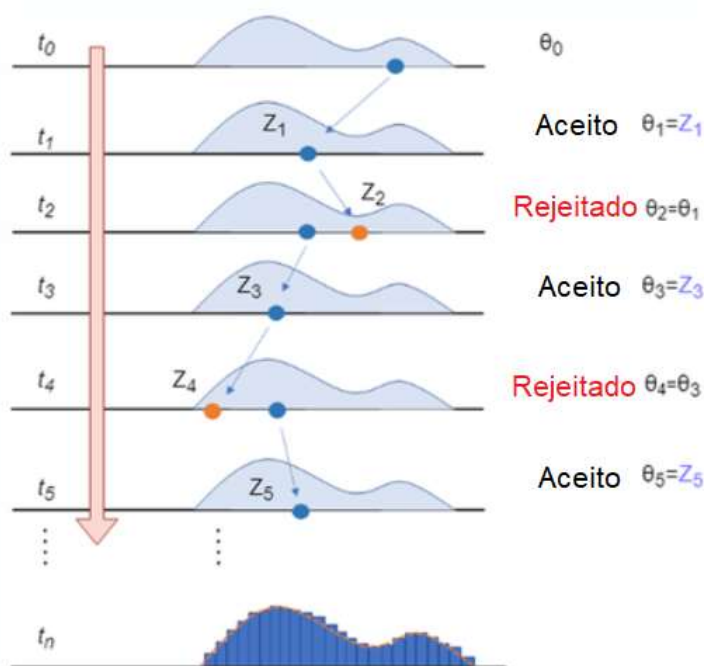


Figura 22 – Amostragem MCMC.

Na Figura 22, o processo iterativo do MCMC é ilustrado em diferentes tempos $t_0, t_1, t_2, \dots, t_n$. Inicialmente, o algoritmo começa com uma amostra inicial θ_0 . A cada iteração, uma nova proposta Z_i é gerada a partir de uma distribuição de transição (indicada pelas curvas em azul). Em seguida, a proposta é avaliada:

1. Se a proposta Z_i for aceita (como em t_1, t_3, t_5), o estado ‘ θ ’ é atualizado para $\theta_i = Z_i$.
2. Caso contrário, como em t_2 e t_4 , a proposta é rejeitada, e o estado permanece inalterado ($\theta_i = \theta_{i-1}$).

Esse mecanismo de aceitação/rejeição é determinado pela razão de probabilidade entre os estados proposto e atual, garantindo que a cadeia explore o espaço de parâmetros e gradualmente convirja para a distribuição estacionária de interesse.

O histograma na parte inferior da Figura 22 ilustra a convergência do método, mostrando como as amostras geradas pelo MCMC se acumulam em torno da distribuição estacionária (representada pela curva laranja). Esse comportamento reflete a capacidade do MCMC de fornecer uma estimativa precisa da distribuição a posteriori, que é fundamental em problemas de inferência e análise probabilística.

O método MCMC oferece uma alternativa poderosa aos métodos não iterativos convencionais, que muitas vezes apresentam limitações ao lidar com distribuições complexas e de difícil acesso analítico. A abordagem iterativa possibilita a obtenção de amostras representativas da distribuição a posteriori, mesmo em situações em que soluções exatas são computacionalmente inviáveis. A partir dessas amostras, é possível calcular estimativas de características importantes, como médias, variâncias ou percentis, fornecendo informações fundamentais para a análise probabilística.

No contexto deste trabalho, o método MCMC é utilizado para inferir os parâmetros do modelo de degradação de equipamentos a partir de dados monitorados em tempo real. A projeção desses parâmetros permite prever o comportamento futuro do sistema, incluindo o Tempo Restante de Vida (RUL) do equipamento. O uso do MCMC possibilita a incorporação das incertezas inerentes ao processo de degradação e às condições operacionais, fornecendo não apenas estimativas pontuais, mas também intervalos de confiança associados.

4.2. ALGORITMO METROPOLIS-HASTINGS

Para garantir a convergência eficiente da cadeia gerada pelo método MCMC, foi utilizado o algoritmo de Metropolis-Hastings. Este algoritmo é uma extensão do método de Monte Carlo e se baseia em um processo iterativo de rejeição e aceitação de amostras, com o objetivo de ajustar a cadeia de Markov para que ela convirja à distribuição a posteriori desejada.

O algoritmo de Metropolis-Hastings é amplamente reconhecido por sua robustez em amostragem de distribuições complexas, onde métodos diretos podem ser inviáveis. Ele utiliza uma distribuição auxiliar para gerar novos valores que são avaliados em relação à probabilidade de aceitação. Essa probabilidade é determinada de forma a garantir que, ao longo das iterações, a cadeia explore eficientemente o espaço de parâmetros e convirja para a distribuição de interesse.

O funcionamento do algoritmo segue as etapas detalhadas abaixo (29):

1. Inicialização:

Para a iteração inicial ($t = 0$), define-se um valor inicial $\theta^{(0)}$ para a cadeia. Este valor inicial pode ser escolhido com base em conhecimento prévio sobre o sistema ou

selecionado aleatoriamente dentro de um intervalo plausível. A escolha de um bom ponto inicial pode acelerar o processo de convergência.

2. Definição do número de iterações:

Antes de iniciar o processo iterativo, é necessário fixar o número de iterações a serem realizadas. Este número depende da complexidade da distribuição e da precisão desejada. Em alguns casos, a convergência pode ser monitorada dinamicamente para determinar se mais iterações são necessárias.

3. Geração de um novo valor de proposta:

Um novo valor θ' é gerado a partir de uma distribuição auxiliar $q(\cdot | \theta)$. Esta distribuição pode ser simétrica (como uma distribuição normal centrada em θ) ou assimétrica, dependendo do problema e das características da distribuição a posteriori.

4. Cálculo da probabilidade de aceitação:

A probabilidade de aceitação $\alpha(\theta, \theta')$ é calculada com base na razão entre a função densidade de probabilidade da distribuição a posteriori avaliada no novo valor θ' e no valor atual θ , ajustada pela distribuição de proposta.

5. Geração de um número aleatório:

Um número aleatório ' u ' é gerado a partir de uma distribuição uniforme no intervalo $[0,1]$.

6. Decisão de aceitação ou rejeição:

- Se $u \leq \alpha(\theta, \theta')$, o valor proposto θ' é aceito, e o próximo estado da cadeia é atualizado para $\theta^{(t+1)} = \theta'$.
- Caso contrário, o valor θ' é rejeitado, e a cadeia permanece no estado atual, ou seja, $\theta^{(t+1)} = \theta^{(t)}$.

7. Atualização do contador e repetição:

O contador da iteração é incrementado, e o processo retorna ao passo 3. Esse ciclo é repetido até que o número total de iterações seja alcançado.

8. Verificação de convergência:

Ao final das iterações, verifica-se se a cadeia atingiu a convergência, ou seja, se a distribuição das amostras geradas reflete adequadamente a distribuição a posteriori.

Caso contrário, pode-se aumentar o número de iterações ou revisar a configuração inicial do algoritmo.

A Figura 22 anterior ilustra o processo de aceitação e rejeição ao longo das iterações. A cadeia gerada eventualmente converge para a distribuição estacionária desejada, permitindo uma exploração abrangente do espaço de parâmetros.

4.3. PROGNÓSTICO VIA INFERÊNCIA BAYESIANA DE COMPONENTES ESPECTRAIS

Nesta seção, será realizada a aplicação da inferência Bayesiana para estimar o Tempo Restante de Vida (RUL, do inglês *Remaining Useful Life*), também denominado prognóstico, de componentes espectrais obtidas de sinais de vibração. Especificamente, as componentes espectrais analisadas correspondem aos valores de uma frequência caracterizada em um conjunto de sinais de vibração coletados sequencialmente. Essa análise pode ser interpretada como uma curva de tendência, refletindo o comportamento dinâmico de uma determinada assinatura elétrica ao longo do tempo.

O conjunto de dados utilizado foi obtido por meio de um acelerômetro acoplado ao mancal de um motor de indução trifásico de 4 polos. Durante o monitoramento, esse motor apresentou falhas progressivas no rolamento, o que torna o caso ideal para a aplicação de técnicas de prognóstico. Os sinais de vibração foram coletados em intervalos regulares de 4 horas utilizando o sistema de aquisição Preditor®, que possui uma resolução de 24 bits. Cada coleta teve uma frequência de amostragem de 11.718 Hz e duração de 22,37 segundos, garantindo uma representação detalhada do comportamento vibracional do equipamento ao longo do tempo.

Ao todo, 400 sinais foram adquiridos durante o experimento, permitindo a análise do desenvolvimento da falha de forma progressiva. O processo de coleta sistemática em intervalos regulares é essencial para alimentar os modelos de prognóstico, pois fornece dados consistentes para a modelagem probabilística da degradação.

A Figura 23 ilustra a evolução do espectro de frequência dos sinais de vibração ao longo do monitoramento. Observa-se que, até a aquisição de ordem 362, as componentes espectrais não sofreram evoluções abruptas consistentes, indicando um estágio inicial da falha. Contudo, a partir desse ponto, verifica-se um crescimento abrupto e consistente na amplitude das

componentes de 138,5 Hz, 200 Hz e 240 Hz. Esse comportamento reflete a intensificação da falha no rolamento, um fenômeno característico em sistemas que operam sob condições de degradação progressiva.

A inferência Bayesiana, aplicada a este cenário, considera a evolução dessas componentes espectrais como uma variável aleatória que pode ser modelada por distribuições probabilísticas. O objetivo é integrar informações históricas, representadas pela distribuição *a priori*, com os dados observados ao longo do tempo, por meio da função de verossimilhança. O resultado dessa combinação é a distribuição *a posteriori*, que reflete a estimativa atualizada do comportamento das componentes espectrais e, conseqüentemente, do RUL.

Essa abordagem probabilística é particularmente eficaz para lidar com as incertezas inerentes ao processo de degradação. Ao contrário de métodos determinísticos, que fornecem uma única estimativa pontual, a inferência Bayesiana permite a obtenção de uma distribuição completa para o RUL. Essa distribuição captura tanto a estimativa mais provável quanto a variabilidade associada, o que é fundamental para a tomada de decisão em ambientes industriais críticos.

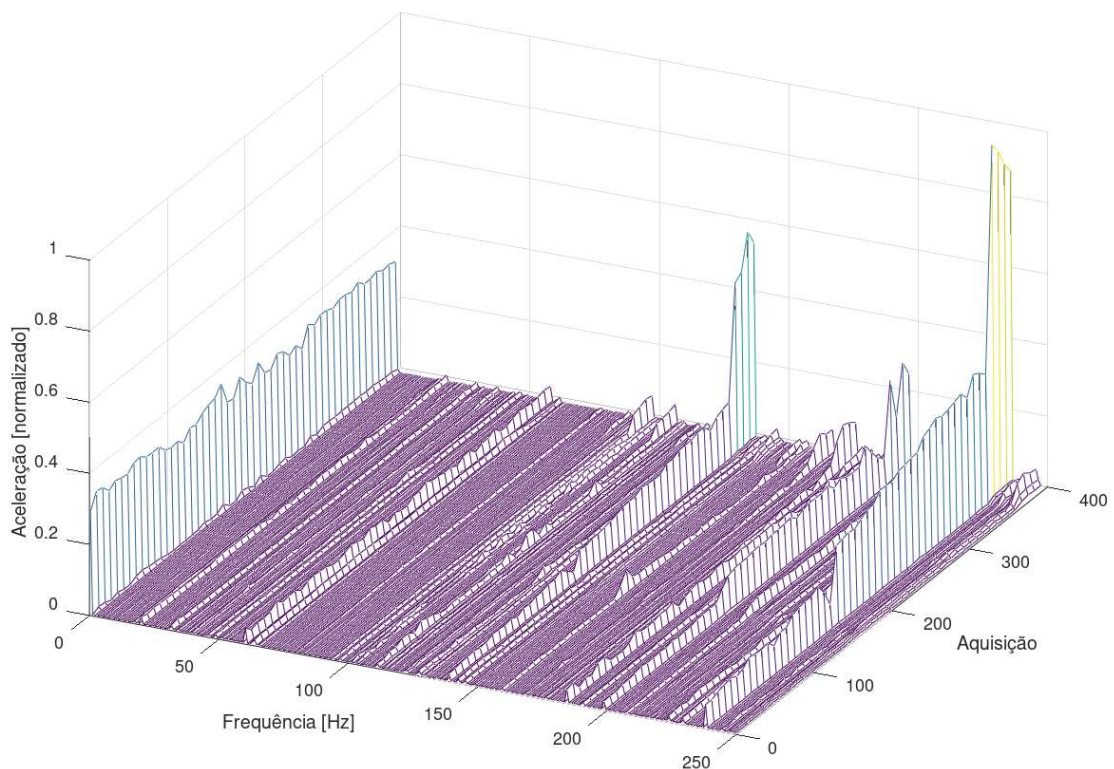


Figura 23 - Evolução das componentes espectrais do sinal de vibração.

Entre as componentes que evoluíram com a severidade da falha, tem-se a frequência de 138,5 Hz, como apresentado nas Figuras 23 e 24, com padrão exponencial até a ocorrência da falha do motor e essa será utilizada no prognóstico Bayesiano.

Nota-se que a evolução da amplitude até a aquisição de ordem 362, assim, considera-se nesse trabalho que essa aquisição marca o início da falha. Assim, o método Bayesiano pode ser aplicado em uma determinada quantidade de amostras iniciais do sinal de vibração e avaliado seu respectivo RUL, de modo a detectar o comportamento exponencial da componente ainda em sua fase incipiente.

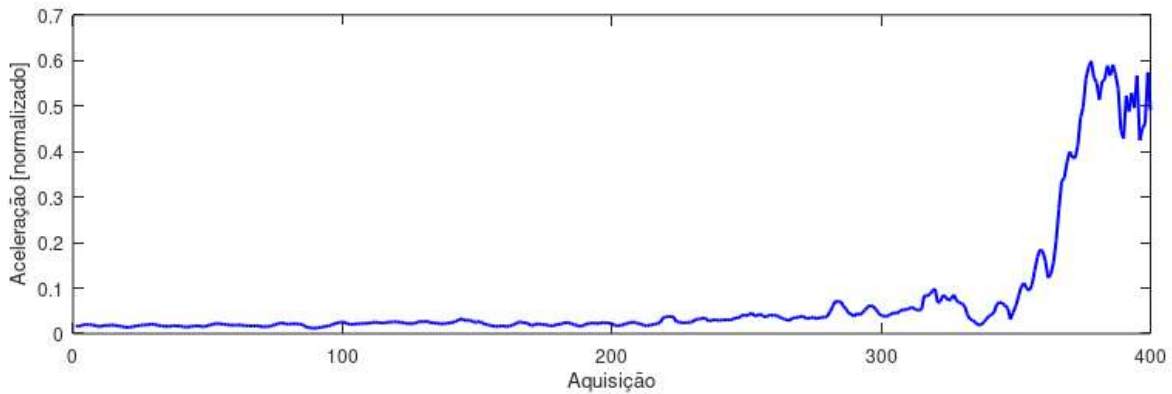


Figura 24 - Evolução da componente espectral de 138,5 Hz do sinal de vibração.

Para a aplicação da inferência Bayesiana utilizando o método de amostragem MCMC, primeiramente será construído um vetor que representa a ordem das aquisições, denominado t_{ordem} , abrangendo desde o instante inicial (t_1 , correspondente à primeira aquisição) até o instante final (t_{final} , referente à última aquisição, no caso, a aquisição 400). Esse vetor é representado matematicamente conforme a equação (12):

$$t_{ordem} = [t_1 t_2 \dots t_{atual} \dots t_{final}] \quad (12)$$

Os dados de medição disponíveis como entrada para o modelo são aqueles compreendidos no intervalo entre t_1 e t_{atual} . A partir desses dados, os parâmetros do modelo Bayesiano são estimados utilizando o conjunto de medições disponíveis, gerando a distribuição de probabilidade a posteriori (PDF) dos parâmetros. Com base nessas estimativas, as

amplitudes das componentes espectrais são, então, projetadas para a fase de previsão, que compreende o intervalo entre t_{atual} e t_{final} .

Na etapa seguinte, a inferência Bayesiana é aplicada sobre a tendência das componentes espectrais mencionadas, utilizando o método de amostragem MCMC. Para inicializar o processo, será selecionada uma quantidade limitada de amostras obtidas anteriormente ao evento de falha. Com base nessas amostras iniciais, o método estima o Tempo Restante de Vida (RUL). Após essa etapa, novas amostras são progressivamente inseridas no modelo, recalculando-se o RUL a cada iteração. Essa abordagem permite monitorar continuamente a evolução da degradação do sistema.

O intervalo entre cada amostra corresponde ao tempo decorrido entre as aquisições consecutivas. No presente trabalho, esse intervalo é de 4 horas, representando o período entre as medições coletadas pelo sistema de monitoramento.

Para avaliar a eficácia do método Bayesiano, compara-se o instante em que o modelo exponencial de falha prevê a falha iminente com o instante em que a componente espectral supera o nível de *threshold* definido. Essa análise permite medir a antecipação em termos de quantidade de amostras proporcionada pelo método Bayesiano em relação ao limite estabelecido pelo *threshold*.

É importante destacar que a precisão da estimativa do RUL depende diretamente do nível de *threshold* adotado. Consequentemente, o capítulo subsequente deste trabalho dedicará atenção à justificativa e ao detalhamento do processo de definição do nível de *threshold*, essencial para a robustez e a confiabilidade do modelo Bayesiano.

4.3.1. Definição do *threshold*

Para determinar o *threshold* inicial que será utilizado no monitoramento da componente espectral, selecionou-se um conjunto de 165 amostras obtidas durante a operação da máquina em condições normais, sem a presença de falhas detectáveis. Este conjunto de dados é considerado o *baseline* do sistema, representando o comportamento saudável da máquina. A Figura 25 ilustra a evolução das amostras iniciais da componente espectral analisada, enquanto a Figura 26 apresenta o histograma das amplitudes dessas amostras, juntamente com a curva de sua distribuição estatística.

Observa-se, pela análise da Figura 26, que a distribuição das amostras apresenta um comportamento assimétrico, indicando que valores extremos não são distribuídos de forma

uniforme em relação à média. Nesse contexto, o uso de desvios padrão para definição de *thresholds* se torna inadequado, pois essa abordagem pressupõe uma simetria na distribuição dos dados e considera apenas eventos que estão a uma certa distância fixa da média. Em vez disso, foi adotada a metodologia baseada em percentis, que permite capturar com precisão os limites superiores dos dados, mesmo em distribuições não simétricas.

Para este trabalho, adotou-se um nível conservador correspondente ao 99º percentil, garantindo que o *threshold* inicial cubra uma ampla margem de variabilidade natural das condições normais de operação, minimizando falsos positivos no monitoramento. O valor calculado para o *threshold* inicial, com base nas 165 amostras da Figura 25, foi de 1,1191 g.

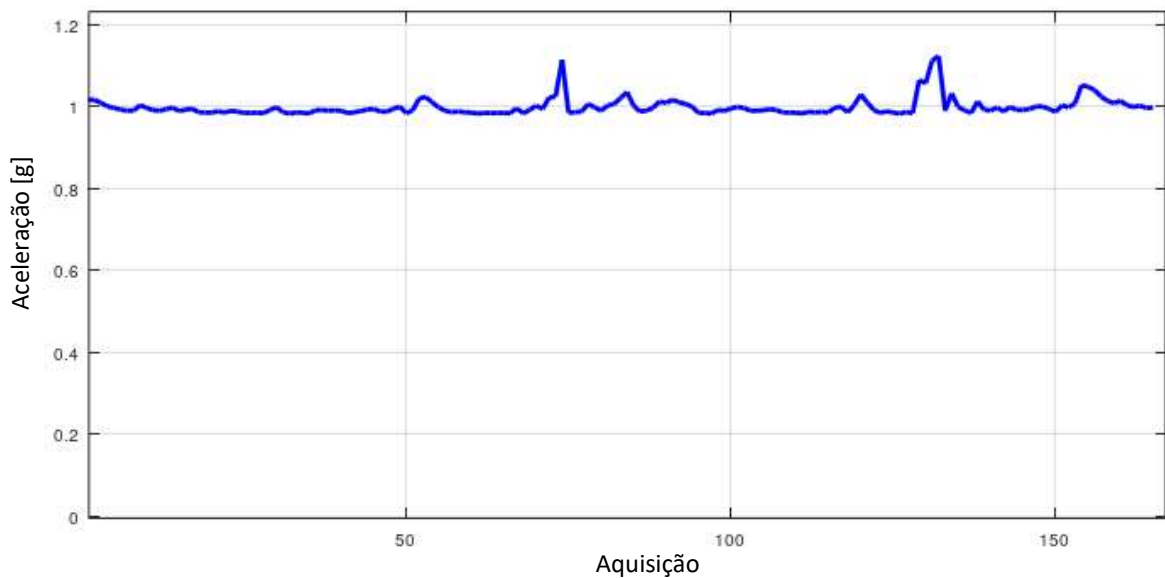


Figura 25 – Amostras iniciais utilizadas na definição do *threshold*.




Figura 26 – Histograma e distribuição das amostras iniciais.

4.3.2. Atualização Dinâmica do *Threshold*

Após a definição do *threshold* inicial, o algoritmo implementado prevê a atualização contínua deste valor à medida que novas amostras são coletadas. O cálculo do novo *threshold* é realizado utilizando sempre um conjunto móvel de amostras mais recentes, definido pelo tamanho da janela de análise do modelo Bayesiano. Por exemplo, para uma janela contendo 140 amostras, o *threshold* é recalculado utilizando apenas essas 140 amostras mais recentes.

No entanto, a atualização do *threshold* segue um critério conservador: o novo valor só será atualizado se exceder o nível previamente definido. Essa abordagem visa evitar flutuações excessivas no *threshold* em resposta a variações momentâneas nas condições de operação, mantendo a robustez e confiabilidade do sistema de monitoramento.

A combinação dessas estratégias – o uso de percentis na definição inicial e a atualização dinâmica baseada em janelas móveis – permite que o *threshold* seja adaptado às mudanças operacionais ao longo do tempo, garantindo que ele permaneça um indicador confiável para a detecção de anomalias na componente espectral analisada.

4.3.3. Curva de Degradação

A escolha de um modelo exponencial para representar a curva de degradação em um algoritmo de prognóstico pode ser amplamente justificada devido à sua capacidade de capturar o comportamento acelerado típico de muitos processos de degradação. De acordo com Gebraeel et al. (2005), sinais de degradação extraídos de sensores podem ser utilizados para prever a evolução futura da condição de um equipamento. Esse prognóstico é realizado por meio de uma modelagem apropriada do sinal de degradação, possibilitando a estimativa da distribuição da vida útil remanescente (RUL, do inglês *Remaining Useful Life*).

No estudo de Gebraeel et al. (2005), o modelo exponencial foi aplicado aos sinais de degradação para estimar a distribuição da vida residual. A escolha do modelo exponencial é justificada por sua habilidade de descrever o comportamento observado em muitos sistemas, onde a degradação ocorre lentamente nas fases iniciais, mas acelera significativamente à medida que o equipamento se aproxima do fim de sua vida útil. Esse padrão é particularmente evidente em cenários de testes acelerados, como os realizados em rolamentos, conforme relatado no estudo.

Além disso, o modelo exponencial oferece a vantagem de possibilitar a atualização contínua dos parâmetros de degradação, tornando-o adaptativo e mais preciso à medida que novos dados são coletados. Essa característica é essencial para sistemas de monitoramento em tempo real, onde as condições operacionais podem variar e requerem ajustes dinâmicos na previsão do RUL.

Assim, com base na aplicação apresentada por Gebraeel et al. (2005), o modelo exponencial se destaca como uma escolha robusta para representar a degradação em sistemas de monitoramento de vibração.

4.3.4. Amostragem MCMC e o Algoritmo de Prognóstico

A amostragem MCMC (Markov Chain Monte Carlo), com algoritmo Metropolis-Hastings (MH) segue o seguinte processo:

1. Início do Algoritmo:

- O processo começa com uma *amostra inicial*, que serve como ponto de partida para a análise.
- Junto com essa amostra, calcula-se a PDF posterior, que é a probabilidade de essa amostra representar bem os dados observados.

2. Gerando Novas Amostras:

- Durante o loop do algoritmo, uma nova *amostra candidata* é gerada. Essa amostra é escolhida aleatoriamente a partir de uma distribuição uniforme que está centrada na amostra atual (ou seja, próxima da amostra inicial).
- Em seguida, calcula-se a PDF posterior para essa amostra candidata, assim como foi feito para a amostra inicial.

3. Decidindo Aceitar ou Rejeitar a Amostra:

- Para decidir se a nova amostra será aceita, calcula-se uma razão de aceitação, que compara a PDF da amostra candidata com a PDF da amostra atual.
- Um número aleatório entre 0 e 1 é gerado. Se a razão de aceitação for maior que esse número, a nova amostra é aceita como a próxima amostra.
- Caso contrário, a amostra atual é mantida.

4. Burn-In (Descarte das Primeiras Amostras):

- Como as primeiras amostras podem estar influenciadas pela escolha inicial, elas não são consideradas representativas.
- Por isso, ao final do processo, os primeiros 20% das amostras geradas são descartados. Esse descarte inicial é chamado de *burn-in*.

Neste trabalho, o algoritmo foi iniciado com 120 amostras reais, que estão apresentadas na Figura 27. Essas amostras foram usadas para calcular os parâmetros do modelo exponencial de degradação, ‘a’ e ‘b’, por meio de uma regressão exponencial. Posteriormente, o modelo resultante *trueData* foi construído, definido pela seguinte equação exponencial:

$$trueData = 1 + a \cdot e^{b \cdot time_inicial} \quad (13)$$

Na Figura 28, é possível ver a curva gerada pelo modelo exponencial (*trueData*) em comparação com os dados medidos (*measuData*).

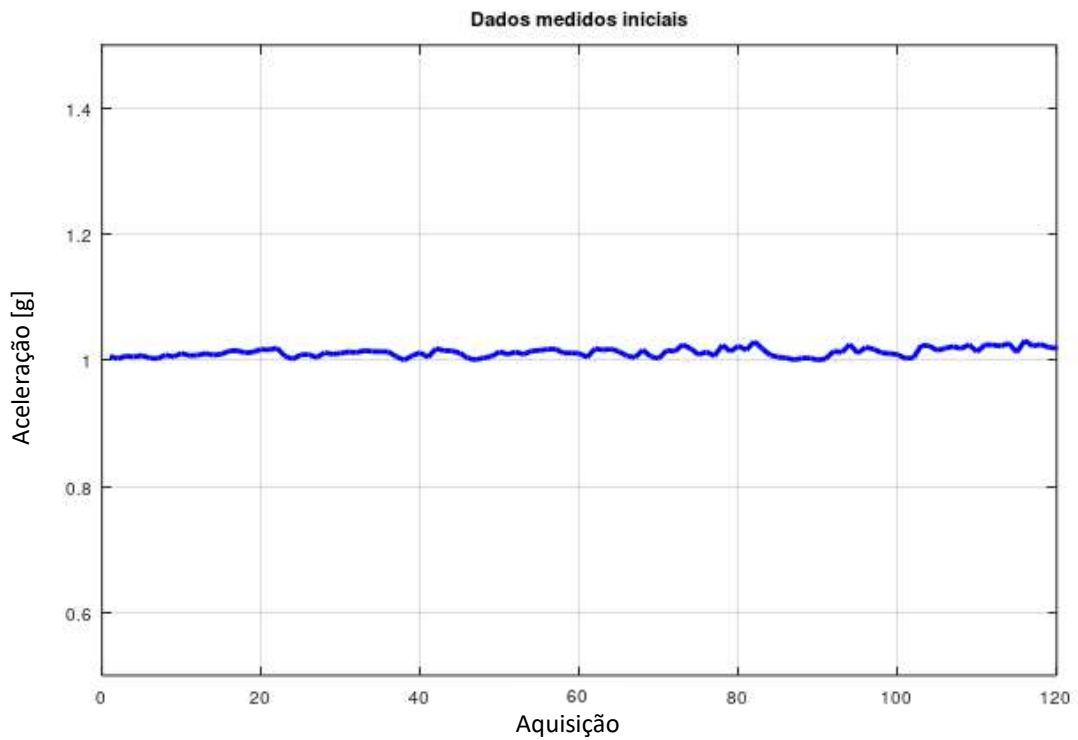


Figura 27 – Amostras iniciais inseridas no algoritmo MCMC.

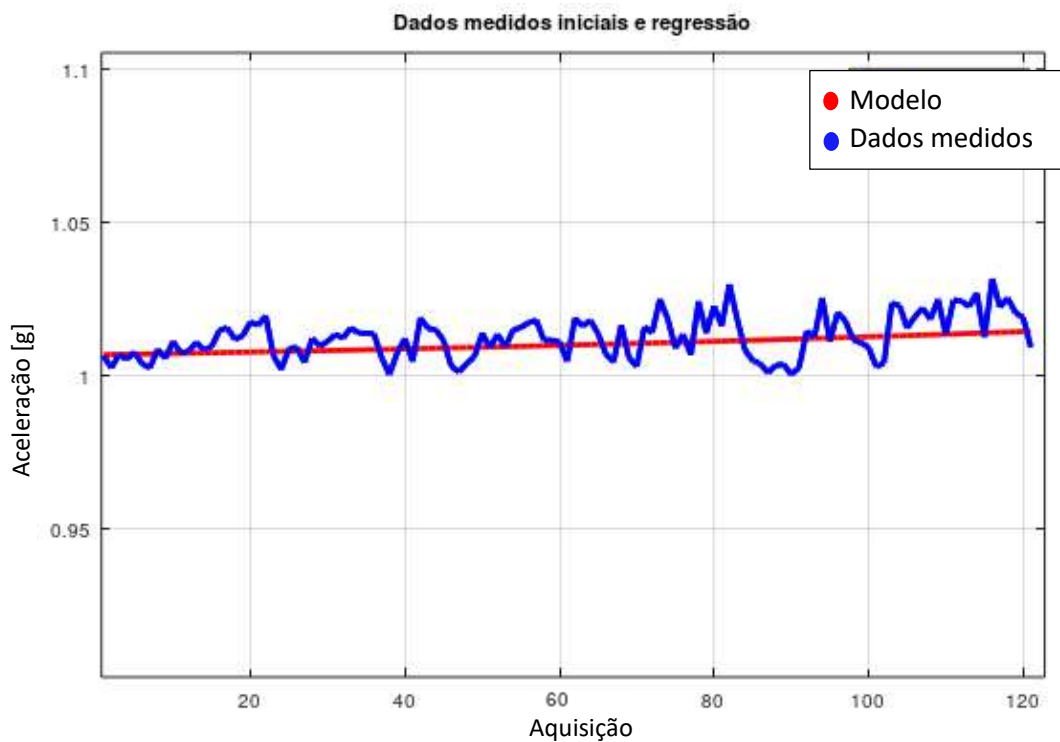


Figura 28 - Curva do modelo exponencial (*trueData*) considerando os valores de 'b' e 'a' e dados medidos (*measuData*).

Conforme descrito na Seção 4.2, as entradas para o algoritmo MCMC consistem nas distribuições *a priori* dos parâmetros. Neste trabalho, foram adotados ‘b’ e ‘s’ como parâmetros, onde ‘s’ representa o desvio padrão do ruído, $s = std(trueData - measuData)$.

- Os dados medidos (*measuData*) são apresentados nas Figuras 26 e 27.
- A Figura 28 também ilustra a curva do modelo exponencial gerada com os valores dos parâmetros ‘b’ e ‘a’ determinados.

No contexto deste trabalho, o algoritmo MCMC (Markov Chain Monte Carlo) utiliza três elementos principais para ajustar os parâmetros do modelo matemático de degradação: priori (*prior*), verossimilhança (*likel*) e posterior (*poste*). Esses conceitos são fundamentais para combinar o que já sabemos sobre o sistema (conhecimento prévio) com as informações fornecidas pelos dados coletados.

1. A prior – O que já se sabe antes de medir os dados

Considere a tentativa de prever a taxa de degradação de um motor. Antes mesmo de coletar dados, pode-se ter uma ideia inicial de que a taxa de degradação deve estar, por exemplo, entre 0,01 e 0,05 por hora, porque essa é a faixa típica observada em motores semelhantes. Essa crença inicial é chamada de *prior*. No modelo, a *prior* é representada por uma função de probabilidade. Por exemplo, podemos usar uma distribuição uniforme que assume que qualquer valor entre 0,01 e 0,05 é igualmente provável antes de observar os dados.

○ Exemplo prático:

Se estamos analisando dois parâmetros do modelo de degradação, como a taxa de crescimento da falha (*b*) e a variabilidade dos dados (*s*), a *prior* inicial poderia dizer:

- *b* está uniformemente distribuído entre 0,01 e 0,05.
- *s* está uniformemente distribuído entre 0,001 e 0,01.

Isso reflete nossa crença inicial sem considerar os dados medidos.

2. O likel – O que os dados nos dizem

Depois de coletar os dados do sistema (por exemplo, medições do nível de degradação ao longo do tempo), necessita-se avaliar quais valores dos parâmetros explicam melhor esses dados. O *likel* (ou *verossimilhança*) mede exatamente isso: ele indica a

probabilidade de observarmos os dados medidos para um conjunto específico de parâmetros.

No caso deste trabalho, utilizou-se uma função Gaussiana (ou Normal) que penaliza diferenças grandes entre os valores previstos pelo modelo de degradação e os valores medidos. Quanto melhor o modelo prever os dados, maior será o valor do *likel*.

○ Exemplo prático:

Suponha que, para uma taxa de degradação $b = 0,03$, o modelo prevê valores muito próximos dos dados medidos. Isso significa que o *likel* para $b = 0,03$ será alto. Por outro lado, se tentarmos um $b = 0,07$, que prevê valores muito diferentes dos dados, o *likel* será baixo, indicando que esse parâmetro é pouco provável.

3. O poste – A combinação do que já sabemos com o que aprendemos

O *poste* (ou *posterior*) é a junção da *prior* (o que sabíamos antes de medir) e do *likel* (o que aprendemos com os dados). Ele representa os valores mais prováveis dos parâmetros depois de considerarmos os dados coletados.

Matematicamente, o *poste* é obtido pelo produto da *prior* com o *likel*, apresentado na equação (14), cujo cálculo é fundamentado na equação (9). Se os dados fornecerem evidências muito fortes (um *likel* alto), o *poste* será dominado pelos dados. Caso contrário, a *prior* inicial terá maior influência.

$$poste = likel . prior \quad (14)$$

○ Exemplo prático:

Suponha que a *prior* inicial dizia que b podia estar entre 0,01 e 0,05, mas os dados indicam que os valores mais prováveis estão em torno de 0,03. O *poste* vai refletir essa atualização, mostrando que $b = 0,03$ é o valor mais provável, enquanto outros valores terão menor peso.

Isso significa que o *poste* ajusta nossas crenças iniciais com base na evidência fornecida pelos dados.

Assim, se os dados observados apresentarem uma evidência forte, isto é, se a função de verossimilhança (*likel*) assumir valores elevados para determinados parâmetros, a posterior será predominantemente influenciada pelos dados. Entretanto, quando os dados são escassos ou apresentam incertezas consideráveis, a posterior será mais influenciada pela *prior*. Em síntese,

a equação (14) responde à seguinte questão: “Quais valores dos parâmetros são mais prováveis, considerando os dados disponíveis e o conhecimento prévio?”.

4.3.5. Construção do *Prior* e do *Likel*

A priori, representada como $f_{\theta}(\theta)$, é obtida pelo produto das distribuições dos parâmetros ‘b’ e ‘s’, conforme apresentado na equação (15):

$$prior = f(b).f(s) \quad (15)$$

Por outro lado, a verossimilhança (*likel*), indicada por $f_Y(y_k | \theta)$, é definida pela equação (16):

$$likel = \frac{1}{s\sqrt{2\pi}} \exp \left[-\frac{1}{2s^2} (y_k - \tilde{y}_k(b))^2 \right], \quad k = 1, 2, \dots, N_{dados} \quad (16)$$

Nesta formulação, y_k representa os dados medidos (*measuData*), enquanto $\tilde{y}_k(b)$ é a previsão do modelo de degradação (*degraModel*). A função exponencial é escolhida por sua propriedade de penalizar erros quadráticos de forma contínua e progressiva, refletindo a natureza dos dados e erros associados ao modelo.

Quando o erro $(y_k - \tilde{y}_k(b))^2$ é pequeno, a probabilidade de ocorrência é alta, aproximando o valor da função de verossimilhança de 1. Por outro lado, para erros elevados, a função decai exponencialmente para valores próximos de zero, atribuindo menor probabilidade a parâmetros que gerem desvios significativos entre os valores medidos e previstos.

O termo $\frac{1}{2s^2}$ normaliza o erro em relação ao desvio padrão ‘s’, modulando o impacto do erro na probabilidade. Assim, um ‘s’ elevado (indicando alta incerteza nos dados) reduz a penalização do erro, enquanto um ‘s’ baixo (indicando maior confiabilidade nos dados) amplifica sua influência.

Por fim, o fator $\frac{1}{s\sqrt{2\pi}}$ garante a normalização da a função de densidade de probabilidade (ou a verossimilhança associada), satisfazendo a propriedade fundamental de uma distribuição de probabilidade, conforme apresentado na equação (17):

$$\int_{-\infty}^{\infty} P(y_k | b) d_{y_k} = 1 \quad (17)$$

Após a definição do *prior* e do *likel*, a distribuição posterior inicial, $jPdf_0$, é calculada pela equação (14), formando a base inicial para a execução do algoritmo MCMC. A rotina é implementada considerando 300 amostras por iteração, com descarte de 20% (*burn-in*).

O processo de atualização dos parâmetros ‘b’ e ‘s’ é realizado pela adição de um ruído randômico aos valores iniciais, conforme demonstrado na linha de código (18), desenvolvida na linguagem Matlab®, onde ‘para0’ é o vetor que armazena os parâmetros ‘b’ e ‘s’ iniciais, ‘para1’ é o que armazena os novos e ‘weigh’ é o peso dado aos valores randômicos gerados.

$$\text{para1} = \text{para0} + \text{weigh} * (2 * \text{rand}(2,1) - 1); \quad (18)$$

Com os novos parâmetros, o modelo de degradação (*degraModel*) é recalculado usando a equação exponencial (equação 13). A nova distribuição posterior ($jPdf_1$) é obtida pela atualização dos valores de priori e verossimilhança. A aceitação ou rejeição dos novos parâmetros segue o critério de Metropolis-Hastings, implementado pelo código (19):

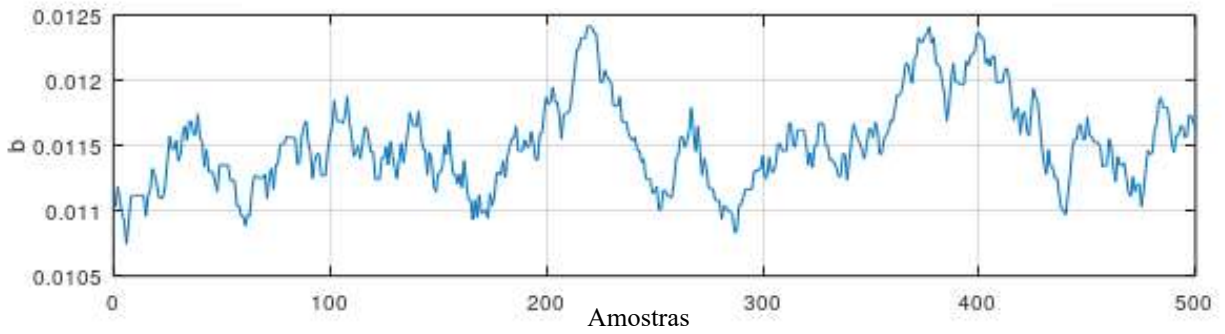
```
if rand < (jPdf1/jPdf0) && jPdf1 > 0 #Critério de aceitação
    para0=para1; #Atualiza a amostra anterior se a nova amostra for aceita.
    jPdf0=jPdf1; #Atualiza a posteriori da amostra anterior se a nova amostra for aceita.
end
```

(19)

Assim se a razão entre o valor atual e o antigo da posterior, ‘ $jPdf_1/jPdf_0$ ’, for maior que um número randômico gerado entre 0 e 1 e o posterior calculado, ‘ $jPdf_1$ ’, for maior que zero, os parâmetros serão atualizados, bem como a posterior antiga, ‘ $jPdf_0$ ’, que passará a ter o valor da atual, ‘ $jPdf_1$ ’, no próximo looping. O parâmetro será armazenado no vetor de amostras, ‘*sampl*’, se a condição apresentada for satisfeita, será armazenado o parâmetro atual, senão, apenas os parâmetros antigos.

A execução do algoritmo MCMC resulta na trajetória das amostras dos parâmetros ‘b’ e ‘s’, conforme ilustrado na Figura 29, e nos respectivos histogramas dessas amostras, apresentados na Figura 30. Essas distribuições refletem a convergência do algoritmo e a variabilidade associada aos parâmetros do modelo.

Trajétória das amostras do algoritmo MCMC, parâmetro 'b'



Trajétória das amostras do algoritmo MCMC, parâmetro 's'

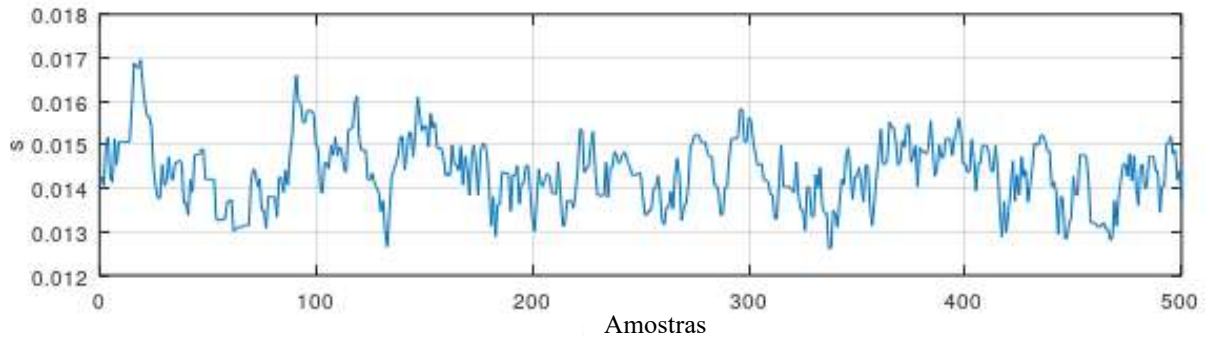



Figura 29 - Trajetória das amostras do algoritmo MCMC, parâmetros 'b' e 's'.

Histograma MCMC, parâmetro 'b'



Histograma MCMC, parâmetro 's'




Figura 30 – Histograma das amostras do algoritmo MCMC, parâmetros 'b' e 's'.

Com os parâmetros obtidos pelo MCMC, são gerados 300 modelos de degradação exponenciais (*degraPredi*), cada um correspondente a uma amostra válida após o descarte de 20%. O cálculo é realizado para todos os instantes de tempo posteriores à medição atual (*k1*), como indicado no código (20):

```
for k=1:length(time(k1:end)) #Loop para previsão da degradação (ou RUL) (20)
    t=time(k1-1+k); # Seleciona o tempo correspondente para a previsão de degradação.
    degrePredi (k,:) = 1+a.*exp(b*t);
end
```

O RUL (Remaining Useful Life) é determinado para cada curva de degradação como o tempo de cruzamento com o limiar (*thres*). A interpolação linear é usada para localizar esse ponto, conforme o código (21):

```
for i=1:300
    RUL(i)=interp1(degrePredi (:,i),time(k1:end),thres,'pchip') - time(k1); (21)
end
```

A Figura 31 a seguir apresenta as 300 curvas de degradação obtidas e a região de cruzamento das curvas com o limiar. Além disso, em azul, tem-se a curva de degradação obtida pela regressão exponencial considerando os dados medidos. O histograma da Figura 31 traz os valores calculados de RUL para cada cruzamento de curva com o limiar. No histograma do RUL tem-se apresentado o intervalo de confiança de 90%, 95 e 5 percentis, considerando a aquisição atual $k=274$. Assim, o prognóstico aponta para uma vida útil remanescente (RUL) de 50 a 77 aquisições, sendo assim o intervalo de previsão de falha. Considerando 4h de intervalo entre as aquisições, tem-se um prognóstico de RUL entre 200h e 308h.

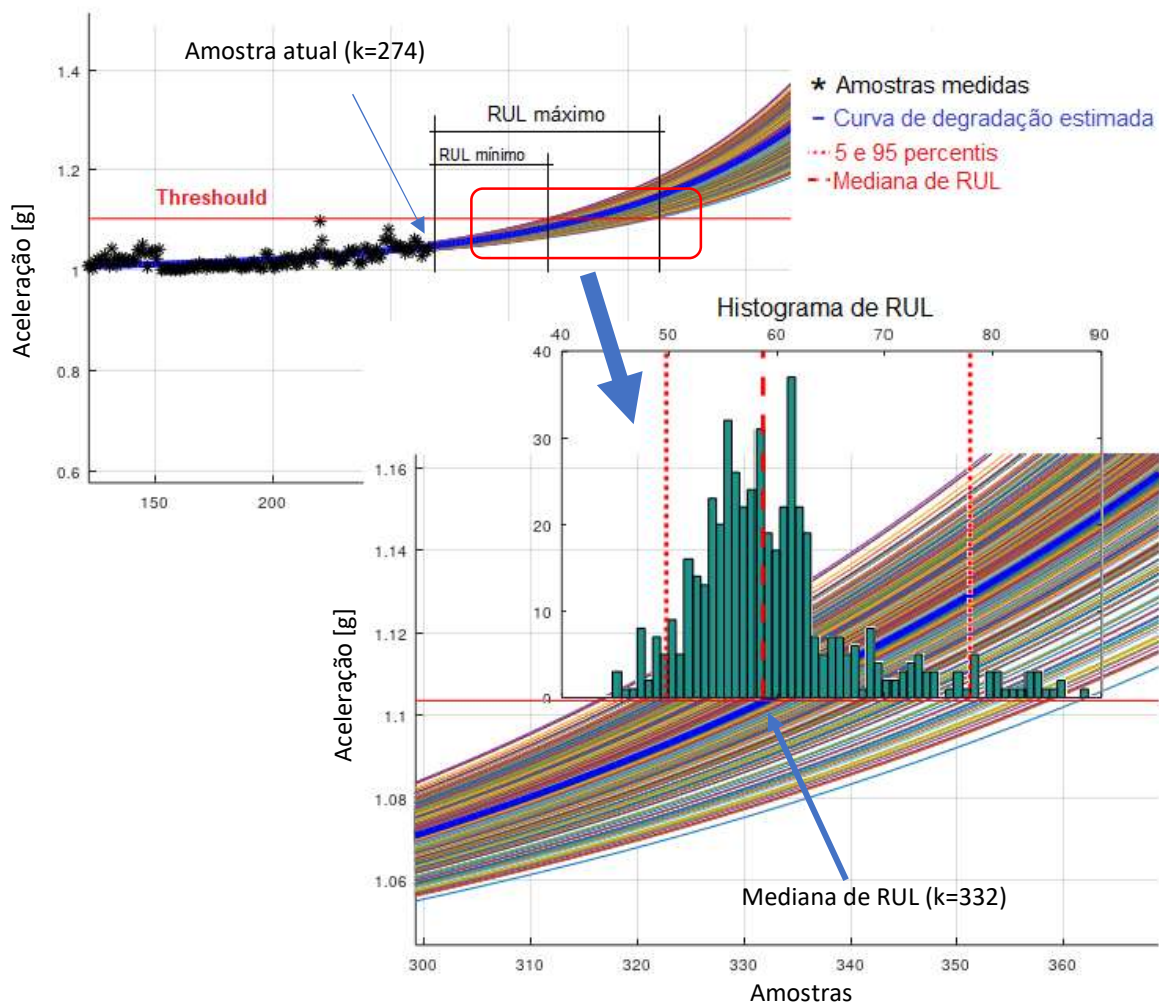


Figura 31 - Curvas de degradação, região de cruzamento com o limiar e o histograma de RUL.

4.4. RESULTADOS DO PROGNÓSTICO BAYESIANO

Na seção anterior foi apresentada a técnica utilizada de amostragem MCMC e o prognóstico Bayesiano que é a base para o algoritmo de prognóstico Bayesiano. Aqui será apresentado o resultado da aplicação desse algoritmo no monitoramento do sinal apresentado na seção 4.3. Na avaliação do algoritmo, aplicou-se o prognóstico com a máquina operando em boas condições inicialmente, até que alcance a condição de falha. Assim, durante as amostras iniciais espera-se um valor infinito de RUL, ou seja, que a curva de degradação estimada não toque no limiar. O comportamento do algoritmo em variações no nível de vibração para condições normais de funcionamento não deve apontar falso positivos, ou seja, valores incoerentes de RUL. A Figura 32 a seguir apresenta os dados iniciais, já obtidos pelo sistema

de prognóstico em azul e o limiar definido na etapa anterior de warm up, apresentado no capítulo 4.3.1, sendo de 1.1036 [g]. Em verde temos os valores futuros da variável de monitoramento pelo algoritmo de prognóstico que serão lidas a cada aquisição de 4h no sistema real.

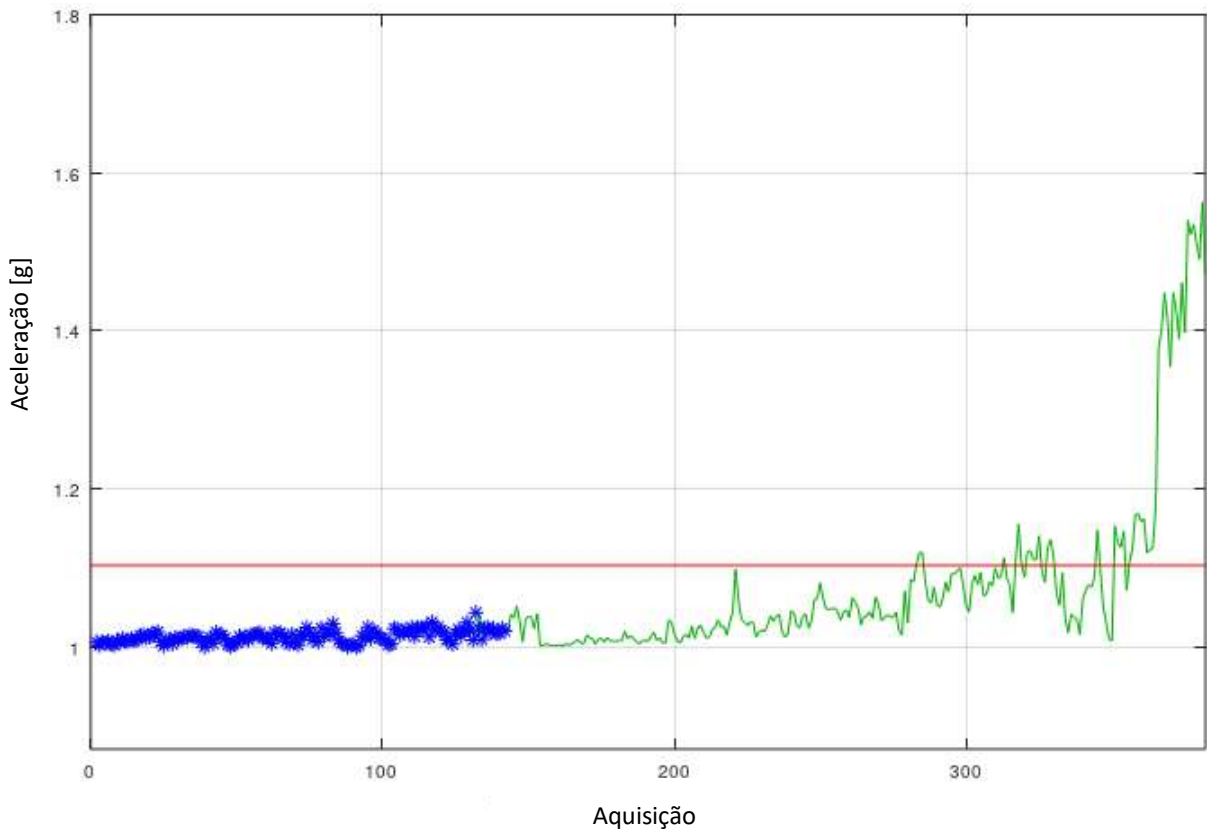


Figura 32 - Dados iniciais obtidos pelo sistema de prognóstico.

A Figura 33, zoom da Figura 32, apresenta algumas regiões da Figura 32 que tendem a ser mais críticas para o algoritmo de prognóstico em que tem mais probabilidade de acusar um falso positivo, tais regiões serão descritas nas seções seguintes. A primeira delas, a Região A, os níveis se elevam, mas depois caem e se estabilizam, indicando uma condição de funcionamento da máquina. Já na Região B ocorre uma subida abrupta da variável aceleração, mas logo se estabiliza.

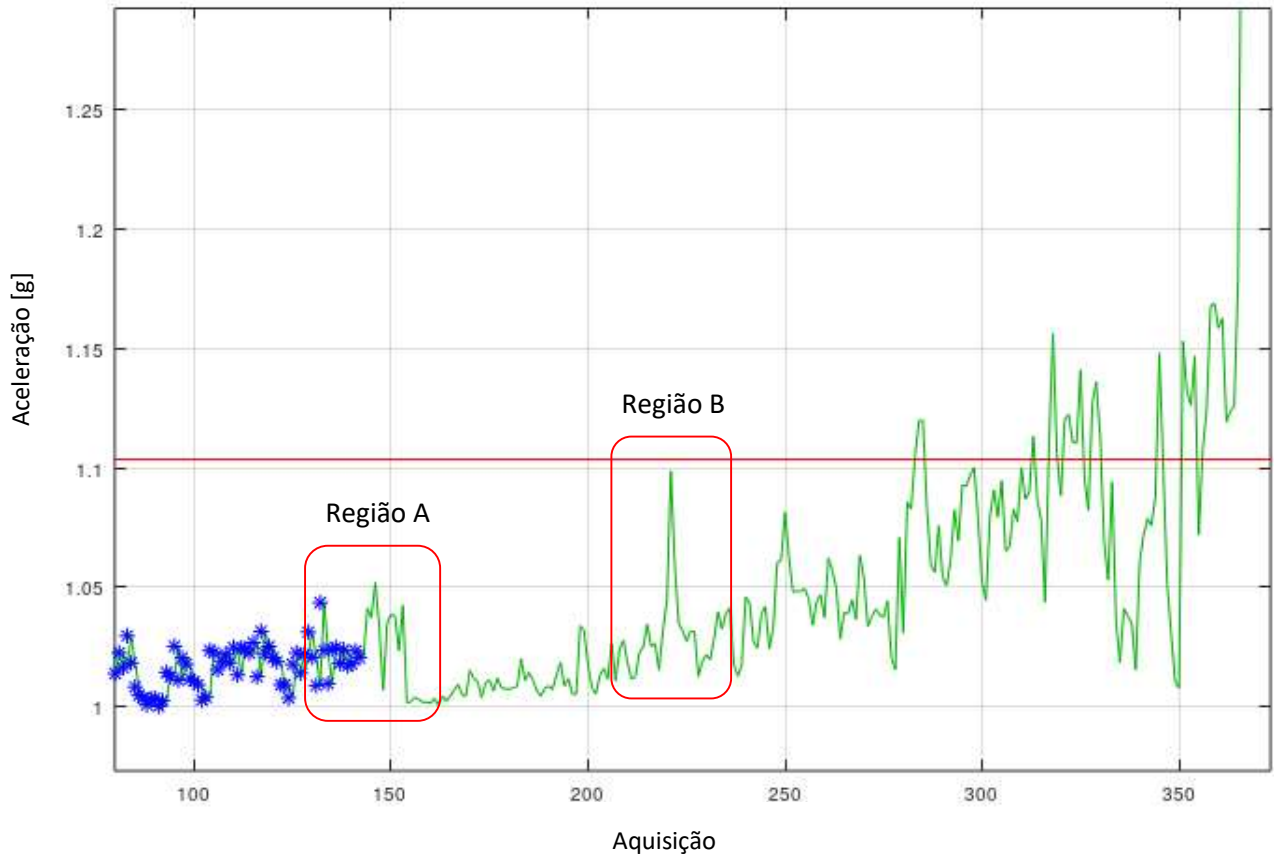


Figura 33 – Regiões A e B, críticas para o algoritmo de prognóstico.

A Figura 34 a seguir apresenta o início do prognóstico, com a máquina ainda operando em boas condições e a Figura 35 um zoom destacando 4 curvas que são geradas pelo algoritmo de prognóstico resumido e apresentado na Figura 36. Os itens a seguir detalham as curvas geradas pelo algoritmo de prognóstico.

Modelo de degradação: a curva em preto

A curva em preto representa o modelo de degradação, no caso do modelo adotado, o exponencial. Os índices ‘a’ e ‘b’ são obtidos com regressão exponencial utilizando as amostras coletadas, dessa forma, o modelo de degradação exponencial é estimado a cada iteração do algoritmo de prognóstico. O esquemático da Figura 36 apresenta a curva em preto, sendo indicada como ‘degraModel’, por representar o modelo de degradação, equação (22). Como ‘b’ e ‘a’ são obtidos pela regressão, sendo apenas dois valores, temos ‘degraModel’ representado apenas por um vetor unidimensional.

$$degraModel = 1 + a \cdot e^{b \cdot time} \quad (22)$$

Predição de degradação: curva tracejada azul

A curva tracejada, denominada como predição de degradação, é obtida por meio da aplicação dos parâmetros ‘a’ e ‘b’ no modelo de degradação exponencial. Esse modelo, que reflete a evolução do processo de falha ao longo do tempo, utiliza os mesmos fundamentos da curva *a priori*, mas incorpora incertezas nos parâmetros. Os índices ‘a’ e ‘b’ não são fixos; eles são gerados pelo algoritmo de amostragem MCMC (Markov Chain Monte Carlo), que realiza uma exploração probabilística do espaço de parâmetros. Cada iteração do MCMC gera um conjunto de valores possíveis para ‘a’ e ‘b’, resultando em um conjunto de curvas de predição de degradação. Para o caso exemplificado, com 300 iterações MCMC, são geradas 300 curvas distintas, cada uma representando um possível cenário futuro de degradação.

Dentre essas curvas, a curva tracejada apresentada na Figura 35 é construída com base na mediana do conjunto de 300 curvas de predição geradas. A mediana é utilizada como um resumo estatístico robusto, representando o comportamento central do processo de degradação, minimizando o impacto de valores extremos ou outliers que poderiam desviar a análise.

Intervalos de predição: par de curvas pontilhadas

A Figura 35 também apresenta os intervalos de predição, o par de curvas pontilhadas, denominados como ‘degraPI’, que são calculados a partir das curvas geradas pelo algoritmo MCMC. Os intervalos de predição são representados por limites superiores e inferiores, tipicamente baseados em percentis (como 5º e 95º percentil), além do percentil mediano (50º), que é a própria curva tracejada em azul. Esses intervalos fornecem uma representação visual e estatística das incertezas associadas ao modelo, permitindo que se identifique a faixa provável em que o processo de degradação pode ocorrer.

Os intervalos ‘degraPI’ são essenciais para análises em cenários industriais, onde a variabilidade e a incerteza são fatores críticos para a tomada de decisão. Eles permitem prever, com um grau de confiança conhecido, o comportamento do sistema em análise. Por exemplo, se a faixa de incerteza estiver muito ampla, isso pode indicar a necessidade de mais dados ou ajustes no modelo. Por outro lado, intervalos estreitos sugerem maior precisão nas estimativas, o que é crucial para decisões de manutenção preditiva. A integração da curva tracejada (baseada na mediana das predições) com os intervalos de predição (degraPI) oferece uma visão completa e detalhada da degradação futura, equilibrando precisão e incerteza. Esse método probabilístico

não só fornece estimativas mais confiáveis, mas também comunica claramente os limites de confiança, auxiliando na gestão de riscos e no planejamento de intervenções.




Figura 34 - Início do prognóstico, com a máquina ainda operando em boas condições.

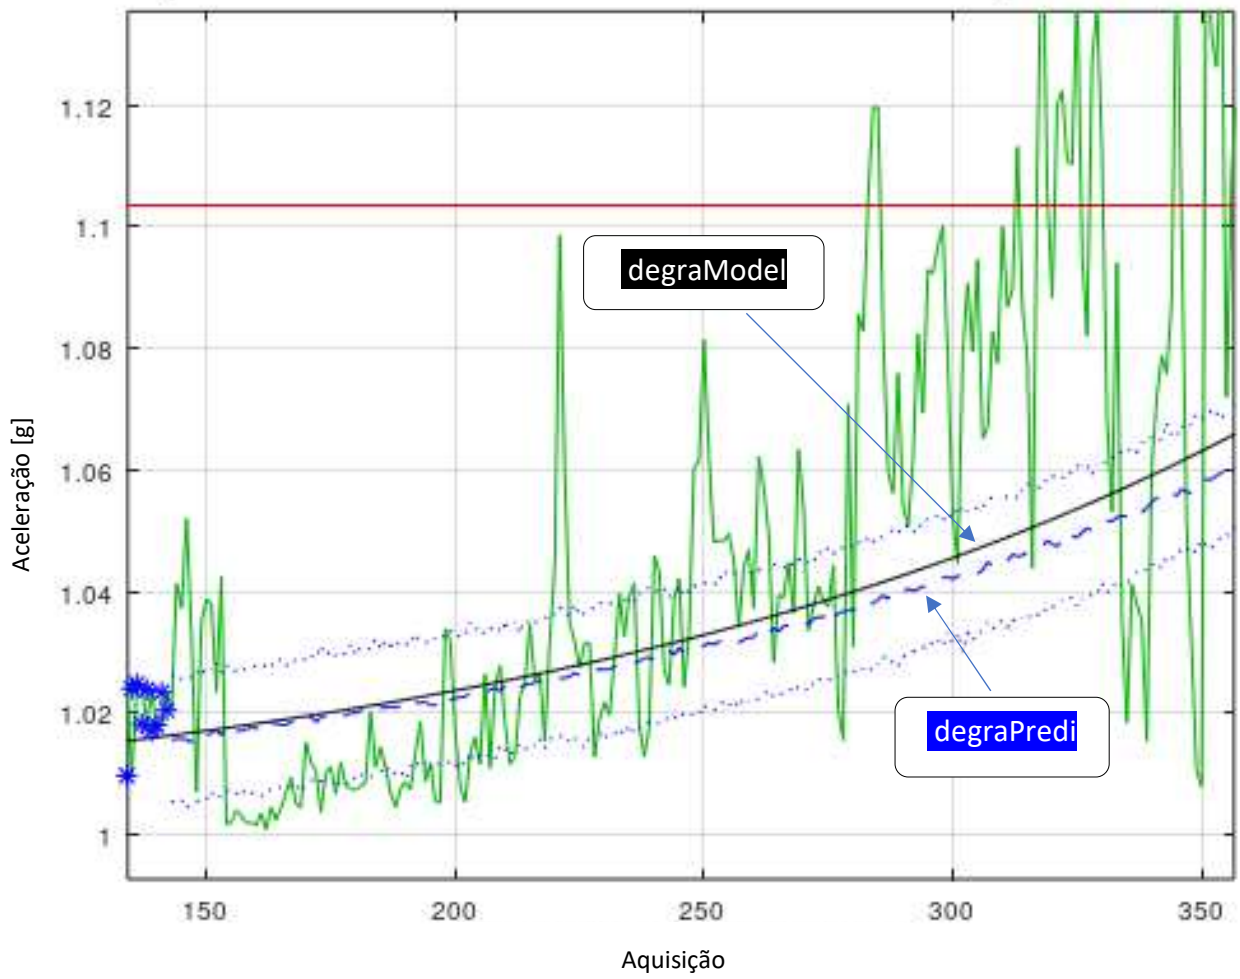
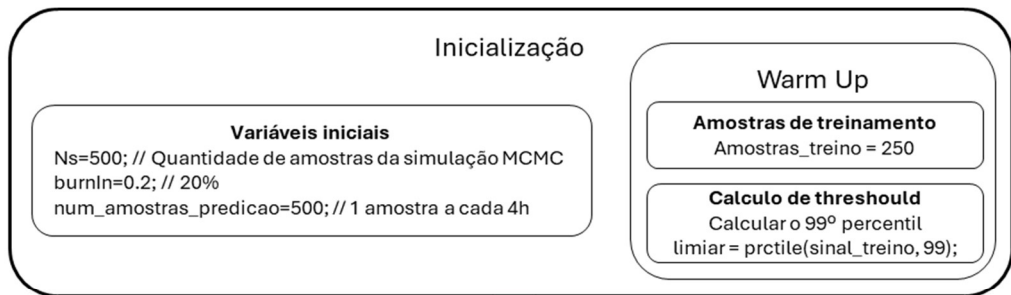

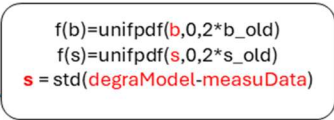



Figura 35 - Detalhe das curvas do algoritmo no início do prognóstico.

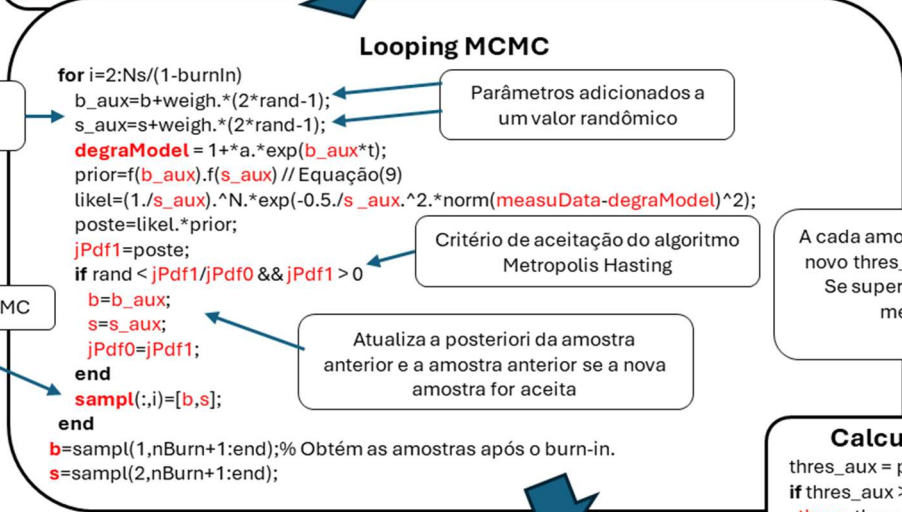


Looping de prognóstico Bayesiano, parâmetros: 'b' e 's'



Equação 10

degraModel



'weigh': peso dado ao randômico

Parâmetros adicionados a um valor randômico

Critério de aceitação do algoritmo Metropolis Hasting

Atualiza a posteriori da amostra anterior e a amostra anterior se a nova amostra for aceita

A cada amostra obtida é calculado um novo thres_aux, sendo o percentil 99. Se superar o threshold inicial, o mesmo é atualizado

Vetor de amostras MCMC



degraPredi

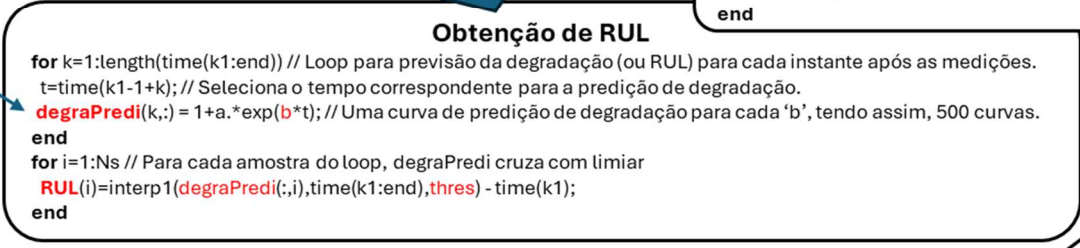


Figura 36 – Algoritmo de prognóstico resumido.

4.4.1 O Algoritmo de Prognóstico – Região A

Nesta seção, é abordada a primeira área de análise do algoritmo de prognóstico Bayesiano, designada como Região A. Conforme evidenciado na Figura 37, essa região representa uma fase inicial do comportamento vibracional do ativo, marcada por pequenas flutuações nos níveis de vibração sem elevações significativas. Apesar de sutis, essas oscilações são de grande importância para a avaliação do desempenho do algoritmo, pois oferecem um cenário controlado para avaliar sua capacidade de distinguir entre comportamento normal e indícios de degradação iminente.

A análise da Região A foi realizada considerando uma sequência de nove aquisições consecutivas das curvas de previsão de degradação, como ilustrado na Figura 37. Cada uma dessas curvas (em azul) foi gerada pelo algoritmo com base nos dados disponíveis até aquele instante, utilizando os modelos probabilísticos para estimar a evolução vibracional futura. Observa-se que, em todas as aquisições, as curvas de previsão permaneceram abaixo do limiar crítico (representado pela linha vermelha), indicando que o algoritmo não detectou um cruzamento significativo que sugerisse a iminência de falha. Essa ausência de cruzamento significa que o algoritmo não calculou valores de RUL (*Remaining Useful Life*) associados a essa região, reforçando que, para o período analisado, não havia sinais claros de degradação significativa.

A escolha da Região A como área de análise é particularmente relevante para a validação da sensibilidade e robustez do algoritmo. Essa fase, que pode ser interpretada como um estágio de "pré-alerta", desempenha um papel essencial no monitoramento preditivo. É nesse momento que sistemas automatizados devem ser capazes de identificar, de forma confiável, padrões iniciais de variação que poderiam evoluir para anomalias, sem, no entanto, gerar alarmes falsos. O desempenho do algoritmo na Região A reflete sua capacidade de operar dentro de margens de tolerância adequadas, evitando interpretações equivocadas de variações normais como indicadores de falha.

A robustez da abordagem pode ser vista na consistência das curvas preditivas geradas ao longo das nove aquisições. Mesmo com a presença de pequenas oscilações entre as amostras, as previsões mantiveram-se dentro de uma faixa aceitável, demonstrando a eficácia dos modelos estatísticos utilizados. Essa consistência é crucial para sistemas de monitoramento

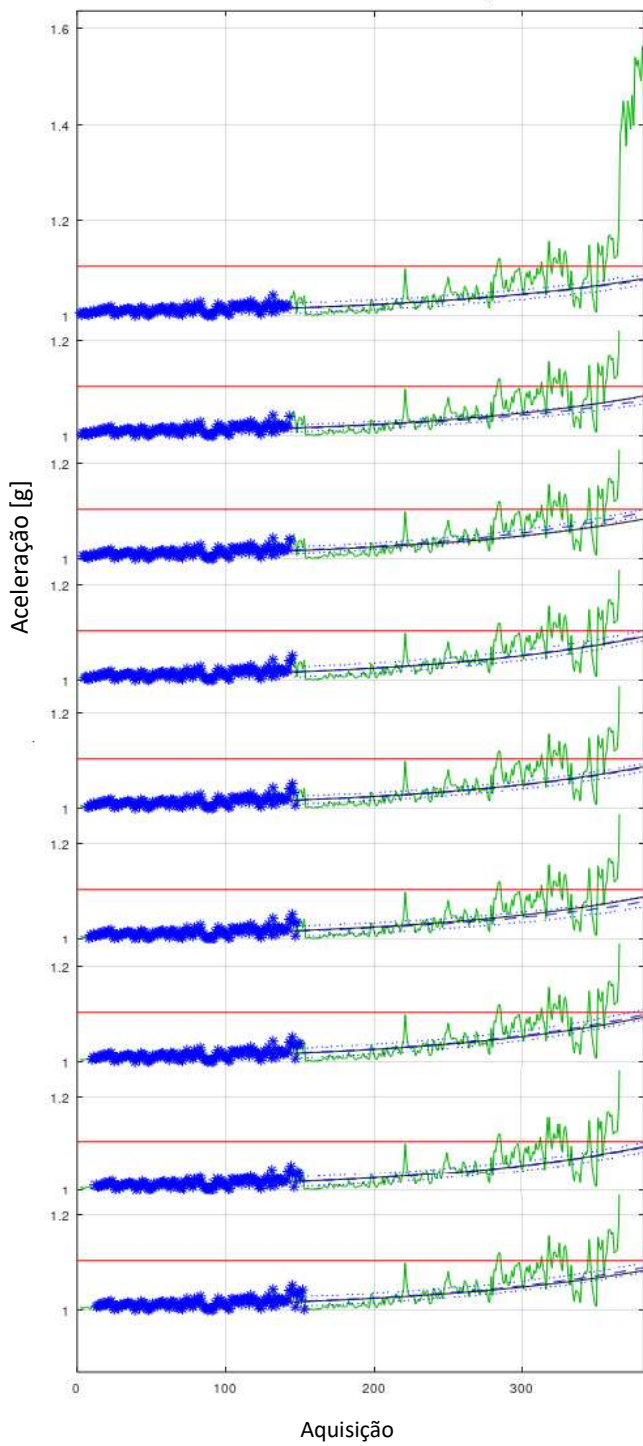
contínuo, especialmente em aplicações industriais, onde decisões equivocadas podem resultar em paradas desnecessárias de máquinas ou intervenções dispendiosas.

Outro aspecto importante a ser destacado é a correlação entre os resultados do algoritmo e o comportamento observado após a Região A. Como mostrado na Figura 37, após essa região, os níveis de vibração apresentaram uma tendência de estabilização, com leve redução. Esse comportamento reforça a adequação do algoritmo em não sinalizar um alerta, validando sua precisão na interpretação de padrões vibracionais em condições normais de operação. A capacidade de diferenciar entre variações transitórias e sinais de degradação é um dos principais desafios em prognósticos industriais, e o desempenho na Região A demonstra que o modelo atende a essa necessidade de forma eficiente.

Adicionalmente, a análise da Região A evidencia algumas das limitações inerentes ao processo de monitoramento preditivo. Por exemplo, embora o algoritmo tenha apresentado um desempenho satisfatório em evitar falsos positivos, é necessário reconhecer que os padrões vibracionais nessa região eram pouco pronunciados, o que pode representar um cenário menos desafiador para os modelos probabilísticos. Essa observação destaca a importância de complementar a análise com estudos em regiões mais complexas, como a Região B, onde o comportamento vibracional apresenta maiores variações e a detecção de degradação se torna mais desafiadora.

Por fim, os resultados obtidos na Região A têm implicações práticas significativas para a implementação de sistemas de monitoramento em ambientes industriais. A ausência de falsos positivos reforça a confiabilidade do modelo, proporcionando maior segurança para operadores e engenheiros de manutenção. Além disso, a capacidade do algoritmo de se manter insensível a variações leves de vibração sugere que ele pode ser utilizado em uma ampla gama de aplicações, incluindo ativos que operam em condições altamente dinâmicas.

Portanto, a consistência dos resultados, aliada à ausência de alarmes indevidos, evidencia o potencial do modelo para ser uma ferramenta confiável no monitoramento contínuo de máquinas. A Região também fornece uma base sólida para comparações com regiões mais complexas, como a Região B, que será explorada em seções subsequentes deste trabalho.



Aquisição
ordem:

- 1
- 2
- 3
- 4
- 5
- 6
- 7
- 8
- 9




Figura 37 – Evolução do prognóstico na Região A.

4.4.2. O Algoritmo de Prognóstico – Região B

Nesta seção, é detalhada a segunda área de análise do algoritmo de prognóstico Bayesiano, designada como Região B. Essa região, destacada previamente na Figura 33, representa um estágio intermediário no comportamento vibracional do sistema. Diferentemente da Região A, aqui ocorrem oscilações mais pronunciadas nos níveis de vibração, embora ainda sem ultrapassar o limiar crítico de falha (em vermelho). A Figura 38 apresenta uma sequência de aquisições das curvas de previsão de degradação para cada instante analisado, evidenciando a dinâmica do algoritmo na identificação de padrões vibracionais mais complexos.

A escolha da Região B para análise não é aleatória, mas reflete um momento crucial no ciclo operacional do ativo. Essa fase é caracterizada por picos de vibração mais elevados que os observados na Região A, indicando um aumento na atividade dinâmica do sistema. No entanto, essas oscilações não são necessariamente um indicativo de falha iminente. É, portanto, uma fase crítica para validar a precisão e a robustez do algoritmo, que deve ser capaz de interpretar corretamente essas flutuações como parte do comportamento normal ou, em alguns casos, como potenciais precursores de degradação.

Durante a análise na Região B, as curvas de previsão e os modelos gerados pelo algoritmo (em azul e preto) mostraram uma consistência notável ao longo das aquisições. Em nenhum dos casos observados as curvas cruzaram o limiar de falha, representado pela linha vermelha. Essa constatação é um indicativo claro da capacidade do algoritmo de evitar falsos positivos, mesmo diante de condições operacionais mais desafiadoras. A ausência de valores de RUL calculados reforça que o sistema de monitoramento reconheceu adequadamente que o ativo ainda estava operando dentro de limites aceitáveis.

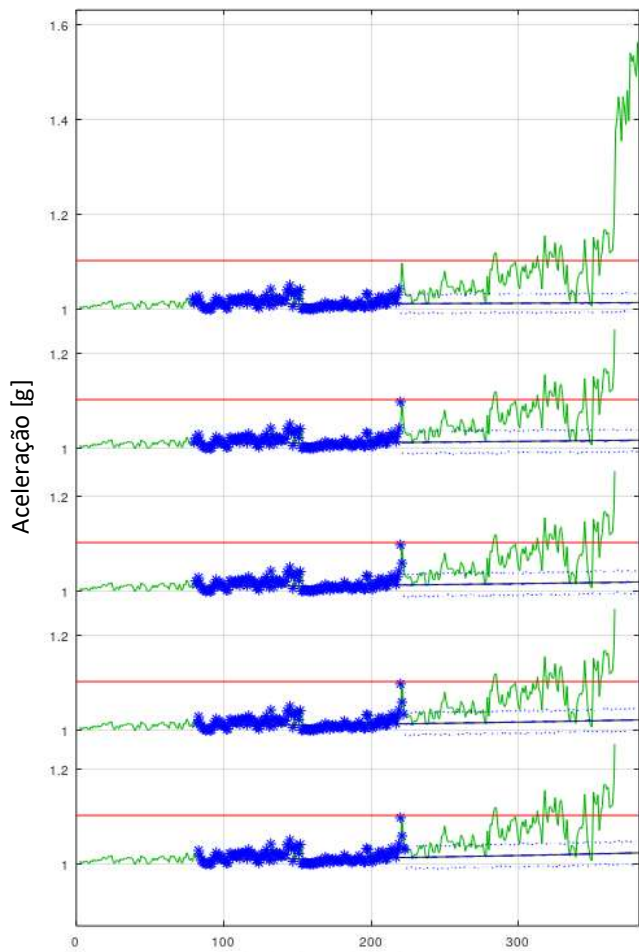
A importância da Região B vai além da análise dos dados apresentados. Essa fase representa um desafio significativo para algoritmos preditivos em geral, pois oscilações mais intensas podem, em outras circunstâncias, ser erroneamente interpretadas como sinais de degradação. O desempenho do algoritmo Bayesiano nesta região demonstra sua capacidade em diferenciar flutuações transitórias de mudanças sistemáticas que indicariam uma degradação real. Essa habilidade é fundamental para evitar alarmes desnecessários, que poderiam levar a paradas preventivas inadequadas ou intervenções desnecessárias, gerando custos adicionais para o processo operacional.

Adicionalmente, a resposta do algoritmo na Região B fornece insights importantes sobre sua modelagem probabilística. A interpretação correta das oscilações elevadas e o retorno subsequente a níveis mais baixos de vibração sugerem que o modelo é capaz de capturar adequadamente tanto as tendências de curto prazo quanto os comportamentos de longo prazo do ativo. Essa capacidade de adaptação é especialmente relevante em sistemas industriais dinâmicos, onde os padrões vibracionais podem variar amplamente devido a mudanças nas condições de operação, como variações de carga ou ajustes no processo.

Outro aspecto digno de nota é a relevância dessa análise para a confiabilidade do sistema de monitoramento como um todo. Ao operar com alta precisão e evitar falsos positivos, o algoritmo reforça a confiança dos operadores no sistema. Essa confiança é essencial para a aceitação de sistemas preditivos no ambiente industrial, onde decisões baseadas em dados precisam ser suportadas por evidências claras e consistentes. A capacidade do algoritmo de distinguir entre comportamento normal e anômalo, mesmo em condições de maior variabilidade, é um diferencial importante que contribui para sua aplicação em larga escala.

Por fim, a análise da Região B tem implicações práticas significativas para a implementação de sistemas de manutenção preditiva. A habilidade do algoritmo de reconhecer padrões vibracionais complexos sem gerar alarmes indevidos é um indicativo de sua aplicabilidade em uma ampla gama de setores industriais. Além disso, os resultados obtidos na Região B complementam os insights da Região A, formando um panorama abrangente sobre o desempenho do algoritmo em diferentes estágios operacionais.

Em resumo, a Região B reforça a eficácia do algoritmo em condições transitórias, reforçando sua robustez e confiabilidade. Os resultados não apenas confirmam sua capacidade de evitar falsos positivos, mas também destacam sua adequação para aplicações industriais exigentes, onde a precisão na detecção de falhas é crucial para garantir a continuidade operacional.



Aquisição

Aquisição
ordem:


1

2

3

4

5



Aquisição

Figura 38 - Evolução do prognóstico na Região B.

4.4.3. O Algoritmo de Prognóstico – Região de Falha

Nesta seção, são apresentados os resultados do algoritmo de prognóstico em todo o processo de monitoramento, abrangendo as análises após as Regiões A e B e culminando no prognóstico de falha. O desempenho do algoritmo é dividido em duas etapas principais, permitindo uma avaliação detalhada de sua capacidade preditiva em diferentes momentos do ciclo de vida do ativo monitorado.

A primeira etapa do estudo contempla os 10 instantes que antecedem o cruzamento da curva de degradação com o limiar de falha. Nesse período, o algoritmo ainda opera sem gerar uma estimativa precisa da vida útil remanescente do ativo. Essa limitação ocorre porque, antes do cruzamento, o sistema monitora apenas as tendências gerais de degradação, sem identificar um ponto de referência claro que permita calcular o tempo restante até a falha.

A segunda etapa do estudo analisa os 10 instantes subsequentes ao cruzamento da curva de degradação com o limiar. Nesse momento, o algoritmo passa a fornecer estimativas diretas da vida útil remanescente, com base na diferença entre o instante do cruzamento e o instante atual, convertida para horas. Adicionalmente, nesta etapa, o erro de estimação do algoritmo é calculado e avaliado. Esse erro consiste na diferença entre o instante em que o algoritmo projeta o cruzamento com o limiar e o instante real em que a falha ocorre, identificado na aquisição 362. Essa abordagem permite avaliar a precisão do algoritmo em prever a falha após a identificação de sinais claros de degradação.

A Figura 39, apresentada a seguir, ilustra de forma detalhada o comportamento do algoritmo no ponto em que a curva de degradação cruza o limiar estabelecido. Nesse exemplo, destaca-se a estimativa da vida útil remanescente, que é calculada como a diferença temporal entre o instante de cruzamento e o instante atual. Considerando que, neste estudo, o intervalo entre cada aquisição é de 4 horas, os valores de RUL fornecidos pelo algoritmo são apresentados nesse mesmo contexto temporal. A Figura também evidencia, em destaque amarelo, o erro de estimação, fornecendo uma visão clara da diferença entre o cruzamento previsto pelo algoritmo e o momento real da falha.

Os resultados detalhados da análise, apresentados na Figura 41, fornecem um panorama abrangente sobre a precisão e confiabilidade do algoritmo em prever falhas. É importante destacar que, antes do cruzamento da curva com o limiar, o algoritmo desempenha uma função crucial de monitoramento preditivo, identificando tendências e comportamentos que indicam o

progresso da degradação. Embora ainda não seja possível calcular o RUL nessa fase, as informações fornecidas pelo algoritmo são essenciais para antecipar possíveis intervenções preventivas e ajustar as estratégias de manutenção com base nas condições do ativo.

Após o cruzamento, o foco do algoritmo muda significativamente. Nesse estágio, a estimativa de RUL passa a ser um dado crítico para a tomada de decisões operacionais. A capacidade do algoritmo de fornecer previsões precisas e erros de estimação reduzidos é um indicativo de sua eficácia em ambientes industriais complexos, onde o tempo para reagir a falhas iminentes pode ser limitado. A análise detalhada do erro de estimação também é fundamental para identificar possíveis ajustes no modelo e aprimorar a precisão do sistema em aplicações futuras.

Além disso, é relevante mencionar que o intervalo de 4 horas entre aquisições é uma característica específica deste estudo e pode influenciar diretamente os valores de RUL e os erros de estimação. Em aplicações reais, intervalos menores entre as aquisições poderiam fornecer uma resolução temporal mais alta, permitindo ao algoritmo captar mudanças mais sutis no comportamento do ativo. Por outro lado, intervalos maiores poderiam reduzir a frequência de monitoramento, mas ainda assim fornecer informações valiosas em sistemas com degradação mais lenta.

Por fim, os resultados apresentados nesta seção não apenas validam a eficácia do algoritmo, mas também destacam sua aplicabilidade prática em cenários industriais. A divisão em duas etapas – antes e depois do cruzamento – permite uma avaliação completa de sua performance em diferentes estágios do ciclo de vida do ativo. A combinação de monitoramento preditivo, estimativa de RUL e análise de erros de estimação fornece uma base sólida para sua implementação em sistemas de manutenção preditiva, contribuindo para a redução de custos, aumento da confiabilidade e prevenção de falhas inesperadas.

Em resumo, esta seção fornece uma análise detalhada do desempenho do algoritmo de prognóstico, desde o início da degradação até a ocorrência da falha. As duas etapas de análise – antes e depois do cruzamento – permitem uma compreensão profunda de como o algoritmo interpreta e processa os dados, ajustando suas previsões à medida que novos sinais de degradação emergem.

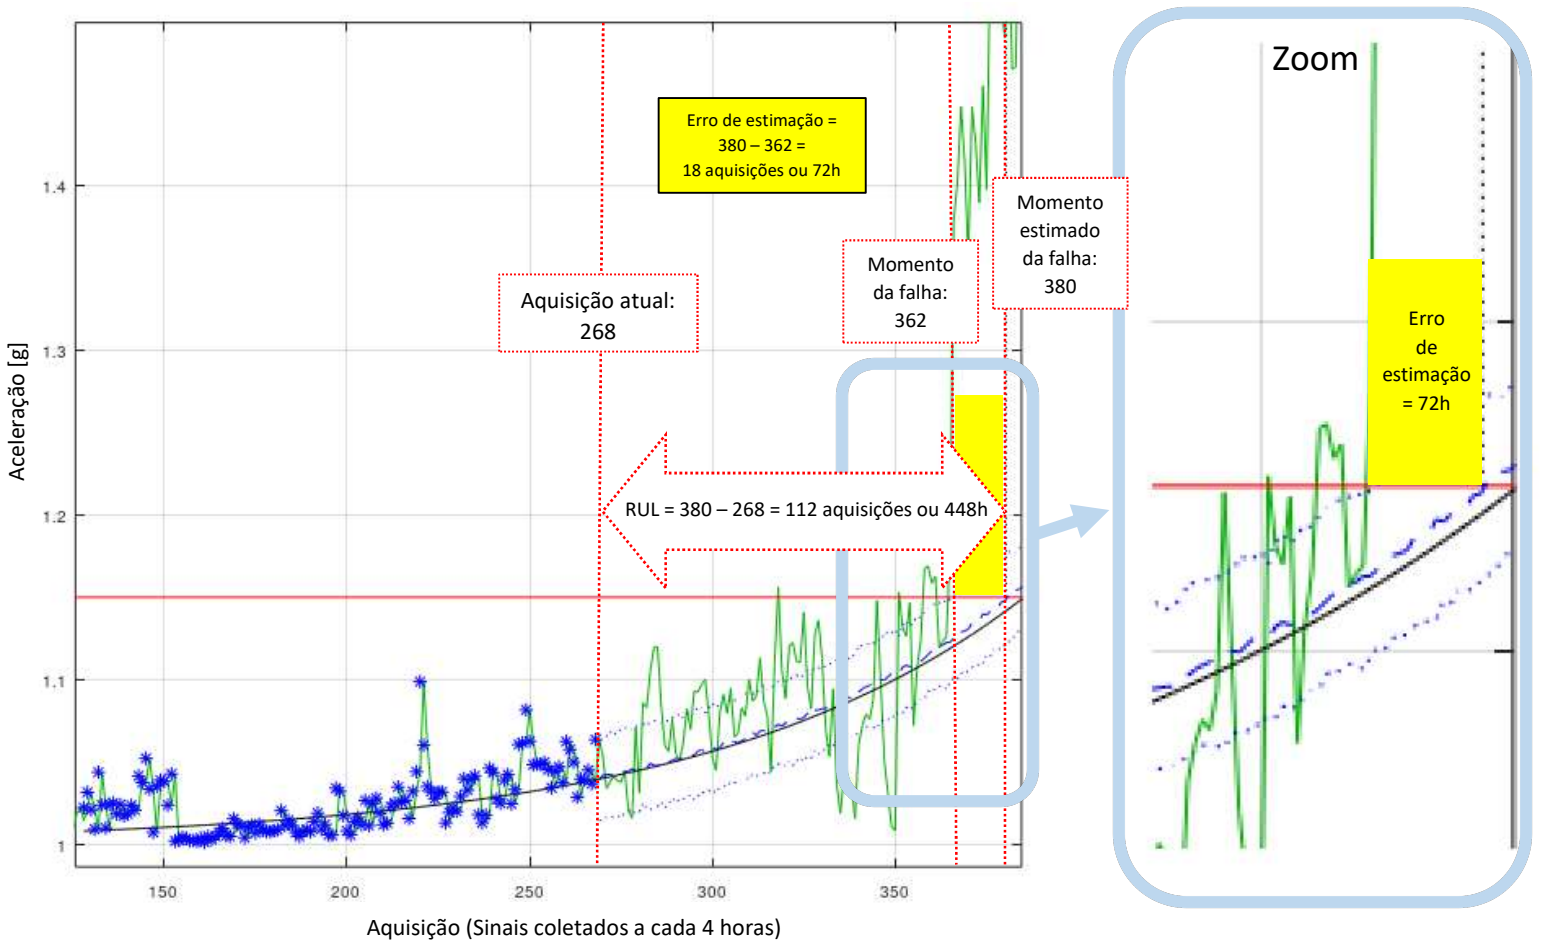


Figura 39 - Exemplo de cruzamento da curva de degradação com o limiar

4.4.4. Resultados Antes do Cruzamento da Curva de Degradação com o Limiar

Nesta seção, são apresentados os resultados do algoritmo de prognóstico na região próxima à falha, especificamente no período que antecede o cruzamento da curva de degradação com o limiar de falha. A Figura 40 ilustra as curvas geradas pelo algoritmo ao longo de 10 instantes consecutivos, abrangendo as aquisições de 258 a 267. Nesse intervalo, observa-se a evolução do comportamento exponencial da curva de degradação predita (representada pela linha tracejada azul), que segue a tendência dos dados reais de degradação futuros (curva verde). Apesar disso, até a aquisição 267, a curva predita ainda não cruza o limiar (linha vermelha), caracterizando uma situação em que o algoritmo não indica a estimativa de vida útil remanescente. Esse período, que ocorre 95 aquisições antes da falha real identificada na aquisição 362, reflete a estratégia conservadora adotada pelo modelo.

Esse atraso no cruzamento da curva de degradação predita com o limiar é uma consequência direta da abordagem probabilística utilizada, que considera cuidadosamente as incertezas intrínsecas ao processo de degradação. Essa abordagem é especialmente relevante para evitar previsões precipitadas que possam levar a falsos positivos. Ao mesmo tempo, o modelo captura com precisão a tendência geral dos dados, mesmo em situações em que as variações ainda não indicam uma falha iminente. Isso é evidente na análise das Regiões A e B, discutidas anteriormente, onde se verificou que o aumento da sensibilidade ou do número de amostras poderia gerar alarmes falsos, prejudicando a confiança nos resultados do prognóstico.

A Figura 40 traz informações visuais adicionais que complementam e enriquecem essa análise. Nota-se a progressão gradual da curva de degradação (linha verde), indicando a estabilidade do sistema antes de atingir o limiar. Além disso, a linha azul tracejada, representando as previsões do modelo, demonstra uma convergência progressiva com a curva real, evidenciando a capacidade do modelo em capturar a tendência geral do processo de degradação ao longo das aquisições.

Outro aspecto visível é a distância considerável entre as curvas de degradação (real e predita) e o limiar (linha vermelha). Essa distância reflete a operação em uma região de segurança até a aquisição 267, sem indicações de falha iminente. As pequenas oscilações no sinal real (linha verde) indicam variações naturais do sistema monitorado, que são suavizadas no modelo preditivo, destacando a robustez do algoritmo em lidar com ruídos e incertezas.

A sequência de subfiguras na Figura 40 também ilustra a evolução temporal do sistema, com cada aquisição específica representando um momento distinto. Apesar das pequenas variações entre as aquisições, a consistência das previsões é evidente, reforçando a estabilidade do algoritmo na análise de dados coletados em tempo real. Por fim, a ausência de qualquer cruzamento com o limiar em todas as aquisições confirma a prudência do modelo ao evitar alarmes prematuros.

A prudência demonstrada pelo algoritmo ao não prever o RUL prematuramente destaca um aspecto crucial de sua operação: a análise criteriosa dos dados disponíveis sem extrapolações precipitadas. Esse comportamento conservador é de grande importância em ambientes industriais, onde alarmes falsos podem gerar custos elevados, como substituições desnecessárias de componentes, interrupções inesperadas de processos produtivos ou intervenções de manutenção não planejadas. Além disso, ele contribui diretamente para a

confiabilidade do sistema de monitoramento, promovendo a tomada de decisões baseadas em evidências sólidas.

Outro ponto a ser destacado é que a ausência de previsão de RUL até este momento indica que o sistema monitorado ainda opera em uma região de relativa estabilidade. Durante essa fase, as incertezas associadas à degradação são mais pronunciadas, e os sinais de falha iminente não são suficientemente claros para justificar uma intervenção. Essa característica demonstra a robustez do modelo, que prioriza a emissão de alertas somente quando há sinais confiáveis de degradação crítica.

Contudo, é importante ressaltar que, embora a abordagem conservadora do algoritmo seja vantajosa em termos de confiabilidade, ela deve ser equilibrada com a necessidade de fornecer estimativas de RUL em tempo hábil para permitir intervenções preventivas antes que o cruzamento com o limiar ocorra. Esse equilíbrio é fundamental para maximizar a eficácia do sistema de monitoramento e garantir que falhas iminentes sejam tratadas de forma proativa, minimizando os impactos nas operações.

Nesse caso específico, o desempenho do algoritmo ao não prever o RUL de forma prematura reflete um comportamento positivo, demonstrando sua capacidade de evitar decisões impulsivas baseadas em extrapolações incertas. Essa característica é particularmente valiosa em cenários industriais complexos, onde o equilíbrio entre a precisão das previsões e a tempestividade das ações corretivas é essencial para garantir a segurança e a eficiência operacional.

Por fim, os resultados apresentados nesta seção reforçam a adequação do algoritmo de prognóstico a aplicações onde uma previsão precisa é preferível ante a detecções antecipadas imprecisas ou à emissão de alarmes falsos. Essa abordagem, que privilegia a confiabilidade das previsões, contribui para decisões mais assertivas e fundamentadas, promovendo uma gestão eficiente dos ativos monitorados. Além disso, o modelo se destaca como uma ferramenta robusta para o suporte à manutenção preditiva, garantindo intervenções alinhadas às reais necessidades do equipamento e, conseqüentemente, otimizando os recursos e a produtividade das operações industriais.

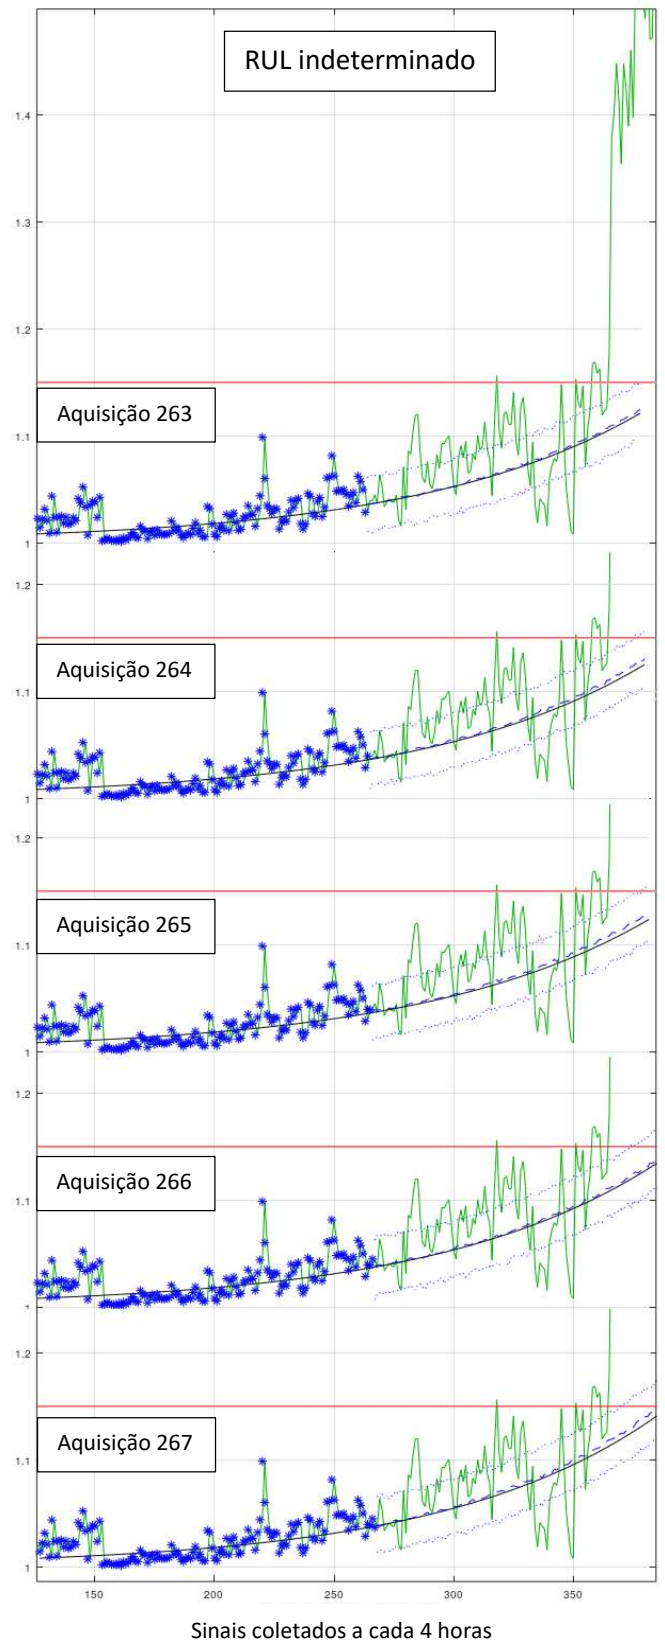



Figura 40 - Curvas geradas pelo algoritmo de prognóstico em 10 instantes subsequentes, abrangendo as aquisições de 258 até 267.

4.4.5. Resultados Após o Cruzamento da Curva de Degradação com o Limiar

Os resultados do algoritmo de prognóstico após o cruzamento da curva de degradação com o limiar, onde é possível estimar o tempo restante de vida útil, são apresentados na Tabela 3 e na Figura 41. Esses resultados abrangem as 10 aquisições consecutivas entre 268 e 277 e ilustram como o modelo se comporta durante a fase crítica de aproximação da falha.

4.4.5.a. Avaliação Inicial e Comportamento Progressivo do Modelo

Inicialmente, na aquisição 268, o *RUL* estimado é de 112,25 aquisições, correspondendo a aproximadamente 449 horas, com um erro de estimativa de 72 horas em relação à falha real. Esse erro inicial relativamente alto reflete a incerteza típica do modelo nas fases iniciais, quando o cruzamento com o limiar ocorre pela primeira vez. Apesar disso, observa-se uma tendência clara de redução progressiva do erro à medida que mais dados de degradação são adquiridos.

Entre as aquisições 268 e 273, o *RUL* estimado diminui consistentemente, com o erro de estimativa sendo reduzido de 72 horas para 0 horas na aquisição 273. Nesse ponto, o algoritmo prevê com exatidão o tempo restante até a falha, demonstrando sua capacidade de ajustar as estimativas conforme novos dados são incorporados. Esse comportamento evidencia o caráter adaptativo do modelo, que refina continuamente as projeções à medida que a curva de degradação real converge para a curva predita.

4.4.5.b. Precisão e Subestimação nas Fases Finais

A partir da aquisição 273, o erro de estimativa é reduzido a 0 horas, representando o momento de máxima precisão do modelo. Essa exatidão ocorre no ponto onde o *RUL* predito (358 horas) coincide exatamente com o tempo real até a falha. A capacidade do modelo de alcançar tal precisão reforça sua robustez e confiabilidade em aplicações práticas, onde decisões precisas são essenciais para evitar falhas catastróficas.

Nas aquisições subsequentes (274 a 277), observa-se uma leve subestimação do *RUL*, com erros de estimativa negativos de até -12 horas. Essa subestimação, embora pequena, é uma característica desejável em sistemas de prognóstico, pois evita superestimações que poderiam levar a atrasos nas ações preventivas. A proximidade entre os valores estimados e os reais durante essa fase crítica demonstra que o modelo continua a operar de forma confiável, mesmo

diante das oscilações típicas associadas ao comportamento estocástico de processos de degradação.

4.4.5.c. Interpretação Detalhada da Figura 41

A Figura 41 ilustra as curvas geradas pelo algoritmo de prognóstico para as 10 aquisições consecutivas, destacando a interação entre os dados reais de degradação (curva verde), a curva predita (linha tracejada azul) e o limiar de falha (linha vermelha). Cada gráfico apresenta a evolução do *RUL*, o erro de estimativa e o momento exato da falha prevista, fornecendo uma visão abrangente do desempenho do modelo em cada etapa. Cada gráfico corresponde a uma aquisição específica, evidenciando:

- A curva de degradação gerada pelo algoritmo, que se ajusta gradualmente à medida que novos dados são incorporados;
- O momento em que a curva cruza o limiar de falha, indicando o ponto crítico para estimativa do tempo restante;
- Os destaques em amarelo, que sinalizam os pontos de cruzamento e ajudam a correlacionar os dados da tabela com os gráficos.

Logo na aquisição 268, observa-se que a curva predita apresenta um comportamento exponencial que acompanha parcialmente os dados reais de degradação. No entanto, o cruzamento com o limiar só ocorre na aquisição 273, momento em que o erro de estimativa é reduzido a 0. Esse comportamento inicial reflete a abordagem conservadora do modelo, que prioriza a robustez das estimativas em detrimento de alarmes precoces ou extrapolações incertas.

Os destaques em amarelo na Figura 41 ressaltam os erros de estimativa ao longo das aquisições, permitindo uma análise visual clara da transição do modelo entre a fase inicial conservadora e a fase final de maior precisão. Essa transição evidencia o equilíbrio entre a redução das incertezas e a adaptação progressiva às tendências reais de degradação.

4.4.5.d. Interpretação dos Dados da Tabela 3

A Tabela 3 apresenta, para cada aquisição, uma visão detalhada das estimativas do modelo, incluindo:

- O *RUL* estimado em número de aquisições e horas;
- O *RUL* máximo projetado (refletindo as incertezas iniciais);
- O tempo total até a falha real;
- O momento estimado da falha (em número de aquisições);
- O erro de estimativa (em horas).

Esses dados destacam como o algoritmo ajusta suas previsões conforme novos sinais de degradação são processados.

1. Aquisição 268:

Nesta aquisição inicial, o *RUL* estimado é de 112,25 aquisições, equivalente a aproximadamente 449 horas. O modelo projeta um *RUL* máximo de 482 horas, indicando incertezas significativas no início do processo. O erro de estimativa é de 72 horas, um valor relativamente elevado, mas esperado em função da menor quantidade de dados disponíveis sobre a degradação.

2. Aquisição 269:

O *RUL* estimado cai para 105,75 aquisições (423 horas), enquanto o *RUL* máximo diminui para 464 horas. O erro de estimativa também reduz para 48 horas, evidenciando a capacidade do modelo de adaptar-se rapidamente com mais dados.

3. Aquisições 270 e 271:

O *RUL* estimado continua diminuindo, chegando a 96 aquisições (384 horas) na aquisição 271. O *RUL* máximo também se ajusta, caindo para 413 horas. O erro de estimativa reduz-se para 20 horas, mostrando uma maior precisão do modelo conforme os sinais de degradação se tornam mais consistentes.

4. Aquisição 273:

Este ponto representa um marco para o algoritmo, onde o erro de estimativa atinge 0 horas. O modelo prevê com exatidão o momento da falha, com o *RUL* estimado em

89,5 aquisições (358 horas). Esse resultado demonstra a robustez do algoritmo em alinhar suas previsões com a realidade no momento crítico.

5. Aquisições 274 a 277:

Nas aquisições finais, o modelo apresenta erros de estimativa ligeiramente negativos (-12 horas), indicando uma leve subestimação do tempo restante. Apesar disso, o *RUL* estimado e o *RUL* máximo continuam alinhados, com valores que se estabilizam em torno de 336 a 331 horas (*RUL*) e 394 a 376 horas (*RUL* máximo), refletindo a proximidade da falha real.

4.4.5.e. Impactos Operacionais e Relevância dos Resultados

Os resultados da Tabela 3 e da Figura 41 mostram como o algoritmo equilibra incertezas iniciais com precisão final. Nas primeiras aquisições, o *RUL* máximo elevado reflete o comportamento conservador do modelo, necessário para evitar subestimações que poderiam comprometer a segurança operacional. À medida que a falha se aproxima, a convergência do *RUL* estimado e o alinhamento com o tempo real destacam a eficácia do modelo em ambientes industriais críticos.

O comportamento do algoritmo nas fases finais, com erros ligeiramente negativos, reforça sua confiabilidade ao evitar superestimações. Essa característica é essencial para o planejamento adequado de manutenções preventivas e para minimizar riscos operacionais.

Em resumo, a análise integrada da Tabela 3 e da Figura 41 confirma que o algoritmo não apenas reflete adequadamente as tendências de degradação, mas também ajusta suas estimativas de forma consistente, garantindo um prognóstico confiável e eficiente.

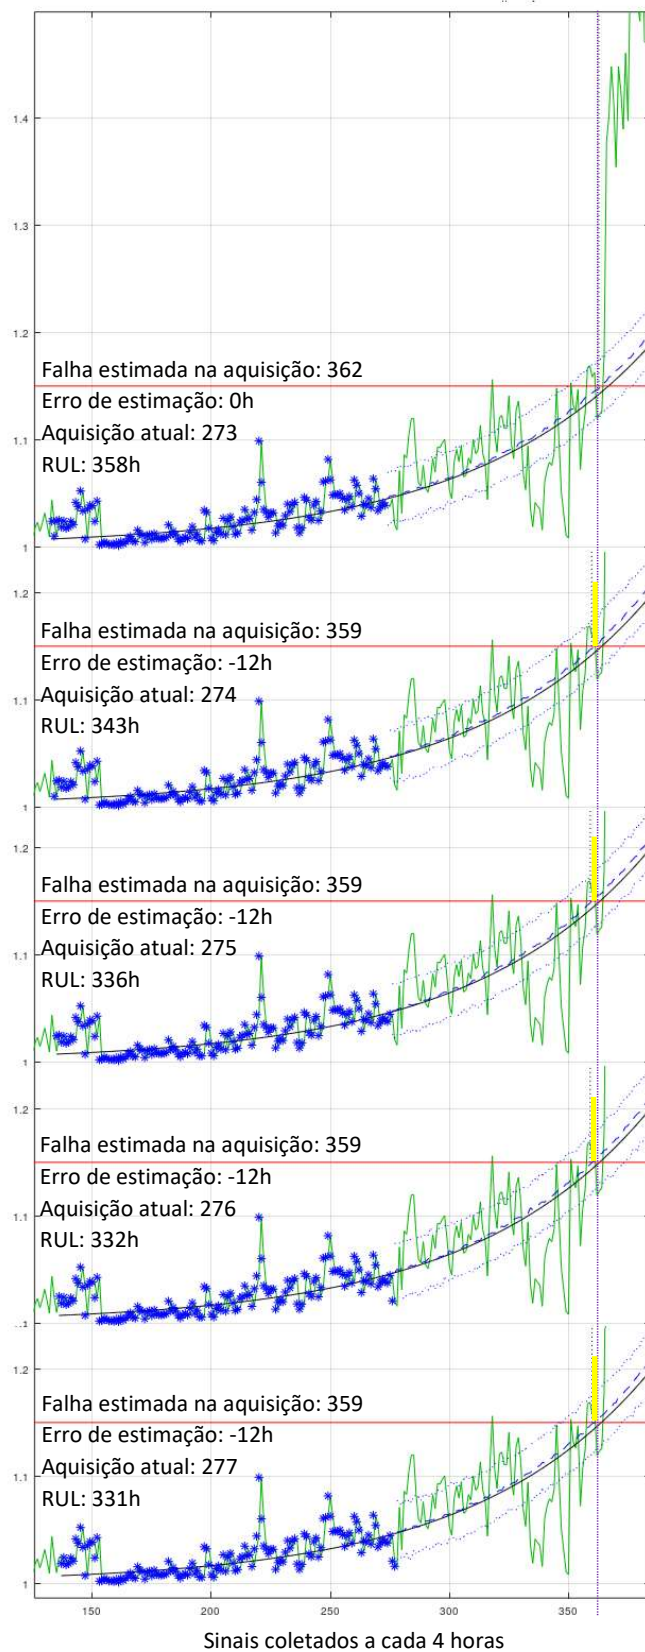
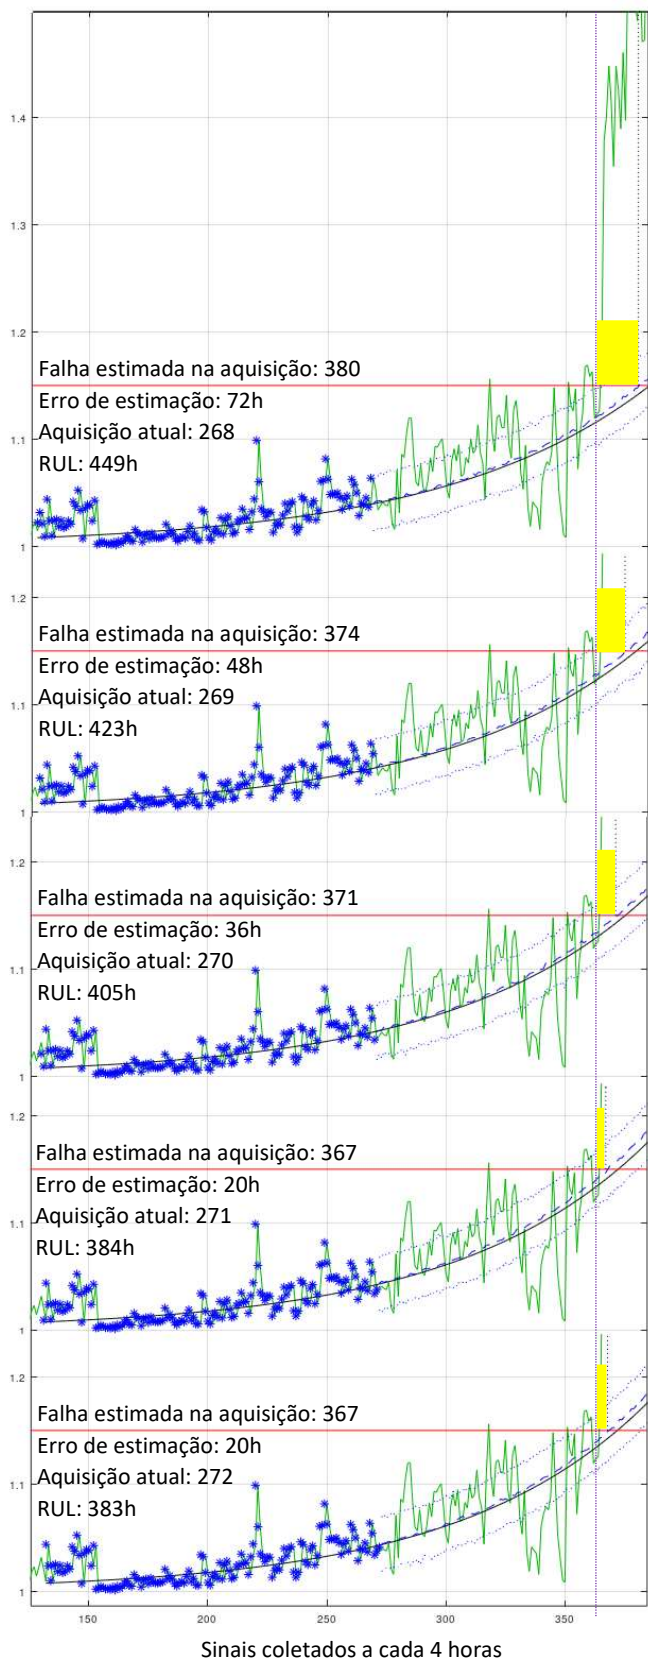


Figura 41 - Curvas geradas pelo algoritmo de prognóstico em 10 instantes subsequentes, abrangendo as aquisições de 268 até 277

Tabela 3 – Resultado do algoritmo de prognóstico com a falha na aquisição 362.

	Aquisição atual	RUL (aquisições)	RUL (h)	RUL máximo (h)	Tempo até a falha	Momento estimado da falha (aquisição)	Erro de estimacão (h)
1	268	112,25	449	482	18d17	380	72
2	269	105,75	423	464	17d15	374	48
3	270	101,25	405	455	16d21	371	36
4	271	96	384	413	16d0	367	20
5	272	95,75	383	413	15d23	367	20
6	273	89,5	358	409	14d22	362	0
7	274	85,75	343	394	14d7	359	-12
8	275	84	336	365	14d0	359	-12
9	276	83	332	374	13d20	359	-12
10	277	82,75	331	376	13d19	359	-12

Para avaliar o desempenho do algoritmo de prognóstico proposto, analisamos os resultados apresentados nas Figuras 41 e 42. Essas figuras ilustram o erro de estimativa nos dez instantes analisados, conforme detalhado na Tabela 3. O erro foi calculado como a diferença entre o RUL estimado e o momento da falha real, que ocorreu na aquisição 362.

A Figura 42 apresenta o erro de estimativa em horas para os dez instantes. No início, o erro era elevado, atingindo 72 horas no primeiro instante, mas mostrou uma redução gradual e consistente ao longo do tempo. Com a aproximação do momento da falha, o erro diminuiu progressivamente, chegando a 0 no instante final. Isso demonstra que o modelo ajustou suas previsões de maneira eficaz à medida que novas informações eram incorporadas, evidenciando sua robustez e capacidade de adaptação. É importante notar que essa tendência reflete a habilidade do modelo em capturar a evolução da degradação do equipamento, ajustando-se progressivamente ao comportamento real do sistema.

Adicionalmente, a Figura 42 ilustra como o algoritmo foi capaz de corrigir os desvios de estimativa de maneira sistemática. A redução contínua do erro ao longo dos instantes reforça o papel do algoritmo como uma ferramenta de suporte à manutenção preditiva.

A Figura 43, por sua vez, representa o erro de estimativa em termos percentuais do RUL calculado em cada instante. Observa-se que, no início, o erro percentual era de aproximadamente 15%, indicando uma subestimação significativa do RUL. Entretanto, com o

passar dos instantes, o erro percentual reduziu continuamente, atingindo valores negativos próximos a -3% nos últimos instantes. Isso sugere que, embora o modelo tenha apresentado um pequeno desvio negativo nas estimativas finais, ele evitou superestimações, o que é crucial para garantir a confiabilidade do planejamento de manutenção.

Os resultados refletem a eficácia do algoritmo na identificação da degradação progressiva do sistema. O modelo conseguiu alinhar suas previsões com o comportamento real da falha, especialmente nos momentos críticos. Isso demonstra a utilidade prática do algoritmo, que pode ser aplicado em contextos industriais para evitar custos elevados de manutenção corretiva e minimizar o tempo de inatividade dos equipamentos.

Outro ponto relevante é o comportamento do erro nas fases iniciais. Apesar de apresentar valores elevados, isso pode ser atribuído à menor quantidade de dados disponíveis para alimentar o modelo nas primeiras iterações. À medida que o histórico de dados aumentava, o algoritmo foi capaz de refinar suas previsões, reduzindo o erro progressivamente. Esse comportamento reforça a importância de um monitoramento contínuo e da atualização constante dos dados para maximizar a precisão das estimativas.

Adicionalmente, a análise dos resultados nas Figuras 41 e 42 permite inferir que o algoritmo foi capaz de identificar mudanças na componente espectral relacionada à degradação do motor, contribuindo para a evolução das estimativas de RUL ao longo do tempo. Isso está alinhado com os objetivos propostos de desenvolver uma solução preditiva que não apenas estime o RUL, mas também acompanhe a progressão das falhas com precisão crescente.

Em suma, as Figuras 41 e 42 comprovam a eficácia do algoritmo de prognóstico proposto em termos de precisão, confiabilidade e utilidade prática. A redução consistente do erro de estimativa, tanto em horas quanto em termos percentuais, demonstra que o modelo pode ser integrado a sistemas de monitoramento preditivo para otimizar o planejamento de intervenções e garantir maior confiabilidade operacional.



Figura 42 - Erro de estimativa em horas para os dez instantes.




Figura 43 - Erro de estimativa em termos percentuais do RUL calculado em cada instante.

5. CONCLUSÕES

Os resultados apresentados ao longo deste estudo demonstram avanços significativos na análise de sinais provenientes de *skid*-BCSS e BCSS, evidenciando a eficácia de técnicas específicas de processamento de sinais aplicadas à assinatura elétrica e ao monitoramento preditivo. A pesquisa destacou que as particularidades desses sistemas, como a presença de componentes espectrais em pares e muito próximas, exigem abordagens robustas e adaptadas para garantir diagnósticos e prognósticos confiáveis.

No contexto da assinatura elétrica, verificou-se a importância da seleção adequada de janelas de processamento espectral. A janela Tukey demonstrou desempenho superior à janela Blackman, amplamente utilizada em motores de indução convencionais. Essa escolha permitiu uma distinção mais clara entre as frequências do sinal analisado, sem comprometer a faixa dinâmica, o que é crucial para a identificação de componentes espectrais sutis indicativas do início de falhas. Além disso, a preservação do leakage é um diferencial essencial.

Outro avanço relevante foi a implementação da técnica de concatenação, que aprimorou a resolução espectral dos sinais analisados. Essa abordagem mostrou-se uma alternativa eficaz para mitigar as limitações impostas pelo aumento da janela de aquisição, como a perda de estacionariedade e o consequente espalhamento espectral. Com a concatenação, foi possível distinguir componentes associadas ao desequilíbrio rotórico em sinais de apenas 22 segundos de duração, representando um avanço na capacidade de análise em condições operacionais reais.

No contexto do monitoramento preditivo, o desenvolvimento e a aplicação do algoritmo Bayesiano em um setup de teste contendo um motor de indução com falhas em rolamentos demonstraram sua eficácia na identificação do crescimento das componentes espectrais associadas à degradação progressiva desses elementos. Os resultados indicaram que o modelo não apenas capturou as tendências gerais de degradação, mas também ajustou suas previsões conforme novos dados foram incorporados, reduzindo progressivamente o erro de estimativa ao longo do tempo.

A robustez do algoritmo foi evidenciada por sua capacidade de evitar estimativas precipitadas da vida útil remanescente (RUL). Nos estágios iniciais da análise, o erro de estimativa, como esperado, foi relativamente alto, mas reduziu-se consistentemente à medida

que mais informações eram incorporadas, convergindo para valores próximos de zero nas fases finais do monitoramento. Esse comportamento destaca a importância dos métodos probabilísticos na avaliação da degradação de sistemas industriais, uma vez que alarmes falsos podem resultar em custos elevados e paralisações desnecessárias.

A análise do erro de estimação revelou que, embora o algoritmo tenha apresentado alguns desvios nas etapas finais, ele evitou superestimações da vida útil remanescente, garantindo que intervenções fossem realizadas apenas quando estritamente necessário. Além disso, o modelo demonstrou a capacidade de detectar mudanças na componente espectral relacionada à degradação, mesmo durante períodos de aparente estabilidade, reforçando sua confiabilidade na tomada de decisões para manutenção preditiva.

Por fim, os resultados deste estudo demonstram o potencial das técnicas aplicadas para futuras análises de prognóstico em sinais de corrente de *skid*-BCSS e BCSS. A implementação dessas metodologias possibilitará uma avaliação mais precisa do desempenho preditivo, quando comparada a outras abordagens de monitoramento online de bombas centrífugas submersas.

Em resumo, este trabalho evidenciou que a combinação de técnicas avançadas de processamento espectral — como o uso de janelas adequadas, concatenação de sinais e algoritmos de prognóstico probabilísticos — representa uma abordagem robusta para a análise de falhas em sistemas complexos. Os resultados obtidos apontam direções promissoras para pesquisas futuras, consolidando a importância das soluções preditivas na gestão de ativos industriais.

REFERÊNCIAS

- 1 R. CERBINO SALLES, “Modelagem em Frequência de um Motor de Bombeamento Centrífcgo Submerso Submarino Utilizando o Método dos Elementos Finitos”, Dissertação (mestrado), UFRJ/ COPPE/ Programa de Engenharia Elétrica, 2011.
- 2 G. TAKACS, “Electrical Submersible Pumps Manual: Design, Operations, and Maintenance”, *Gulf Equipment Guides*, Elsevier, 2009.
- 3 RODRIGUES, ROBERTO, SIQUEIRA, J.M., ESTEVAM, V., DRUMOND, F. G., “Rotas tecnológicas para sistemas de bombeamento e elevação artificial em poços de completação submarina”, III Seminário de Elevação Artificial e Escoamento. Petrobras, 2007b.
- 4 SOUZA, EMILIO PAULO SANTOS E HAYASHI, LUCILA MASSAE, “Sistemas de Bombeio Submarino”, Situação Atual na Petrobras e Principais Desafios – UFBA, Salvador, 2006.
- 5 RIBEIRO, MARCOS PELLEGRINI, “Inaccessible equipment monitoring via vibratory signature analysis utilising data collected by remote accelerometers”, Thesis (Ph.D.), Imperial College London, 1999.
- 6 API RP 11S8, “Recommended Practice on Electric Submersible Pump System Vibrations”, 1st Ed., American Petroleum Institute, 1993.
- 7 P. POPALENY, A. DUYAR, C. OZEL, Y. ERDOGAN, “Electrical Submersible Pumps Condition Monitoring Using Motor Current Signature Analysis”, In Abu Dhabi International Petroleum Exhibition & Conference, Society of Petroleum Engineers, Nov 2018.
- 8 W. T. THOMSON, I. CULBERT, “Current Signature Analysis for Condition Monitoring of Cage Induction Motors”, IEEE PRESS, WILEY, 2017.
- 9 API RP 11S, “Recommended Practice for Operation, Maintenance, and Troubleshooting of Electric Submersible Pump Installation”, 3rd Ed., American Petroleum Institute, 1994.
- 10 CUSIDO, J.; ROMERAL, L.; GARCIA, A.; ROSERO, J. A.; ORTEGA, J. A. “Fault Detection in Induction Machines by Using Continuous and Discrete Wavelet Decomposition”, In European Conference on Power Electronics and Applications, 2007.
- 11 BONALDI, E. L. “Diagnóstico Preditivo de Avarias em Motores de Indução Trifásicos com MCSA e Teoria de Conjuntos Aproximados”, 185 f. Tese (Doutorado em Engenharia Elétrica). Universidade Federal de Itajubá, Itajubá (UNIFEI), 2005.
- 12 J. G. BORGES DA SILVA, “Aplicação da Análise de Componentes Principais (PCA) no Diagnóstico de Defeitos em Rolamentos através da Assinatura Elétrica de Motores de Indução, Dissertação de Mestrado – Universidade Federal de Itajubá (UNIFEI), 2008.
- 13 DIAGNOSTIC TECHNOLOGIES INDIA PVT. LTD: “On-line Condition Monitoring of Motors Using Electrical Signature Analysis”. E-mail: diatech@vsnl.com.
- 14 S. M. A. CRUZ E A. J. M. CARDOSO, “Rotor Cage Fault Diagnosis in Three-Phase Induction Motors by Extended Park’s Vector Approach,” Proceedings of the International Conference on Electrical Machine, vol. 3, 1998.
- 15 I. Y. ONEL, K. B. DALCI E I. SENOL, “Detection of Outer Raceway Bearing Defects in Small Induction Motors Using Stator Current Analysis,” vol. 30, n° 6, 2005.
- 16 OBAID, R. R., HABETLER, T. G. E STACK, J. R. “Stator Current Analysis for Bearing Damage Detection in Induction Motors”. IEEE International symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003.

- 17 TARCHA, B. A.; BORGES, O. C., & FURTADO, R. G., ESP Installed In a Subsea *Skid* at Jubarte Field. SPE Artificial Lift Conference. Latin America and Caribbean, Salvador, Bahia, Brazil. doi: <https://doi.org/10.2118/173931-MS>, 2015
- 18 KUWAŁEK P, OTOMAŃSKI P, WANDACHOWICZ K., Influence of the Phenomenon of Spectrum Leakage on the Evaluation Process of Metrological Properties of Power Quality Analyser. *Energies*. 2020; 13(20):5338. <https://doi.org/10.3390/en13205338>
- 19 S. V. VASEGHI, “Advanced Digital Signal Processing and Noise Reduction,” 4a ed., John Wiley & Sons Ltd, 2008, p. 277.
- 20 G. THONET E J. M. VESIN, “Stationarity Assessment with Time-Varying Autoregressive Modeling,” em IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), Munich, 1997.
- 21 K. BARBÉ, W. V. MOER, L. LAUWERS E N. BJÖRSELL, “A Simple Nonparametric Preprocessing Technique to Correct for Nonstationary Effects in Measured Data,” IEEE Transactions on Instrumentation and Measurement, vol. 61, pp. 2085-2094, Agosto 2012.
- 22 D. B. D. SOUZA, J. CHANUSSOT, A. C. FAVRE E P. BORGNAT, “A Modified Time-Frequency Method for Testing Wide-Sense Stationarity,” em IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2012.
- 23 P. BASU, D. RUDROY E P. J. WOLFE, “A Nonparametric Test for Stationarity Based on Local Fourier Analysis,” em IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Taipei, 2009.
- 24 S. L. MARPLE. JR., Digital Spectral Analysis and its Applications. Moscow: Mir Publishers, 1990. P. 584.
- 25 CARLOS E. DAVILA, “Signals, Systems, and Society”. Rice University, Houston, Texas, <http://cnx.org/content/col10965/1.15/>>, 2012
- 26 NUTTALL, ALBERT H., "Some Windows with Very Good Sidelobe Behavior". IEEE Transactions on Acoustics, Speech, and Signal Processing. 29 (1): 84–91. doi:10.1109/TASSP.1981.1163506. 1981
- 27 BAYES, T., “An essay towards solving a problem in the doctrine of chances”, *Philos. T. Roy. Soc.*, 53, 370- 418. DOI: 10.1098/rstl.1763.0053, 1763.
- 28 ATHANASIOS P., “Probability, Random Variables, and Stochastic Processes”. New York: McGraw-Hill; 1984.
- 29 GAMERMAN, D., “Markov chain Monte Carlo: Stochastic Simulation for Bayesian Inference”. Texts in Statistical Sciences. Chapman and Hall, London, 1997.
- 30 GEBRAEEL, N. Z., LAWLEY, M. A., LI, R., & RYAN, J. K., “Residual-life distributions from component degradation signals: A Bayesian approach”. *IIE Transactions*, 37(6), 543–557, 2005.