isec Engenharia

MESTRADO EM ENGENHARIA E GESTÃO INDUSTRIAL

# Monitorização e manutenção preditiva em motores elétricos com base na análise espectral


Autor

**João Paulo Proença Costa**

Orientadores

**José Manuel Torres Farinha**

**Mateus Mendes**


Coimbra, Junho e 2024


INSTITUTO POLITÉCNICO DE COIMBRA

isec Engenharia

DEPARTAMENTO DE ENGENHARIA MECÂNICA

# Monitorização e manutenção preditiva em motores elétricos com base na análise espectral

Relatório de Trabalho de Projeto para a obtenção do grau de Mestre em Engenharia e Gestão Industrial


Autor

**João Paulo Proença Costa**

Orientador

**José Manuel Torres Farinha**

Supervisor na empresa **ENGING Make Solutions SA**

**Jorge Oliveira Estima**


Coimbra, Junho de 2024


INSTITUTO POLITÉCNICO DE COIMBRA

INSTITUTO SUPERIOR DE ENGENHARIA DE COIMBRA

## AGRADECIMENTOS

Nesta secção, quero expressar a minha profunda gratidão a todas as pessoas e instituições que, de alguma forma, contribuíram para a realização desta tese e para a conclusão desta importante etapa da minha vida

Em primeiro lugar, à minha namorada Tatiana, que esteve sempre ao meu lado em todos os momentos, tanto nos bons como nos mais desafiadores. O teu amor e constante apoio incondicional foram fundamentais para que eu pudesse continuar e superar todas as dificuldades ao longo do caminho, por fim, a tua paciência e compreensão ao longo destes anos foram uma fonte constante de motivação e força.

Aos meus pais, o meu eterno agradecimento pela educação e valores que me transmitiram. O vosso apoio foi crucial para que eu pudesse alcançar este objetivo. Sem o vosso sacrifício e dedicação, nada disto teria sido possível. À minha irmã, agradeço pela amizade e pelo suporte que me deu ao longo de todos estes anos, a tua presença e as tuas palavras foram sempre uma fonte de conforto e motivação. Vocês foram a minha base e a minha inspiração para superar todos os desafios que encontrei pelo caminho.

Aos meus orientadores, quero expressar a minha profunda gratidão pelo vosso apoio e orientação ao longo deste percurso académico. Em especial, ao Professor Torres Farinha, o meu sincero agradecimento pela sua sábia orientação, paciência e dedicação. A sua confiança nas minhas capacidades e o seu constante apoio tem um significado enorme para mim, por fim, o seu exemplo de profissionalismo e rigor académico será sempre uma inspiração para mim.

Um agradecimento especial ao Jorge e a toda a equipa da empresa Enging, pelo apoio e suporte prestado durante a realização deste trabalho. O vosso contributo foi essencial para o desenvolvimento deste projeto.

Por último, mas não menos importante, quero agradecer aos meus colegas. A amizade, o companheirismo e o carinho que me proporcionaram ao longo destes anos foram fundamentais para tornar esta jornada num marco fantástico. As discussões, as partilhas de conhecimento e as palavras de conforto foram vitais para o meu crescimento pessoal.

A todos vós, o meu mais profundo e sincero agradecimento. Sem o vosso apoio, este trabalho não teria sido possível. Muito obrigado por acreditarem em mim e por me ajudarem a alcançar este marco na minha vida.

## RESUMO

As falhas nas correias dos ativos industriais representam desafios significativos para as operações de fabrico, resultando em paragens dispendiosas e intervenções de manutenção. Este estudo apresenta uma abordagem abrangente para a análise de falhas nas correias, utilizando técnicas avançadas de monitorização e diagnóstico.

Através da integração da Análise de Assinatura de Corrente do Motor (MCSA) e algoritmos de *machine learning*, nomeadamente Long Short-Term Memory (LSTM), o objetivo é prever e detetar a degradação das correias em tempo real. A metodologia envolve a recolha e o pré-processamento de dados espectrais brutos de ativos industriais, seguida pelo treino e otimização de modelos preditivos usando algoritmos inteligentes. A eficácia da abordagem é demonstrada através de testes extensivos com dados do mundo real, evidenciando a capacidade de prever com precisão falhas nas correias e possibilitar melhores estratégias de manutenção. Os resultados obtidos na fase de testes revelam um alto nível de precisão na previsão de falhas das correias, com os modelos desenvolvidos a superar consistentemente os métodos tradicionais. A incorporação de redes LSTM e algoritmos de inteligentes levou a uma melhoria significativa nas capacidades preditivas, permitindo a deteção precoce de padrões de degradação e intervenção atempada.

Ao aproveitar o poder da análise preditiva, o trabalho realizado oferece um caminho promissor para melhorar a eficiência operacional e minimizar as paragens não planeadas nos ambientes industriais. Este trabalho não só contribui para o campo da manutenção preditiva, mas também sublinha o potencial transformador das tecnologias avançadas de monitorização na otimização da fiabilidade e desempenho dos ativos.


**Palavras-Chave:** Falha nas correias; Manutenção preditiva; Análise de Assinatura de Corrente do Motor; Long Short-Term Memory; Ativo industrial

## ABSTRACT

Industrial belt failures pose significant challenges to manufacturing operations, often resulting in costly downtime and maintenance interventions. This study presents a comprehensive approach to belt failure analysis leveraging advanced monitoring and diagnostic techniques.

Through the integration of Motor Current Signature Analysis (MCSA) and machine learning algorithms, particularly Long Short-Term Memory (LSTM) networks, aim to predict and detect belt degradation in real time. The methodology involves the collection and pre-processing raw spectral data from industrial assets, followed by the training and optimization of predictive models using swarm intelligence algorithms. The effectiveness of the approach is demonstrated through extensive testing against real-world data, showcasing its ability to accurately forecast belt failures and enable proactive maintenance strategies. Results obtained from the testing phase reveal a high level of accuracy in predicting belt failures, with the developed models consistently outperforming traditional methods. The incorporation of LSTM networks and swarm intelligence algorithms led to a significant improvement in predictive capabilities, allowing for early detection of degradation patterns and timely intervention.

By harnessing the power of data-driven predictive analytics, the research offers a promising pathway towards enhancing operational efficiency and minimizing unplanned downtime in industrial settings. This study not only contributes to the field of predictive maintenance but also underscores the transformative potential of advanced monitoring technologies in optimizing asset reliability and performance.


**Keywords:** Belt failure; Predictive maintenance; Motor Current Signature Analysis; Long Short-Term Memory; Industrial asset

# ÍNDICE

**LISTA DE FIGURAS** ..... vii
**LISTA DE TABELAS** ..... ix
**SIMBOLOGIA E ACRÓNIMOS** ..... x
**CAPÍTULO 1 - Introdução** ..... 1
**CAPÍTULO 2 - Introdução aos motores elétricos** ..... 2
**2.1 – Motores DC** ..... 2
**2.1.1 – *Separately Excited*** ..... 3
**2.1.2 – *Shunt*** ..... 4
**2.1.3 – *Series*** ..... 4
**2.1.4 – *Compound*** ..... 4
**2.2 – Motores AC** ..... 5
**2.2.1 – Motores de indução** ..... 6
**2.2.2 – Motores Síncronos** ..... 7
**2.3 – Principais tipos de falhas no motores DC** ..... 7
**2.4 – Principais tipos de falhas nos motores AC Indução** ..... 8
**2.4.1 – Falhas no estator** ..... 8
**2.4.2 – Falhas no rotor** ..... 8
**2.4.3 – Falha nos rolamentos** ..... 9
**2.5 – Principais Aplicações industriais e a sua caracterização** ..... 10
**2.5.1 – Bombas** ..... 10
**2.5.2 – Bomba Centrífugas** ..... 11
**2.5.3 – Compressores** ..... 14
**2.5.4 – Compressor Centrífugo** ..... 15
***2.5.5* – Compressor Recíproco** ..... 17
**2.5.6 – Ventiladores** ..... 19
**2.5.7 – Ventilador Centrífugo** ..... 20
**2.5.8 – Moinhos** ..... 21
**2.5.9 – Moinhos de bolas horizontais** ..... 22
**2.5.10. – Moinhos Vertical de rolos** ..... 23
**2.6 – Conclusão do capítulo** ..... 24
**CAPÍTULO 3 – Enquadramento Teórico** ..... 25
**3.1 – Métodos de Deteção de Falhas** ..... 26
**3.1.1 – Métodos baseados na análise espetral das vibrações** ..... 27
**3.1.2 – Métodos baseados na análise espetral das correntes do estator** ..... 27

**3.1.3 – Métodos baseados na análise espetral do fluxo magnético axial** ..... 28
**3.1.4 – Métodos baseados no vetor de *Park*** ..... 28
**3.1.5 – Métodos baseados em redes neuronais artificiais** ..... 29
**3.2 – Técnica MCSA** ..... 30
**3.2.1 – Padrões de falha no motor** ..... 31
**3.2.2 – Sistemas de Transmissão** ..... 35
**3.2.3 – Bombas Centrífugas** ..... 37
**3.2.4 – Ventiladores** ..... 38
**3.3 – Conclusão do capítulo** ..... 38
**CAPÍTULO 4 - Deteção de falhas através da análise espectral** ..... 39
**4.1 – Base de Dados** ..... 39
**4.1.1 – Estatística Descritivas** ..... 40
**4.1.2 – Tendências Temporais dos principais indicadores** ..... 41
**4.2 – Deteção de Falhas** ..... 43
**4.2.1 – Falha nas correias** ..... 43
**4.2.2 – Falha Mecânica** ..... 44
**4.3 – Conclusão do capítulo** ..... 45
**CAPÍTULO 5 - Classificação e previsão de falhas** ..... 46
**5.1 – Classificação e identificação de falhas** ..... 46
**5.1.1 – Introdução de várias frequências de falha** ..... 48
**5.2 – Base de dados para a predição da falha nas correias** ..... 50
**5.2.1 – Estatística Descritivas** ..... 51
**5.2.2 – Tendência Temporal** ..... 52
**5.3 – Modelos de Previsão** ..... 52
**5.3.1 – Modelo ARIMA** ..... 53
**5.3.2 – Modelos LSTM** ..... 57
**5.3.3 – Métricas de avaliação** ..... 62
**CAPÍTULO 6 - Análise de Resultados** ..... 64
**6.1 – Série temporal** ..... 64
**6.2 – Modelo ARIMA** ..... 66
**6.3 – Modelos LSTM** ..... 69
**6.4 – Estimação da tendência da falha para o futuro** ..... 77
**CAPÍTULO 7 – Contribuições** ..... 79
**CAPÍTULO 8 - Conclusão** ..... 80
**CAPÍTULO 9 - Bibliografia** ..... 81
**ANEXOS** ..... 85

**Anexo A – Teste de otimização das LSTM com diferentes optimizadores** ..... 85
**Anexo B – Analise Espectral de todo o dataset ao longo do tempo**..... 89

# LISTA DE FIGURAS

Figura 1 - Fluxograma dos tipos de motores ..... 2
Figura 2 - motor DC ..... 3
Figura 3- Circuito Separately Excited ..... 3
Figura 4 - Circuito Shunt ..... 4
Figura 5 - Circuito Series ..... 4
Figura 6 - Circuito Coumpound ..... 5
Figura 7 - Motor AC ..... 5
Figura 8 - Principais falhas em motores de indução ..... 9
Figura 9 – Esquema de funcionamento dos principais tipos de Bombas ..... 10
Figura 10 - Principais tipos de bombas ..... 11
Figura 11 - Esquema de uma Bomba centrífuga. ..... 12
Figura 12 - Diferentes formatos do impulsor ..... 13
Figura 13 - Diferente forma das pás do impulsor ..... 13
Figura 14 - Principais tipos de Compressores ..... 15
Figura 15 - Principais componentes de um compressor centrífugo ..... 16
Figura 16 - Caracterização de Compressor Recíproco ..... 17
Figura 17 - Principais componentes do compressor recíproco ..... 18
Figura 18 - Esquema dos principais tipos de ventiladores ..... 19
Figura 19 - Principais componentes de um ventilador centrífugo ..... 20
Figura 20 - Impacto da velocidade na redução de tamanho ..... 22
Figura 21 - Principais componentes do moinho de bolas horizontal ..... 23
Figura 22 - Principais componentes do moinho vertical de rolos ..... 24
Figura 23 - Vetor de Park ..... 29
Figura 24 - Padrão de falha de barras quebradas ..... 32
Figura 25 - Pdrão de falha excentricidade estática ..... 33
Figura 26 - Padrão de falha excentricidade dinâmica ..... 33
Figura 27 - Padrão de falha rolamentos ..... 34
Figura 28 - Padrão de falha polias ..... 35
Figura 29 - Padrão de falha correias ..... 36
Figura 30 - Padrão de falha engrenagens ..... 37
Figura 31 - Padrão de falha bomba centrífuga ..... 37
Figura 32 - Padrão de falha ventiladores ..... 38
Figura 33 - Figura 5 - Dados estatísticos relativos a cada semana das diferentes variáveis de diagnóstico: (a) SFsup; (b) SFsta; (c) SFrot; (d) SFmec; (e) SFlvar; (f) LF. ..... 42
Figura 34 - Análise Espectral antes da paragem ..... 43
Figura 35 - Análise Espectral depois da paragem ..... 43
Figura 36 - Análise Espectral depois ..... 44
Figura 37 - Análise Espectral antes ..... 44
Figura 38 - Raw file ..... 46
Figura 39 - Espectro com os principais picos de falha ..... 47
Figura 40 - Identificação de uma falha no espectro ..... 47
Figura 41 - Identificação de múltiplas falhas no espectro ..... 48
Figura 42 - Comparação de espectros ..... 49
Figura 43 - Mensagem recebida pelo utilizador ..... 49
Figura 44 -Valor da amplitude ao longo do tempo ..... 52
Figura 45 - Estrutura de uma rede neuronal recorrente ..... 57

Figura 46 - Estrutura de uma rede neuronal LSTM ..... 58
Figura 47 - Transporte de informação - LSTM..... 58
Figura 48 - Primeira gate do neurónio - LSTM ..... 59
Figura 49 - Segunda gate do neurónio - LSTM ..... 59
Figura 50 - última etapa do neurónio - LSTM..... 60
Figura 51 - Curva Sigmoid..... 60
Figura 52 - Curva Tanh ..... 61
Figura 53 - Curva ReLU ..... 61
Figura 54 - Comparação entre o Fator de severidade da variação da carga e a falha nas correias..... 64
Figura 55 - Componente 0.8 Hz antes (a) e depois (b) da correção do problema no ativo ..... 65
Figura 56 - Principais zonas identificadas no fator de severidade das correias..... 65
Figura 57 - Excentricidade mecânica..... 66
Figura 58 - Alisamento do fator de severidade das correias..... 66
Figura 59 – Autocorrelação (a) e Autocorrelação Parcial (b) ..... 67
Figura 60 - Previsão modelo ARIMA..... 68
Figura 61 - Previsão modelo ReLU ..... 69
Figura 62 - Previsão modelo ReLU ao detalhe ..... 69
Figura 63 - Curva de Aprendizagem modelo ReLU..... 70
Figura 64 - Previsão modelo sigmoid ..... 70
Figura 65 - Previsão modelo sigmoid ao detalhe ..... 70
Figura 66 - curva de aprendizagem sigmoid ..... 71
Figura 67 - Previsão modelo Tanh..... 71
Figura 68 - Previsão modelo Tanh ao detalhe..... 72
Figura 69 - Curva de aprendizagem Tanh..... 72
Figura 70 - Previsão com todas os modelos..... 73
Figura 71 - Previsão com todas os modelos..... 73
Figura 72 - Previsão com novos dados..... 75
Figura 73 - Previsão com novos dados ao detalhe ..... 75
Figura 74 -Previsão da falha da correia para o futuro..... 78
Figura 75 - Visualização 3D de todo o espectro - perspetiva 1 ..... 89
Figura 76 - Visualização 3D de todo o espectro - perspetiva 2 ..... 89

# LISTA DE TABELAS

Tabela 1 - Resumo dos principais modelos de deteção de falhas ..... 26
Tabela 2 - Resumo dos principais padrões de falhas ..... 30
Tabela 3 - Base de dados ..... 39
Tabela 4 - Estatísticas Descritivas ..... 41
Tabela 5 - Base de dados ..... 50
Tabela 6 - Nova base de dados com as frequências necessárias ..... 51
Tabela 7 - Estatísticas Descritivas ..... 52
Tabela 8 - Comparação modelos de previsão ..... 53
Tabela 9 - Comparação entre os modelos de previsão ..... 74
Tabela 10 - Comparação do período de deteção da falha ..... 76
Tabela 11 - Teste com os diferentes optimizadores com 80% de dados de teste ..... 85
Tabela 12 - Teste com os diferentes optimizadores com 80% de dados de teste ..... 85
Tabela 13 - Teste com os diferentes optimizadores com 80% de dados de teste ..... 85
Tabela 14 - Teste com os diferentes optimizadores com 85% de dados de teste ..... 86
Tabela 15 - Teste com os diferentes optimizadores com 85% de dados de teste ..... 86
Tabela 16 - Teste com os diferentes optimizadores com 85% de dados de teste ..... 86
Tabela 17 - Teste com os diferentes optimizadores com 75% de dados de teste ..... 87
Tabela 18 - Teste com os diferentes optimizadores com 75% de dados de teste ..... 87
Tabela 19 - Teste com os diferentes optimizadores com 75% de dados de teste ..... 87
Tabela 20 - Teste com diferentes optimizadores com 80% de dados de teste após retirar a excentricidade mecânica ..... 87
Tabela 21 - Teste com diferentes optimizadores com 80% de dados de teste após retirar a excentricidade mecânica ..... 88
Tabela 22 - Teste com diferentes optimizadores com 80% de dados de teste após retirar a excentricidade mecânica ..... 88

# SIMBOLOGIA E ACRÓNIMOS

| | |
|---|---|
| *DC* | *Corrente Continua* |
| *AC* | *Corrente Alternada* |
| *FFT* | *Fast Fourier Transform* |
| *MCSA* | *Motor Current Signature Analysis* |
| *ANN* | *Artificial Neuronal Network* |
| *IA* | *Inteligência Artificial* |
| *V* | *Tensão média* |
| *I* | *Corrente média* |
| *SFsup* | *Indicador da alimentação* |
| *SFsta* | *Indicador do estator* |
| *SFrot* | *Indicador do rotor* |
| *SFmec* | *Indicador mecânico* |
| *SFlvar* | *Indicador da variação de carga* |
| *LF* | *indicador da carga* |
| *ML* | *Machine Learning* |
| *ARIMA* | *Auto Regressive Integrated Moving Average* |
| *LSTM* | *Long short-term memory network* |
| *ACF* | *Auto Correlation Function* |
| *PACF* | *Partial Auto Correlation Function* |
| *BP* | *Box-Pierce* |
| *LB* | *Ljung-Box* |
| *AIC* | *Akaike information criterion* |
| *BIC* | *Bayesian information criterion* |
| *HQC* | *Hannan–Quinn information criterion* |
| *RNN* | *Recurrent neuroonal network* |
| *MAPE* | *Mean Absolute Percentage Error* |
| *RMSE* | *Root Mean Square Error* |

# CAPÍTULO 1 - Introdução

Nos últimos anos, a manutenção preditiva tem ganho destaque como uma abordagem fundamental para a gestão eficiente de sistemas elétricos industriais. A capacidade de antecipar falhas em ativos críticos, como motores elétricos, permite reduzir custos operacionais, minimizar tempos de inatividade e otimizar processos produtivos. Neste contexto, a análise espectral emerge como uma ferramenta poderosa, capaz de detetar anomalias e mudanças nas características de funcionamento dos motores.

A complexidade dos sistemas elétricos industriais, aliada à diversidade de condições operacionais e tipos de falhas, impõem desafios significativos à implementação eficaz da manutenção preditiva baseada em análise espectral. Assim, este trabalho propõe-se a explorar e a investigar diferentes aspetos deste domínio, visando contribuir para o avanço do conhecimento e práticas nesta área.

A presente tese está estruturada em várias seções que abordam diferentes perspetivas e desafios associados à monitorização e manutenção preditiva em motores elétricos. Inicialmente com uma revisão detalhada da literatura, onde são explorados os fundamentos teóricos e as metodologias existentes no campo da análise espectral e da manutenção preditiva.

Em seguida, é apresentada uma análise aprofundada das principais técnicas de deteção e diagnóstico de falhas em motores elétricos, com ênfase na aplicação de algoritmos de *machine learning* e análise de dados. Ao longo deste trabalho é investigado o impacto de diferentes fatores, como a seleção de características, o pré-processamento de dados e a escolha de optimizadores, na precisão e na robustez dos modelos desenvolvidos.

Além disso, foram ainda realizados testes práticos para avaliar o desempenho e a eficácia das metodologias propostas. Estes permitem validar a viabilidade e a aplicabilidade das abordagens propostas, bem como identificar desafios e oportunidades para futuras pesquisas.

Por fim, são discutidas as conclusões obtidas deste trabalho, destacando contribuições significativas, limitações e direções para investigações futuras. Através desta análise, é esperado fornecer *insights* valiosos para profissionais, pesquisadores e todos os interessados em manutenção preditiva, análise de sistemas elétricos e aplicações de *machine learning* em contextos industriais

# CAPÍTULO 2 - Introdução aos motores elétricos

As máquinas elétricas capazes de promover a conversão da energia elétrica em energia mecânica, através da interação dos campos magnéticos presentes no processo, são denominadas de motores elétricos. Estes equipamentos estão presentes em diversas aplicações, não só no setor industrial, como também no nosso quotidiano como por exemplo: no uso de projetos complexos, como satélites bem como também em aplicações mais simples, como o funcionamento de uma simples máquina de lavar.

Os motores elétricos são comumente classificados de acordo com os tipos de fornecimento de energia elétrica nos seus terminais, tipo de enrolamento do rotor, padrão de controlo, orientação do fluxo magnético, métodos de arrefecimento e razão de potência.

A figura 1 mostra uma breve classificação dos motores elétricos.

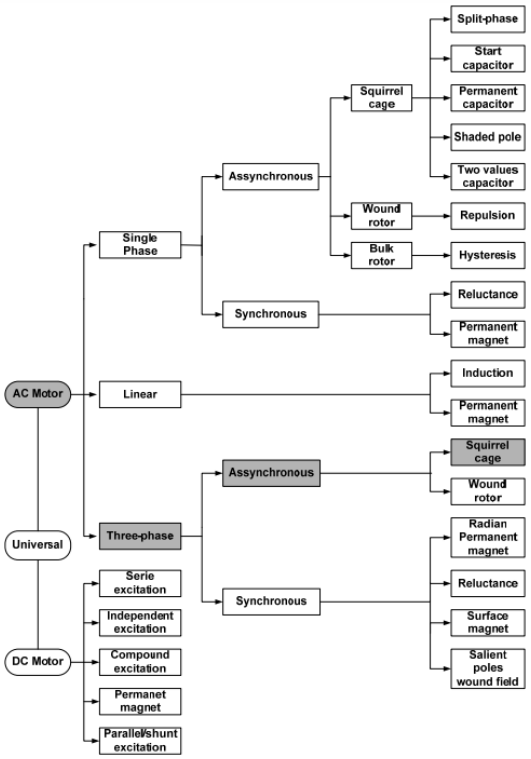


*Figura 1 - Fluxograma dos tipos de motores* [1]

## 2.1 – Motores DC

Os motores elétricos de corrente contínua (DC) desempenham um papel fundamental na conversão de energia elétrica em energia mecânica. O princípio básico de operação de um motor DC reside na interação entre um condutor percorrido com corrente e um campo magnético, resultando na criação de uma força que dá origem ao movimento mecânico [2]. Esta capacidade de transformar energia elétrica em trabalho mecânico torna os motores DC dispositivos essenciais em diversas aplicações.

Os motores DC são notáveis pela sua diversidade, uma vez que podem ser classificados com base nas ligações do enrolamento [2]. Esta classificação abrange os tipos de motores DC mais comuns, incluindo os motores *Separately Excited*, *Shunt*, *Series* e *Compound*. Cada tipo tem características distintas que os tornam adequados para aplicações específicas, desde velocidades controladas e elevado torque até aplicações que requerem velocidades variáveis.

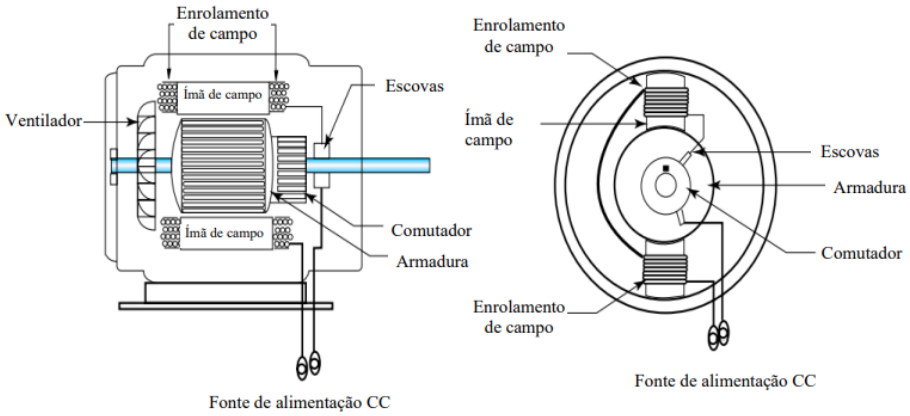


*Figura 2 - motor DC* [3]

### 2.1.1 – *Separately Excited*

De acordo com Chapman [1] no seu livro *Electric Machinery Fundamentals*, os motores DC excitados separadamente são caracterizados pela separação das fontes de alimentação para o campo e para a armadura. Esta configuração permite um controlo mais preciso do motor, uma vez que a excitação do campo pode ser ajustada independentemente da tensão ou corrente aplicada à armadura. Isto é particularmente útil em aplicações que requerem um controlo fino da velocidade e do torque.

Como observado por Chaston [4], a independência das fontes de alimentação do campo e da armadura também proporcionam uma maior flexibilidade na operação destes motores. É possível adaptar as características de desempenho do motor excitado separadamente para atender a requisitos específicos de aplicação, tornando-o adequado para uma ampla variedade de tarefas industriais e comerciais.

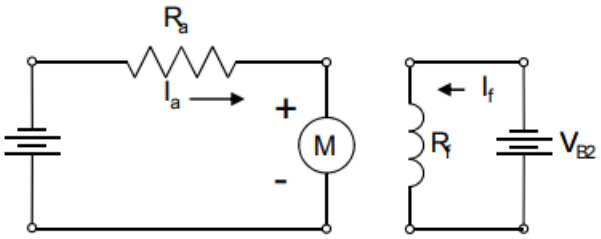


*Figura 3- Circuito Separately Excited* [5]

**2.1.2 – *Shunt***

Este motor apresenta características naturais de regulação de velocidade. A velocidade do motor é essencialmente controlada pela produção de uma força eletromotriz inversa, (*back EMF*). Quando uma carga é aplicada ao motor, este começa a desacelerar. Com menos *back EMF* sendo criada, permite que o motor puxe mais corrente para a armadura, o que produz mais torque, acelerando novamente o motor até sua velocidade original. Em resumo, as características do motor DC tornam-no num motor de velocidade constante, mesmo em condições de ausência de carga [5].

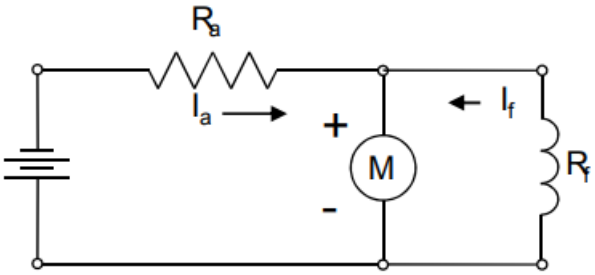


*Figura 4 - Circuito Shunt* [5]

**2.1.3 – *Series***

O motor *series* possui um maior torque de arranque do que o motor Shunt. Isto deve-se ao facto de que, durante o arranque, a corrente que flui para a armadura passar também pelo campo. Assim à medida que esta o percorre, o fluxo magnético aumenta, conferindo ao motor um maior torque de arranque. A desvantagem, é que os enrolamentos do campo devem ser capazes de lidar com a mesma corrente que a armadura, bem como, devido ao fio mais grosso este normalmente é mais pesado e menos maleável, tornando-o difícil de dobrar em laços ou curvas. Significando assim, que o enrolamento do campo num motor série terá poucas voltas de fio grosso, ao contrário do motor Shunt, que possui muitas voltas de fio fino [5].

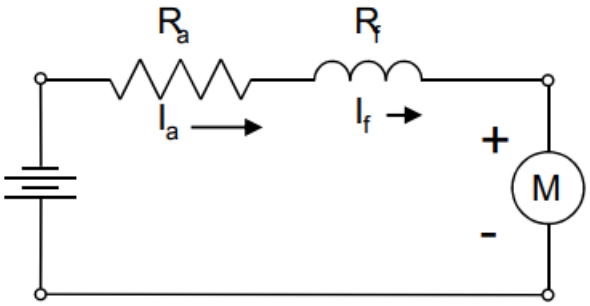


*Figura 5 - Circuito Series* [5]

**2.1.4 – *Compound***

Os motores *compound* podem ser ligados de maneira acumulativa ou diferencial. Numa configuração acumulativa, a corrente flui para os enrolamentos em *Shunt* e em *series* para

produzir uma maior força magnomotriz positiva. Numa configuração diferencial, as forças em *shunt* e em *series* subtraem-se uma da outra. O *design* do motor composto acumulativo permite que ele tenha um efeito híbrido dos motores em série e em *shunt*, ou seja, este tem um melhor torque de partida do que o motor em *shunt*, mas menos torque de partida do que um motor em *series*. Além disso, devido às características em *shunt*, este motor não vai superaquecer enquanto estiver a funcionar sem carga, [1].

O motor composto diferencial é teoricamente possível, mas é praticamente inútil. A configuração do circuito torna quase impossível iniciar um motor desse tipo [1].

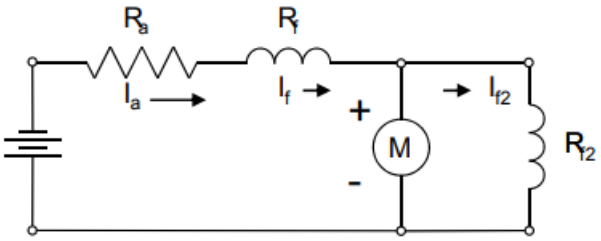


*Figura 6 - Circuito Coumpound* [5]

## 2.2 – Motores AC

Os motores AC referem-se a máquinas elétricas que convertem energia elétrica AC em energia mecânica. Assim sendo existe uma grande variedade de máquinas que diferem nos princípios de funcionamento, características físicas e nível de potência.

Assim, em relação aos motores AC, existem duas categoriais amplamente utilizadas, as quais podem ser pertencentes: os motores síncronos e os motores de indução.

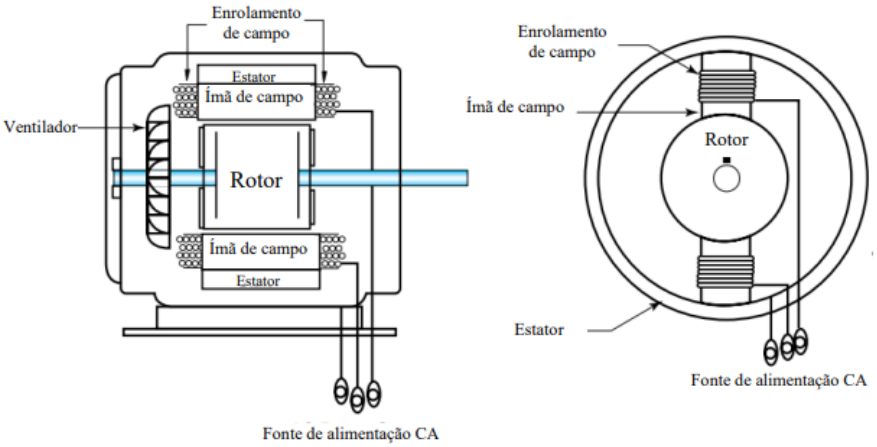


*Figura 7 - Motor AC* [3]

#### 2.2.1 – Motores de indução

Sendo responsável por desempenhar um papel fundamental no setor industrial, o motor de indução apresenta como suas principais características a sua robustez, a alta confiabilidade e a sua simplicidade construtiva.

Os motores de indução operam com uma corrente alternada fornecida ao estator e a corrente no rotor é formada por indução. Os motores de indução tipicamente utilizam energia de três fases, com bobinas deslocadas 120 graus, [6] [7].

Devido à corrente no rotor ser induzida, não é necessário o uso de escovas num motor de indução. A ausência de escovas permite que o motor tenha capacidades de alta velocidade e uma vida útil muito superior em comparação com motores com escovas. Além disso, a ausência de escovas permite que o motor opere em ambientes perigosos, pois não há produção de faíscas devido ao atrito das escovas nos espaços do comutador [6].

Para que a indução funcione corretamente, a velocidade do rotor deve ser ligeiramente mais lenta do que a velocidade do campo magnético rotativo no estator. Devido a essa diferença de velocidade, o motor é frequentemente referido como assíncrono. A diferença de velocidade entre o rotor e o campo magnético rotativo do estator é denominada deslizamento, [6], [7]. Quanto maior a carga aplicada, maior será o deslizamento gerado, o que faz com que o rotor consuma mais corrente. A corrente mais elevada produzirá mais torque, o que levará o rotor de volta à velocidade adequada.

Por fim, existem dois tipos principais:

- Motor assíncrono tipo gaiola de esquilo
- Motor assíncrono com rotor bobinado.

##### *2.2.1.1 – Motores com rotor bobinado*

Nas máquinas de rotor bobinado, tanto os enrolamentos do estator quanto os do rotor são compostos por bobinas individualmente isoladas. As bobinas do rotor são acessíveis no lado do estator através de anéis deslizantes.

O rotor bobinado, é constituído por enrolamentos de fio de cobre isolados, semelhantes aos do estator. Os terminais são ligados a anéis colectores e escovas, sendo acessíveis do exterior. Os motores de rotor bobinado são mais caros, necessitam de maior manutenção e são menos robustos. Todavia, permitem controlar as correntes do rotor e as características de binário e de velocidade da máquina. Através dos anéis e escovas, podem-se ligar resistências variáveis externas de forma a regularem a corrente no rotor, principalmente na fase de arranque do motor. Em funcionamento normal as resistências são curto-circuitadas e a máquina funciona com o rotor em curto-circuito [8].

##### *2.2.1.1 – Motores com gaiolas de esquilo*

Nas máquinas de gaiola de esquilo, os enrolamentos do rotor são substituídos por barras longitudinais colocadas em ranhuras sob a superfície externa do rotor. As barras do rotor são

conectadas por condutores circulares nas extremidades. Em termos de funcionamento, um motor de gaiola de esquilo é semelhante a um motor de rotor bobinado com enrolamentos curto-circuitados.

O rotor em curto-circuito (ou rotor em gaiola de esquilo) é formado por barras de alumínio unidas por anéis em ambas as extremidades. Este enrolamento forma uma espécie de gaiola de esquilo que não é acessível do exterior. Os anéis nas extremidades garantem a rigidez mecânica do conjunto e possuem normalmente aletas para ventilação forçada. A forma das barras de alumínio influencia as características de binário [8].

#### 2.2.2 – Motores Síncronos

No motor síncrono, como por exemplo do tipo *Wound*, uma corrente alternada é fornecida ao estator e uma corrente contínua é fornecida ao rotor. A corrente contínua no rotor cria um campo magnético que permanece constante. A corrente alternada no estator cria um campo magnético rotativo que está sempre alinhado com o rotor. É por isso que o motor é chamado síncrono. Motores síncronos não são muito comuns na indústria, principalmente porque requerem alimentação de corrente alternada e corrente contínua. O uso mais comum de máquinas síncronas *wound* é na geração de energia. Quando usado para geração de energia, o motor síncrono é conhecido como alternador [5].

### 2.3 – Principais tipos de falhas no motores DC

Os motores de corrente contínua (DC) são componentes essenciais numa ampla gama de aplicações, devido à sua versatilidade e capacidade de controlo preciso. No entanto, como qualquer equipamento, os motores DC estão sujeitos a uma variedade de falhas que podem afetar seu desempenho e confiabilidade.

Uma das falhas críticas que McKinnon [9] abordou é o "Curto-circuito entre Voltas" (*Turn-to-turn Short*). Esta falha ocorre devido à acumulação de poeira de carbono nos comutadores, resultando num curto-circuito entre as barras do comutador. A deteção dessa falha é facilitada por meio da Análise de Assinatura de Corrente, que permite identificar modulações na frequência de 120 Hz, um indicativo claro de um curto-circuito entre voltas.

Outra falha relevante é o "Curto-circuito de Grupo de Bobinas" (*Coil Group Short*) [9]. Nessa situação, ocorre um curto-circuito que afeta todo um grupo de bobinas.

A posição das escovas (*Brush Position*) é um aspeto crítico da operação dos motores DC [9]. A deteção de falhas relacionadas com esta área pode ser difícil, especialmente quando o motor não está acessível durante a operação. No entanto, a análise da forma de onda da tensão pode ajudar na configuração adequada das escovas, identificando a presença de ruído quando as escovas estão fora do eixo neutro magnético.

A Corrente Diferencial (*Differential Current*) é uma ferramenta valiosa para a deteção de falhas, especialmente em situações em que dois ou mais cabos alimentam um terminal único ou quando

ocorre corrente de *bypass* devido a comutação de alta frequência [9]. A análise numérica desempenha um papel crucial na deteção de variações significativas na corrente.

## 2.4 – Principais tipos de falhas nos motores AC Indução

### 2.4.1 – Falhas no estator

As falhas no estator estão geralmente relacionadas a falhas no isolamento. Vários estudos demonstraram que grande parte das falhas em motores de indução ocorrem devido a quebras nas bobinas do estator [10][11].

O enrolamento do estator consiste em bobinas de fio de cobre isolado colocado nas ranhuras do estator e as falhas no enrolamento do estator geralmente começam devido a uma falha no isolamento entre duas voltas adjacentes na mesma bobina para a mesma fase, essa falha é geralmente chamada de falha entre voltas ou curto-circuito entre voltas. Assim, esse tipo de falha produzirá um calor adicional e um desequilíbrio no campo magnético da máquina. O calor local adicional entre duas ou mais voltas causará danos adicionais no isolamento das voltas vizinhas até ocorrer uma falha, como falhas de fase, falhas de fase para fase, falhas de fase para terra ou falhas de fase para fase para terra [10]. No entanto, as falhas no estator podem ser amplamente classificadas nas seguintes duas categorias:

- Defeitos nas lâminas
- Falhas nas bobinas do estator

Na verdade, a maioria desses defeitos ocorre devido a uma combinação de várias tensões que atuam sobre o estator, que podem ser classificadas segundo fatores térmicos, elétricos, mecânicos e ambientais. Curto-circuitos entre voltas nas bobinas do estator constituem uma das categorias de falhas mais comuns nos motores de indução. Tipicamente, os curtos-circuitos nas bobinas do estator ocorrem entre as voltas de uma fase, entre as voltas de duas fases ou entre as voltas de todas as fases. Além disso, ocorrem curtos-circuitos entre os condutores das bobinas e o núcleo do estator [6].

### 2.4.2 – Falhas no rotor

As falhas no rotor representam cerca de 5-10% do total de falhas nos motores de indução [12]. As razões para a quebra das barras do rotor são diversas e são principalmente causadas por:

- Tensões térmicas devido a sobrecarga térmica e desequilíbrio, pontos quentes ou perdas excessivas ou faíscas.
- Tensões magnéticas causadas por forças eletromagnéticas, atração magnética desequilibrada, ruído e vibração eletromagnética
- Tensões residuais devido a problemas de fabricação
- Tensões dinâmicas decorrentes de torques no eixo, forças centrífugas e tensões cíclicas.
- Tensões ambientais, causadas por exemplo, pela contaminação e abrasão do material do rotor devido a produtos químicos ou umidade
- Tensões mecânicas devido a lâminas soltas, peças fatigadas ou falha nos rolamentos

Uma vez que a maior parte dos motores de indução são do tipo gaiola de esquilo, é necessário prestar atenção especial às falhas nas barras do rotor. Na verdade, a quebra ou fissura das barras do rotor no ponto em que se unem ao anel final é o mecanismo normal de falha no rotor do tipo gaiola. Por outro lado, as falhas levam à flutuação de velocidade, pulsação de torque, alterações no componente de frequência na corrente de alimentação do motor, aumento da temperatura, arco no rotor e vibração da máquina. Estes efeitos colaterais podem ser utilizados na deteção e classificação desse tipo de falha. No entanto, as falhas no rotor do motor de indução geralmente começam com uma pequena fratura ou um ponto de alta resistividade na barra do rotor.

As falhas na gaiola do rotor podem levar à vibração do eixo e consequentemente, a falhas nos rolamentos e excentricidade da folga de ar, enquanto a quebra de uma barra leva a uma corrente elevada nas barras adjacentes, o que pode levar a possíveis falhas adicionais, bem como falhas no estator [13].

Portanto, a deteção precoce da assimetria do rotor é essencial não apenas para a proteção do rotor, mas também para reduzir outros tipos de falhas no motor [14].

#### 2.4.3 – Falha nos rolamentos

Como apresentado na Figura 8, cerca de 40% das falhas em máquinas de indução são causadas por defeitos nos rolamentos.

Em geral, os rolamentos são compostos por um anel interno e um anel externo, enquanto um conjunto de elementos rolantes está localizado entre eles. As formas padrão de elementos rolantes incluem esferas, rolos cilíndricos, rolos cônicos e rolos de agulha. Normalmente, os elementos rolantes num rolamento são dispostos ou guiados numa gaiola, de modo a garantir a distância uniforme entre os elementos para evitar o contato mútuo [15].

Os diferentes defeitos que ocorrem nos elementos rolantes podem ser classificados de acordo com o elemento danificado, como defeito na bola, defeito na pista interna e defeito na pista externa. Os elementos rolantes são um dos componentes mais críticos nos motores de indução, porque a grande maioria dos problemas decorre de falhas nos rolamentos. Portanto, tanto a deteção quanto o diagnóstico de falhas mecânicas nos rolamentos são muito importantes para a boa operação de um motor de indução [16]

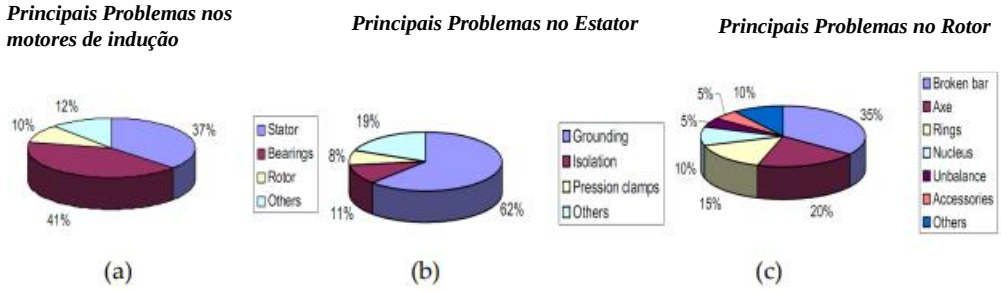


*Figura 8 - Principais falhas em motores de indução* [17]

## 2.5 – Principais Aplicações industriais e a sua caracterização

### 2.5.1 – Bombas

As Bombas são máquinas cuja a sua finalidade é realizar o deslocamento de um líquido por escoamento. Assim, esta transforma o trabalho mecânico que recebe de uma fonte externa, para o seu funcionamento, em energia que é transmitida para líquido sob as forma de energia de pressão e cinética [18].

De forma geral, a transformação do trabalho em energia e o recurso para cede-la ao líquido aumentando a pressão e a velocidade [19] permitem classificar as bombas em dois grandes grupos:

- Bombas de deslocamento positivo
- Bombas centrífugas

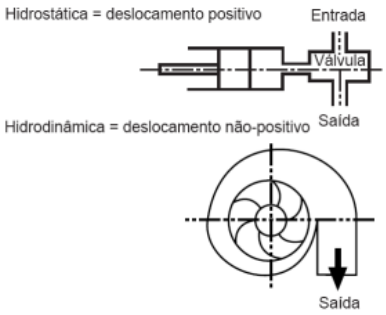


*Figura 9 – Esquema de funcionamento dos principais tipos de Bombas* [19]

#### 2.5.1.1 – Bombas de deslocamento positivo

As bombas de deslocamento positivo são utilizadas nos casos onde é necessária uma saída constante de fluido, independente de variação da carga sobre a bomba. A descarga é proporcional à velocidade do propulsor da bomba.

#### 2.5.1.2 – Bombas Centrifugas

Estas bombas são caracterizadas por possuírem um órgão rotatório dotado de pás, chamado rotor, que exerce uma força sobre o líquido que resulta da aceleração que este lhe imprime. Esta aceleração, ao contrário do que se verifica nas bombas de deslocamento positivo, não possui a mesma direção nem o mesmo sentido do movimento do líquido em contato com as pás [19].

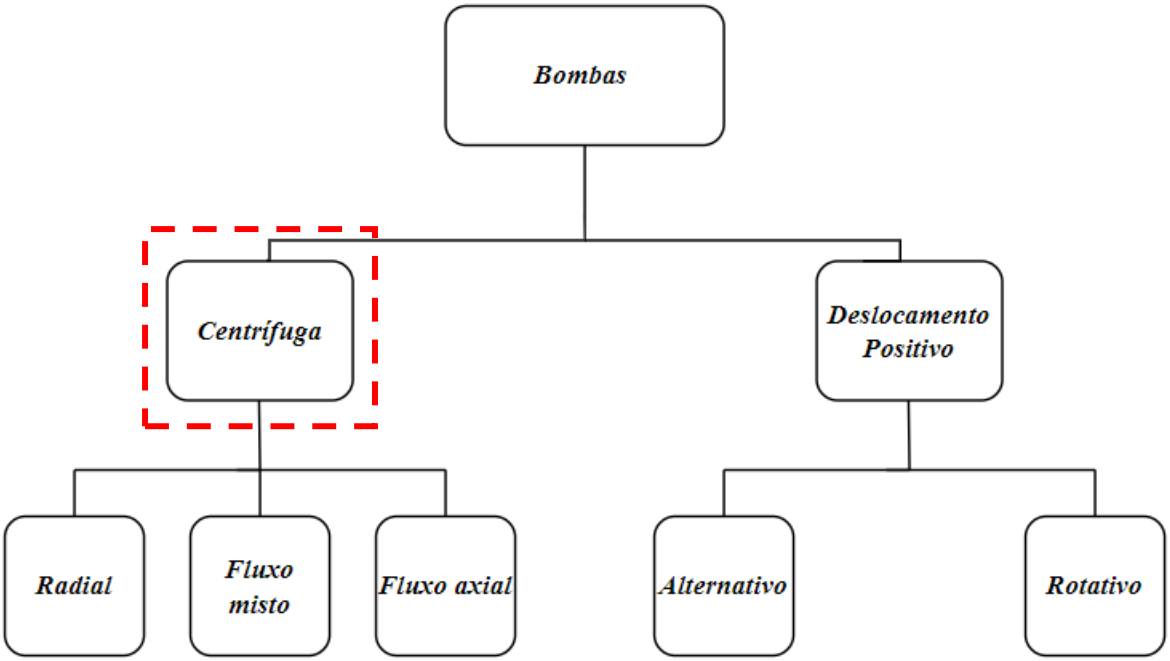


*Figura 10 - Principais tipos de bombas*

### 2.5.2 – Bomba Centrífugas

#### 2.5.2.1 – Princípio de operação

A Bomba Centrífuga tem como base de funcionamento a criação de duas zonas de pressão diferenciadas, uma de baixa pressão e outra de alta pressão. Para que ocorra a formação destas duas zonas distintas de pressão, é necessário existir no interior da bomba a transformação da energia mecânica, que é fornecida pelo motor primeiramente em energia cinética, o que irá deslocar o fluído, e posteriormente, em maior escala, em energia de pressão, o que irá adicionar "carga" ao fluído para que ele vença as alturas de deslocamento [20].

Assim, a carcaça serve como ponto de entrada axial para o fluido, que é então recolhido nas lâminas do impulsor. O impulsor instalado no eixo do motor principal gira, criando uma elevação de sucção no olho do impulsor. As lâminas do impulsor conferem energia cinética ao fluido, que depois se afasta e é transportado através de uma espiral, onde esta energia é transformada em pressão.

#### 2.5.2.2 – Caracterização de uma bomba centrífuga

Principais componentes da bomba centrífuga:

- Base
- Carcaça
- Acoplamento
- Impulsor
- Eixo
- Anéis de desgaste
- Luva de eixo
- Caixa de vedação ou câmara de selagem, Selo mecânico
- Rolamento e Sistema de Lubrificação e Instrumentos

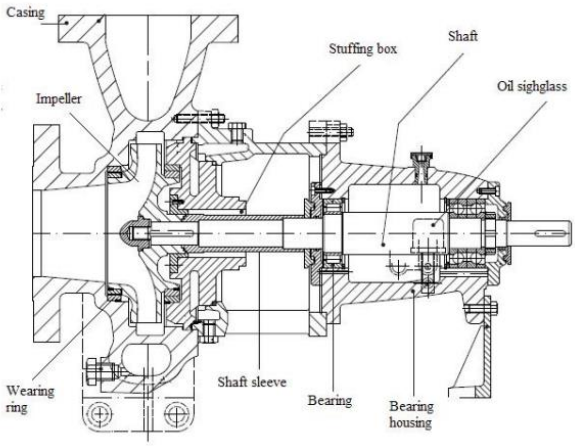


*Figura 11 - Esquema de uma Bomba centrífuga* [21].

### Luva de Eixo

O eixo é o componente girante principal da bomba e está acoplado aos rolamentos de esferas que facilitam a rotação. Este conjunto está ligado a uma luva chamada luva de eixo. Ela é usada para proteger o eixo contra corrosão e escorrimentos, vedando a abertura da luva [21].

### Impulsor

O termo impulsor refere-se a uma roda ou rotor com uma série de palhetas ou lâminas curvadas para trás. Ele está ligado ao eixo de um motor elétrico e é uma parte rotativa da bomba contida num invólucro à prova de água. É através da rotação do impulsor que se confere velocidade a um fluido.

Assim, o impulsor de uma bomba centrífuga pode ser categorizado em três tipos principais:

- **Impulsor Aberto:** As palhetas de um impulsor aberto são fixadas a um cubo central que é montado diretamente no eixo. Como nenhuma cobertura envolve as palhetas, os impulsores abertos são mais fracos que os fechados.
- **Impulsor Fechado:** Este tipo consiste em placas de cobertura traseira e frontal entre as quais as palhetas geralmente são posicionadas. Estes impulsores têm entradas duplas ou simples e são comumente instalados em bombas de fluxo radial.

- **Impulsor Semiaberto:** Uma placa de cobertura na parte traseira dos impulsores semiabertos impulsiona mecanicamente as palhetas, deixando o outro lado aberto. Bombas de tamanho médio utilizam impulsores semiabertos.

*Figura 12 - Diferentes formatos do impulsor* [22]

- **Forma das Pás:** As pás do impulsor podem ter diferentes formas, como curvas para trás (pás radiais), curvas para frente (pás axiais), ou uma combinação dessas (pás mistas).
- **Quantidade de Pás:** O número de pás no impulsor pode variar e é um fator crítico no design da bomba. Um menor número de pás pode resultar num fluxo mais turbulento, enquanto um maior número de pás pode proporcionar uma distribuição mais uniforme do fluxo.
- **Ângulo das Pás**: O ângulo das pás em relação ao plano do impulsor é conhecido como ângulo de inclinação. O ângulo de inclinação afeta o desempenho da bomba. Pás com inclinação para trás (ou curvatura negativa) são comuns para pás radiais, enquanto pás axiais podem ter inclinação para frente.

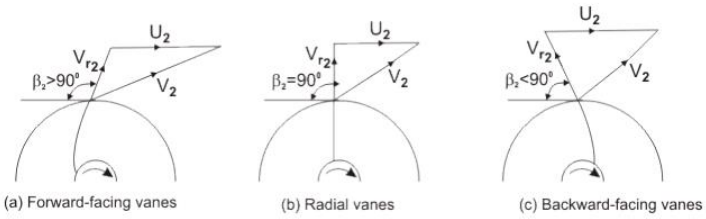


*Figura 13 - Diferente forma das pás do impulsor* [23]

**2.5.2.3 – Principais Falhas**

Uma das categorias predominantes de falhas está relacionada com defeitos mecânicos nos componentes da bomba, incluindo a carcaça, o impulsor, o eixo, os rolamentos e a vedação. Estes defeitos mecânicos podem causar danos físicos nos componentes da bomba e em casos mais graves, afetar significativamente a sua eficiência [22].

O impulsor, frequentemente designado como o coração da bomba centrífuga, é particularmente sensível a defeitos, uma vez que qualquer anomalia afeta diretamente o desempenho global da bomba. A cavitação e reações químicas com o líquido bombeado podem resultar em corrosão, levando à formação de pontos de corrosão no impulsor. Além disso, o desgaste pode ocorrer quando o impulsor não está devidamente ajustado ao eixo [22].

Os rolamentos nas bombas industriais também são suscetíveis a várias falhas. Fatores como o fluxo, a temperatura, a pressão e outros devem ser cuidadosamente considerados ao selecionar

os rolamentos adequados para aplicações específicas. O vazamento excessivo e os problemas nos rolamentos são duas das principais causas de falha nas bombas centrífugas. O superaquecimento dos rolamentos devido à dissipação ineficiente de calor, cargas radiais excessivas causadas por operações com baixo fluxo, desalinhamento da unidade, eixo deformado ou vibrações severas na instalação podem contribuir para essas falhas [22].

Apesar dos avanços nas técnicas de vedação de eixos, problemas com vedações mecânicas ainda persistem como uma das causas mais comuns das falhas nas bombas industriais. A fiabilidade das vedações mecânicas dependem do seu design, da adequação à bomba em questão e da forma como a bomba é utilizada, que nem sempre corresponde à sua aplicação original [22].

Por último, a cavitação é a falha mais comum em bombas centrífugas. Este fenómeno ocorre quando a pressão no interior da bomba atinge a pressão de vapor do fluido bombeado, formando cavidades em regiões de baixa pressão que colapsam quando atingem regiões de pressão mais elevada na bomba.

#### 2.5.3 – Compressores

Na indústria, os compressores desempenham um papel vital na manipulação de gases e no fornecimento de pressão para uma ampla gama de aplicações.

Em primeiro lugar, temos os compressores dinâmicos, dos quais se destacam: o compressor axial e o compressor centrífugo. O compressor axial é amplamente utilizado em aplicações de média e alta potência, enquanto que o compressor centrífugo é preferencialmente utilizado aplicações de menor potência [24].

Outra categoria fundamental inclui os compressores de deslocamento positivo, que desempenham um papel crucial na indústria. Estes compressores são geralmente acionados por correias. Um exemplo notório é o compressor recíproco, também conhecido como compressor de pistão, este tipo de compressor pertence à categoria de deslocamento positivo e utiliza o movimento de um pistão dentro de um cilindro para deslocar o gás de um nível de pressão para outro mais elevado [25].

Por fim, de forma resumida, nos compressores de deslocamento positivo, o aumento de pressão é alcançado através da redução do volume de gás contido no cilindro do compressor, por meio de uma ação mecânica. Por outro lado, nos compressores dinâmicos, a pressão é aumentada através do aumento da velocidade do gás, utilizando um elemento rotativo, que converte assim a energia transmitida ao gás em pressão.

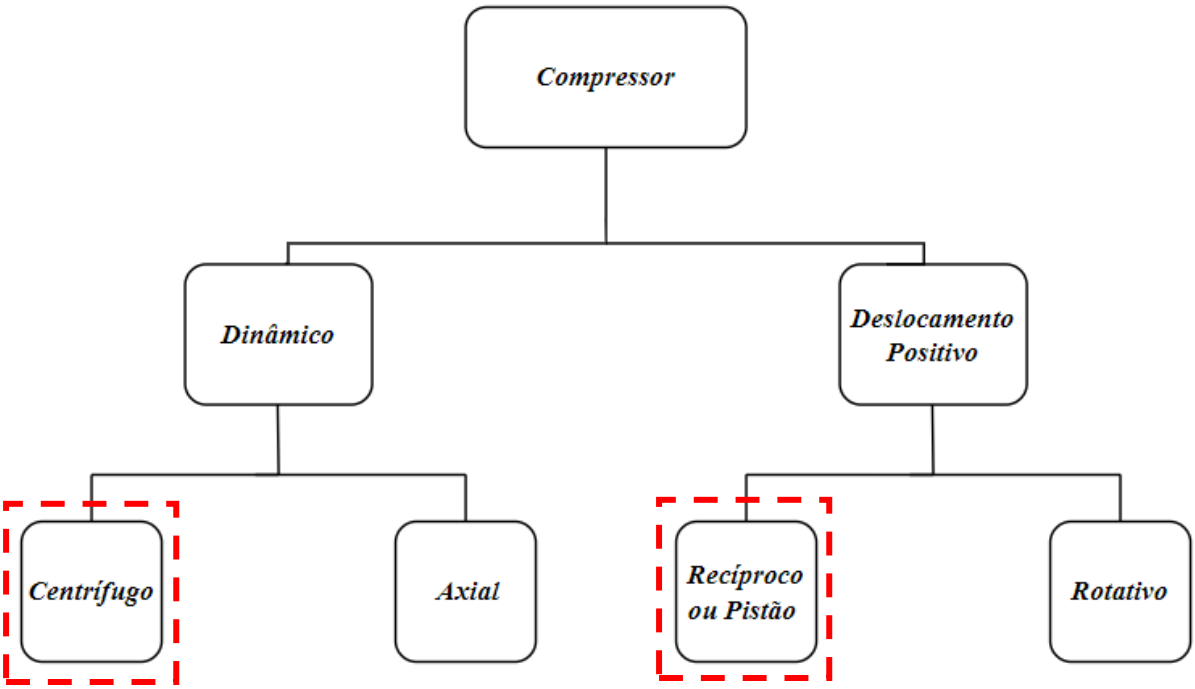


*Figura 14 - Principais tipos de Compressores* [24][25]

### 2.5.4 – Compressor Centrífugo

#### 2.5.4.1 – Princípio de operação

Num compressor centrífugo o impulsor aspira o fluido compressível de baixa pressão (vapor refrigerante) do evaporador. Uma vez que o impulsor gira, o vapor refrigerante é empurrado do centro para a borda externa do impulsor por meio da força centrífuga. A alta velocidade de rotação do impulsor mantém o fluido em alta velocidade nas pontas das palhetas. Quando o fluido de alta velocidade passa por um difusor, a energia cinética do fluido é convertida em entalpia (aumento de pressão). Em seguida, a carcaça recolhe o fluido do difusor e converte a energia cinética restante do fluido em energia de pressão antes de sair do compressor [26].

#### *2.5.4.2* – Caracterização de um Compressor Centrífugo

Principais componentes de um compressor centrífugo:

- Carcaça
- Acoplamento
- Impulsor
- Eixo
- Anéis de desgaste
- Rolamento

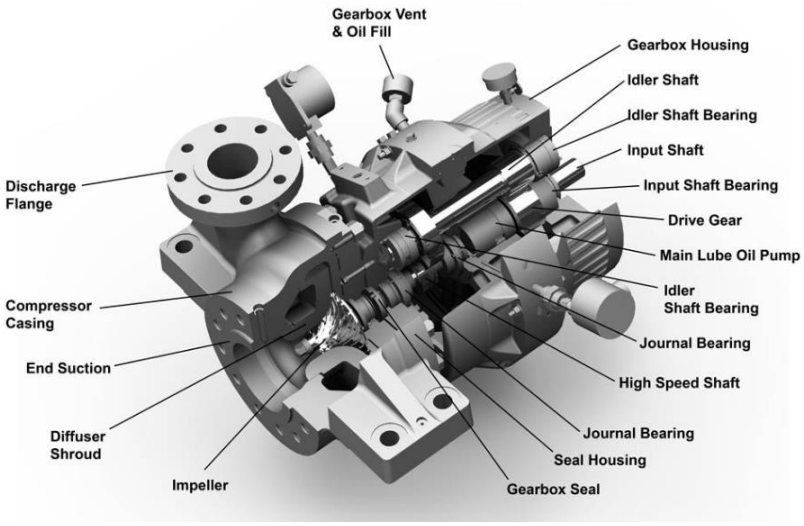


*Figura 15 - Principais componentes de um compressor centrífugo* [26]

***2.5.4.3 – Principais Falhas***

De todas as diversas falhas identificadas, as questões de ordem mecânica são as primeiras a surgir. O desgaste mecânico, pode manifestar-se de maneira preeminente nos rolamentos do compressor. Tais manifestações resultam de cargas operacionais excessivas, deficiências na lubrificação ou mesmo a contaminação por agentes externos. Paralelamente, os selos mecânicos, componentes críticos na preservação da estanqueidade, estão suscetíveis a deterioração, resultando em vazamentos que comprometem a eficiência do compressor [25].

A integridade do impulsor, elemento central na dinâmica do compressor centrífugo, enfrenta diversos desafios associados a desequilíbrios, desgaste progressivo, corrosão e possíveis danos físicos. A presença destas adversidades, se não mitigadas, traduzem-se em vibrações prejudiciais e declínio significativo na eficácia do compressor.

Aspetos de alinhamento, muitas vezes subestimados, entre o motor e o compressor, surgem como ponto crítico na prevenção de tensões inoportunas e consequentemente, na extensão da vida útil dos componentes. Desalinhamentos podem precipitar falhas prematuras, levando a intervenções dispendiosas.

O desafio térmico, nomeadamente associado ao superaquecimento, representa uma ameaça de falha concreta. Condições operacionais inadequadas podem conduzir a um aumento descontrolado da temperatura, resultando em danos irreparáveis nos componentes e por consequência na eficiência global do compressor [25].

### *2.5.5* – Compressor Recíproco

#### *2.5.5.1* – Princípio de funcionamento

A operação normal de um compressor recíproco, resumidamente consiste no movimento descendente do pistão, onde a pressão no cilindro diminui, a válvula de entrada abre e o "ar" entra no cilindro. À medida que o pistão começa a mover-se para cima, ele comprime o "ar" preso acima dele, aumentando a pressão até que o "ar" seja forçado a sair através da válvula de descarga [24].

Assim, o princípio de funcionamento de um compressor pode ser descrito por três processos diferentes: primeiro, um processo eletromagnético em que o torque elétrico é criado e transmitido, o segundo é o movimento dinâmico, que representa os processos mecânicos, incluindo o movimento do pistão e da válvula e finalmente, o fluido que flui para dentro e para fora do cilindro através das válvulas de entrada e saída, criado pelo movimento do pistão [25].

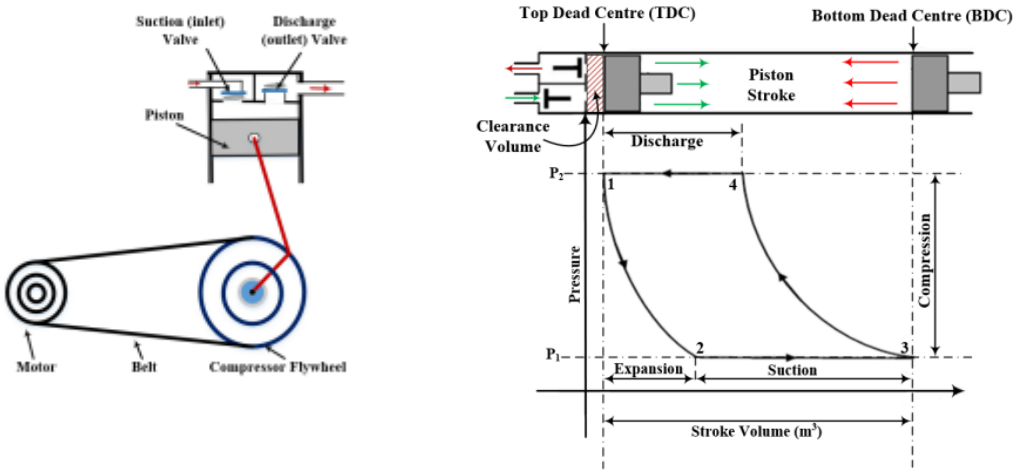


*Figura 16 - Caracterização de Compressor Recíproco* [24]

#### 2.5.5.2 – Principais componentes do compressor recíproco

- *Crankshaft*
- Biela
- Cabeça Cruzada
- Haste do Pistão
- Pistão e anéis
- Anéis de Vedação ou Anéis de Selo
- Válvulas de Retenção
- Espaçadores

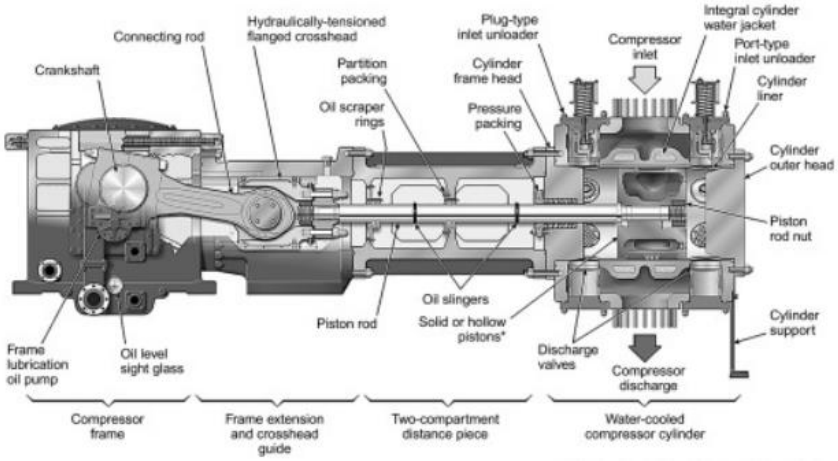


*Figura 17 - Principais componentes do compressor recíproco* [27][28]

**2.5.5.2 – Principais Falhas**

O termo *compressor fouling* [25], refere-se à acumulação de resíduos, partículas sólidas, óleo ou outros contaminantes no interior de um compressor, o que pode afetar adversamente o seu desempenho e eficiência. O acúmulo de contaminantes no compressor pode causar vários problemas, como:

- **Redução da Eficiência:** A acumulação de resíduos nas partes internas do compressor pode diminuir a eficiência do processo de compressão, resultando num maior consumo de energia para atingir a mesma pressão desejada [24].
- **Desgaste Prematuro:** A presença de contaminantes sólidos pode causar desgaste prematuro nas peças móveis do compressor, como pistões, anéis de vedação e válvulas, o que pode levar a reparações frequentes e custos de manutenção mais elevados [25]

O entupimento do compressor recíproco (seja devido a detritos ou líquidos no gás) pode resultar em danos nas válvulas de sucção ou de descarga e na haste do pistão.

Danos nas válvulas manifestam-se com um aumento da temperatura nas coberturas das válvulas. Danos na haste podem ser detetados durante a operação devido ao movimento não linear da haste à medida que passa pela junta na interface entre a cruzeta e o cilindro [24].

O excesso de folga nos rolamentos pode resultar numa instalação inadequada dos rolamentos ou do desgaste do eixo e da sapata do rolamento ao longo do tempo. Em qualquer um dos casos, o efeito da folga nos rolamentos pode ser detetado durante a operação.

### 2.5.6 – Ventiladores

Os ventiladores, desempenham um papel fundamental na movimentação de grandes volumes de ar, seja para proporcionar ventilação em ambientes confinados, refrigerar equipamentos ou otimizar processos industriais específicos.

Os ventiladores são máquinas de fluxo que transmitem a energia mecânica recebida do eixo para o fluido (gás). O seu funcionamento é similar ao das bombas, sendo a principal diferença a de que o fluido que recebe energia é um gás.

As formas de classificação dos ventiladores variam bastante, podem ser classificados de acordo com a forma do rotor, formas das pás, número de rotores, entre outros.

De forma simples os ventiladores classificam-se da seguinte forma:

- **Centrífugos:** A trajetória da partícula é sobre um plano praticamente normal ao eixo. O fluxo de gases é direcionado para uma única saída. O motor é ligado diretamente ao rotor por meio de polias/correias;
- **Hélico-centrífugos**: A trajetória da partícula é na superfície de revolução cônica cuja geratriz é uma linha curva;
- **Axiais:** A trajetória da partícula é paralela ao eixo do rotor. São os mais comuns para uso residencial, ventilação em computadores, entre outros.

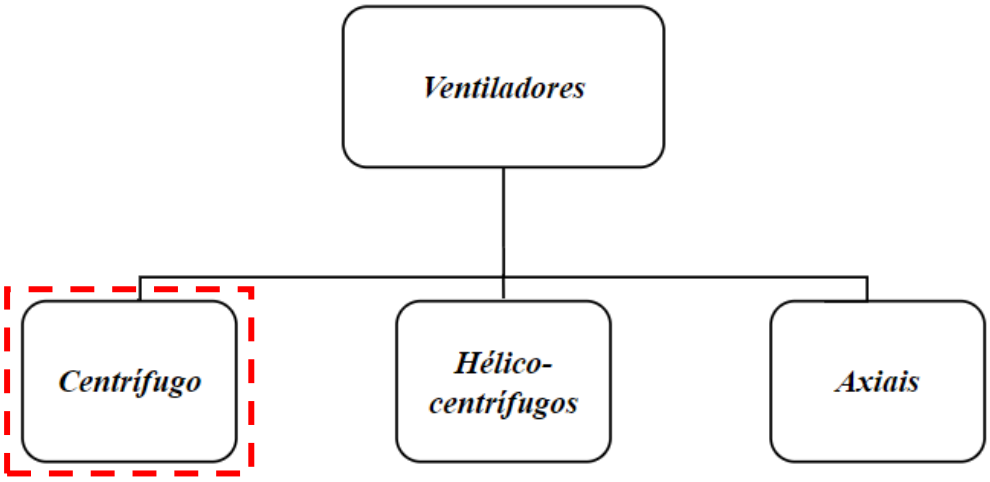


*Figura 18 - Esquema dos principais tipos de ventiladores*

### 2.5.7 – Ventilador Centrífugo

#### 2.5.7.1 – Princípio de operação

O princípio de funcionamento de um ventilador centrífugo baseia-se na criação de pressão por meio do movimento rotativo de um impulsor. Este componente possui pás curvadas, que ao girarem, criam uma força centrífuga que direciona o ar radialmente para fora do impulsor. Este movimento resulta na compressão do ar, criando assim uma pressão e proporcionando eficiência em situações que é necessária a movimentação controlada de ar [29].

Em suma, a ação centrífuga do impulsor é a essência do desempenho singular do ventilador centrífugo.

#### 2.5.7.2 – Caracterização de um Ventilador Centrífugo

Principais componentes de um ventilador centrífugo:

- Carcaça
- Acoplamento
- Impulsor
- Eixo
- Anéis de desgaste
- Rolamento

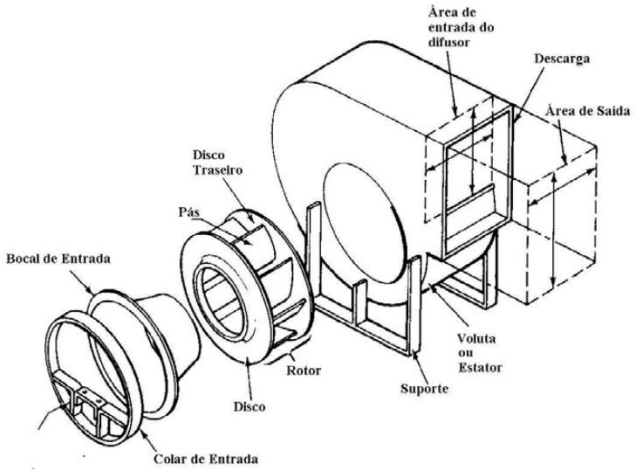


*Figura 19 - Principais componentes de um ventilador centrífugo*[29]

#### 2.5.7.3 – Falhas

Uma das falhas críticas reside no desgaste do impulsor, onde as pás, sujeitas a operações contínuas, podem evidenciar um desgaste progressivo, comprometendo a eficiência e criar desequilíbrios prejudiciais. O desequilíbrio, seja no próprio impulsor ou noutras partes rotativas, pode resultar em vibrações excessivas, danos nos rolamentos e em última instância, numa degradação do desempenho global.

O desalinhamento entre o motor e o ventilador é outra fonte de potenciais falhas, impondo tensões mecânicas excessivas que podem culminar em falhas prematuras. Problemas nos rolamentos, causados por cargas elevadas, falta de lubrificação adequada ou contaminação, representam uma ameaça significativa à operação do ventilador [29].

Por fim, obstruções no fluxo de ar, seja devido a detritos ou outras obstruções, podem reduzir a eficiência do ventilador, comprometendo seu desempenho.

### 2.5.8 – Moinhos

Os moinhos industriais são máquinas projetadas para a redução do tamanho de materiais sólidos, transformando-os em partículas menores [30] [31]. Normalmente os componentes essenciais são:

- **Câmara de Moagem:** Local onde o material é alimentado para ser processado.
- **Elemento de Moagem**: Este é o componente que realiza a ação da moagem. Podem ser uma série de martelos, lâminas, rolos ou bolas, dependendo do tipo de moinho.
- **Motor:** Um motor elétrico fornece a potência necessária para acionar o elemento de moagem.
- **Sistema de Alimentação e Descarga:** Os Moinhos podem ter sistemas de alimentação controlados por correias transportadoras, rosca ou outros mecanismos. A descarga das partículas moídas é feita normalmente através de peneiras, transportadores ou outros métodos.

#### 2.5.8.1 – Tipos de Moinhos

Existem vários tipos de moinhos industriais, cada um projetado para aplicações específicas [30][32]. Alguns dos tipos mais comuns incluem:

- **Moinho de Martelos:** composto por um rotor equipado com martelos
- **Moinho de Bolas:** Utilizado na moagem de minério, é constituído por um tambor giratório com bolas de aço que colidem com o material.
- **Moinho de Rolos**: Utilizado na moagem de grãos e materiais granulares, possui dois ou mais rolos que esmagam o material.
- **Moinho de Lâminas:** Usado para reduzir o tamanho de plásticos, borrachas com lâminas giratórias.
- **Moinho de Pinos:** Utilizado para materiais muito finos, possui pinos que trituram o material.

### 2.5.9 – Moinhos de bolas horizontais

#### 2.5.9.1 – Princípio de operação

Princípio de operação, por exemplo de um moinho de bolas, baseia-se no impacto e no atrito. Ambos são responsáveis pela redução de tamanho, onde as bolas movendo-se rapidamente são usadas para diminuir o tamanho de materiais frágeis

O impacto da velocidade na redução do tamanho:

- **Baixa velocidade**: Em baixa velocidade, a massa de esferas desliza ou rola uma sobre a outra e não produz uma quantidade significativa de redução de tamanho.
- **Alta velocidade:** Em alta velocidade, as esferas são lançadas para a parede do cilindro devido à força centrífuga, e não ocorrerá moagem.
- **Velocidade normal**: Em velocidade normal, as esferas são carregadas quase até o topo do moinho e depois caem em cascata através do diâmetro do moinho. Desta forma, obtém-se a máxima redução de tamanho.

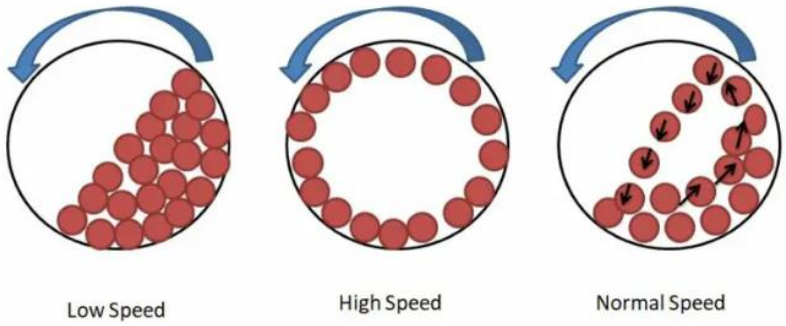


*Figura 20 - Impacto da velocidade na redução de tamanho*

#### 2.5.9.2 – Caracterização

Principais componentes de um moinho de bolas horizontal:

- Tambor
- Caixa redutora
- Acoplamento
- Rolamento
- Correias e polias
- Bolas (elemento de moagem)

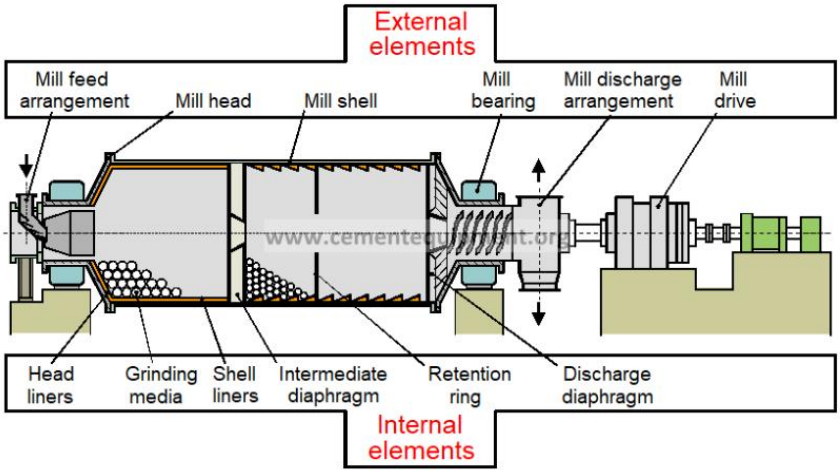


*Figura 21 - Principais componentes do moinho de bolas horizontal* [33]

**2.5.10. – Moinhos Vertical de rolos**

**2.5.10.1 – Princípio de operação**

O material é alimentado a uma taxa constante e cai no centro da mesa. Em seguida, o material é centrifugado para a periferia da mesa e é comprimido entre a mesa e o rolo. Ele é então comprimido e cortado para a moagem onde a força de moagem pode ser facilmente controlada ajustando a pressão hidráulica. Um batente é fornecido para evitar o contato direto da mesa com o rolo.

**2.5.10.2 – Caracterização**

Principais componentes de um moinho de bolas horizontal:

- Caixa redutora
- Acoplamento
- Rolamento
- Correias e polias
- Bolas (elemento de moagem)
- Mesa

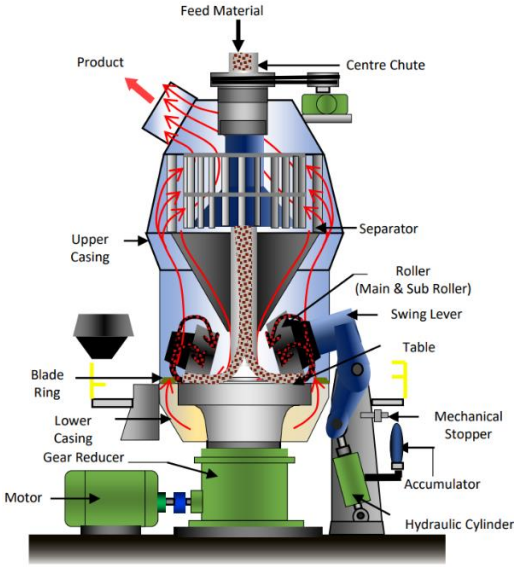


*Figura 22 - Principais componentes do moinho vertical de rolos* [34]

#### *2.5.11 – Principais Falhas dos Moinhos*

Alguns dos problemas mais comuns incluem:

- **Sobrecarga do Motor**: Um aumento repentino na carga do moinho pode sobrecarregar o motor, levando a superaquecimento e possíveis danos.
- **Desalinhamento**: Desalinhamento inadequado do motor e do elemento de moagem pode causar vibrações excessivas e desgaste prematuro.
- **Falha no Sistema de Transmissão**: Se houver uma falha no sistema de transmissão, como correias partidas ou engrenagens desgastadas, a operação do moinho será prejudicada.
- **Problemas Elétricos**: Falhas elétricas, como curtos-circuitos ou problemas no sistema de controlo, podem afetar o funcionamento do motor.
- **Desgaste das Peças do Moinho**: As partes do moinho, como martelos, lâminas ou bolas, podem desgastar-se ao longo do tempo, exigindo manutenção ou substituição.

## 2.6 – Conclusão do capítulo

No Capítulo 2 foi possível explorar detalhadamente os motores elétricos, com foco especial nos motores de indução e motores de corrente contínua. Bem como os seus componentes cruciais, tais como o estator e rotor, e ainda os princípios fundamentais de operação dos principais ativos industriais.

Aprofundar este conhecimento é crucial, uma vez que estabelece a base para os capítulos subsequentes, que se dedicarão à identificação e resolução de falhas nos motores elétricos. Este capítulo não se dedicou apenas a introduzir os conceitos essenciais, mas também preparou o terreno para a aplicação prática das estratégias de diagnóstico que serão apresentadas no capítulo seguinte.

# CAPÍTULO 3 – Enquadramento Teórico

A deteção e o diagnóstico de falhas são métodos avançados de supervisão e monitorização de falhas. A deteção e diagnóstico de falhas pode organizar-se em quatro etapas, tal como apresentado em seguida [35] [36].

A primeira etapa consiste na aquisição das grandezas da máquina através de diferentes tipos de sensores (tensão, corrente, fluxo, aceleração), normalmente associados a filtros que eliminam o ruído presente nas instalações e a conversores analógico-digitais responsáveis pela conversão das grandezas analógicas em sinais digitais para posterior processamento. Na segunda etapa é efetuado o processamento dos sinais obtidos dos sensores por forma a extrair as suas características fundamentais. Na terceira etapa é realizada a deteção de falhas, que associada ao diagnóstico (quarta etapa) determina o tipo de falha, o seu impacto e a sua localização.

A presença de qualquer tipo de falha na máquina resulta em alterações nas tensões e correntes da fase do estator e no campo magnético, que provocam um aumento da temperatura, do ruído e das vibrações na máquina.

A aquisição destas grandezas, elétricas e mecânicas, é relativamente fácil, o que permite a monitorização do estado de funcionamento da máquina e consequentemente, a deteção e o diagnóstico da ocorrência de falha. Neste sentido, têm-se desenvolvido várias metodologias para deteção e diagnóstico de falhas em máquinas elétricas, existindo atualmente diversos métodos, cada um com as suas particularidades, diferindo uns dos outros pelo número e tipos de falhas que são capazes de detetar e pelas grandezas usadas nessa deteção.

Os métodos de monitorização e deteção de falhas nas máquinas elétricas podem também ser classificados como métodos invasivos ou não invasivos. Os métodos invasivos, como o nome indica, precisam de ter acesso à máquina para aquisição das grandezas necessárias à análise. Assim, a sua aplicação tem desvantagens face aos métodos não invasivos que não têm essa necessidade, utilizando normalmente grandezas elétricas mais fáceis de medir.

Nos últimos anos, vários métodos de deteção e de diagnóstico de falhas em máquinas elétricas têm-se centrado na utilização das técnicas de inteligência artificial ou sistemas inteligentes [37], que recorrem a aspetos da inteligência humana tais como: a capacidade de aprendizagem com a experiência do passado, o reconhecimento de padrões e a capacidade de fazer deduções. De um modo geral, as técnicas de diagnóstico baseadas em sistemas inteligentes, combinadas com os métodos de deteção ditos tradicionais, permitem automatizar a deteção e o diagnóstico de falhas.

A Tabela 1 mostra um resumo de alguns trabalhos relevantes no campo

## 3.1 – Métodos de Deteção de Falhas

*Tabela 1 - Resumo dos principais modelos de deteção de falhas*

| Modelo | Deteção de Falhas | Referencias |
|---|---|---|
| Análise de Vibrações | Avarias mecânicas, falha dos rolamentos, excentricidades e outras avarias no geral | [38][39] |
| MCSA | Curto-circuitos dos enrolamentos do estator; barras quebradas do rotor, rolamentos, correias polias | [38] [40] |
| Fluxo magnético axial | Curto-circuitos dos enrolamentos do estator, barras quebradas do rotor | [36] [41] |
| Vetor de Park | Excentricidades, curto-circuitos nos enrolamentos estatóricos, avarias no rotor e desequilíbrios na rede de alimentação | [38] [42] |
| ANN – Artificial Neuronal Network | Curto-circuitos no estator e barras quebradas do rotor | [37] [43] |

#### 3.1.1 – Métodos baseados na análise espetral das vibrações

A existência de vibrações numa máquina é uma resposta complexa a diversas forças dinâmicas, algumas das quais podem ser consideradas anómalas. Estas forças, provenientes de vários estímulos que afetam a máquina, geram vibrações em múltiplas frequências, espalhando-se por toda a estrutura. A identificação dessas frequências é crucial e na maioria das situações, está relacionada com diferentes tipos de falhas. Inicialmente, a análise espectral de vibrações mecânicas em máquinas elétricas tinha como objetivo primário a deteção e o diagnóstico de falhas mecânicas, abrangendo desgaste em rolamentos, excentricidade, desalinhamentos, através da análise de componentes de frequência ou grupos de frequências [39].

O procedimento de análise inicia-se com a aquisição do sinal de vibração por meio de um acelerômetro posicionado estrategicamente, como por exemplo nas chumaceiras. Este sinal, originalmente no domínio do tempo, passa por uma transformação para o domínio da frequência, utilizando métodos como a FFT (Transformada Rápida de Fourier), criando assim o espectro de vibração da máquina. Este espectro pode então ser comparado com um espectro padrão de vibração da máquina em condições normais, possibilitando a deteção de potenciais falhas mecânicas [38].

No entanto, esta metodologia não se limita exclusivamente a falhas mecânicas, sendo também capaz de detetar falhas elétricas. Por exemplo, no caso de um curto-circuito entre espiras num enrolamento do estator (uma falha de natureza elétrica), ocorre uma alteração no comportamento da força magnetomotriz total no entreferro, resultando em variações na indução magnética no entreferro. Estas variações geram forças que provocam vibrações nos diversos componentes da máquina. Consequentemente, na presença de uma falha elétrica, o espectro padrão de vibração da máquina é modificado, refletindo as alterações nas características das forças que atuam sobre ela [38].

Por meio da análise destas modificações no espectro, torna-se possível diagnosticar se a variação na dinâmica de vibração é causada por uma falha num componente elétrico ou mecânico. Todavia, é imperativo possuir conhecimento das frequências naturais de vibração dos componentes estruturais da máquina, assim como das frequências associadas às falhas, a fim de identificar a origem específica da falha [39].

#### 3.1.2 – Métodos baseados na análise espetral das correntes do estator

A técnica conhecida como Análise da Assinatura da Corrente do Motor (MCSA - Motor Current Signature Analysis) é uma abordagem não invasiva amplamente utilizada para diagnosticar falhas em máquinas de indução, valorizada pela sua simplicidade de uso e pela ausência da necessidade de conhecimento detalhado dos parâmetros da máquina.

Essencialmente, a obtenção de informações suficientes para diagnóstico requer apenas o registo da corrente de uma das fases da máquina. Este método fundamenta-se na análise espectral do sinal de corrente proveniente de uma fase do estator. As correntes do estator de máquinas de indução contêm harmónicos devido à não perfeita configuração sinusoidal dos enrolamentos nas ranhuras ou a imperfeições resultantes da construção da máquina, juntamente com possíveis componentes harmónicos presentes na rede elétrica de alimentação [38].

No caso de um curto-circuito num dos enrolamentos do estator, seja entre espiras do mesmo enrolamento ou entre espiras de enrolamentos de fases diferentes, a configuração da força magnetomotriz rotativa é alterada, resultando em alterações nas amplitudes dos harmónicos nas correntes do estator. Portanto, observando o espectro de frequência das correntes do estator, é possível detetar um curto-circuito, pois o espectro diferencia-se do obtido quando a máquina está a operar normalmente [35].

Quando a falha ocorre no rotor, como a quebra de barras ou de um dos anéis de curto-circuito, o rotor manifesta-se como um circuito trifásico desequilibrado. Este desequilíbrio gera correntes de sequência negativa, criando um campo magnético que gira na direção oposta à rotação do rotor, resultando num binário no sentido contrário e causando oscilações na velocidade do rotor. Essas oscilações afetam as correntes do estator, nas quais os harmónicos são induzidos em duas bandas laterais à frequência da rede. A presença dessas bandas laterais no espectro de frequências possibilita o diagnóstico e identificação de falhas no rotor. Embora esta técnica seja eficaz na deteção de quebras de barras do rotor, há desvantagens, como a amplitude das correntes, que é diretamente influenciada pela carga conectada à máquina.

A deteção de excentricidades no veio do rotor também pode ser realizada por meio da análise do espectro de frequência da corrente do estator [40].

#### 3.1.3 – Métodos baseados na análise espetral do fluxo magnético axial

O método baseado na análise espetral do fluxo magnético axial consiste na análise do fluxo da máquina, o que torna necessário realizar a respetiva medida do fluxo. De acordo com a localização do sensor usado para a medida do fluxo, no interior da máquina ou na sua parte exterior, este método pode ser considerado como invasivo ou não invasivo.

Em qualquer máquina de indução, mesmo em condições normais de funcionamento sem falha, existem pequenos desequilíbrios nas correntes de fase, que são devidos a imperfeições de construção dos enrolamentos e a desequilíbrios na rede de energia elétrica. O desequilíbrio nas correntes de fase resulta na presença de correntes de sequência negativa na máquina e também no desequilíbrio no fluxo das bobinas, que resultam assim num fluxo na direção axial da máquina.

A colocação de uma bobina na extremidade da máquina de uma forma concêntrica com o seu eixo permite medir este fluxo axial e através da análise do seu espetro de frequência, é possível detetar curto-circuitos nos enrolamentos do estator, excentricidades e quebra de barras do rotor. Nas máquinas de elevada tensão e potência, onde é muita complexa a análise das correntes do estator, a utilização de uma bobina de fluxo axial apresenta-se como uma boa alternativa na deteção de falhas [36] [41].

#### 3.1.4 – Métodos baseados no vetor de *Park*

Alguns estudos, destacam quatro algoritmos distintos baseados no Vetor de *Park*, projetados para permitir o diagnóstico em tempo real. Estes algoritmos são avaliados considerando critérios essenciais, tais como a eficácia, a robustez contra falsos alarmes, a velocidade de

deteção, esforço de implementação, esforço de ajuste e carga computacional. A seleção e avaliação criteriosa destes algoritmos constituem elementos fundamentais na pesquisa, proporcionando *insights* valiosos para o desenvolvimento e aplicação prática de métodos de diagnóstico de falhas [42].

A relevância do Vetor de Park é destacada na sua aplicação específica do autodiagnóstico de conversores de potência. Os resultados evidenciam não apenas a eficácia da técnica, mas também a sua aplicabilidade e desempenho distintos em ambientes industriais. A capacidade de deteção precoce e precisa de falhas torna-se crucial nestes contextos, onde interrupções não planeadas podem ter impactos significativos na operação dos sistemas.

Assim, o Vetor de Park, consolida-se como uma ferramenta indispensável no domínio do diagnóstico de falhas em sistemas elétricos industriais. A sua versatilidade e eficácia, demonstradas através da aplicação de diferentes algoritmos, reforçam a sua posição como uma técnica de relevo para melhorar a fiabilidade e a eficiência.

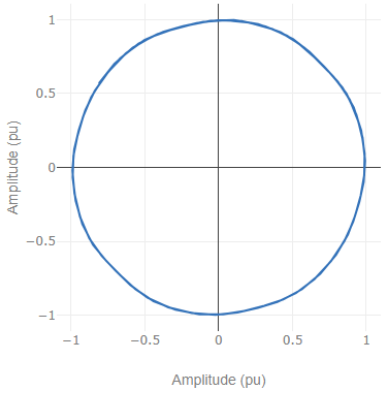


*Figura 23 - Vetor de Park*

#### 3.1.5 – Métodos baseados em redes neuronais artificiais

As Redes Neuronais Artificiais, também conhecidas como *Artificial Neuronal Networks* (ANN), são modelos computacionais inspirados no funcionamento dos sistemas nervosos biológicos. Estas redes são constituídas por unidades de processamento interligadas, simulando a estrutura de neurónios e as conexões sinápticas presentes nas redes neuronais biológicas. Durante o processo de aprendizagem, o conhecimento adquirido é disseminado por toda a rede, adaptando os pesos sinápticos das conexões entre as unidades de processamento. Este ajuste é realizado com o intuito de obter, nas saídas da rede, respostas coerentes com um conjunto predefinido de estímulos de entrada [43].

A principal característica das ANN é a capacidade de lidar com problemas que envolvem um grande número de variáveis e dados. Além disso, estas têm a capacidade para representar sistemas não lineares e variantes no tempo, exigindo pouca informação sobre modelos analíticos. As ANN têm a capacidade única de desenvolver critérios próprios e ajustar-se internamente com base nos algoritmos de aprendizagem aos quais são submetidas. Esta capacidade é crucial para a modelação de sistemas complexos, onde a expressão analítica é desafiadora, tornando possível a definição de regras necessárias à construção de algoritmos.

Devido às suas características, as ANN destacam-se como uma ferramenta eficaz no diagnóstico de falhas em máquinas elétricas. A sua estabilidade e capacidade de processamento paralelo resultam em tempos de cálculo reduzidos para os parâmetros do circuito elétrico, mantendo a precisão em comparação com técnicas convencionais. Em particular, os métodos baseados em ANN têm demonstrado sucesso na deteção de curto-circuitos nos enrolamentos do estator. No entanto, é importante salientar que sua aplicação requer um período de aprendizagem e um controlo contínuo das variáveis elétricas da máquina [37].

## 3.2 – Técnica MCSA

Com o intuito de organizar a apresentação dos padrões de falha, dividiu-se os mesmos em três grupos: falhas no motor, falhas no sistema de transmissão e falhas na carga acoplada.

Como é possível verificar através da Tabela 2.

*Tabela 2 - Resumo dos principais padrões de falhas*

| Padrões de Falha | Avarias | Frequência |
|---|---|---|
| Motor | Barras quebradas | $f_{bq} = f(1 \pm 2ks)$ |
| | Air Gap | $f_{\frac{slot}{exc}} = f_1\left[(kR \pm n_{ecc})\left(\frac{1-s}{\frac{p}{2}}\right)\right] \pm n_s$ |
| | Rolamento | $f_{BPFO} = \frac{n}{2} f_r \left(1 - \frac{BD}{PD} cos\beta\right)$ |
| Sistema de transmissão | Polias | $f_{pulley} = \frac{D_{motor_{pulley}} f_r}{D_{load_{pulley}}}$ |
| | Correias | $f_b = \frac{D_{motor_{pulley}} \pi f_r}{L_{belt}}$ |
| | Engrenagens | $f_g = n f_{r1} = N f_{r2}$ |
| Carga acoplada | Bombas | $f_{vp} = n f_{r_{pump}}$ |
| | Ventiladores | $f_{bq} = N_b f_{r_{fan}}$ |

### 3.2.1 – Padrões de falha no motor

#### 3.2.1.1 – Barras quebradas

A barra quebrada faz com que apareçam no espectro de corrente dois picos igualmente afastados de $2fs$ da componente fundamental, onde $f$é a frequência de alimentação e $s$ é o deslizamento da máquina em $pu$. A componente da esquerda $(f - 2fs)$ é resultado direto da falha, enquanto que a componente da direita $(f + 2fs)$ é resultado do *ripple* de velocidade. Assim, desta forma, pode-se afirmar que as barras quebradas resultam no aparecimento de componentes no espectro da corrente do estator nas frequências dadas por:

$$f_{bq} = f(1 \pm 2ks) \tag{1}$$

Pode-se ainda calcular o número de barras quebradas através da amplitude da banda lateral esquerda $(f - 2fs)$ que é proporcional ao número de barras quebradas. Essa fórmula é empírica e reflete o número de barras quebradas de forma aproximada.

$$\frac{I_{bq}}{I_f} = \frac{sen\alpha}{2p(2\pi - \alpha)} \tag{2}$$

Onde:

$I_{bq}$ é a amplitude da componente $(f - 2fs)$

$I_f$ é a amplitude da componente fundamental

$p$ é o número de par de polos

E α é dado por:

$$\alpha = \frac{2\pi R_b p}{R} \tag{3}$$

Onde:

$R_b$ é o número de barras quebradas

$R$é o número de barras do rotor

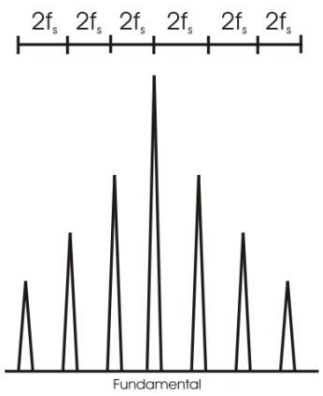


*Figura 24 - Padrão de falha de barras quebradas* [44]

**3.2.1.2 – Air Gap**

Excentricidade de *air gap*, é a condição em que o *air gap* não apresenta uma distância uniforme entre o rotor e o estator, resultando numa região de máxima e outra região de mínima de *air gap*. Existem dois tipos de excentricidade: estática e dinâmica, onde $f_1$ é a frequência fundamental de alimentação, $R$ é o número de barras do rotor e $CF$ é a frequência central.

- **Excentricidade Estática:** a posição mínima radial é fixa no espaço. O núcleo do estator está arqueado ou há um posicionamento incorreto entre o rotor e o estator gerado como consequência do desalinhamento. Além destas possibilidades, aspetos construtivos permitem um nível inerente de excentricidade devido às tolerâncias do processo de fabrico.
- **Excentricidade Dinâmica**: o *air gap* move-se com o rotor. As principais causas são, o diâmetro externo do rotor não ser concêntrico, problemas de rolamento, desequilíbrio do rotor ou da carga.

As frequências associadas à excentricidade do *air gap* são determinadas por:

$$f_{\frac{slot}{exc}} = f_1 \left[ (kR \pm n_{ecc}) \left( \frac{1-s}{\frac{p}{2}} \right) \right] \pm n_s \qquad (4)$$

Onde:

$f_1$ = frequência elétrica de alimentação

$k$=1, 2, 3, …

$R$ = número de barras do rotor

s = escorregamento da máquina em pu

$n_{ecc}$ (número da ordem da excentricidade) = 1, 2, 3, 4, 5, ...

$p$ = número de pólos

$n_s$ (ordem da harmónica da frequência de alimentação) = 1, 3, 5, 7, 9, ...

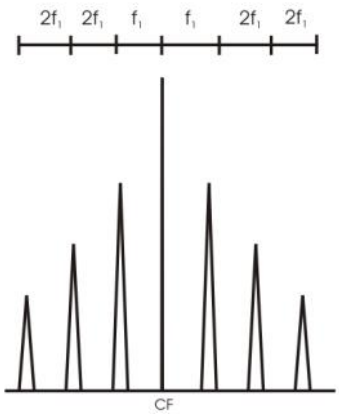


*Figura 25 - Pdrão de falha excentricidade estática* [44]

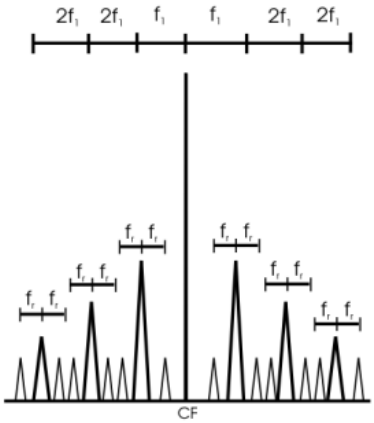


*Figura 26 - Padrão de falha excentricidade dinâmica* [44]

**3.2.1.3 – Rolamentos**

A monitorização de falhas nos rolamentos é muito importante, uma vez que esses problemas, tal como referido anteriormente representam 40% do total de falhas num motor de indução.

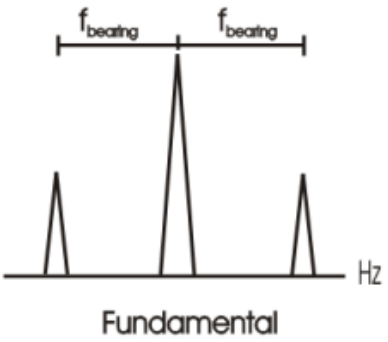


*Figura 27 - Padrão de falha rolamentos* [44]

As principais equações são:

$$f_{BPFO} = \frac{n}{2} f_r \left(1 - \frac{BD}{PD} cos\beta\right) \quad (5)$$

$$f_{BPFI} = \frac{n}{2} f_r \left(1 - \frac{BD}{PD} cos\beta\right) \quad (6)$$

$$f_{BSF} = \frac{PD}{BD} f_r \left(1 - \left(\frac{BD}{PD} cos\beta\right)^2\right) \quad (7)$$

$$f_{BPFO} = \frac{1}{2} f_r \left(1 - \frac{BD}{PD} cos\beta\right) \quad (8)$$

Onde:

$f_{BPFO}$ é a frequência da pista externa

$f_{BPFI}$ é a frequência da pista interna

$f_{BSF}$ frequência do elemento girante

$f_{BPFO}$ frequência da gaiola

$PD$ diâmetro do rolamento

$BD$ diâmetro do elemento girante

β ângulo de contacto do rolamento

n número de elementos girantes

$f_r$ velocidade de rotação em HZ

### 3.2.2 – Sistemas de Transmissão

#### 3.2.2.1 – Polias

Ao analisar a frequência de rotação, é possível detetar problemas relacionados à polia do motor. Quando não há alteração na velocidade, não é possível distinguir a polia danificada da saudável, uma vez que ambas têm a mesma frequência de rotação. No entanto, quando há uma transformação de velocidade, é possível monitorar a polia de carga e a carga associada através do padrão.

$$f_{pulley} = \frac{D_{motor_{pulley}} f_r}{D_{load_{pulley}}} \tag{9}$$

Onde$f_r$ é a frequência de rotação, $D_{motor_{pulley}}$ é o diâmetro da polia do motor e $D_{load_{pulley}}$ é o diâmetro da polia de carga. Os componentes de banda lateral da fundamental estão em $f_1 f_p$.

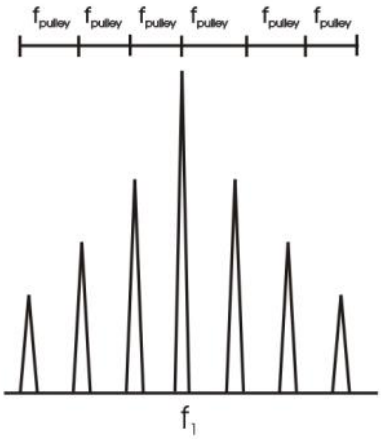


*Figura 28 - Padrão de falha polias* [44]

Os problemas mais comuns são polia excêntrica, polia com folga mecânica e polia desequilibrada.

#### 3.2.2.2 – Correias

O primeiro passo ao monitorar os componentes da frequência característica da correia é calcular a frequência da correia $f_b$. Neste caso, $f_{lf}$ é igual a $f_b$, e $f_b$ é a frequência característica da correia dada por:

$$f_b = \frac{D_{motor_{pulley}} \pi f_r}{L_{belt}} \tag{10}$$

Onde $L_{belt}$ é o comprimento da correia. Desta forma, os componentes da banda lateral da fundamental estão em $f_1 \pm f_b$ Após calcular esta frequência, basta seguir o padrão apresentado na Figura 29 e acompanhar a curva de tendência para diagnosticar problemas neste elemento do sistema de transmissão.

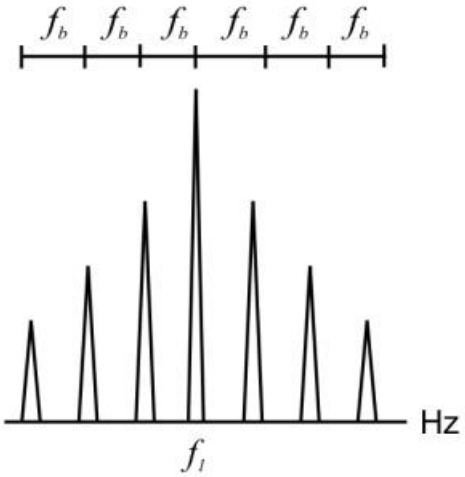


*Figura 29 - Padrão de falha correias* [44]

Além de diagnosticar problemas como correia fraca, correia quebrada ou correia excessivamente tensionada, é possível analisar problemas originados na carga. No caso de falha na carga, os níveis de vibração nas correias aumentam consideravelmente, resultando em amplitudes mais altas para as frequências características da correia.

#### 3.2.2.3 – Engrenagens

Neste caso, duas regiões espectrais devem ser monitoradas. A primeira, em uma faixa de frequência mais baixa, mostra falhas pontuais na engrenagem (por exemplo, um dente quebrado). Estas frequências estão relacionadas às frequências de rotação antes e depois da transformação de velocidade. Dessa forma, as componentes da banda lateral da fundamental estão em $f_1 f_{r1}$ e $f_1 f_{r2}$, respetivamente, onde $f_{r1}$ é a frequência de rotação antes da transformação de velocidade e $f_{r2}$ é a frequência de rotação após a transformação de velocidade. A segunda região espectral de interesse mostra falhas distribuídas na engrenagem. Elas são conhecidas como frequência da malha da engrenagem $(f_g)$ e podem ser calculadas multiplicando a velocidade de rotação do eixo pelo número de dentes da engrenagem.

$$f_g = n f_{r1} = N f_{r2} \tag{11}$$

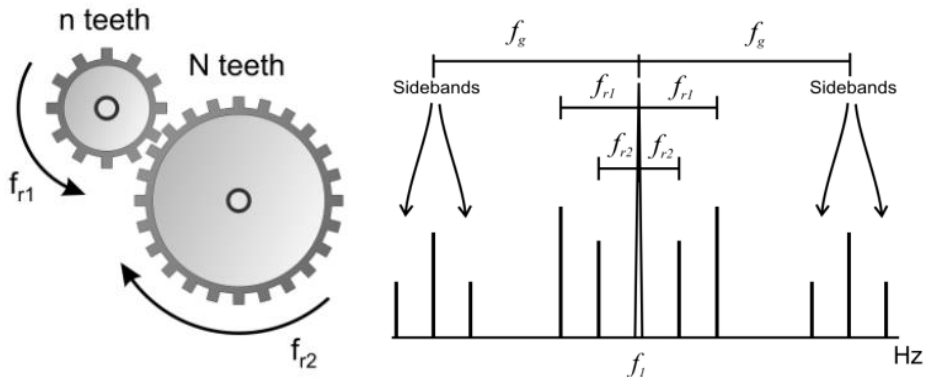


*Figura 30 - Padrão de falha engrenagens* [44]

### 3.2.3 – Bombas Centrífugas

Para a análise de bombas centrífugas, é necessário considerar a frequência de rotação da bomba ($fr_{bomba}$) e a frequência de passagem da pá ($f_{vp}$), que é dada por:

$$f_{vp} = nf_{r_{pump}} \tag{12}$$

Onde ***n*** é o número de pás da bomba.

A análise da frequência de rotação da bomba $f_{r_{pump}}$ indica problemas relacionados a desalinhamento ou desequilíbrio da bomba. Neste caso, $f_{lf}$ é igual a $f_{r_{pump}}$ e os componentes da banda lateral da fundamental estão em $f_1 f_{r_{pump}}$. Por outro lado, o aumento das amplitudes da frequência de passagem da pá indica problemas dentro da bomba, como deterioração da pá. Por fim, os componentes da banda lateral da fundamental estão em $f_1 f_{vp}$.

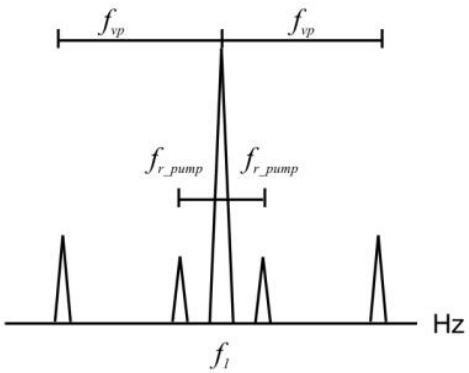


*Figura 31 - Padrão de falha bomba centrífuga* [44]

Além dessas frequências, é necessário monitorar o aumento das amplitudes próximas à frequência de alimentação. Essas frequências são características da assinatura da bomba e também podem indicar problemas na bomba.

#### 3.2.4 – Ventiladores

Da mesma forma que nas bombas, a análise de falhas em ventiladores considera a frequência de rotação do ventilador e a frequência de passagem da pá $f_{bp}$

$$f_{bq} = N_b f_{r_{fan}} \tag{13}$$

Onde $N_b$ é o número de lâminas e $f_{r_{fan}}$ é a frequência de rotação do ventilador.

Analisando a frequência de rotação $f_{r_{fan}}$, podem ser detetados problemas relacionados a desalinhamento ou desequilíbrio do ventilador. Quando $f_{lf}$ é igual a $f_{r_{fan}}$ os componentes da banda lateral da fundamental estão em $f_1 f_{r_{fan}}$. Além disso, o aumento das amplitudes da frequência de passagem da pá indica problemas como deterioração ou quebra da pá. Os componentes da banda lateral da fundamental são dados por $f_1 f_{bp}$

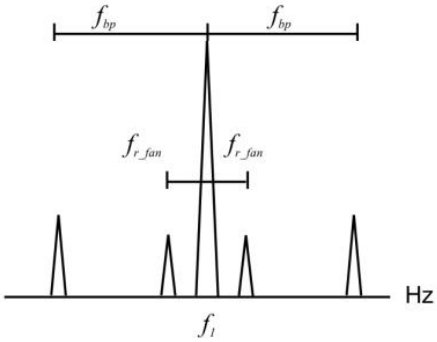


*Figura 32 - Padrão de falha ventiladores* [44]

### 3.3 – Conclusão do capítulo

Neste capítulo foram enunciadas as principais contribuições de pesquisadores e especialistas no domínio de manutenção preditiva e diagnóstico de motores elétricos, no qual foram exploradas diversas metodologias, desde a análise da assinatura elétrica até técnicas avançadas baseadas em Inteligência Artificial.

A revisão literária permitiu assim uma compreensão abrangente das abordagens existentes, destacando tanto os pontos fortes quanto as suas limitações.

Este mapeamento da literatura forneceu um contexto essencial para a aplicação prática das estratégias de diagnóstico de falhas na técnica MCSA pois, tal como verificado anteriormente através da análise espectral, é possível identificar as principais falhas na maior parte dos principais ativos industriais. No entanto, vale a pena realçar que embora não existam falhas especificas para o caso dos moinhos, este ativo é passível de decomposição, transformando-o assim em diversos subsistemas, como, por exemplo, num sistema de caixa redutora e correias/polias, que são possíveis de analisar na técnica MCSA e identificar possíveis falhas.

# CAPÍTULO 4 - Deteção de falhas através da análise espectral

No contexto atual, onde a complexidade dos sistemas mecânicos e elétricos são cada vez mais aprimoradas, a necessidade de técnicas avançadas de monitorização e diagnóstico torna-se imperativa. O Método de Análise da Assinatura da Corrente do Motor (MCSA) emerge como uma ferramenta valiosa para a deteção precoce de falhas em componentes essenciais dos ativos, proporcionando uma manutenção mais eficaz e minimizando interrupções inesperadas.

Este capítulo centra-se na análise descritiva dos dados provenientes do ***ePreditMntc***, aplicado à monitorização do ativo ***ITK Ventilationsanlaeg Smelt***, ao longo de um período de aproximadamente dois anos, em que foram recolhidos dados detalhados, abrangendo correntes, tensões e fatores de severidade associados a componentes cruciais do ativo, tais como os indicadores do estator, rotor, mecânico, alimentação e carga.

O objetivo central é proporcionar uma visão abrangente e significativa da saúde do equipamento, destacando padrões, tendências e eventos ou ainda padrões que possam indicar potenciais áreas de preocupação.

## 4.1 – Base de Dados

O presente capítulo realiza uma análise detalhada dos dados obtidos por meio de um ficheiro *csv*, extraído da plataforma ***ePreditMnt***. A extensa série temporal, que abrange aproximadamente dois anos, oferece uma visão abrangente das condições elétricas e mecânicas do equipamento, proporcionando *insights* cruciais para a análise da condição do ativo e a deteção precoce de falhas.

*Tabela 3 - Base de dados*

| ***Tempo*** | ***V*** | ***I*** | ***SFsup*** | ***SFsta*** | ***SFrot*** | ***SFmec*** | ***SFlvar*** | ***LF*** |
|---|---|---|---|---|---|---|---|---|
| 22/nov/2023 | 391,8657 | 311,0579 | 0,225085 | 0,541981 | 0,01349 | 1,516978 | 0,512211 | 89,38455 |
| 22/nov/2023 | 390,4785 | 309,9625 | 0,28226 | 0,429208 | 0,013707 | 0,032178 | 1,190929 | 89,01277 |
| 22/nov/2023 | 388,5126 | 312,3304 | 0,185727 | 0,413059 | 0,015799 | 0,048955 | 0,303024 | 89,81447 |
| 22/nov/2023 | 390,3882 | 310,205 | 0,137605 | 0,302533 | 0,004476 | 0,043672 | 0,49001 | 89,13017 |
| 22/nov/2023 | 383,661 | 313,9696 | 0,197606 | 0,262837 | 0,046858 | 1,845022 | 0,435753 | 90,14178 |
| 22/nov/2023 | 384,188 | 314,6485 | 0,243942 | 0,515453 | 0,018563 | 0,038884 | 0,573053 | 90,38357 |
| 22/nov/2023 | 386,5937 | 313,3088 | 0,232563 | 0,3094 | 0,016678 | 2,356643 | 0,692105 | 90,0116 |
| 22/nov/2023 | 387,1168 | 315,489 | 0,249232 | 0,303038 | 0,045244 | 0,04527 | 0,368665 | 90,98975 |
| 22/nov/2023 | 384,5936 | 313,6818 | 0,266621 | 0,318421 | 0,035872 | 1,440949 | 0,653805 | 90,26122 |
| 22/nov/2023 | 382,556 | 316,1728 | 0,237271 | 0,228315 | 0,029647 | 0,041479 | 0,658851 | 91,10525 |
| 22/nov/2023 | 384,3331 | 315,4748 | 0,207438 | 0,399233 | 0,016854 | 0,278063 | 0,515985 | 90,92977 |
| 22/nov/2023 | 383,5092 | 316,2075 | 0,291942 | 0,158889 | 0,071316 | 0,04422 | 0,684807 | 91,02198 |
| 22/nov/2023 | 386,5443 | 315,5134 | 0,177982 | 0,90408 | 0,065633 | 0,032661 | 0,473117 | 90,72784 |
| 22/nov/2023 | 386,6642 | 314,9858 | 0,244108 | 1,883504 | 0,042361 | 0,038529 | 0,518099 | 90,4562 |
| ……. | ……. | ……. | ……. | ……. | ……. | ……. | ……. | ……. |
| ……. | ……. | ……. | ……. | ……. | ……. | ……. | ……. | ……. |
| 3/jan/2022 | 386,9828 | 297,7843 | 0,057275 | 1,996457 | 0,010823 | 0,088764 | 1,467779 | 85,10129 |
| 3/jan/2022 | 390,1041 | 301,8836 | 0,117047 | 0,907595 | 0,278863 | 0,067692 | 1,660152 | 86,27211 |

| | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| 3/jan/2022 | 394,675 | 299,0249 | 0,12106 | 0,446269 | 0,019111 | 0,087815 | 1,656009 | 85,47572 |
| 3/jan/2022 | 395,7753 | 300,251 | 0,063008 | 0,854735 | 0,012556 | 0,060204 | 0,662597 | 85,96051 |
| 3/jan/2022 | 391,9211 | 298,9789 | 0,140574 | 0,772037 | 0,045262 | 0,085743 | 1,421558 | 85,52163 |
| 3/jan/2022 | 387,4731 | 309,834 | 0,085437 | 0,723383 | 0,034349 | 0,039799 | 0,59051 | 88,92718 |
| 3/jan/2022 | 389,726 | 316,6029 | 0,071177 | 1,173817 | 0,039696 | 0,058213 | 1,093626 | 90,86658 |

Analisando o *dataset* apresentado na Tabela 3 é possível verificar que as principais variáveis em estudo deste ativo são:

- **Tempo**: Indica a data da observação, representada no formato dia/mês/ano.
- **V (Tensão Média):** Valor médio da tensão monitorizada.
- **I (Corrente Média):** Valor médio da corrente elétrica monitorizada.
- **SFsup (Fator de Severidade da Alimentação):** Reflete a severidade de problemas relacionados com a alimentação do equipamento.
- **SFsta (Fator de Severidade do Estator):** Avalia a severidade das falhas no estator do equipamento.
- **SFrot (Fator de Severidade do Rotor):** Indica a severidade dos problemas identificados no rotor.
- **SFmec (Fator de Severidade Mecânico):** Avalia a severidade de falhas mecânicas no equipamento.
- **SFlvar (Fator de Severidade da Carga):** Reflete a severidade de problemas associados à carga do equipamento.
- **LF (Fator de Carga):** Representa o fator de carga do equipamento durante o período observado

A Tabela 3 abrange uma variedade de métricas, oferecendo uma visão detalhada da condição do equipamento ao longo do tempo. O foco, com este *dataset*, está na capacidade de identificar padrões, tendências e possíveis áreas de preocupação, que ajudem a determinar a condição do ativo e prever/identificar falhas no mesmo. Estes dados constituem a base para análises mais aprofundadas e decisões mais informadas, relacionadas com manutenção e operação do ativo.

#### 4.1.1 – Estatística Descritivas

As métricas estatísticas, como média, mediana, desvio padrão, mínimo e máximo, fornecem uma base numérica sólida para avaliar a variabilidade, identificar padrões e compreender a evolução temporal dos principais indicadores de condição deste ativo.

A Tabela 4 apresenta valores representativos dessas métricas, proporcionando uma síntese inicial das principais características dos dados. A interpretação destas métricas é crucial para a compreensão da condição do ativo, identificação de possíveis anomalias e orientação de estratégias de manutenção.

*Tabela 4 - Estatísticas Descritivas*

| ***Métrica*** | ***V*** | ***I*** | ***SFsup*** | ***SFsta*** | ***SFrot*** | ***SFmec*** | ***SFlvar*** | ***LF*** |
|---|---|---|---|---|---|---|---|---|
| ***Média*** | 390,1812 | 311,4774 | 0,193084 | 0,499179 | 0,039477 | 0,110116 | 0,6625 | 89,39766 |
| ***Mediana*** | 390,2055 | 312,4023 | 0,191354 | 0,446269 | 0,0313 | 0,038566 | 0,551383 | 89,7597 |
| ***Desvio Padrão*** | 3,065938 | 12,64844 | 0,05335 | 0,292168 | 0,055821 | 0,366255 | 0,586914 | 4,268668 |
| ***Max*** | 403,5119 | 353,8032 | 0,454119 | 3,499442 | 1,69745 | 3,963445 | 8,467354 | 101,7728 |
| ***Min*** | 371,9 | 146,2207 | 0,009942 | 0,013055 | 0,000221 | 0,011745 | 0,065773 | 24,95278 |

De forma a ser mais fácil a interpretação dos dados, a plataforma, ***ePreditMnt***, utiliza um sistema semafórico para que de forma simples e objetiva seja possível identificar a condição dos ativos.

Assim, a plataforma utiliza a cor verde como *estado bom*, até ao limite de 1, entre 1 e 2, o estado do ativo é classificado como em estado de alerta com uma cor amarela, e por fim a cor vermelha, com um limite superior a 2 significa que o ativo se encontra num nível crítico.

Com base nisto, analisando as principais estatísticas é possível verificar que, embora os principais fatores de severidade em média permaneçam baixos e segundo a plataforma pudéssemos classificar o ativo como em *bom estado*, na realidade verifica-se que este ativo atinge valores máximos bastante elevados nos principais indicadores de diagnóstico de condição do ativo, tais como o SFmec e o SFlvar, quando comparados com as suas respetivas médias, indiciando assim a presença de alguma falha neste ativo.

#### 4.1.2 – Tendências Temporais dos principais indicadores

De forma a se poder identificar possíveis padrões e tendências que permitissem identificar anomalias foram realizados os seguintes gráficos da Figura 33:

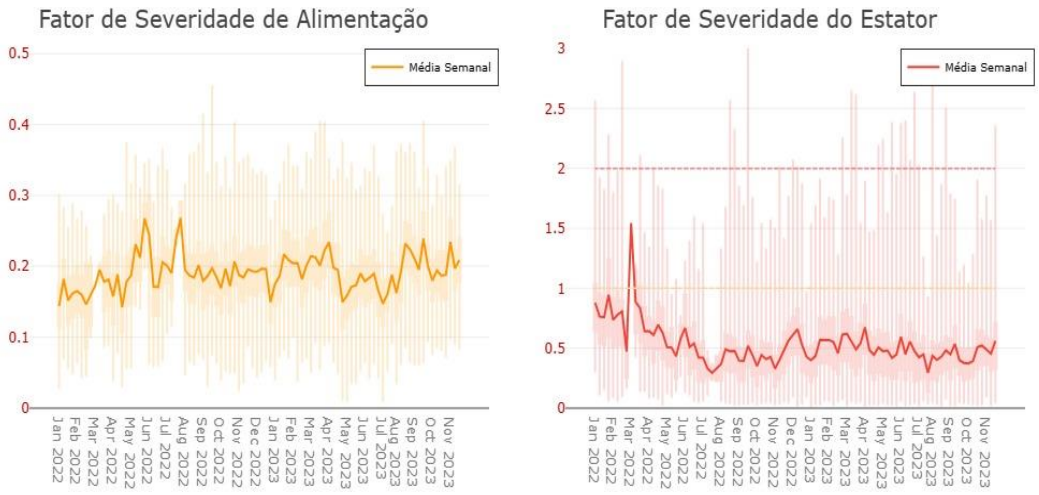


(a) (b)

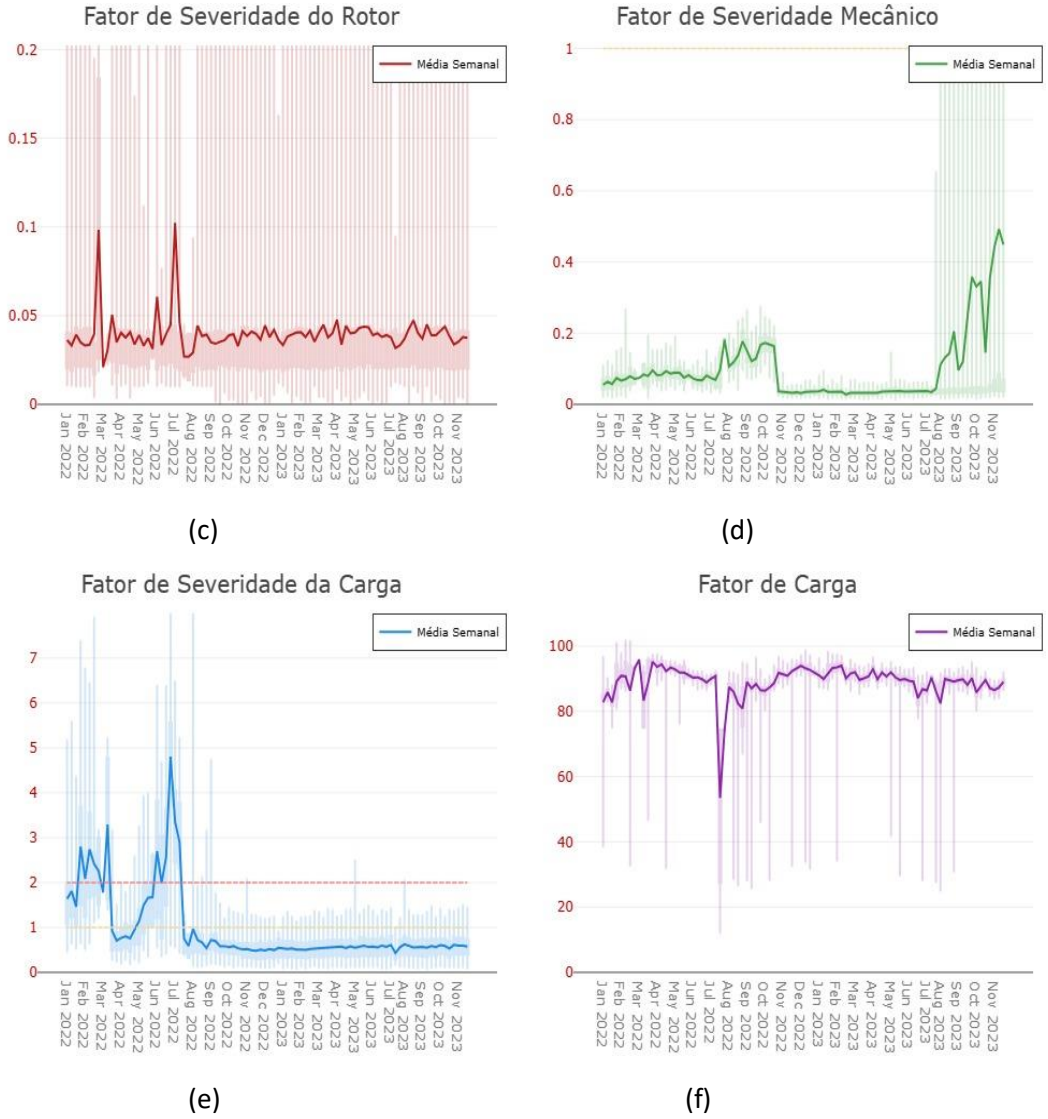


*Figura 33 - Figura 5 - Dados estatísticos relativos a cada semana das diferentes variáveis de diagnóstico: (a) SFsup; (b) SFsta; (c) SFrot; (d) SFmec; (e) SFlvar; (f) LF.*

Analisando os gráficos das principais variáveis de diagnóstico é possível concluir que o indicador mecânico e o indicador da variação da carga são os que apresentam tendências mais notórias e preocupantes. No caso do SFmec verificam-se que, após setembro de 2023, existiu um grande aumento do indicador evidenciando a existência de algum problema mecânico no ativo.

Juntamente com este facto também se realçam os valores elevados da variação da carga no final de julho de 2022, em que nos meses seguintes, após uma paragem, apresentam uma tendência muito mais estável e normal, apontando assim, a existência de uma possível falha no ativo antes desta paragem existir.

Assim, com base nesta análise e com a deteção de um padrão/tendência fora do comum, foi feita em seguida uma análise espectral para se compreender se existe realmente alguma falha no ativo.

Conclui-se assim que é possível caracterizar o ativo com base no motor que lhe está associado e analisar os seus principais indicadores. Analisando estes indicadores é notória a existência de

uma maior tendência no indicador mecânico e da variação da carga, indiciando a presença de alguma falha/anomalia presente neste ativo.

## 4.2 – Deteção de Falhas

Como anteriormente referido, é no indicador mecânico e da variação de carga que se verifica uma alteração significativa no padrão/ tendência no mês de setembro de 2023 e julho de 2022, respetivamente. Assim sendo, uma alteração tão significativa como as observadas é indicativa de uma potencial falha no ativo.

### 4.2.1 – Falha nas correias

Com o apoio da análise MCSA é possível verificar as principais de falha nos ativos, através da existência de valores elevados em certas frequências. Frequências essas que podem ser calculadas matematicamente e posteriormente relacionadas com tipos de falhas específicos.

Assim, verificando os instantes imediatamente antes e depois da alteração do padrão no indicador da variação da carga, constata-se a existência de um pico de forma muito mais acentuada na análise espectral, na frequência 4.1 Hz, como é possível verificar na Figura 34 e 35 confirmando assim a existência de uma falha no ativo.

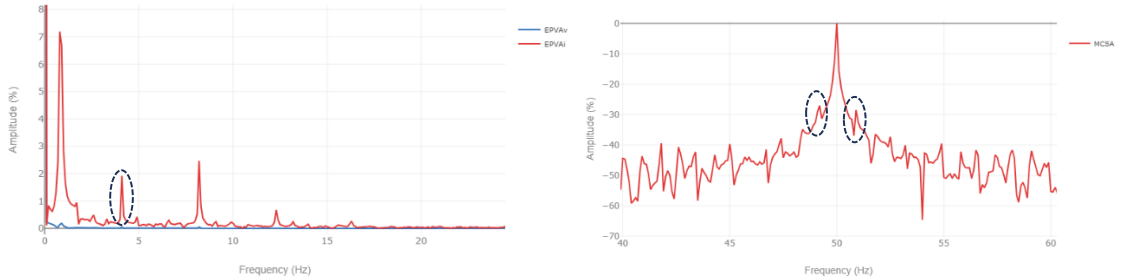


*Figura 34 - Análise Espectral antes da paragem*

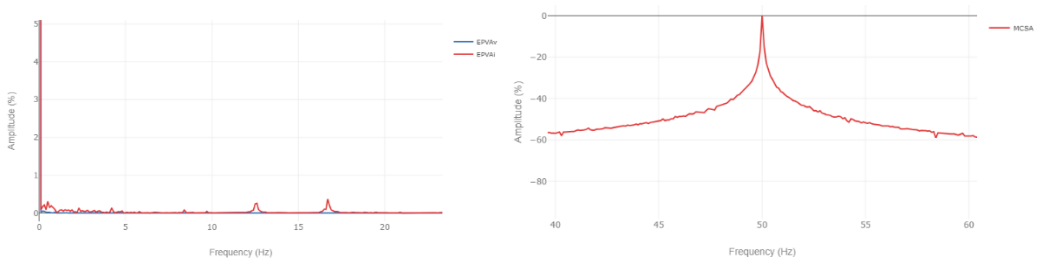


*Figura 35 - Análise Espectral depois da paragem*

De modo a identificar eficazmente a falha foram pedidos alguns dados mais específicos ao cliente, nomeadamente os valores do diâmetro da polia do motor ($D_{motor_{pulley}}$), o diâmetro da polia da carga ($D_{load_{pulley}}$) e, por fim o comprimento da correia ($L_{belt}$).

Assim, com estes dados foi então possível, a partir da Equação 1:

$$f_b = \frac{D_{motor_{pulley}} \pi f_r}{L_{belt}} \tag{14}$$

concluir que o pico identificado a 4.1 Hz correspondia a uma falha nas correias do ativo.

Vale realçar que através desta técnica foi possível identificar previamente a causa do problema que existia no ativo e assim permitir uma paragem para manutenção de modo a não implicar custos elevados para o proprietário do ativo. Assim, como se pôde verificar no gráfico da variação de carga após a paragem efetuada em julho, verifica-se que o ativo trabalhou sempre de forma mais estável e em melhor estado.

#### 4.2.2 – Falha Mecânica

Tal como verificado anteriormente, para o indicador mecânico constata-se exatamente o mesmo através da visualização do espectro antes e depois do drástico aumento no indicador mecânico, é assim possível identificar um pico bastante relevante a cerca de 24.5 Hz, como se verifica na Figura 36 e 37, que corresponde exatamente à frequência da componente de falha mecânica.

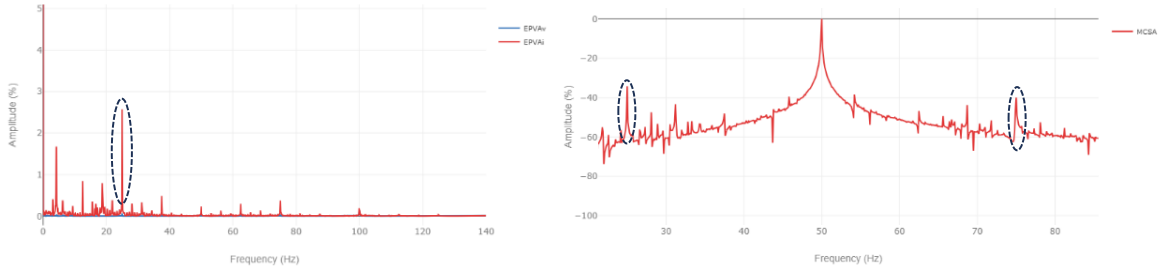


*Figura 36 - Análise Espectral depois*

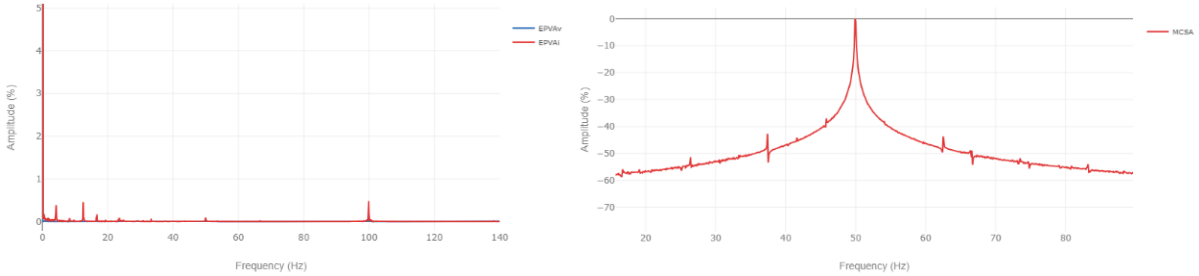


*Figura 37 - Análise Espectral antes*

## 4.3 – Conclusão do capítulo

Através da análise MCSA é possível verificar matematicamente a origem dos picos observados na frequência 4.1 Hz e 24.5 Hz e com base na análise espectral saber exatamente qual é a falha que lhe está associada, realizando assim um diagnóstico mais fino e preciso da condição do ativo em tempo real.

Por fim, após a verificação matemática do modelo, será agora possível passar ao desenvolvimento de uma ferramenta que permita identificar automaticamente a deteção de falhas do ativo e associar-lhe posteriormente um fator de severidade de modo a que seja possível avaliar a sua evolução ao longo do tempo.

# CAPÍTULO 5 - Classificação e previsão de falhas

Tal como visto anteriormente é possível matematicamente identificar o tipo de falha específico num determinado ativo através da sua componente espectral e da sua correspondente amplitude.

Assim, tendo isto em vista, foi desenvolvida uma ferramenta em *python* que tem como principal foco, inicialmente, a capacidade de classificar e identificar automaticamente as falhas nos ativos, através da introdução de parâmetros necessários para o cálculo dessas falhas. Isto permitirá uma maior automatização e uma mais rápida capacidade de resposta na identificação de falhas nos ativos e consequentemente uma maior rapidez na sua resolução.

Por fim, após o desenvolvimento desta etapa surge a necessidade de criar uma ferramenta capaz de prever e fornecer *insights*, sobre o estado desta falha bem como tentar prever a ocorrência desta falha num determinado período. Tal como anteriormente referido, esta ferramenta foi desenvolvida em *python*, tendo sido baseada em algoritmos de *Time Series*, de forma a poder realizar a melhor e mais fidedigna previsão possível.

## 5.1 – Classificação e identificação de falhas

Com base na extração dos sinais elétricos dos ativos é possível, através de técnicas matemáticas, como a transformada de Fourier [44], que basicamente consiste na conversão de um sinal nas suas componentes espectrais individuais, fornecendo assim informação sob a forma de frequência sobre o sinal inicial.

É através destas frequências, como demonstrado matematicamente nos capítulos anteriores, que é possível identificar as falhas especificas de um ativo.

Assim, inicialmente foi realizado um processamento dos sinais elétricos de modo a obter as ondas sinusoidais do ativo (Figura 38).

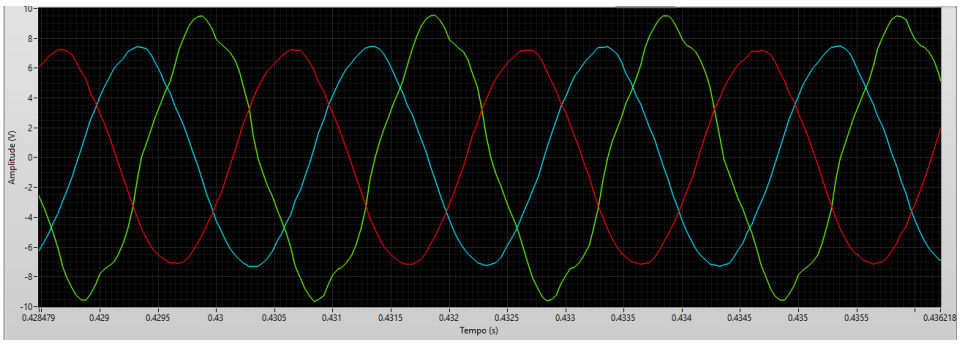


*Figura 38 - Raw file*

Após a obtenção das ondas em função do tempo é então necessário convertê-las para o domínio da frequência de forma a obter um espectro com as principais frequências em que seja possível identificar as falhas do ativo (Figura 39).

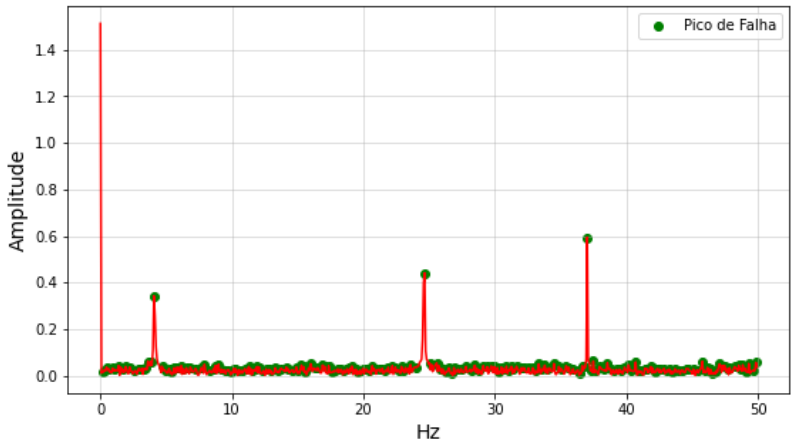


*Figura 39 - Espectro com os principais picos de falha*

Após o algoritmo ter processados o sinal e criado o espectro com as principais frequências do ativo, foi necessário adicionar-lhe algumas funcionalidades de modo a que este consiga identificar as frequências de falha no espectro.

Como foi demonstrado nos capítulos anteriores, a frequência de 4.1 Hz diz respeito a uma falha nas correias do ativo e a 24.5 Hz uma falha mecânica, no entanto, para se obter esta conclusão foi necessária a informação de uma série de parâmetros específicos sobre o ativo. Assim, o algoritmo antes de realizar a identificação dos picos de falha, terá primeiro que pedir ao utilizador que insira os respetivos valores dos parâmetros, para que este possa calcular a frequência de falha de modo a identifica-la automaticamente.

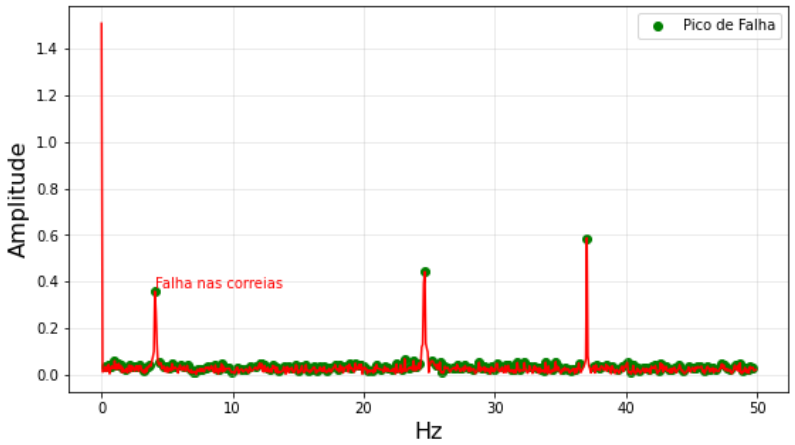


*Figura 40 - Identificação de uma falha no espectro*

Como podemos verificar através da Figura 40, o algoritmo foi capaz de identificar todos os picos mais elevados bem como identificar e classificar a frequência 4.1 Hz como a frequência de falha das correias.

Contudo, a falha nem sempre surge na frequência 4.1 Hz, por vezes surge a 4 Hz ou mesmo a 4.2 Hz, por conta de alguns desvios de processamento ou pequenos erros no sinal, o que faz com que seja assim necessário ajustar o algoritmo para que não se restrinja apenas à frequência 4.1 Hz, mas que procure num intervalo de valores entre 4 e 4.2 Hz.

### 5.1.1 – Introdução de várias frequências de falha

Visto o trabalho em questão ser especificamente com as componentes de falha do ativo ***ITK Ventilationsanlaeg Smelt***, o algoritmo foi desenvolvido segundo as suas necessidades, no entanto, este necessita de ser robusto o suficiente para que atenda às necessidades não só deste ativo como de qualquer outro, permitindo assim identificar e classificar qualquer uma das falhas que foram identificadas no Capítulo 4.

Assim, o algoritmo foi novamente atualizado de modo a que o utilizador tenha a possibilidade de inserir todos os parâmetros que são necessários aos cálculos das frequências de falhas identificadas no Capítulo 4. Importa realçar que muitas vezes é difícil obter a informação de certos parâmetros sobre o ativo e por conta disso o algoritmo foi pensado de modo a que este tenha a capacidade de calcular e identificar apenas as frequências de falhas nas quais lhe são dadas informações (Figura 41).

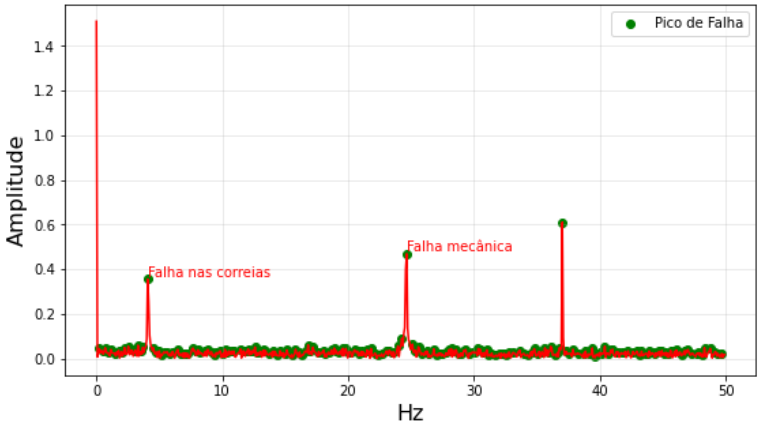


*Figura 41 - Identificação de múltiplas falhas no espectro*

Contudo, após o algoritmo ter a capacidade de identificar múltiplas falhas no ativo, entendeu-se que seria muito interessante existir a possibilidade de comparar espectros em sucessivas amostras, ou seja, basicamente sempre que o algoritmo recebesse uma nova amostra o algoritmo iria não só identificar todas as múltiplas frequências de falha como também compará-las com a amostra anterior, permitindo assim compreender se as frequências de falha estão a aumentar/diminuir, bem como a sua percentagem de aumento/diminuição.

Vale realçar que o algoritmo apenas irá realizar esta comparação caso o espectro inicial tenha uma amplitude superior a 0.2 nas frequências de falha, caso contrário apenas irá identificar as frequências de falha do novo espectro (Figura 42).

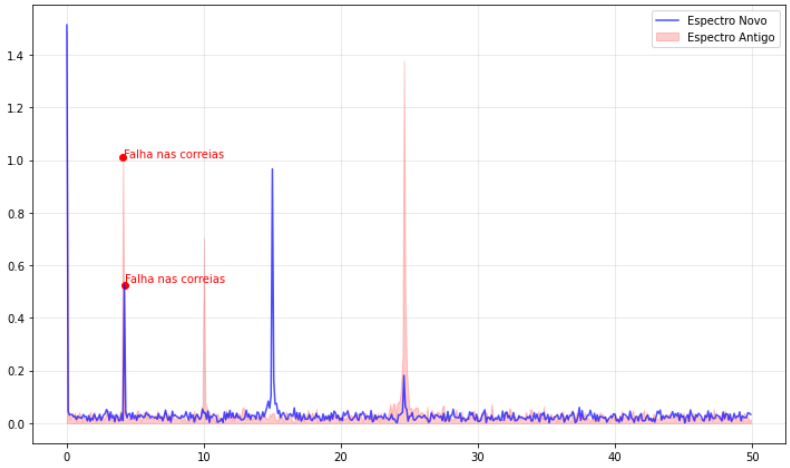


*Figura 42 - Comparação de espectros*

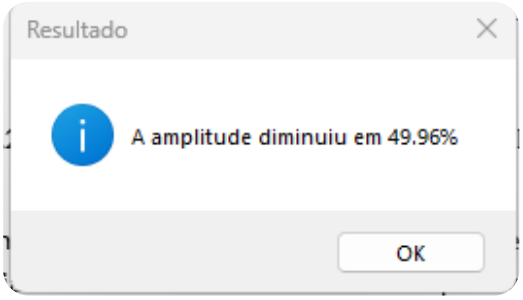


*Figura 43 - Mensagem recebida pelo utilizador*

## 5.2 – Base de dados para a predição da falha nas correias

Esta seção apresenta uma análise detalhada dos dados obtidos por meio de um ficheiro *csv*, extraído da plataforma ***ePreditMnt***. A extensa série temporal abrange aproximadamente dois anos e consiste no conjunto de espectros do ativo, ***ITK Ventilationsanlaeg Smelt***, ao longo do período. Nesta base de dados estão presentes todas as frequências, bem como as correspondentes amplitudes ao longo de todo o período (Tabela 5).

*Tabela 5 - Base de dados*

| ***Tempo*** | ***Frequência*** | ***Amplitude*** |
|---|---|---|
| nov/2023 | 0 | 100 |
| nov/2023 | 0.1 | 0.055 |
| nov/2023 | 0.2 | 0.112 |
| nov/2023 | 0.3 | 0.137 |
| nov/2023 | 0.4 | 0.061 |
| nov/2023 | 0.5 | 0.133 |
| nov/2023 | 0.6 | 0.041 |
| nov/2023 | 0.7 | 0.085 |
| nov/2023 | 0.8 | 0.099 |
| nov/2023 | 0.9 | 0.049 |
| nov/2023 | 1 | 0.063 |
| nov/2023 | 1.1 | 0.034 |
| nov/2023 | 1.2 | 0.011 |
| nov/2023 | 1.3 | 0.078 |
| ……. | ……. | ……. |
| ……. | ……. | ……. |
| jan/2022 | 24 | 0.229 |
| jan/2022 | 25 | 0.442 |
| jan/2022 | 26 | 0.296 |
| jan/2022 | 27 | 0.193 |
| jan/2022 | 28 | 0.015 |
| jan/2022 | 29 | 0.009 |
| jan/2022 | 30 | 0.004 |

Analisando o *dataset* apresentado na Tabela 5 é possível verificar que as principais variáveis em estudo deste ativo são:

- **Tempo**: Indica a data da observação, representada no formato mês/ano.
- **Amplitude:** valor máximo atingido por uma determinada frequência
- **Frequência:** valor correspondente a uma determinada falha no ativo

A Tabela 5 apresenta a variação das amplitudes de diferentes frequências ao longo do tempo. No entanto, para este estudo apenas interessa a frequência da falha que queremos prever, como exemplificado anteriormente, a falha das correias, que se encontra numa gama de valores entre 4 e 4.2 Hz, surgindo assim a Tabela 6.

*Tabela 6 - Nova base de dados com as frequências necessárias*

| ***Tempo*** | ***Frequência*** | ***Amplitude*** |
|---|---|---|
| nov/2023 | 4 | 0.063 |
| nov/2023 | 4.1 | 0.058 |
| nov/2023 | 4.2 | 0.521 |
| nov/2023 | 4 | 0.042 |
| nov/2023 | 4.1 | 0.062 |
| nov/2023 | 4.2 | 0.231 |
| nov/2023 | 4 | 0.163 |
| nov/2023 | 4.1 | 0.039 |
| nov/2023 | 4.2 | 0.981 |
| nov/2023 | 4 | 0.083 |
| nov/2023 | 4.1 | 0.043 |
| nov/2023 | 4.2 | 1.323 |
| nov/2023 | 4 | 0.068 |
| nov/2023 | 4.1 | 0.045 |
| ……. | ……. | ……. |
| ……. | ……. | ……. |
| jan/2022 | 4 | 0.231 |
| jan/2022 | 4.1 | 0.926 |
| jan/2022 | 4.2 | 1.401 |
| jan/2022 | 4 | 0.075 |
| jan/2022 | 4.1 | 0.923 |
| jan/2022 | 4.2 | 1.02 |
| jan/2022 | 4 | 1.912 |

**5.2.1 – Estatística Descritivas**

Tal como referido anteriormente, as métricas estatísticas, como média, mediana, desvio padrão, mínimo e máximo, fornecem uma base numérica sólida para avaliar a variabilidade, identificar padrões e compreender a evolução temporal dos principais indicadores da condição do ativo.

No entanto, neste caso visto já sabermos quais são as frequências de falha, apenas fará sentido avaliar e calcular estas estatísticas para a variável *amplitude*.

A Tabela 7, apresenta valores destas métricas para a variável *amplitude*. A interpretação destas métricas é crucial para a compreensão da condição do ativo relativamente a esta falha especifica e orientação de estratégias ao nível da manutenção.

*Tabela 7 - Estatísticas Descritivas*

| ***Métrica*** | ***Amplitude*** |
|---|---|
| ***Média*** | 0.443 |
| ***Mediana*** | 0.250 |
| ***Desvio Padrão*** | 0.424 |
| ***Max*** | 2.253 |
| ***Min*** | 0.002 |

#### 5.2.2 – Tendência Temporal

De forma a ser possível interpretar a evolução da amplitude da falha nas correias do ativo, ***ITK Ventilationsanlaeg Smelt,*** foi criado um gráfico que representa um fator de severidade das correias para que seja mais fácil identificar a sua tendência (Figura 44).

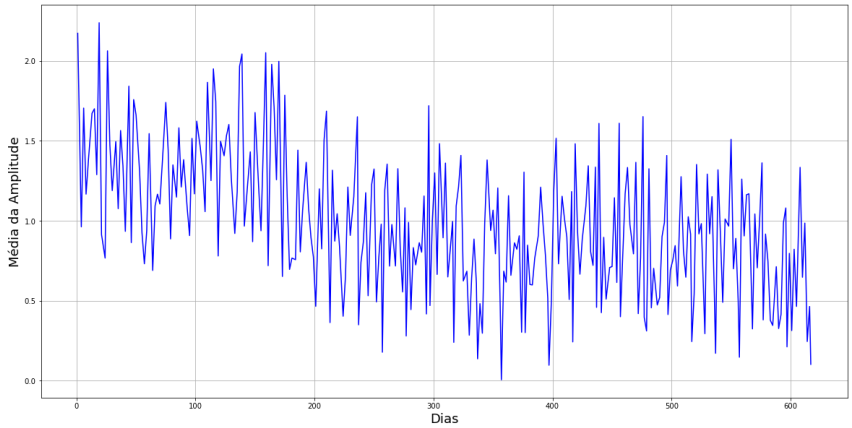


*Figura 44 -Valor da amplitude ao longo do tempo*

### 5.3 – Modelos de Previsão

Tendo em conta a procura por compreender e antecipar padrões em séries temporais, a aplicação dos modelos de previsão torna-se uma peça-chave em diversas áreas da pesquisa. Estes modelos desempenham um papel crucial ao permitir a identificação de tendências, padrões sazonais e comportamentos subjacentes, proporcionando uma base sólida para decisões mais informadas.

A previsão temporal procura estimar valores futuros com base em padrões identificados nos dados históricos. Num cenário de constante evolução, a capacidade de antecipar eventos futuros torna-se inestimável, permitindo uma melhor alocação de recursos, otimização de processos e mitigação de riscos.

Enquanto modelos tradicionais, como o ARIMA, oferecem interpretabilidade e simplicidade, modelos avançados de *machine learning*, como LSTM, procuram lidar com complexidades não

lineares e recolher relações temporais mais indicadas. A escolha entre estas abordagens depende da natureza dos dados e dos objetivos específicos da previsão [45].

Este capítulo aborda em detalhe a aplicação prática desses dois modelos, ARIMA e LSTM. Ao compreender as nuances de cada modelo, será possível extrair *insights* valiosos para aprimorar a capacidade preditiva em cenários diversos (Tabela 8).

*Tabela 8 - Comparação modelos de previsão*

| Modelo | Objetivo | Referencias |
|---|---|---|
| ARIMA | Modelagem de séries temporais estacionárias e previsão de tendências e sazonalidades. | [45] [46][47] [48] |
| LSTM-Sigmoid | Recolha de padrões de longo prazo em dados sequenciais, útil para problemas de previsão onde a relação entre as variáveis é não linear. A ativação sigmoid é eficaz na modelagem de relações de dependência suaves. | [49][50] |
| LSTM-Tanh | Similar à LSTM - sigmoid, mas a função de ativação Tanh tem um intervalo maior (-1 a 1), o que pode ser útil para lidar com gradientes mais estáveis durante o treino. | [49] [51] [52] |
| LSTM-ReLu | A função de ativação ReLU é útil para lidar com problemas de desaparecimento de gradiente e pode ajudar a acelerar o treino. É usado principalmente quando se deseja obter padrões de curto prazo em dados sequenciais, priorizando ativações positivas. | [49] [53] |

#### 5.3.1 – Modelo ARIMA

Os modelos ARIMA são modelos estatísticos lineares usados para análise de séries temporais. A abreviação ARIMA, em inglês significa *Auto-Regressive Integrated Moving Average Model*, ou seja, autorregressivo, integrado e médias móveis. Os termos autorregressivos correspondem a desfasamentos da série e as médias móveis são os desfasamentos dos erros aleatórios [47].

Os modelos ARIMA (p, d, q) são, em teoria, a classe mais geral dos modelos utilizados para a previsão de uma série temporal que, não sendo estacionárias podem ser estacionadas por diferenciações.

Os modelos ARIMA são uma generalização dos modelos ARMA que visam tornar o processo estacionário através de uma série de operações.

Os desfasamentos da série diferenciada que aparecem na equação de previsão são chamados de termos autorregressivos. Os desfasamentos dos erros de previsão são chamados termos da média móvel e uma série temporal que necessita de ser diferenciada para ser estacionária é dita ser uma versão integrada de uma série estacionária.

Ao analisar o gráfico de uma série temporal, se os dados indicarem uma não estacionaridade, procede-se à sua diferenciação, para transformar a série não estacionária numa série estacionária [47].

Far-se-á uma diferenciação de 1ª ordem se a série está a crescer a uma taxa constante e uma diferenciação de 2ª ordem se a série estiver a crescer com uma taxa de crescente.

$$\begin{gathered} W_t = \nabla^d X_t = (1-B)^d X_t \\ X_t = \alpha_1 W_{t-1} + \cdots + \alpha_1 W_{t-1} + \alpha_t + \beta_1 a_{t-q} \\ \emptyset(B)(1-B)^d X_t = \emptyset(B)_{\epsilon t} \end{gathered} \tag{15}$$

Um modelo ARIMA não sazonal é classificado como um modelo ARIMA (*p, d, q*), em que:

*p* é o número de termos autorregressivos;
*d* é o número de diferenciações para que a série se torne estacionária;
*q* é o número de termos de médias móveis.

Os termos *p*, *d* e *q* são todos inteiros, maiores ou iguais a zero.

Assim, modelos aleatórios de tendências, modelos autorregressivos e os modelos de alisamento exponencial são todos casos especiais de modelos ARIMA.

Considerando $Z_t$ uma série temporal não estacionária, $W_t = \Delta = Z_t - Z_{t-1}$, será a série diferenciada, em vez de $Z_t$ .

Assim sendo, $W_d^t = \Delta^d Z_t$, será a série temporal diferenciada *d* vezes $Z_t$.

#### *5.3.1.1* – Identificação da Ordem

A identificação das ordens (p, d, q) é crucial e pode ser realizada por meio de análise de autocorrelação (ACF) e autocorrelação parcial (PACF).

Sendo que a função de autocorrelação (ACF) é uma medida estatística que avalia a correlação entre os valores de uma série temporal e os seus próprios valores em atrasos específicos. Esta análise permite identificar padrões temporais, sazonalidades e estruturas subjacentes nos dados. A fórmula da ACF compara os valores originais da série com as suas versões atrasadas, fornecendo assim uma visão quantitativa da dependência temporal.

$$pk = \frac{\sum_{t=k+1}^{n}\left(Y_t - \overline{Y}\right)\left(Y_{t-k} - \overline{Y}\right)}{\sum_{t=k+1}^{n}\left(Y_t - \overline{Y}\right)^2} \tag{16}$$

Um valor elevado na autocorrelação sugere uma forte correlação entre os valores nesse intervalo de tempo. Por outro lado, valores próximos de zero indicam pouca correlação entre valores em diferentes momentos.

O termo *k*, frequentemente chamado de *lag* representa a distância temporal entre os valores comparados. Por fim, a análise da Função de Autocorrelação Parcial (PACF) também é valiosa, pois retira as contribuições dos pontos intermédios, permitindo assim uma avaliação mais específica da correlação [46].

#### *5.3.1.2* – Análise do modelo ARIMA

Depois de realizados os dois passos anteriores é necessário verificar se este se encontra adequado aos dados. Assim sendo, é através da análise dos resíduos que é possível fazer o diagnóstico do modelo.

I. Testes de Box-Pierce e Ljung-Box

Estes testes são uma ferramenta útil para testar o ajuste do modelo, que se baseia numa série temporal. Este teste é aplicado aos resíduos de uma série temporal, após o ajuste do modelo. São analisadas *m* autocorrelações dos resíduos e quanto menor for esse valor melhor o ajustamento do modelo escolhido [47].

A estatística de Box-Pierce pode ser definida da seguinte forma:

$$Q = N \sum_{k=1}^{m} \hat{r}_k^2 \tag{17}$$

onde:

*N* – é o tamanho da amostra;

*m* – a duração do desfasamento;

$\hat{r}_k$- autocorrelação estimada da série.

Para grandes amostras, a estatística *Q* distribui-se segundo uma distribuição qui-quadrado com *m* graus de liberdade.

O teste de Ljung-Box (LB) é uma alteração do teste de Box-Pierce, tornando-o mais generalizado.

A estatística de Ljung-Box pode se expressa como:

$$LB = N(N+2) \sum_{k+1}^{m} \frac{\hat{r}_k^2}{N-k} \tag{18}$$

A distribuição da estatística *LB* também é qui-quadrado com *m* graus de liberdade.

A hipótese nula para os dois testes refere a não existência de uma autocorrelação conjunta dos resíduos. Esta hipótese será rejeitada se o valor da estatística do teste for superior ao valor

crítico da distribuição qui-quadrado para um determinado nível de significância $\alpha$ e grau de liberdade, isto quer dizer que as autocorrelações para um determinado número de *lags* poderão ser significativamente diferentes de zero, mostrando que os valores não são aleatórios e independentes ao longo do tempo.

II. Critério de Informação de Akaike (AIC)

O Critério de Informação de Akaike (AIC) baseia-se na existência de um modelo "real" que é desconhecido, mas permite descrever os dados. Este critério minimiza a divergência de Kullback-Leibler [47] [48].

A estimativa do AIC para um determinado modelo é dada por:

$$AIC = -2L + 2K \tag{19}$$

Onde:

$L$ é a log-verossimilhança máxima

$K$ é o número de parâmetros do modelo.

O modelo com menor valor de AIC é considerado o modelo de melhor ajuste.

III. Critério de informação Bayesiano (BIC)

Este critério também denominado de Schwarz é definido como a estatística que maximiza a probabilidade de se identificar o melhor modelo dentro dos que se estão a estudar [48].

A estimativa do BIC para um determinado modelo é dada por:

$$AIC = -2L + 2Kln(n) \tag{20}$$

Sendo:

$L$ é a log-verossimilhança máxima;

$K$ é o número de parâmetros do modelo;

$n$ o número de observações.

Tal como no critério anterior, o modelo que apresentar menor valor da estimativa BIC é considerado o de melhor ajuste.

IV. Critério Informações Hannan-Quinn (HQC)

O critério de informação Hannan-Quinn é outro instrumento de seleção de modelos. É uma alternativa ao critério de informação de Akaike (AIC) e critério de informação Bayesiano (BIC) [47].

A estimativa do HQC para um determinado modelo é dada por:

$$HQC = -2L + 2Kln(ln(n)) \tag{21}$$

sendo:

*L* é a log-verossimilhança máxima;

*K* é o número de parâmetros do modelo;

*n* o número de observações.

#### 5.3.2 – Modelos LSTM

As *LSTMs*, são um tipo especial de RNN, capazes de aprender dependências a longo prazo. Foram introduzidas por Hochreiter & Schmidhuber [48] e foram aprimoradas e popularizadas por várias pessoas em trabalhos seguintes. Funcionam excecionalmente bem numa grande variedade de problemas sendo atualmente amplamente utilizadas.

As LSTMs foram concebidas para evitar o problema da dependência a longo prazo. Memorizar a informação por longos períodos de tempo é o seu comportamento padrão, ou seja, não é algo com que o modelo luta para aprender.

Todas as redes neuronais recorrentes têm a forma de uma cadeia de módulos repetidos da rede neuronal. Nas RNNs convencionais, este módulo repetido terá uma estrutura muito simples, como mostra a Figura 45.

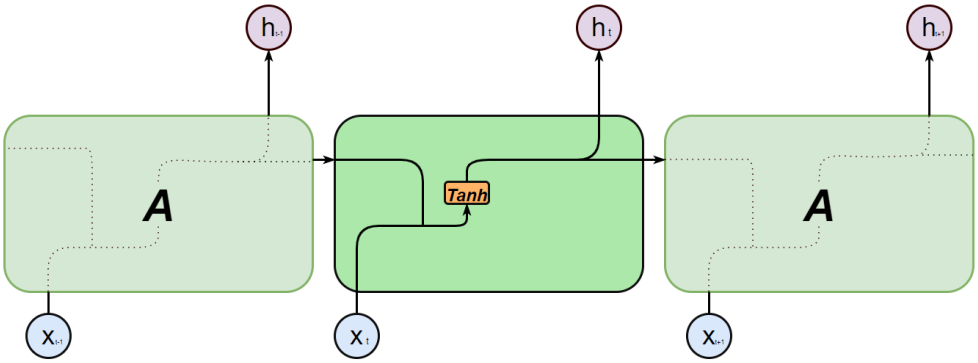


*Figura 45 - Estrutura de uma rede neuronal recorrente*

As LSTM também têm essa estrutura em cadeia, mas o módulo repetido possui uma estrutura diferente. Em vez de ter uma única camada da rede neuronal, existem quatro, interagindo de uma maneira muito especial, como mostra a Figura 46.

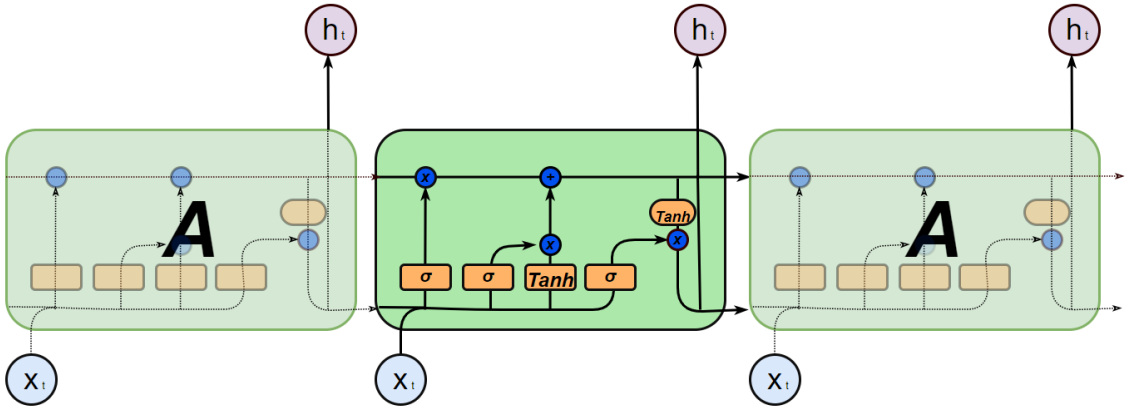


*Figura 46 - Estrutura de uma rede neuronal LSTM*

A chave para a LSTM é o estado da célula, representado pela linha horizontal que percorre o topo do diagrama.

O estado da célula pode ser imaginado como uma correia transportadora que percorre diretamente toda a cadeia, com apenas algumas interações lineares mínimas. Sendo assim, é fácil para a informação simplesmente fluir sem alterações, (Figura 47).

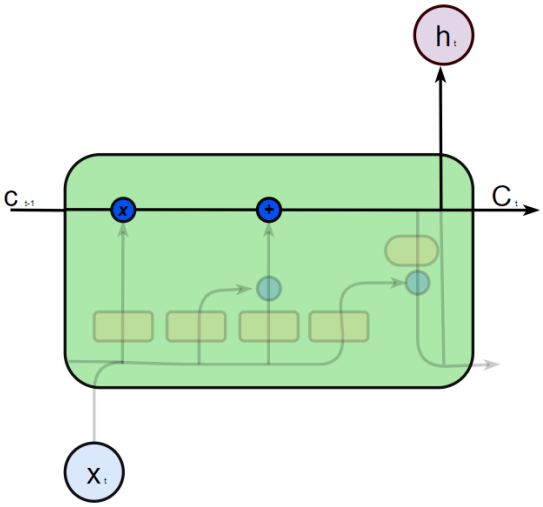

*Figura 47 - Transporte de informação - LSTM*

A LSTM tem assim a capacidade de remover ou adicionar informação ao estado da célula, cuidadosamente regulado por estruturas chamadas *gates*.As *gates* são uma forma de permitir opcionalmente a passagem de informação. Estas são compostas por uma camada de uma rede neuronal sigmoidal e uma operação de multiplicação ponto a ponto.

A camada sigmoidal produz números entre zero e um, descrevendo quanto de cada componente deve ser permitido passar. Um valor de zero significa "não permitir nada", enquanto valor de um significa "permitir tudo".Assim, uma LSTM tem três dessas *gates*, para proteger e controlar o estado da célula.

A primeira etapa do nó dentro da LSTM, exemplificada na Figura 48, é escolher qual informação será esquecida pela rede, isto é, qual a informação que possui menos relevância.

$$F_t = \sigma\left(W_f \times [h_{t-1}, x_t]\right) + b_f \qquad (22)$$

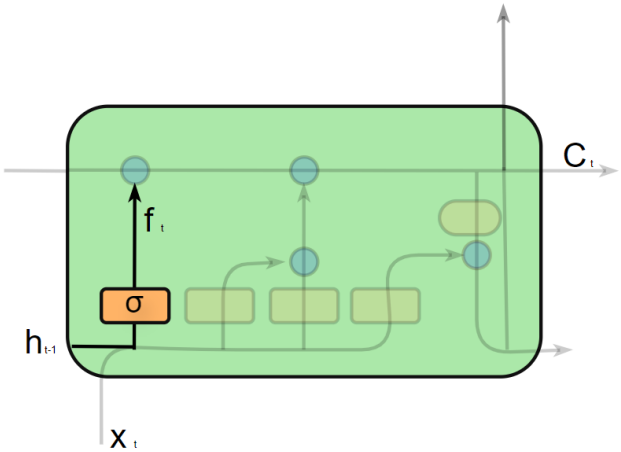


*Figura 48 - Primeira gate do neurónio - LSTM*

Na segunda etapa, exemplificada na Figura 49, o nó verifica quais dados que irá armazenar. Esta etapa possui duas partes, sendo que a primeira possui duas camadas. A primeira camada, a *sigmoid* de entrada decide os dados que serão atualizados com a seguinte função:

$$I_t = \sigma(W_i \times [h_{t-1}, x_t]) + b_i \tag{23}$$

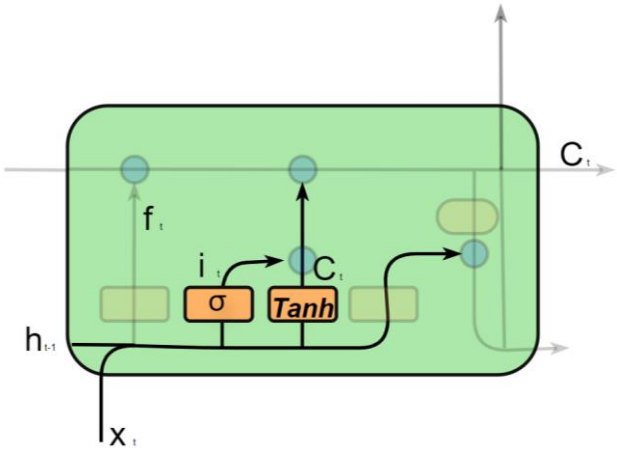


*Figura 49 - Segunda gate do neurónio - LSTM*

Na segunda camada, com a função de ativação, é criado um vetor com os novos valores que serão adicionados ao estado do nó.

Após a segunda etapa atualiza-se o estado do nó anterior para o novo estado do nó correspondente com base nos resultados das etapas anteriores.

Na última etapa é então decidido os dados que o nó irá produzir. Uma camada *sigmoid* irá então decidir o que será produzido e em seguida adiciona-se o estado atual do nó por meio de uma função de ativação, conforme ilustrado na Figura 50, com a função da tangente hiperbólica, multiplicando o valor, de modo a que o nó apenas reproduza os dados estabelecidos.

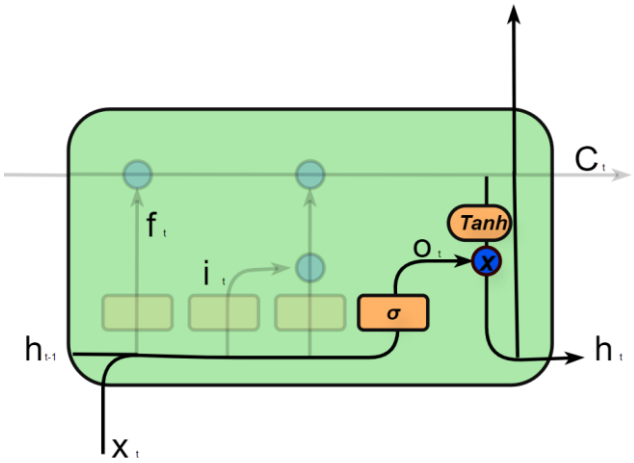


*Figura 50 - última etapa do neurónio - LSTM*

**5.3.2.1 – Funções de Ativação**

As funções de ativação são essenciais e estão presentes em cada neurónio da rede neuronal, com o objetivo de adicionar uma componente não linear onde a rede consiga aprender mais do que apenas relações lineares entre as variáveis dependentes e independentes [50].

I. Função *Sigmoid*

A função logística referenciada pelas bibliotecas como função *Sigmoid* possui um formato sigmoidal (Figura 51) [50] .

A função é dada como:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \tag{24}$$

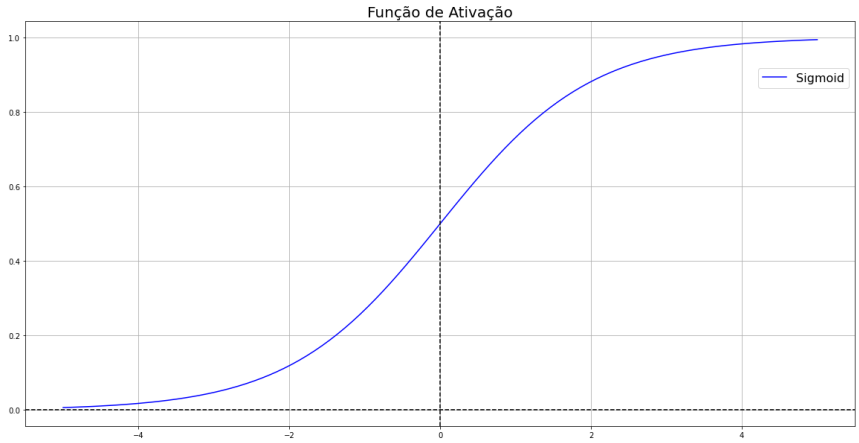


*Figura 51 - Curva Sigmoid*

A função possui um intervalo de (0,1).

## II. Tangente Hiperbólica

A função da tangente hiperbólica é outra função sigmoidal utilizada em casos similares às aplicações que são atendidas pela função logística (Figura 52) [51] [52], podendo ser definida como:

$$tanh(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}} \tag{25}$$

A tangente hiperbólica possui um intervalo [-1,1].

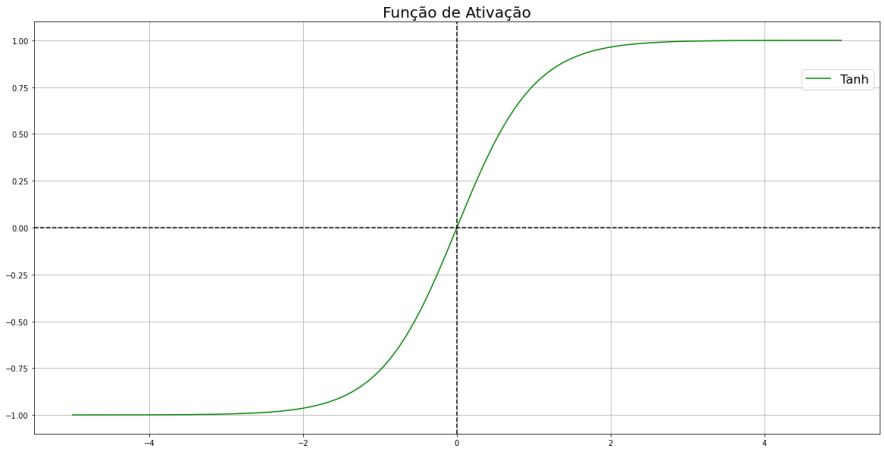


*Figura 52 - Curva Tanh*

## III. Unidade Linear Retificada

A função Unidade Linear Retificada, conhecida como *ReLU* (Figura 53), abreviação para *Rectified Linear Unit*, gera valores entre [0, ∞ [, retornando a zero para qualquer valor negativo [53]. É uma função computacionalmente leve; porém, para valores negativos o neurónio tem a sua saída em zero. Pode ser definida como:

$$f(x) = max\ (0, x) \tag{26}$$

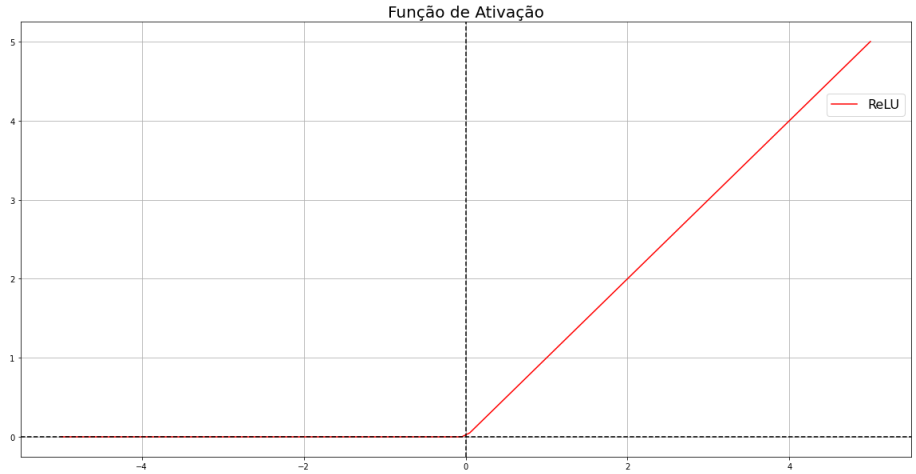


*Figura 53 - Curva ReLU*

#### 5.3.3 – Métricas de avaliação

##### 5.3.3.1 – MAPE

O MAPE, ou Erro Percentual Absoluto Médio, é uma métrica amplamente utilizada na avaliação de modelos de previsão. Este fornece uma medida da precisão das previsões em termos percentuais, o que é particularmente útil quando se trabalha com séries temporais e é necessário avaliar o erro relativo em relação aos valores reais.

O cálculo do MAPE é direto e intuitivo. Para cada ponto de dados na amostra de teste, calculando a diferença percentual absoluta entre o valor previsto e o valor real, é obtida a média dessas diferenças [54]. A fórmula para o cálculo do MAPE é dada por:

$$MAPE = \frac{1}{n} \times \sum_{i=1}^{n} \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \tag{27}$$

onde:

- $n$ é o número total de observações na amostra de teste,
- $y_i$ representa o valor real na posição $i$,
- $\hat{y}_i$ representa o valor previsto na posição $i$.

Essencialmente, o MAPE mede a precisão média das previsões em termos percentuais. Valores mais baixos de MAPE indicam uma melhor concordância entre os valores previstos e os valores reais, enquanto valores mais altos indicam uma maior discrepância entre eles.

Ao incorporar o MAPE na avaliação dos modelos LSTM, é possível quantificar de forma eficaz a precisão das previsões e identificar áreas de melhoria ou ajustes no modelo.

##### 5.3.3.2 – RMSE

O RMSE, ou Erro Quadrático Médio da Raiz, é outra métrica popular e amplamente utilizada na avaliação de modelos de previsão. Este fornece uma medida da dispersão dos erros de previsão em relação aos valores reais, levando em consideração tanto a magnitude quanto a direção desses erros.

A fórmula para o cálculo do RMSE é expressa como:

$$\sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2} \tag{28}$$

onde:

- $n$ é o número total de observações na amostra de teste;
- $y_i$ representa o valor real na posição $i$;
- $\hat{y}_i$ representa o valor previsto na posição $i$.

O RMSE é útil porque fornece uma medida de erro que está na mesma unidade dos dados originais, facilitando assim a interpretação direta. Quanto menor o valor do RMSE, melhor o desempenho do modelo, indicando uma concordância mais próxima entre os valores previstos e os valores reais.

Ao incorporar o RMSE na avaliação de modelos de previsão é possível avaliar a dispersão dos erros de previsão de forma eficaz, identificar áreas onde o modelo pode estar subestimando ou superestimando e ajustar adequadamente os parâmetros do modelo para melhorar o seu desempenho.

É importante observar que o RMSE é sensível a valores discrepantes (*outliers*) e tende a penalizar os erros maiores de forma mais significativa do que erros menores.

#### 5.3.3.3 – Accuracy

A *accuracy* é uma métrica fundamental para avaliar a qualidade geral dos modelos de previsão.

Matematicamente, a *acccuracy* é calculada como:

$$Accuracy = \frac{Nºdeprevisõescorretas}{Totaldeobservações} \times 100\% \qquad (29)$$

onde:

- O *Número de previsões corretas* é o número de observações para as quais o modelo previu a classe correta;
- O *Total de observações* é o número total de observações na amostra de teste.

Uma *accuracy* alta indica que o modelo está a fazer previsões precisas e está correto na maioria das vezes, enquanto uma *accuracy* baixa sugere que o modelo está com dificuldades em prever corretamente as observações.

# CAPÍTULO 6 - Análise de Resultados

Neste capítulo é apresentada uma análise detalhada dos resultados obtidos através dos modelos desenvolvidos anteriormente. A implementação e avaliação destes modelos visam fornecer uma compreensão abrangente do desempenho, capacidades e limitações de cada abordagem no intuito de identificar e classificar espectros e na previsão baseada em séries temporais.

Serão exploradas métricas de desempenho, destacando a precisão e eficácia de cada modelo em diferentes cenários. Além disso, são analisadas cuidadosamente todas as previsões realizadas em comparação com os valores reais, identificando padrões, tendências e possíveis áreas de melhoria.

Ao longo deste Capítulo é possível quantificar a precisão numérica e fornecer uma interpretação significativa dos resultados, contextualizando-os dentro do domínio específico da aplicação. A compreensão profunda dos resultados é crucial para tirar *insights* valiosos e orientação futura.

## 6.1 – Série temporal

Ao analisar o gráfico da Figura 54 é preciso ter em consideração que este corresponde a uma falha específica do ativo em estudo. No entanto, vale a pena realçar que esta e muitas outras falhas atualmente são possíveis de analisar através do indicador da variação da carga, disponível na plataforma ***ePreditMnt***.

Assim, analisando estes dois gráficos em simultâneo é possível perceber a existência de uma semelhança entre os mesmos.

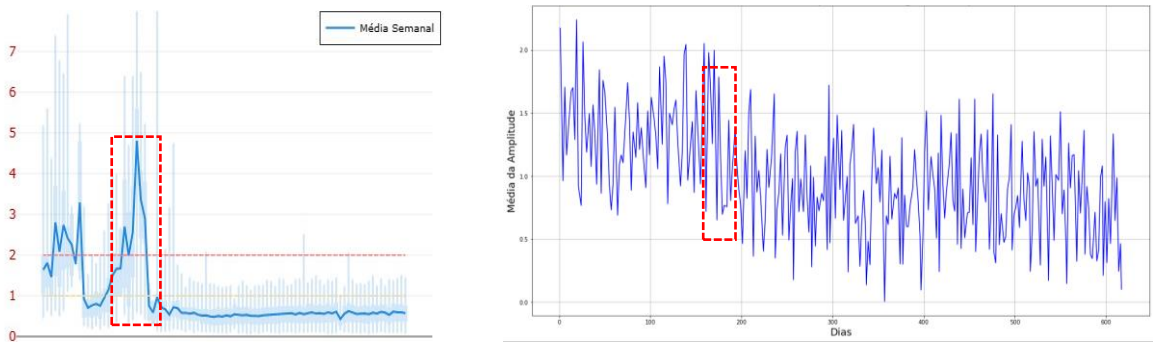


*Figura 54 - Comparação entre o Fator de severidade da variação da carga e a falha nas correias*

No entanto, é possível verificar que a descida registada no indicador da falha das correias é substancialmente menor do que o registado no indicador da variação de carga. Isto deve-se à existência de uma componente espectral muito elevada a cerca de 0.8 Hz, que influencia drasticamente este indicador, fazendo com que a sua descida após a reparação do ativo seja bastante acentuada (Figura 55).

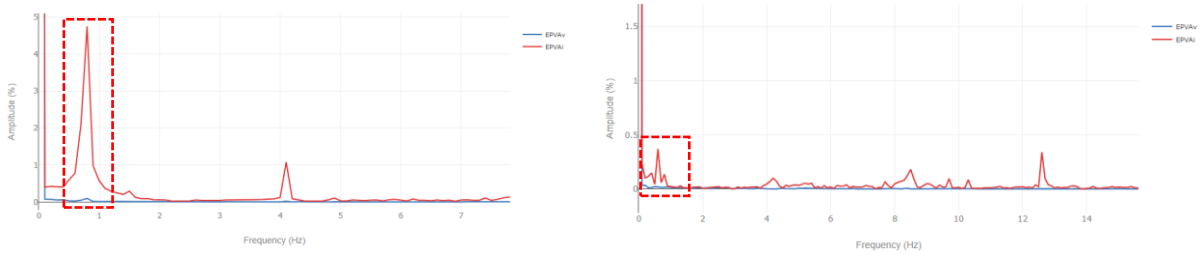


(a) (b)

*Figura 55 - Componente 0.8 Hz antes (a) e depois (b) da correção do problema no ativo*

Ao analisar o gráfico da série temporal das amplitudes de falha das correias é possível facilmente identificar 3 zonas distintas (Figura 56): A primeira, marcada por valores mais elevados, relativos ao período em que o ativo estava com problemas. Uma segunda zona marcada por um decréscimo, por via da correção do problema do ativo, que levou a uma estabilização dos valores. E, por fim, uma terceira zona onde se verifica um decréscimo das amplitudes.

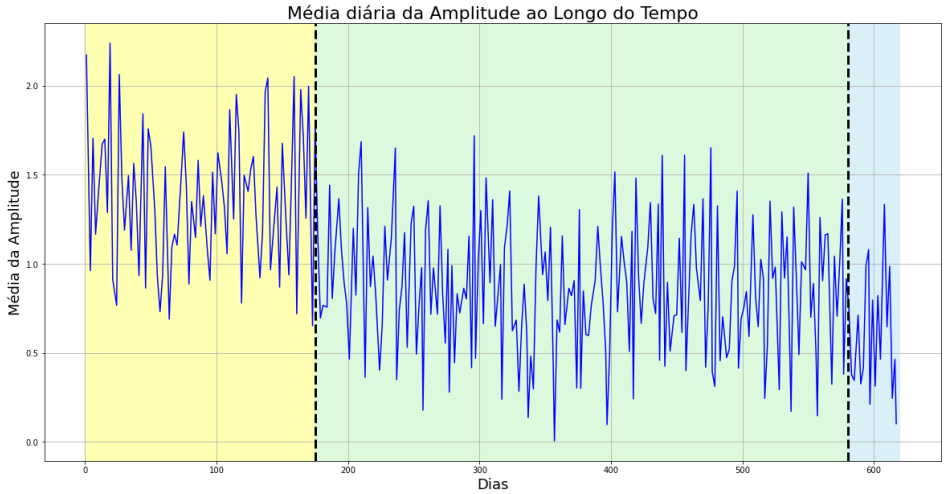


*Figura 56 - Principais zonas identificadas no fator de severidade das correias*

Nesta última zona, este decréscimo é relativamente estranho, pois do ponto de vista do indicador significaria que esta falha ao longo do tempo estaria a melhorar, o que é intrigante tendo em conta a curva expectável do ciclo de vida de um ativo [55].

No entanto, olhando para os principais indicadores do ***ePreditMnt***, na figura 33, verifica-se que nesse mesmo período existiu um aumento bastante significativo no indicador mecânico do ativo. A presença desta excentricidade mecânica terá tido um impacto substancial na componente das correias, influenciando assim a sua amplitude na análise espectral, como é possível verificar na Figura 57.

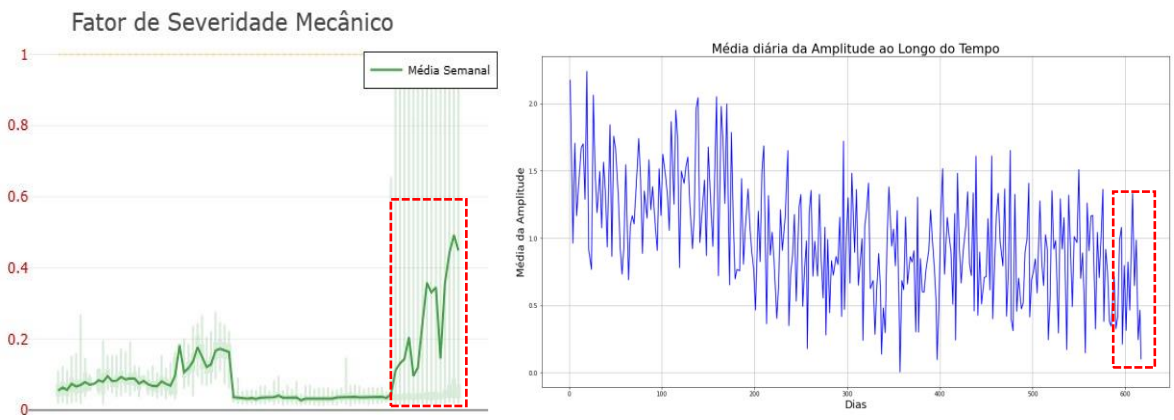


*Figura 57 - Excentricidade mecânica*

## 6.2 – Modelo ARIMA

Após a obtenção do indicador da componente de falha nas correias ao longo do tempo decidiu-se começar o estudo da previsão segundo o modelo ARIMA.

No entanto, como verificado na figura 44, o gráfico apresenta uma grande variabilidade de valores devido à constante variação de carga. Assim, foi possível concluir através da plataforma ***ePreditMnt*** que os valores mais elevados correspondiam a níveis de carga mais elevados e os picos menores a níveis de carga mais baixos. No entanto, de forma a ter previsões mais fidedignas e precisas, procedeu-se a um alisamento dos dados e à remoção dos dados que foram influenciados pela excentricidade mecânica, de modo a tornar mais fácil e fidedigna a análise (Figura 58).

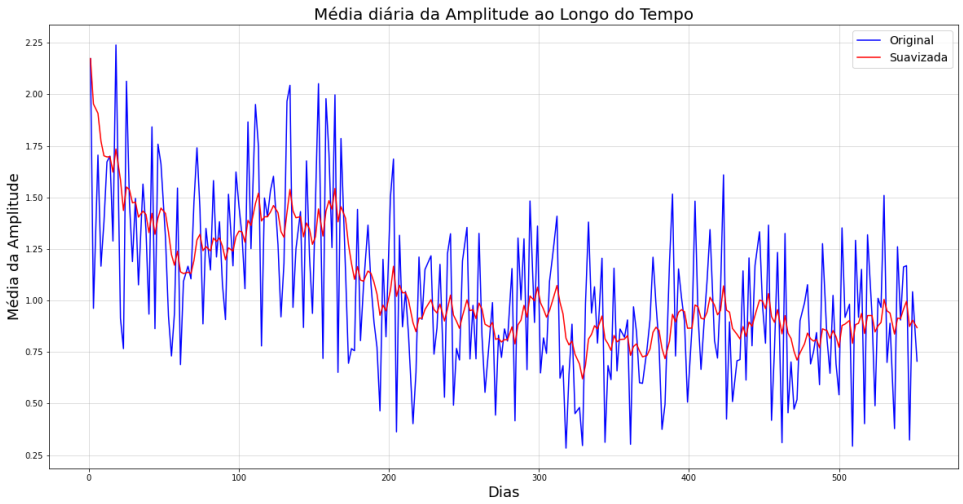


*Figura 58 - Alisamento do fator de severidade das correias*

Após isto, procedeu-se então à elaboração dos gráficos da autocorrelação para definir quais seriam os valores ideais para o método ARIMA (*p*,*d*,*q*) (Figura 59).

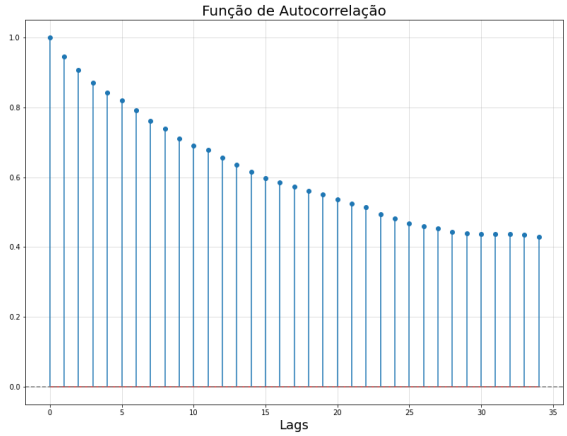


*(a)*

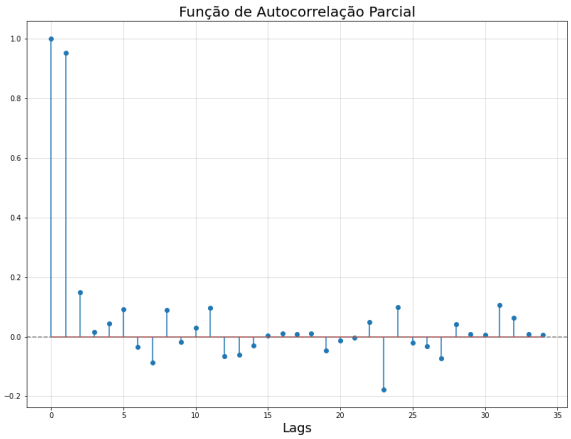


*(b)*

*Figura 59 – Autocorrelação (a) e Autocorrelação Parcial (b)*

Numa série temporal estacionária, as propriedades estatísticas, como média e variância, não mudam ao longo do tempo. Na Figura 58 é possível observar claramente uma mudança sistemática na média e na variância ao longo do tempo. Portanto, é possível concluir que a série não é estacionária. Como o valor no tempo *t* é igual ao valor no tempo *t-1* mais um ruído aleatório, os valores dependem dos seus valores anteriores, resultando assim numa correlação entre valores consecutivos.

Podemos visualizar essa correlação na Figura 59, que mostra os coeficientes de autocorrelação em diferentes intervalos de tempo.

É possível observar uma correlação muito forte entre dois valores consecutivos, porém, à medida que a diferença de tempo (*lag*) aumenta, o coeficiente de autocorrelação diminui, uma vez que a cada instante de tempo introduz um ruído aleatório adicional ao valor inicial.

Depois de analisada a autocorrelação é necessário descobrir de forma iterativa os valores ideais para os valores do modelo ARIMA. Assim, através de um pequeno algoritmo, em que segundo uma série de iterações são calculados os valores ideais de *p*, *d* e *q* para o modelo ARIMA, segundo a base de dados utilizada. Obtêm-se assim os valores de 3, 1, 2 para o modelo, resultando no gráfico da Figura 60.

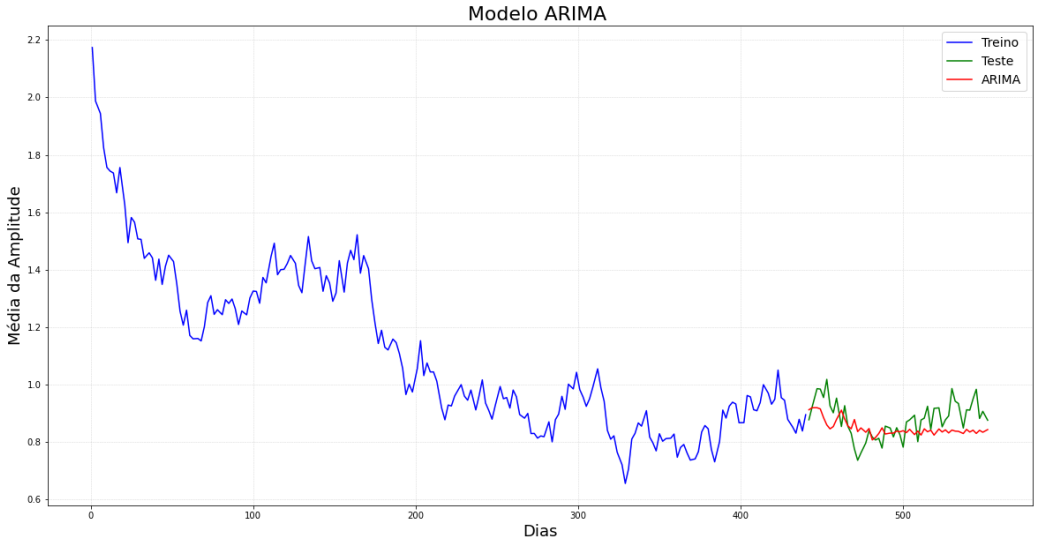


*Figura 60 - Previsão modelo ARIMA*

Com a criação do modelo de previsão foi automaticamente criado um parâmetro no algoritmo para que fosse possível fazer o diagnóstico do modelo.

Assim, analisando os resultados do modelo é possível concluir que:

| Diagnóstico | Resultado |
|---|---|
| *AIC* | -631.491 |
| *BIC* | -628.028 |
| *HQC* | -630.095 |
| *Teste de Ljung-Box / (p)* | 7.83 / (0.07) |

- O AIC penaliza a complexidade do modelo e, neste caso, um valor baixo indica um bom ajuste do modelo. Portanto, -631.491 sugere que o modelo ARIMA tem um bom equilíbrio entre ajuste e complexidade;
- Similar ao AIC, um valor baixo de BIC indica um bom ajuste. Neste caso, -628.028 também sugere um bom ajuste do modelo ARIMA;
- Como o BIC, o HQIC também penaliza a complexidade do modelo. Neste caso, -630.095 também sugere um bom ajuste do modelo ARIMA;
- O valor de Q é 7.83. Um valor *p* menor que 0.05 sugere que há autocorrelação significativa nos resíduos. Portanto, o valor de *p* de 0.07 indica que não há autocorrelação significativa nos resíduos do modelo ARIMA.

## 6.3 – Modelos LSTM

Em seguimento, da previsão realizada anteriormente, procedeu-se à previsão com modelos mais avançados.

Utilizaram-se modelos LSTM, mais precisamente modelos com as funções de ativação *ReLU*, *Sigmoid* e *Tanh*, com os quais se obtiveram as previsões ilustradas nas Figuras 61-71.

I. Função de ativação *ReLu*

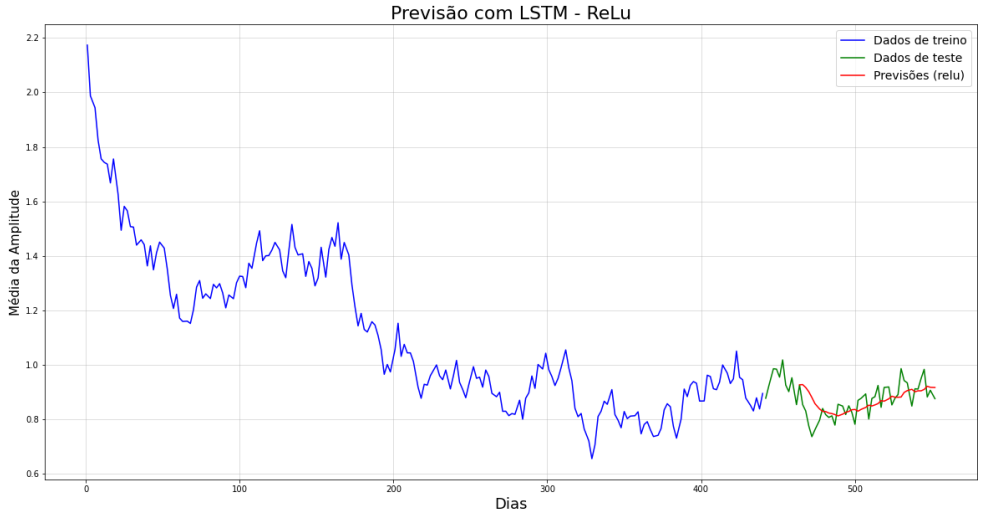


*Figura 61 - Previsão modelo ReLU*

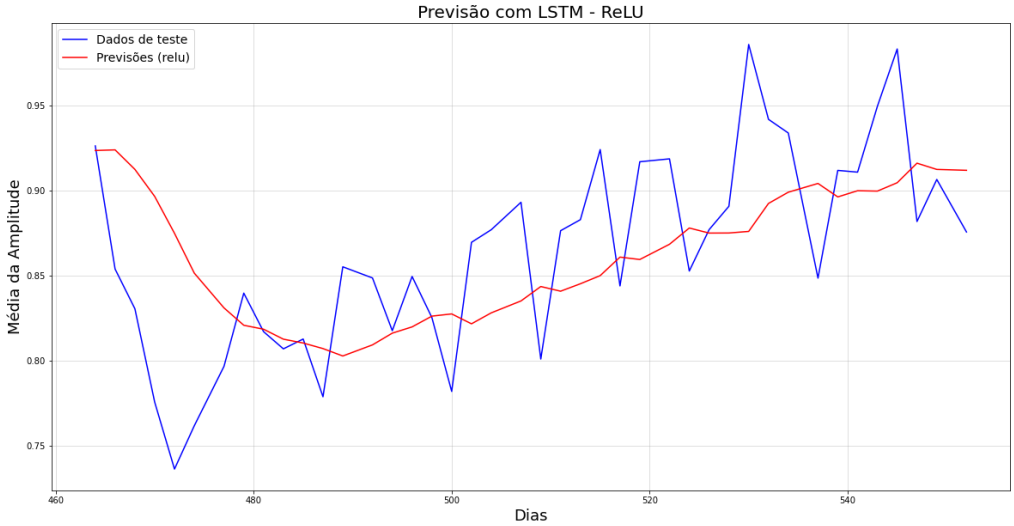


*Figura 62 - Previsão modelo ReLU ao detalhe*

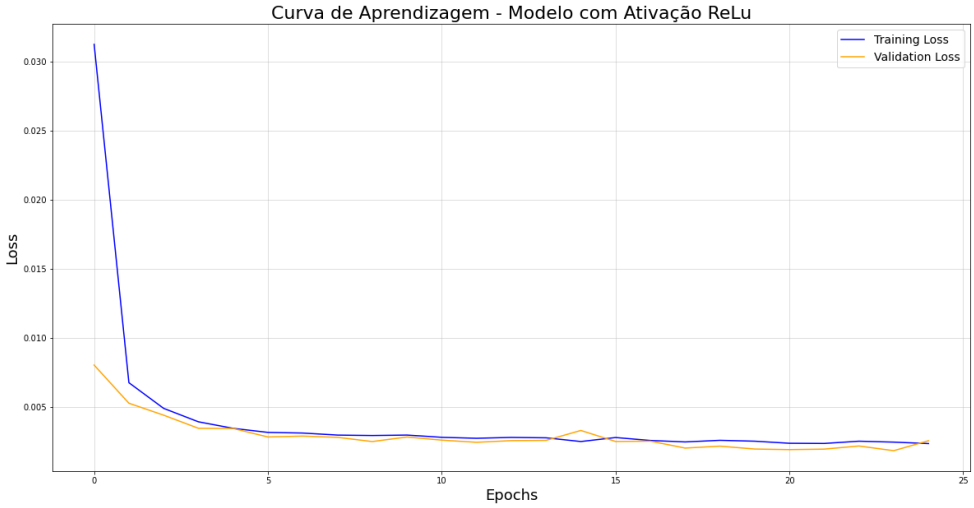


*Figura 63 - Curva de Aprendizagem modelo ReLU*

## II. Função de ativação Sigmoid

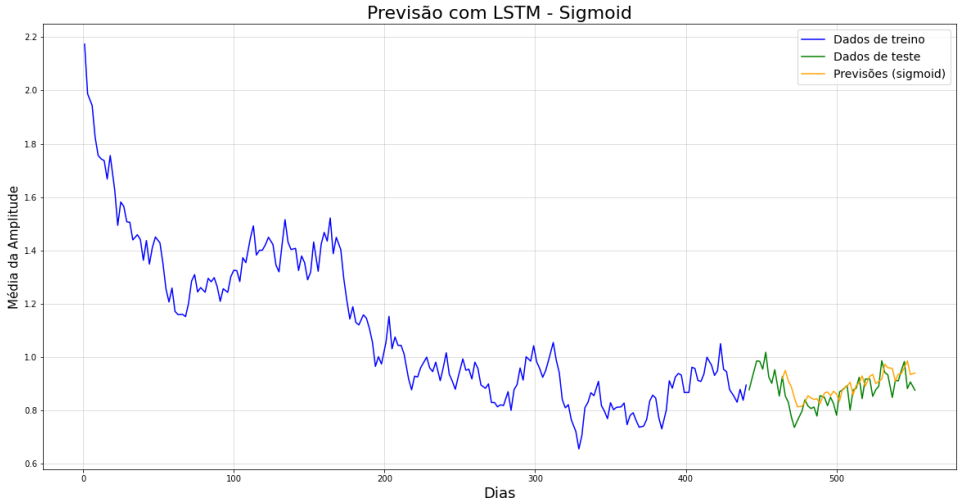


*Figura 64 - Previsão modelo sigmoid*

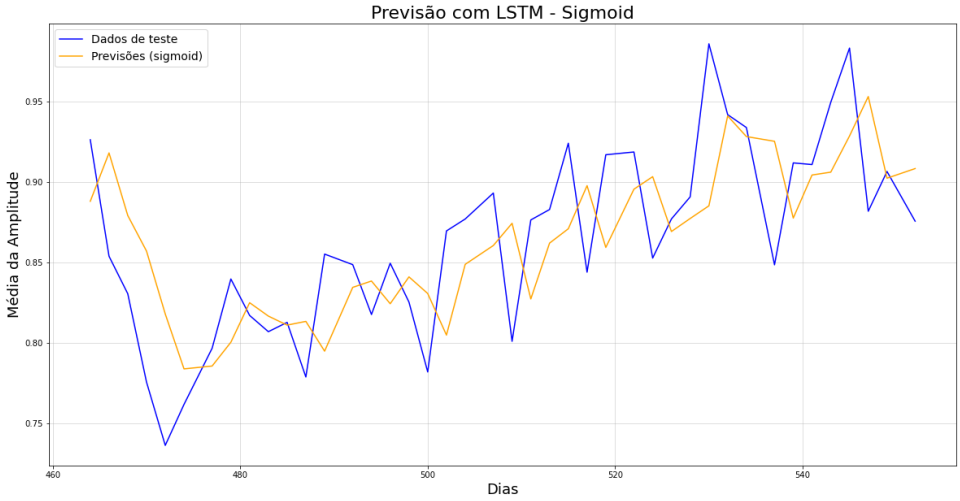


*Figura 65 - Previsão modelo sigmoid ao detalhe*

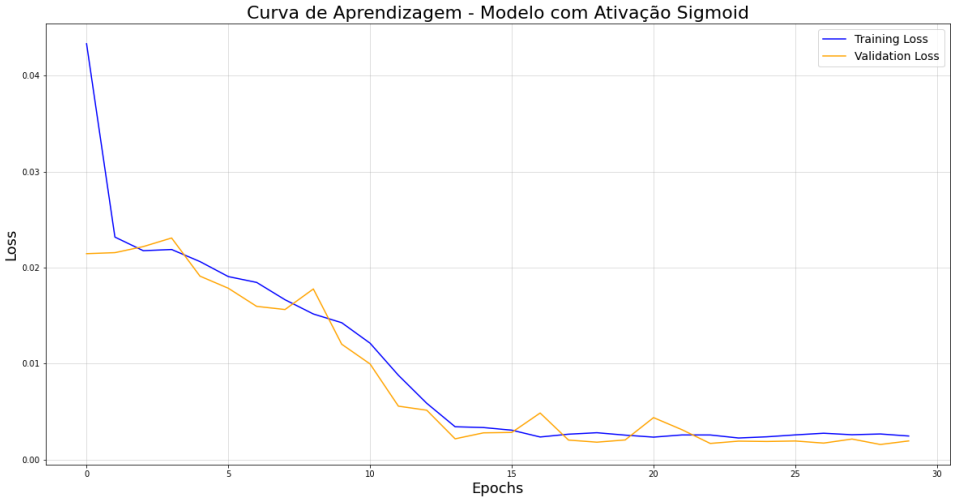


*Figura 66 - curva de aprendizagem sigmoid*

## III. Função de ativação Tanh

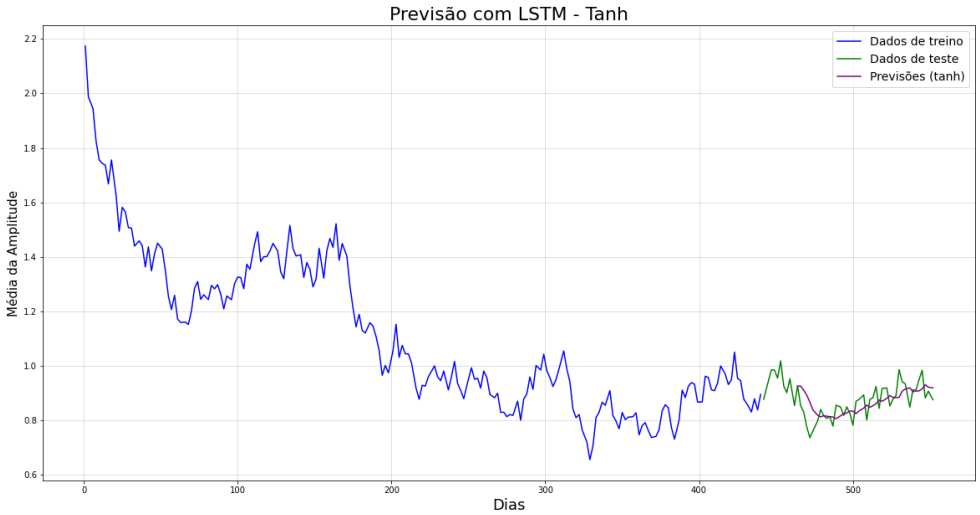


*Figura 67 - Previsão modelo Tanh*

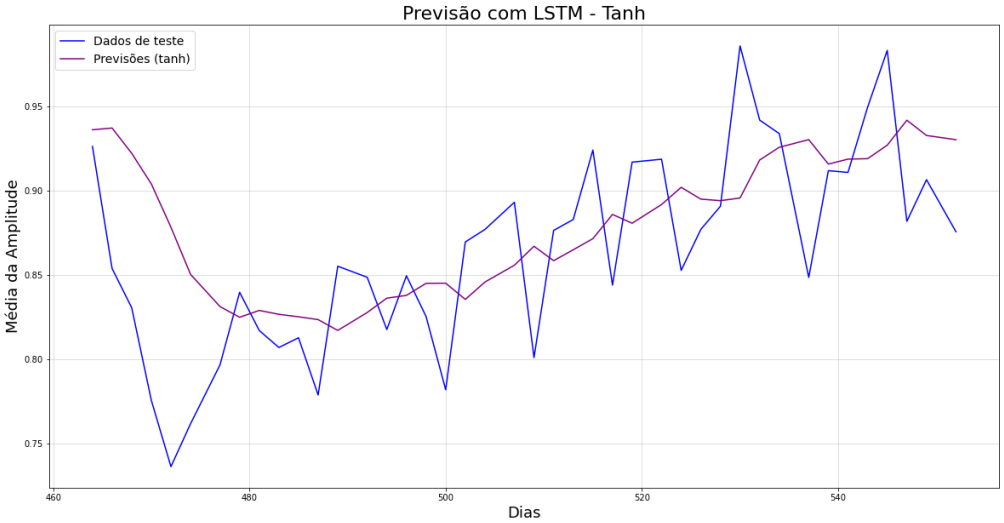


*Figura 68 - Previsão modelo Tanh ao detalhe*

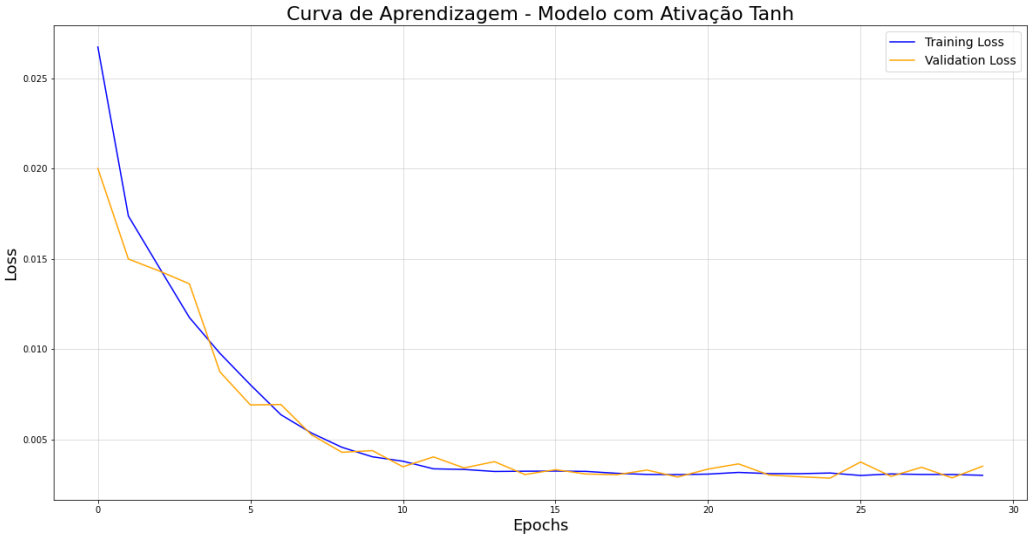


*Figura 69 - Curva de aprendizagem Tanh*

## IV. Previsão com todos os modelos LSTM

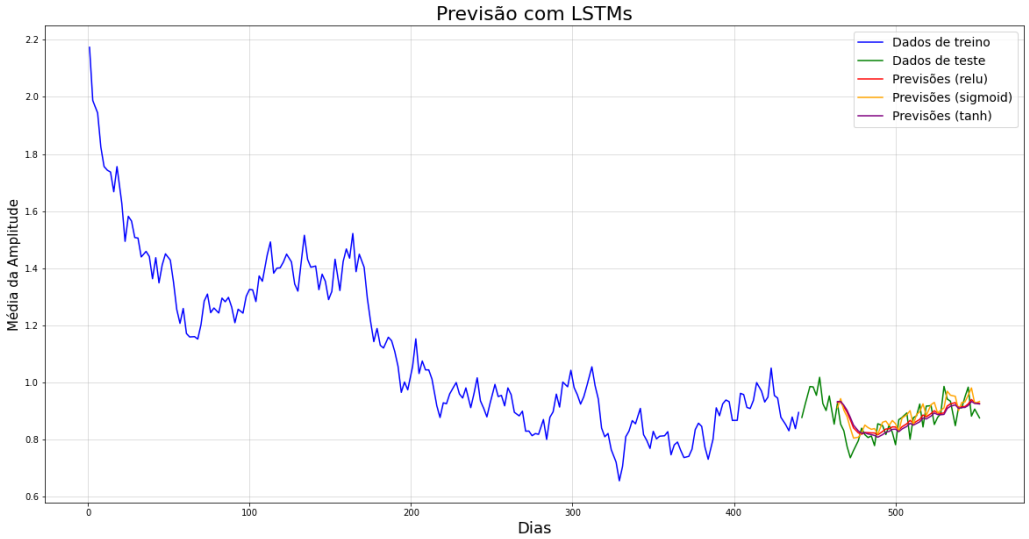


*Figura 70 - Previsão com todas os modelos*

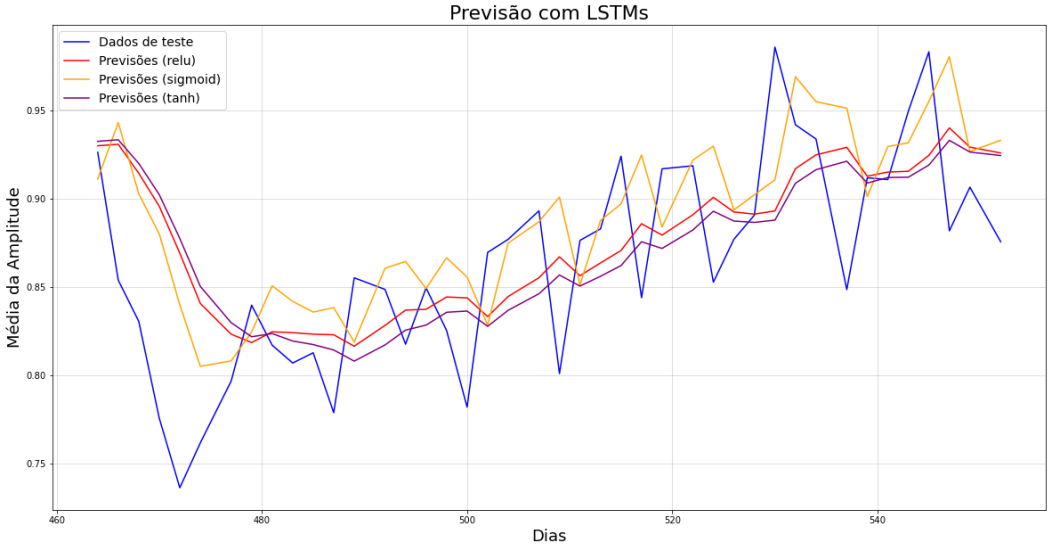


*Figura 71 - Previsão com todas os modelos*

De forma, a facilitar a interpretação dos dados, a Tabela 9 mostra a comparação entre todos os modelos utilizados neste estudo.

*Tabela 9 - Comparação entre os modelos de previsão*

| Modelo | RMSE | MAPE | Accuracy |
|---|---|---|---|
| ARIMA | 0.1 | 11.20% | 88.8% |
| LSTM-Sigmoid | 0.06 | 5.60% | 94.40% |
| LSTM-Tanh | 0.06 | 5.40 % | 94.60% |
| LSTM-ReLU | 0.05 | 5.20% | 94.80% |

Analisando a Tabela 9 é possível concluir que:

- O RMSE é uma métrica que mede a diferença entre os valores previstos e os valores reais, dando mais peso a grandes erros. O modelo LSTM - *ReLU* exibiu o menor RMSE, indicando uma melhor capacidade de ajuste aos dados em comparação com os outros modelos;
- O MAPE é uma métrica que calcula a média das diferenças percentuais absolutas entre as previsões e os valores reais. O modelo *ReLU* demonstrou uma maior precisão, com um MAPE de 5.20%;
- A *accuracy* é uma medida da proporção de previsões corretas em relação ao total de previsões. Embora o modelo *RelU* tenha a maior *accuracy* (94.80%), os outos modelos também mostram resultados competitivos, tal como o LSTM-*Sigmoid* e *Tanh*, com uma *accuracy* de 94.40% e 94.60%. Por fim, o modelo ARIMA apresentou também um valor razoável com uma accuracy de 88.80%.

Com base nos resultados obtidos, é evidente que o modelo *ReLU* apresenta um desempenho superior em termos de MAPE e *accuracy* em comparação com outras redes neuronais LSTM analisadas e o modelo ARIMA. Por fim, analisando os resultados dos modelos LSTM, estes demonstraram ser capazes de identificar padrões temporais e fornecer previsões precisas, com o modelo LSTM-*ReLU* mostrando-se como a melhor variante entre os modelos LSTM e o modelo ARIMA.

Assim, é possível concluir que através da LSTM – *ReLU*, parametrizada da seguinte forma:

- **Units** – 35
- **Batch size** – 2
- **Epochs** – 25
- **Optimizer** – ADAMAX
- **Base de previsão** - 23 dias

foi possível obter resultados bastante precisos, 94.80% de exatidão, demonstrando que o algoritmo e a LSTM parametrizada estão a conseguir identificar corretamente padrões temporais bem como a apresentar uma boa previsão dos resultados tendo por base sempre os 23 dias anteriores da série temporal para efetuar a previsão.

Por fim, foram adicionados novos dados do ativo em análise, sendo que estes novos dados continham informação de uma falha nas correias. Assim, o objetivo deste último teste foi perceber a capacidade de o algoritmo identificar e comunicar a existência/probabilidade de ocorrência de uma falha no ativo, segundo os seguintes níveis de amplitude:

- *Amplitude ≤ 0.99 – Nível 0 - Normal*
- *1 ≥ Amplitude ≤ 1.19 – Nível 1 – Alerta de Falha*
- *1.2 ≥ Amplitude ≤ 1.49 – Nível 2 – Falha Detetada*
- *Amplitude ≥ 1.5 – Nível 3* – Falha Critica

Resultando assim nas Figuras 72 e 73, bem como na Tabela 10, com os resultados obtidos.

*Figura 72 - Previsão com novos dados*

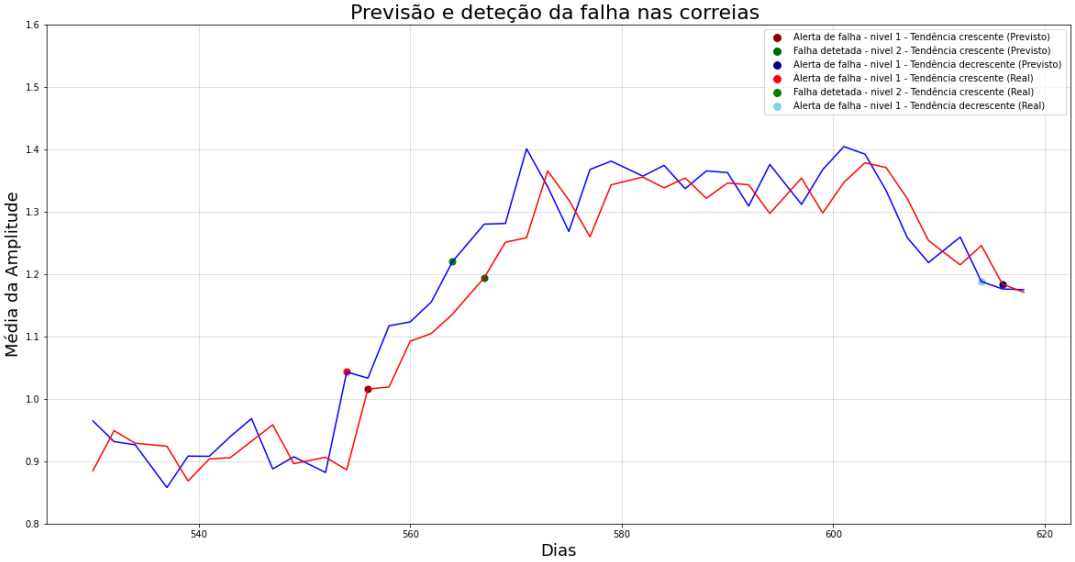


*Figura 73 - Previsão com novos dados ao detalhe*

*Tabela 10 - Comparação do período de deteção da falha*

| ***Dia da previsão*** | ***Valor real*** | ***Valor Previsto*** | ***Nível de severidade*** |
|---|---|---|---|
| ***1*** | *0.964728* | *0.870708* | *Nível 0 - Normal* |
| ***2*** | *0.931581* | *0.932184* | *Nível 0 - Normal* |
| ***3*** | *0.926352* | *0.912502* | *Nível 0 - Normal* |
| ***4*** | *0.857883* | *0.907696* | *Nível 0 - Normal* |
| ***5*** | *0.908254* | *0.854476* | *Nível 0 - Normal* |
| ***6*** | *0.907872* | *0.888513* | *Nível 0 - Normal* |
| ***7*** | *0.939738* | *0.890787* | *Nível 0 - Normal* |
| ***8*** | *0.968402* | *0.915852* | *Nível 0 - Normal* |
| ***9*** | *0.887764* | *0.940871* | *Nível 0 - Normal* |
| ***10*** | *0.907131* | *0.88073* | *Nível 0 - Normal* |
| ***11*** | *0.88194* | *0.890902* | *Nível 0 - Normal* |
| ***12*** | ***1.043397*** | *0.87172* | *Nível 0 - Normal* |
| ***13*** | *1.033239* | ***0.99614*** | ***Nível 1 - Alerta de falha*** |
| ***14*** | *1.117284* | 0.999295 | *Nível 1 - Alerta de falha* |
| ***15*** | *1.123449* | *1.069485* | *Nível 1 - Alerta de falha* |
| ***16*** | *1.155618* | *1.081343* | *Nível 1 - Alerta de falha* |
| ***17*** | ***1.220232*** | *1.110784* | *Nível 1 - Alerta de falha* |
| ***18*** | *1.280303* | *1.167767* | *Nível 1 - Alerta de falha* |
| ***19*** | *1.281332* | ***1.223036*** | ***Nível 2 - Falha detetada*** |
| ***20*** | *1.401132* | *1.228815* | *Nível 2 - Falha detetada* |
| ***21*** | *1.340241* | *1.333555* | *Nível 2 - Falha detetada* |
| ***22*** | *1.268536* | *1.286336* | *Nível 2 - Falha detetada* |
| ***23*** | *1.367944* | *1.22593* | *Nível 2 - Falha detetada* |
| ***24*** | *1.381326* | *1.309181* | *Nível 2 - Falha detetada* |
| ***25*** | *1.357277* | *1.322206* | *Nível 2 - Falha detetada* |
| ***26*** | *1.374584* | *1.303185* | *Nível 2 - Falha detetada* |
| ***27*** | *1.337244* | *1.318273* | *Nível 2 - Falha detetada* |
| ***28*** | *1.365689* | *1.286355* | *Nível 2 - Falha detetada* |
| ***29*** | *1.363002* | *1.310275* | *Nível 2 - Falha detetada* |
| ***30*** | *1.309369* | *1.30805* | *Nível 2 - Falha detetada* |
| ***31*** | *1.376014* | *1.262187* | *Nível 2 - Falha detetada* |
| ***32*** | *1.311946* | *1.318161* | *Nível 2 - Falha detetada* |
| ***33*** | *1.367761* | *1.263771* | *Nível 2 - Falha detetada* |
| ***34*** | *1.404658* | *1.311064* | *Nível 2 - Falha detetada* |
| ***35*** | *1.3925* | *1.343333* | *Nível 2 - Falha detetada* |
| ***36*** | *1.334054* | *1.334444* | *Nível 2 - Falha detetada* |
| ***37*** | *1.258673* | *1.284694* | *Nível 2 - Falha detetada* |
| ***38*** | *1.218647* | *1.219053* | *Nível 2 - Falha detetada* |
| ***39*** | *1.259524* | *1.202313* | *Nível 2 - Falha detetada* |
| ***40*** | ***1.188217*** | *1.213908* | *Nível 2 - Falha detetada* |
| ***41*** | *1.176315* | ***1.153644*** | ***Nível 1 - Alerta de falha*** |
| ***42*** | *1.175084* | *1.141274* | *Nível 1 - Alerta de falha* |

A tabela 10 apresenta detalhadamente os resultados obtidos, segmentados por "Dia da previsão", "Valor real", "Valor Previsto" e "Nível de severidade".

Inicialmente o modelo apresentou previsões alinhadas com uma faixa considerada normal, categorizada como "Nível 0 - Normal". No entanto, à medida que a análise temporal avançava, foi observada uma mudança substancial nos valores previstos, indicando o surgimento de anomalias iminentes.

Tal como referido anteriormente, foram definidos limiares críticos para contextualizar os níveis de severidade, para que quando os valores previstos ultrapassassem estes limites fossem categorizados de acordo com o nível de severidade da falha.

A análise dos dados revela que o modelo demonstrou uma boa capacidade de antecipar anomalias antes que estas atingissem níveis críticos. Contudo, o tempo necessário para essa deteção variou consideravelmente, dependendo da amplitude da anomalia e da rapidez com que os valores previstos se afastaram dos valores reais. Por exemplo, observou-se que anomalias detetadas no estado inicial da previsão, antes de atingirem níveis críticos, exigiram menos tempo para deteção do que aquelas detetadas nos estados posteriores.

Destaca-se assim que o facto de os resultados serem melhores numa deteção em fases iniciais das anomalias, proporciona oportunidades para uma melhor tomada de decisão bem como a implementação de medidas corretivas antes que as falhas se materializem completamente.

## 6.4 – Estimação da tendência da falha para o futuro

Por fim, com base no melhor modelo, foi ainda feita uma previsão para o futuro. No entanto, o objetivo era que a previsão se adaptasse à medida que a tendência dos últimos 23 dias se alterasse, como é possível verificar na Figura 74. No entanto, esta predição é feita de acordo com cenários, em que a cor vermelha representa o pior cenário, onde a amplitude da falha na correia piora. Inversamente, a cor verde indica uma melhoria na amplitude e a cor amarela representa o valor mais expectável que a componente de falha das correias irá atingir.

Vale a pena notar que há um desvanecimento nas cores de cada cenário, para que o agravamento ou melhoria da amplitude possa ser visualmente percebido com mais facilidade. Além disso, há um aumento no intervalo de valores previstos à medida que estendemos a previsão para o futuro, devido à crescente margem de erro, resultando assim num efeito parabólico para cada cenário

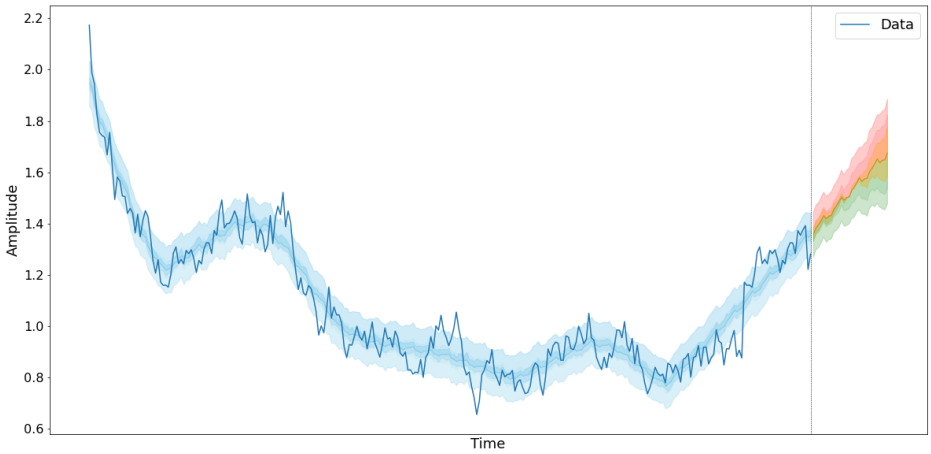


*Figura 74 -Previsão da falha da correia para o futuro.*

# CAPÍTULO 7 – Contribuições

A análise dos resultados deste estudo proporciona *insights* relevantes sobre a previsão e deteção de falhas em motores de indução, com foco particular na falha das correias. Estas descobertas são contextualizadas dentro do quadro da pesquisa e das hipóteses formuladas nesta investigação.

Ao comparar os resultados com os modelos discutidos na revisão literária, destacam-se algumas diferenças significativas. Enquanto os modelos tradicionais como o ARIMA têm sido amplamente utilizados na análise de séries temporais, é possível concluir que os modelos *LSTM* superaram estes modelos em termos de precisão e capacidade de adaptação a padrões complexos nos dados. Por exemplo, o ARIMA, embora eficaz em séries temporais estacionárias, frequentemente enfrenta dificuldades ao lidar com a sazonalidade e não linearidade presentes nos dados de falhas da correia. É também mais adequado para previsões de curto prazo.

Além disso, a capacidade do modelo *LSTM* aprender com sequências temporais de dados torna-o mais adequado para capturar relações de longo prazo e detetar padrões subtis nos sinais de falha. Enquanto modelos convencionais baseados em regressão dependem de uma série de pressupostos sobre a estacionariedade dos dados e linearidade dos relacionamentos, a *LSTM* lida de forma mais flexível com a complexidade inerente dos sinais de falha da correia.

Outro destaque é a capacidade da *LSTM* fornecer previsões dinâmicas e adaptativas. Ao utilizar dados dos últimos 23 dias para fazer previsões, o modelo foi capaz de ajustar as previsões conforme a tendência dos dados mais recentes se alteravam. Isto permitiu uma resposta mais ágil às mudanças nas condições operacionais e aumentou a precisão nas previsões de falhas.demonstrando assim que a *LSTM* oferece uma abordagem promissora para a previsão de falhas em motores de indução, superando a maioria dos modelos em termos de precisão e adaptabilidade.

Por fim, é importante mencionar que os resultados deste estudo foram divulgados em dois artigos científicos distintos. O primeiro, intitulado *Advanced Predictive Maintenance of Belt Systems integrating LSTM Networks and Motor Current Signature Analysis*, para publicação na *Emerald Publishing* [56]. Neste artigo, é detalhada a combinação de redes *LSTM* com a Análise da Assinatura da Corrente do Motor para melhorar a manutenção preditiva de sistemas com correias. Concentrando-se principalmente na aplicação destas técnicas em cenários industriais para prever falhas nas correias e otimizar os processos de manutenção.

O segundo artigo, submetido na conferência *ENEG*I, recebeu o título de *Manutenção Preditiva Avançada de Sistemas com Correias: Integração de Redes LSTM e da Análise da Assinatura da Corrente do Motor* [57]. Neste artigo, foram explorados em maior detalhe os resultados obtidos no estudo. Além de discutir a metodologia utilizada, destaca-se o caso prático em que a abordagem foi aplicada com sucesso. Além disso, é enfatizada a eficácia da solução na deteção e previsão de falhas em motores de indução, proporcionando uma otimização significativa em termos de tempo e recursos de manutenção.

# CAPÍTULO 8 - Conclusão

Este estudo centrou-se na utilização de modelos preditivos, nomeadamente uma rede neuronal LSTM, para detetar e prever falhas em motores de indução, com foco principal na falha das correias. Os resultados demonstram de forma inequívoca a eficácia deste modelo na antecipação de falhas, fornecendo assim à indústria uma ferramenta poderosa para a manutenção preditiva.

Através da aplicação de uma *LSTM,* com uma janela temporal de 23 dias, foram alcançados resultados notáveis. O melhor modelo *LSTM* apresentou erros próximos de 5%, com a maioria a ficar abaixo do limite de 10%. Isto sublinha a fiabilidade e precisão da abordagem na antecipação de falhas em motores de indução.

As vantagens de utilizar uma *LSTM* para a previsão de falhas são significativas, pois não só oferece uma alta precisão na previsão, como também fornece previsões dinâmicas e adaptativas ao aproveitar sequências temporais. Além disso, a *LSTM* pode detetar dependências de longo prazo e padrões subtis nos sinais de falha, aprimorando as suas capacidades preditivas.

No entanto, é importante reconhecer as limitações do modelo *LSTM*. A sua implementação pode exigir recursos computacionais substanciais e grandes volumes de dados históricos para a fase de treino, o que pode representar desafios práticos em alguns ambientes industriais. Além disso, a interpretabilidade das previsões da *LSTM* pode ser limitada, uma vez que o processo de tomada de decisão depende dos padrões aprendidos existentes nos dados.

Olhando para o futuro, os esforços de futuras pesquisas podem concentrar-se em abordar estas limitações e refinar o modelo *LSTM* em novas aplicações industriais. Isso pode envolver a investigação de métodos para simplificar os requisitos de computação, melhorar a interpretabilidade do modelo e explorar a integração de técnicas de diagnóstico adicionais.

# CAPÍTULO 9 - Bibliografia


[1] S. J. Chapman, " Electric Machinenery Fundamentals: Solution Manual ", 5th ed.,no July. *McGraw Hill*, 2012, ISBN: 9780073529547 https://bayanbox.ir/view/1242248320693376779/Electrical-Machinery-chapman-5th-2012-solution.pdf

[2] K. M. Kumar, A. Krishnaveni, D. E. Selvaraj, T. Gunasekaran, P. Manikandan, and Lieutenant. J. Ganesan, "A Review on Maintenance and Troubleshooting of DC Machines," *International Journal of Science and Engineering Applications*, vol. 5, no. 3, 2016, doi: 10.7753/ijsea0503.1008.

[3] M. A. Silva, "Método de estimação da velocidade em motores de indução trifásicos através da corrente de armadura com aplicação da Teoria do Caos," *Universidade Federal da Paraíba*, 2021,https://repositorio.ufpb.br/jspui/bitstream/123456789/26078/1/MarlioAntonioDaSilva_Tese.pdf

[4] A. N. Chaston, " Electric Machinery ", 1th ed. *Reston Pub Co*, 1986, ISBN: 0835915808

[5] B. C. Groen, "Investigation of DC Motors for Electric and Hybrid Electric Motor Vehicle Applications Using an Infinitely Variable Transmission ", *Brigham Young University*, 2011, https://scholarsarchive.byu.edu/etd/2696/

[6] A. Silva, "Induction motor fault diagnostic and monitoring methods," *Marquette University*, 2006, https://epublications.marquette.edu/theses/4444/

[7] G. Rizzoni, "Principles and Applications of Electrical Engineering", 5th ed. *McGraw Hill*, 1996, ISBN: 0071254447

[8] J. D. Costa, "Apontamentos de Máquinas Eléctrica." *Universidade Federal Fluminense*, 2010, https://cursos.if.uff.br/!eletroeng10117/lib/exe/fetch.php?media=maquinaselectricas_1ocap.pdf

[9] D. L. McKinnon, "Online fault analysis of DC motors,", Electrical Manufacturing and Coil Winding Association - *Electrical Manufacturing Technical Conference*, 2006, https://www.pdma.com/pdfs/Articles/Online_Fault_Analysis_of_DC_Motors.pdf

[10] M. O. Mustafa, "On Fault Detection, Diagnosis and Monitoring for Induction Motors," *Luleå University of Technology*, 2015, https://www.divaportal.org/smash/get/diva2:991792/FULLTEXT01.pdf

[11] A. Siddique, G. S. Yadava, and B. Singh, "A review of stator fault monitoring techniques of induction motors," *IEEE Transactions on Energy Conversion*, vol. 20, no. 1. 2005. doi: 10.1109/TEC.2004.837304.

[12] M. Hajiaghajani and S. M. Madani, "A new method for analysis of rotor broken bar fault in induction machines," in *IEEE International Conference on Electric Machines and Drives, 2005.*, 2005, pp. 1669–1674. doi: 10.1109/IEMDC.2005.195944.

[13] A. Bellini, F. Filippetti, C. Tassoni, and G. A. Capolino, "Advances in diagnostic techniques for induction machines," *IEEE Transactions on Industrial Electronics*, vol. 55, no. 12, 2008, doi: 10.1109/TIE.2008.2007527.

[14] P. Zhang, Y. Du, T. G. Habetler, and B. Lu, "A survey of condition monitoring and protection methods for medium-voltage induction motors," *IEEE Transactions on Industry Applications*, vol. 47, no. 1. 2011. doi: 10.1109/TIA.2010.2090839.

[15] I. Y. Önel and M. E. H. Benbouzid, "Induction motor bearing failure detection and diagnosis: Park and concordia transform approaches comparative study," *IEEE/ASME Transactions on Mechatronics*, vol. 13, no. 2, 2008, doi: 10.1109/TMECH.2008.918535.

[16] M. B. Gülmezoğlu and S. Ergin, "An approach for bearing fault detection in electrical motors," *European Transactions on Electrical Power*, vol. 17, no. 6, 2007, doi: 10.1002/etep.161.

[17] E. Leandro, L. E. de Lacerda de Oliveira, J. G. B. da Silva, G. Lambert-Torresm, and L. E. B. da Silv, "Predictive Maintenance by Electrical Signature Analysis to Induction Motors," in *Induction Motors - Modelling and Control*, 2012. doi: 10.5772/48045.

[18] M. Volk, "Pump Characteristics and Applications", *CRC Press*, 2013. doi: 10.1201/b15559.

[19] J. A. Portella, "Máquinas Termohidráulicas de Fluxo." *Universidade Paulista*, 2012, www.studocu.com/pt-br/document/universidade-paulista/fluidos-e-termodinamica/teoriageral-maquinas-de-fluxo/10389034

[20] D. Kernan, "Pumps 101 : Operation, Maintenance and Monitoring Basics," *ITT White Paper*, 2009, www.gouldspumps.com/ittgp/medialibrary/goulds/website/Literature/White%20Papers/ITT_white_paper_Pumps_101_Operation_Maintenance_and_Monitoring_Basics.pdf

[21] S. Pumps, Centrifugal Pump Handbook, 3th ed. *Butterworth-Heinemann*, 2010, ISBN-13: 978-0750686129

[22] O. H. I. Hamomd, "Compound Fault Diagnosis of Centrifugal Pumps Using Vibration Analysis Techniques," *University of Huddersfield*, 2017, https://core.ac.uk/download/pdf/161937589.pdf

[23] C. M. Sewatkar, "Centrifugal Pump.", *Government College of Engineering & Research*, 2012, www.gcoeara.ac.in/learning_material/mech/Unit_IV_Centrifugal_Pump.pdf

[24] U. A. M. Haba, "Information Extraction Based on the Analysis of Motor Supply and Structural Vibration for Machinery Condition Monitoring," *University of Huddersfield*, 2019, https://eprints.hud.ac.uk/id/eprint/35237/

[25] T. Giampaob, "Compressor Handbook: Principles and Practice", 1th ed. *CRC Press*, 2010, ISBN: 1439815712, https://www.igytechnicalcollege.com/Compressor%20Handbook.pdf

[26] Sundyne, "The Basics: Centrifugal Gas Compressors 101.", www.sundyne.com/the-basics-centrifugal-gas-compressors-101/ , (website visitado em 15/11/2023)

[27] P. Hanlon, "Compressor Handbook", 1th ed. *McGraw Hill*, 2001, ISBN-10: 0070260052, http://www.irantpm.ir/wp-content/uploads/2014/12/Compressor-Handbook.pdf

[28] K. Brun and R. Kurz, *Compression machinery for oil and gas*. 2018. doi: 10.1016/C2017-0-02064-5.

[29] F. P. Bleier, "Fan Handbook: Selection, Application, and Design", 1st ed. *McGraw Hill*, 1997, ISBN: 0070059330

[30] D. LAJAS, "Projeto de um moinho de martelos para preparação de amostras de minério," *Universidade NOVA de Lisboa*, 2021, https://run.unl.pt/bitstream/10362/141756/1/Lajas_2021.pd

[31] R. F. Oliveira, "Uma Revisão dos Princípios de Funcionamento e Métodos de Dimensionamento de Moinhos de Bolas," *Escola de Engenharia da Universidade Federal de Minas Gerais*, vol. 10, no. 9, 2012, uma_revis_o_dos_princ_pios_de_funcionamento_e_m_todos_de_dimensionamento_de__moinhos_de_bolas.pdf (ufmg.br)

[32] G. Oliveira, "Critérios de projeto para moinhos de cimento Portland", *Universidade Federal do Rio de Janeiro*, 2012, https://pantheon.ufrj.br/bitstream/11422/19227/1/GARNOliveira.pdf

[33] Cement equipment, "Every componente of ball mil detailed & explained", 2021, https://www.cementequipment.org/main-categor/cement-grinding-main-category/every-component-of-ball-mill-detailed-explained/ , (website visitado em 25/11/2023)

[34] Loesche, "Loesche Mills for Solid Fuel", 2016, 132-Loesche-Mills-for-Solid-Fuels-Coal-Mill-E-2016.pdf, (website visitado em 10/12/2023)

[35] M. E. H. Benbouzid, "A review of induction motors signature analysis as a medium for faults detection," *IEEE Transactions on Industrial Electronics*, vol. 47, no. 5, 2000, doi: 10.1109/41.873206.

[36] S. Nandi, H. A. Toliyat, and X. Li, "Condition monitoring and fault diagnosis of electrical motors - A review," *IEEE Transactions on Energy Conversion*, vol. 20, no. 4. 2005. doi: 10.1109/TEC.2005.847955.

[37] F. Filippetti, G. Franceschini, C. Tassoni, and P. Vas, "Recent developments of induction motor drives fault diagnosis using AI techniques," *IEEE Transactions on Industrial Electronics*, vol. 47, no. 5, 2000, doi: 10.1109/41.873207.

[38] B. Duarte, "Análise da Condição e Diagnóstico de Avarias em Motores Elétricos para Efeitos de Manutenção Preventiva," *Universidade NOVA de Lisboa* , 2019, https://run.unl.pt/bitstream/10362/89182/1/Duarte_2019.pdf

[39] S. S. Goundar, M. R. Pillai, K. A. Mamun, F. R. Islam, and R. Deo, "Real time condition monitoring system for industrial motors," in *2015 2nd Asia-Pacific World Congress on Computer Science and Engineering, APWC on CSE 2015*, 2016. doi: 10.1109/APWCCSE.2015.7476232.

[40] W. T. Thomson and M. Fenger, "Current signature analysis to detect induction motor faults," *IEEE Industry Applications Magazine*, vol. 7, no. 4, 2001, doi: 10.1109/2943.930988.

[41] H. Henao, C. Demian, and G. A. Capolino, "A frequency-domain detection of stator winding faults in induction machines using an external flux sensor," *IEEE Trans Ind Appl*, vol. 39, no. 5, 2003, doi: 10.1109/TIA.2003.816531.

[42] J. O. Estima, N. M. A. Freire, and A. J. M. Cardoso, "Recent advances in fault diagnosis by Park's vector approach," in *Proceedings - 2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis, WEMDCD 2013*, 2013. doi: 10.1109/WEMDCD.2013.6525187.

[43] S. Haykin, "Redes Neurais: Princípios e Prática", 2th ed. Bookman Editora , 2001, ISBN: 9788573077186

[44] C. Bingham, M. D. Godfrey, and J. W. Tukey, “Modern Techniques of Power Spectrum Estimation,” *IEEE Transactions on Audio and Electroacoustics*, vol. 15, no. 2, 1967, doi: 10.1109/TAU.1967.1161895.

[45] F. Francis and M. Mohan, “ARIMA Model based Real Time Trend Analysis for Predictive Maintenance,” Feb. 2019, pp. 735–739. doi: 10.1109/ICECA.2019.8822191.

[46] Y. Pan, M. Zhang, Z. Chen, M. Zhou, and Z. Zhang, “An ARIMA based model for forecasting the patient number of epidemic disease,” in *2016 13th International Conference on Service Systems and Service Management, ICSSSM 2016*, 2016. doi: 10.1109/ICSSSM.2016.7538560.

[47] S. L. Ho and M. Xie, “The use of ARIMA models for reliability forecasting and analysis,” *Comput Ind Eng*, vol. 35, no. 1–2, 1998, doi: 10.1016/s0360-8352(98)00066-7.

[48] J. M. N. Xavier, “Análise e previsão de séries temporais com modelos ARIMA e análise espectral singular,” *Universidade Aberta*, 2016, *Séries Temporais (uab.pt)*

[49] F. A. Gers, J. Schmidhuber, and F. Cummins, “Learning to forget: Continual prediction with LSTM,” *Neural Comput*, vol. 12, no. 10, 2000, doi: 10.1162/089976600300015015.

[50] W. Duch and N. Jankowski, “Survey of neural transfer functions,” *Department of Computer Methods, Nicholas Copernicus University*, vol. 2, 1999, *99ncs.pdf (umk.pl)*

[51] Y. Canalli, “Funções de ativação hiperbólicas em redes neurais,” *Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia - UFRJ*, 2017, *https://www.cos.ufrj.br/uploadfile/publicacao/2759.pdf*

[52] S. Feng and Y. Feng, “A Dual-Staged Attention Based Conversion-Gated Long Short Term Memory for Multivariable Time Series Prediction,” *IEEE Access*, vol. 10, 2022, doi: 10.1109/ACCESS.2021.3136712.

[53] S. Pasari, A. Shah, and U. Sirpurkar, “Wind energy prediction using artificial neural networks,” in *Sustainable Production, Life Cycle Engineering and Management*, 2020. doi: 10.1007/978-3-030-44248-4_10.

[54] A. Vieira, I. Sousa, and S. Dória-Nóbrega, “Forecasting daily admissions to an emergency department considering single and multiple seasonal patterns,” *Healthcare Analytics*, vol. 3, 2023, doi: 10.1016/j.health.2023.100146.

[55] J. T. Farinha, H. D. N. Raposo, J. E. de-Almeida-e-Pais, and M. Mendes, “Physical Asset Life Cycle Evaluation Models—A Comparative Analysis towards Sustainability,” *Sustainability*, vol. 15, no. 22, 2023, doi: 10.3390/su152215754.

[56] J.Costa, José Torres Farinha, Mateus Mendes, and J. O.Estima, “Advanced Predictive Maintenance of Belt Systems integrating LSTM Networks and Motor Current Signature Analysis,” *Industrial Management & Data Systems*, 2024, (submetido)

[57] J.Costa, José Torres Farinha, Mateus Mendes, and J. O.Estima, “Manutenção Preditiva Avançada de Sistemas com Correias: Integração de Redes LSTM e da Análise da Assinatura da Corrente do Motor,” *ENEGI - Congress*, 2024, (submetido)

# ANEXOS

## Anexo A – Teste de otimização das LSTM com diferentes optimizadores

*Tabela 11 - Teste com os diferentes optimizadores com 80% de dados de teste*

| ***Função de ativação ReLu*** | ***5 dias*** | ***10 dias*** | ***12 dias*** | ***23 dias*** |
|---|---|---|---|---|
| *ADAM* | *88.14* | *87.92* | *86.68* | *85.30* |
| *NADAM* | *87.91* | *87.74* | *86.63* | *84.84* |
| *SGD* | *88.15* | *87.93* | *87.63* | *85.78* |
| *ADAMAX* | *87.19* | *87.43* | *87.63* | *85.65* |
| *ADADELTA* | *85.54* | *82.35* | *83.13* | *83.43* |
| *FTRL* | ***89.56*** | *88.59* | *88.09* | *86.81* |
| *RMSPROP* | *87.59* | *86.38* | *87.36* | *85.75* |

*Tabela 12 - Teste com os diferentes optimizadores com 80% de dados de teste*

| ***Função de ativação Sigmoid*** | ***5 dias*** | ***10 dias*** | ***12 dias*** | ***23 dias*** |
|---|---|---|---|---|
| *ADAM* | *85.60* | *85.91* | *87.05* | *85.33* |
| *NADAM* | *87.41* | *86.38* | *87.11* | *85.36* |
| *SGD* | *65.61* | *84.73* | *73.37* | *76.31* |
| *ADAMAX* | ***87.58*** | *86.84* | *87.23* | *84.60* |
| *ADADELTA* | *70.71* | *71.62* | *62.28* | *67.35* |
| *FTRL* | *67.88* | *69.47* | *70.30* | *69.93* |
| *RMSPROP* | *87.44* | *84.94* | *86.65* | *84.31* |

*Tabela 13 - Teste com os diferentes optimizadores com 80% de dados de teste*

| ***Função de ativação Tanh*** | ***5 dias*** | ***10 dias*** | ***12 dias*** | ***23 dias*** |
|---|---|---|---|---|
| *ADAM* | *86.94* | *86.69* | *85.81* | *85.30* |
| *NADAM* | *87.24* | *86.41* | *86.52* | *84.84* |
| *SGD* | *87.45* | *86.07* | *87.08* | *85.78* |
| *ADAMAX* | *87.30* | *87.31* | *86.77* | *85.65* |
| *ADADELTA* | *87.55* | *84.00* | *80.90* | *83.43* |
| *FTRL* | ***89.51*** | *88.74* | *87.94* | *86.81* |
| *RMSPROP* | *87.14* | *83.03* | *86.64* | *85.75* |

*Tabela 14 - Teste com os diferentes optimizadores com 85% de dados de teste*

| ***Função de ativação ReLu*** | ***5 dias*** | ***10 dias*** | ***12 dias*** | ***23 dias*** |
|---|---|---|---|---|
| *ADAM* | *86.42* | *85.63* | *85.92* | *85.73* |
| *NADAM* | *86.02* | *85.21* | *84.84* | *87.07* |
| *SGD* | *86.33* | *84.96* | *85.19* | *85.07* |
| *ADAMAX* | *86.15* | *85.48* | *85.19* | *84.57* |
| *ADADELTA* | *87.13* | *86.52* | *87.31* | ***89.68*** |
| *FTRL* | *87.36* | *86.59* | *86.40* | *88.87* |
| *RMSPROP* | *85.19* | *84.49* | *84.16* | *87.41* |

*Tabela 15 - Teste com os diferentes optimizadores com 85% de dados de teste*

| ***Função de ativação Sigmoid*** | ***5 dias*** | ***10 dias*** | ***12 dias*** | ***23 dias*** |
|---|---|---|---|---|
| *ADAM* | *85.45* | *82.96* | *85.15* | *87.41* |
| *NADAM* | *85.54* | *82.22* | *84.29* | *87.38* |
| *SGD* | *71.80* | *59.15* | *70.14* | *68.56* |
| *ADAMAX* | *85.42* | *84.39* | *84.97* | *84.65* |
| *ADADELTA* | *75.63* | *71.31* | *73.96* | *61.31* |
| *FTRL* | *67.96* | *68.14* | *67.11* | *59.55* |
| *RMSPROP* | *76.83* | *84.91* | *85.08* | ***88.28*** |

*Tabela 16 - Teste com os diferentes optimizadores com 85% de dados de teste*

| ***Função de ativação Tanh*** | ***5 dias*** | ***10 dias*** | ***12 dias*** | ***23 dias*** |
|---|---|---|---|---|
| *ADAM* | *86.01* | *84.39* | *84.13* | *87.72* |
| *NADAM* | *85.50* | *84.32* | *84.18* | *86.98* |
| *SGD* | *85.55* | *83.97* | *84.31* | *82.46* |
| *ADAMAX* | *85.44* | *84.17* | *84.09* | *87.33* |
| *ADADELTA* | *86.82* | *86.54* | *86.93* | ***89.58*** |
| *FTRL* | *87.06* | *86.87* | *87.19* | *88.36* |
| *RMSPROP* | *85.40* | *82.95* | *83.93* | *87.20* |

*Tabela 17 - Teste com os diferentes optimizadores com 75% de dados de teste*

| **Função de ativação ReLu** | **5 dias** | **10 dias** | **12 dias** | **23 dias** |
|---|---|---|---|---|
| ADAM | 89.12 | 88.20 | 88.40 | 87.58 |
| NADAM | 87.96 | 89.15 | 88.39 | 87.50 |
| SGD | 88.78 | 81.00 | 88.40 | 88.10 |
| ADAMAX | 88.80 | 89.20 | 88.80 | 88.64 |
| ADADELTA | 90.34 | 90.30 | 87.64 | 88.26 |
| FTRL | **90.62** | 90.47 | 90.26 | 89.00 |
| RMSPROP | 89.40 | 89.17 | 88.33 | 86.59 |

*Tabela 18 - Teste com os diferentes optimizadores com 75% de dados de teste*

| **Função de ativação Sigmoid** | **5 dias** | **10 dias** | **12 dias** | **23 dias** |
|---|---|---|---|---|
| ADAM | 87.89 | 88.40 | 87.91 | 87.75 |
| NADAM | 88.18 | 88.40 | 87.63 | 86.09 |
| SGD | 66.10 | 74.38 | 71.50 | 67.85 |
| ADAMAX | **88.88** | 88.44 | 88.22 | 87.85 |
| ADADELTA | 74.72 | 74.23 | 72.08 | 87.20 |
| FTRL | 66.73 | 75.65 | 68.30 | 72.41 |
| RMSPROP | 88.13 | 88.15 | 87.62 | 86.22 |

*Tabela 19 - Teste com os diferentes optimizadores com 75% de dados de teste*

| **Função de ativação Tanh** | **5 dias** | **10 dias** | **12 dias** | **23 dias** |
|---|---|---|---|---|
| ADAM | 87.43 | 87.24 | 87.10 | 86.80 |
| NADAM | 88.24 | 88.31 | 87.41 | 87.35 |
| SGD | 87.79 | 88.50 | 88.47 | 87.27 |
| ADAMAX | 87.82 | 87.80 | 87.59 | 88.68 |
| ADADELTA | **90.58** | 90.44 | 88.20 | 88.45 |
| FTRL | 90.45 | 90.00 | 90.12 | 88.49 |
| RMSPROP | 87.79 | 88.23 | 86.63 | 86.06 |

*Tabela 20 - Teste com diferentes optimizadores com 80% de dados de teste após retirar a excentricidade mecânica*

| **Função de ativação ReLu** | **5 dias** | **10 dias** | **12 dias** | **23 dias** |
|---|---|---|---|---|
| ADAM | 92.91 | 92.60 | 92.91 | 94.56 |
| NADAM | 92.45 | 93.25 | 93.07 | 94.31 |
| SGD | 91.79 | 93.07 | 92.80 | 94.74 |
| ADAMAX | 92.78 | 93.31 | 93.01 | **94.80** |
| ADADELTA | 86.90 | 80.10 | 82.74 | 85.45 |
| FTRL | 91.55 | 91.98 | 92.11 | 89.61 |
| RMSPROP | 91.96 | 91.40 | 92.83 | 93.85 |

*Tabela 21 - Teste com diferentes optimizadores com 80% de dados de teste após retirar a excentricidade mecânica*

| ***Função de ativação Sigmoid*** | ***5 dias*** | ***10 dias*** | ***12 dias*** | ***23 dias*** |
|---|---|---|---|---|
| *ADAM* | *92.40* | *92.42* | *93.17* | ***94.40*** |
| *NADAM* | *92.55* | *93.29* | *93.33* | *94.01* |
| *SGD* | *68.01* | *69.90* | *58.87* | *71.18* |
| *ADAMAX* | *77.02* | *80.32* | *84.55* | *87.28* |
| *ADADELTA* | *79.65* | *63.83* | *56.78* | *70.72* |
| *FTRL* | *73.89* | *73.76* | *73.28* | *82.25* |
| *RMSPROP* | *91.93* | *92.99* | *93.28* | *93.86* |

*Tabela 22 - Teste com diferentes optimizadores com 80% de dados de teste após retirar a excentricidade mecânica*

| ***Função de ativação Tanh*** | ***5 dias*** | ***10 dias*** | ***12 dias*** | ***23 dias*** |
|---|---|---|---|---|
| *ADAM* | *92.06* | *92.74* | *92.88* | *92.99* |
| *NADAM* | *92.45* | *92.46* | *92.17* | *94.33* |
| *SGD* | *92.71* | *93.30* | *93.40* | ***94.60*** |
| *ADAMAX* | *92.68* | *93.03* | *93.21* | *94.05* |
| *ADADELTA* | *85.17* | *83.74* | *82.59* | *83.76* |
| *FTRL* | *87.75* | *88.65* | *88.92* | *86.88* |
| *RMSPROP* | *92.23* | *92.93* | *92.73* | *93.64* |

# Anexo B – Analise Espectral de todo o dataset ao longo do tempo

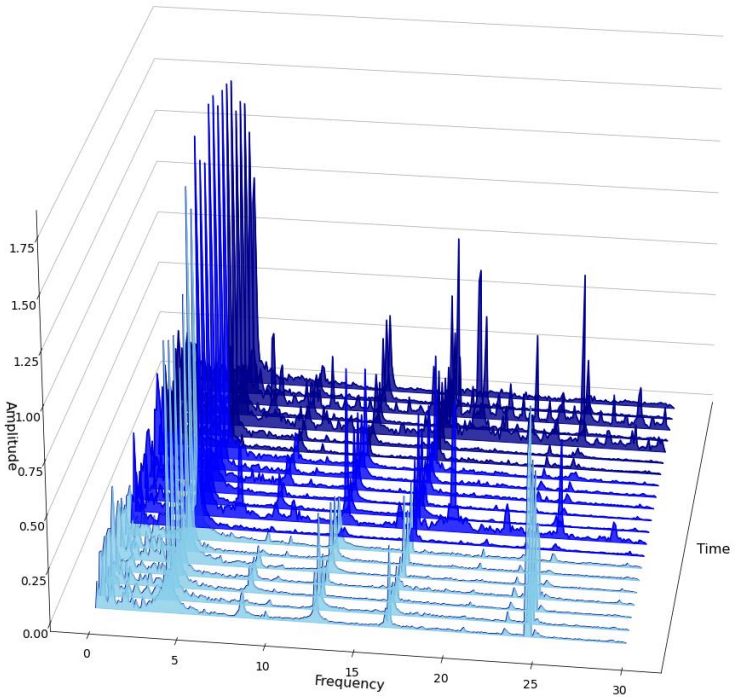


*Figura 75 - Visualização 3D de todo o espectro - perspetiva 1*

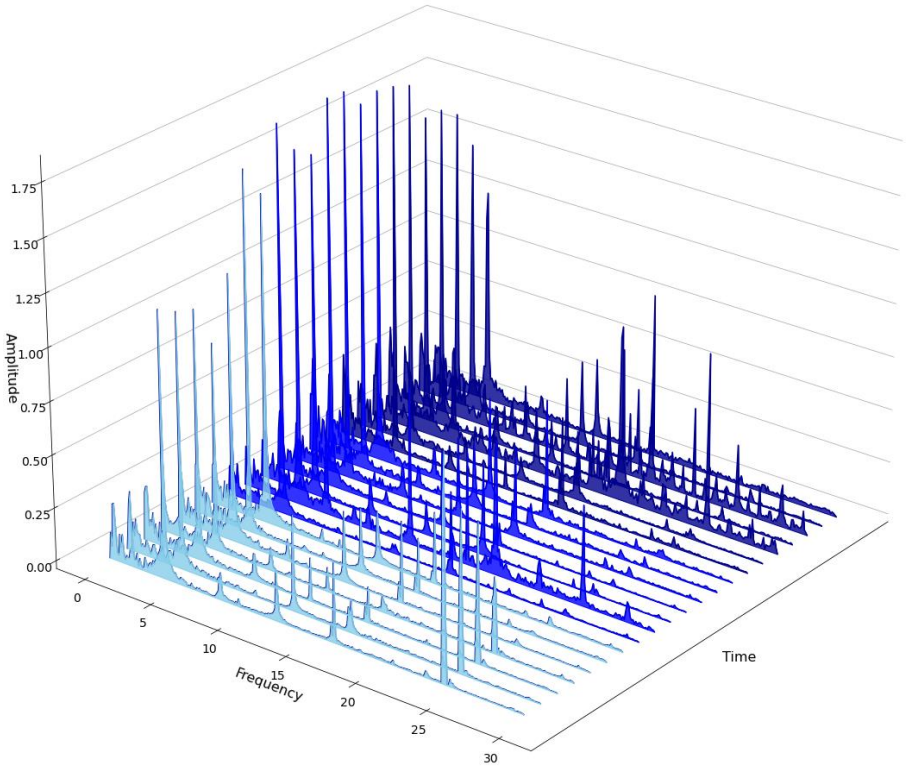


*Figura 76 - Visualização 3D de todo o espectro - perspetiva 2*