



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE AUTOMAÇÃO E SISTEMAS

Gabriel Thaler

**Aprendizado de máquina para monitoramento de ciclo de vida em componentes de
sistemas de refrigeração**

Florianópolis
2025

Gabriel Thaler

Aprendizado de máquina para monitoramento de ciclo de vida em componentes de sistemas de refrigeração

Tese submetida ao Programa de Pós-Graduação em Engenharia de Automação e Sistemas da Universidade Federal de Santa Catarina para a obtenção do título de doutor em Engenharia de Automação e Sistemas.
Orientador: Prof. Rodolfo César Costa Flesch, Dr.
Coorientadores: Antonio Luiz Schalata Pacheco, Dr.
Prof. Tao Jin, Dr.

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Thaler, Gabriel

Aprendizado de máquina para monitoramento de ciclo de vida em componentes de sistemas de refrigeração / Gabriel Thaler ; orientador, Rodolfo César Costa Flesch, coorientador, Antonio Luiz Schalata Pacheco, coorientador, Tao Jin, 2025.
166 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia de Automação e Sistemas, Florianópolis, 2025.

Inclui referências.

1. Engenharia de Automação e Sistemas. 2. Sistemas de refrigeração. 3. Aprendizado de máquina. 4. Detecção de regime permanente. 5. Estimação de fim de vida útil. I. Flesch, Rodolfo César Costa. II. Pacheco, Antonio Luiz Schalata. III. Jin, Tao IV. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia de Automação e Sistemas. V. Título.

Gabriel Thaler

Aprendizado de máquina para monitoramento de ciclo de vida em componentes de sistemas de refrigeração

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof.^a Lucia Valeria Ramos de Arruda, Dra.
Universidade Tecnológica Federal do Paraná

Prof. Leandro dos Santos Coelho, Dr.
Universidade Federal do Paraná

Prof. Marcelo Ricardo Stemmer, Dr.
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de doutor em Engenharia de Automação e Sistemas.



Documento assinado digitalmente
Max Hering de Queiroz
Data: 24/11/2025 10:27:00-0300
CPF: ***.550.079-**
Verifique as assinaturas em <https://v.ufsc.br>

Coordenação do Programa de Pós-Graduação



Documento assinado digitalmente
Rodolfo Cesar Costa Flesch
Data: 24/11/2025 08:27:36-0300
CPF: ***.466.879-**
Verifique as assinaturas em <https://v.ufsc.br>

Prof. Rodolfo César Costa Flesch, Dr.
Orientador

Florianópolis, 2025.

Aos meus pais, por todo o apoio.
À minha Oma, por todo o carinho que sempre levarei comigo.

AGRADECIMENTOS

Estou escrevendo esses agradecimentos em um domingo de manhã, dois dias após a minha defesa. Ninguém em casa acordou além de mim, e teria sido uma boa manhã chuvosa para ficar na cama. É justamente em momentos assim, quando estou sozinho no silêncio, quando o dia ainda nem clareou, que mais sinto gratidão e carinho por todos que me acompanharam não só nesses quatro anos de doutorado, mas durante toda a minha (ainda curta) caminhada. Agradeço:

Aos meus pais, Werner e Jeane. Tudo o que sou hoje é resultado do apoio, carinho e amor de vocês. Obrigado pelas conversas, pelo suporte nos dias difíceis e pelas risadas nos dias fáceis. Quanto mais eu cresço, mais quero ser como meus pais quando crescer. Aproveito também para agradecer ao meu irmão, Vinícius, que até que não saiu tão mal assim para um irmão caçula. Amo você, maninho.

Ao meu Opa, André, e à minha Vó, Herondina. Vocês são um exemplo de força e energia, e a vida de vocês me inspira para o futuro. De forma especial, agradeço muito, muito, muito à minha Oma, Elisabeth, que recentemente nos deixou. Todo o amor, todos os bons momentos, os lanches da tarde, os encontros, as conversas, os abraços apertados... Dói muito não poder estar comemorando essa conquista com você, mas sei que o Céu a recebe com muito mais festa do que eu conseguiria fazer. Vou levar você sempre como uma flor no meu coração.

À minha namorada Rafaela, que neste momento está dormindo no quarto aqui ao lado, mas que logo vai acordar e, junto com o Floki e o Goku, vai encher a nossa casa de vida, assim como enche todos os meus dias. Amo muito você. Amo sua gentileza, seu humor, sua criatividade, e estou ansioso para dividir com você todo o nosso futuro. Também agradeço ao Silvio, à Rita, ao Bruno, à Cibele, à Clarice, à Bianca, ao Neandro e à Yasminka por não só me “emprestarem” a Rafaela, mas por terem me aceitado com tanto carinho em sua família desde o início.

Ao meu orientador, Rodolfo, que em março de 2015 aceitou orientar um Gabriel da terceira fase que não sabia nem se continuaria no curso. Hoje, mais de dez anos depois, não consigo imaginar minha trajetória acadêmica e profissional sem a sua orientação e amizade. Obrigado pelas oportunidades, pelo profissionalismo e por toda a paciência durante o aprendizado. Tenho muita alegria em poder continuar essa parceria ainda além desta tese.

Ao meu coorientador, Pacheco, que admiro cada vez mais. É um privilégio poder trabalhar com um profissional tão completo e, ao mesmo tempo, tão humano. Desde as precisas correções textuais até as conversas e divagações, sou profundamente grato, e espero continuar traçando minha trajetória contigo ao meu lado.

Aos membros da banca examinadora desta tese. Obrigado pela dedicação, pelos comentários e pela disposição em participar deste momento.

Ao meu primeiro amigo de faculdade, depois colega de laboratório, e hoje irmão de

coração, João Paulo. Muito obrigado pelo apoio, pelos desabafos e por toda a parceria dentro e fora da Universidade. Uma amizade assim já faz tudo valer a pena. Aproveitando, agradeço à Ritieli e ao Pedro, que também considero minha família, por todos os encontros e risadas que tivemos e que teremos daqui pra frente. Agradeço também aos amigos Murilo e Jamal, que seguem seus caminhos profissionais longe, mas que espero ansiosamente poder rever logo.

Ao amigo Ruy e à família Carvalho, que me acolheram tantas vezes e que me deram um gostinho de casa todas as vezes que precisei. Em especial, agradeço ao Matheus, outro irmão que encontrei na vida, que me traz tanto apoio e alegria, e a quem admiro agora não só como amigo, mas também como pai.

Ainda falando sobre irmãos, agradeço ao Rodrigo, companheiro de conversas, ideias, histórias e hiperfocos. Agradeço também por ter me trazido para perto da Angelina, do Douglas, do Eduardo e da Luana, todos amigos que eu amo e admiro, e que só pecam por não estarem mais próximos e mais vezes. Devo muito a todos vocês.

Aos amigos inesperados que conheci nos últimos anos e que hoje são uma parte tão grande da minha vida: Malena, Janson, William, Ericke, Cyan, Larissa e Augusto, que vivem comigo o sonho de infância de inventar histórias cercado de bons amigos; e Marcelo, Lara, Thaiane, Duda (que já era amizade antiga, mas incluo junto com os amigos que me apresentou), Lucas, Malu e André, que me resgataram da solidão pandêmica e, já nas primeiras semanas, proporcionaram mais histórias do que eu tinha vivido em meses.

Aos amigos distantes: Giovani, Yasmim, André, Mariana, Ana Maria, Gabriel (e agora também Miguel), Giovana, Giovanna e Romulo. Gostaria muito de estar mais próximo, e sinto saudades de todos. Espero que a vida nos aproxime mais e proporcione mais momentos de encontro.

Ao Departamento de Engenharia de Automação e Sistemas, em especial à Livia e aos professores do departamento. Ninguém se forma sozinho, e isso se torna ainda mais evidente na pós-graduação. Obrigado pela disponibilidade, profissionalismo e dedicação de todos, que foram imprescindíveis para a minha permanência na Universidade.

A todos os colegas do LIAE, pelo aprendizado e apoio na realização deste e de tantos outros trabalhos. Agradeço também à Nidec GA, em especial ao Maurício, por todo o suporte nesses tantos anos de estudo e de projetos.

致金涛教授以及福州大学先进电力技术国际研究中心的全体同事：非常感谢在贵实验室学习与工作的宝贵经历。我从中获得的知识与成长将永远陪伴我。期望不久后能再次与各位相见。

Por fim, a todos aqueles que, de uma forma ou de outra, colaboraram com este trabalho, e a você, leitor. Espero que o que escrevi nestas páginas possa ser útil para muitos outros trabalhos vindouros.

*“Os sonhos dos que caíram!
As esperanças dos que virão!
Dois destinos entrelaçados como uma dupla hélice, abrindo caminho rumo ao amanhã!”
Simon, o escavador - Tengen Toppa Gurren Lagann*

RESUMO

Esta tese propõe técnicas de sensoriamento virtual e aprendizado de máquina para estimação do ciclo de vida de componentes do sistemas de refrigeração, com foco em compressores e seus sistemas de acionamento. O objetivo é ampliar o monitoramento desses dispositivos de forma não invasiva e automática utilizando métodos de aprendizado de máquina. Dois problemas são abordados: (i) identificar o término do amaciamento tribológico em compressores; e (ii) estimar o fim da vida útil dos capacitores do barramento de corrente contínua de conversores que os acionam. Na primeira frente, um método não supervisionado com agrupamento e análise probabilística foi desenvolvido, mostrando que indicadores derivados da corrente elétrica concentraram até 99% das detecções válidas. Um novo núcleo de agrupamento, usando função de base radial e distância de Mahalanobis, atingiu 93% de acertos em um modelo de compressor, enquanto o núcleo clássico foi mais eficaz em outro modelo (67%). Para aplicação on-line, foi desenvolvido um modelo semissupervisionado por autotreinamento otimizado por algoritmos de otimização com múltiplos objetivos. Na segunda frente, um sensor virtual de capacitância baseado em variáveis elétricas do conversor foi apresentado. O método combina extração recursiva de características nos domínios do tempo e da frequência, utilizando uma rede neural de memória longa de curto prazo para regressão. Com 500 ensaios experimentais, o modelo apresentou erro médio de $6,9 \mu\text{F}$ e desvio padrão de $5,0 \mu\text{F}$, superando em 40% o erro médio de outras abordagens. Os resultados confirmam a viabilidade do sensoriamento virtual e aprendizado de máquina para monitoramento e manutenção preditiva dos componentes propostos em sistemas de refrigeração. Esta tese contribui para a literatura com: (i) um novo núcleo para agrupamento por *kernel k*-médias combinando função de base radial e distância de Mahalanobis, (ii) um método baseado em aprendizado não supervisionado para detecção off-line de transições tribológicas, aplicado em um estudo de caso para identificação do amaciamento em compressores alternativos, (iii) uma aplicação de autotreinamento para identificação do amaciamento e (iv) um novo método para estimação de capacitância em capacitores de conversores de frequência baseado em redes neurais artificiais.

Palavras-chave: Sistemas de refrigeração. Aprendizado de máquina. Detecção de regime permanente. Estimação de fim de vida útil. Amaciamento. Deterioração de capacitores. Compressores herméticos alternativos.

ABSTRACT

This thesis proposes virtual sensing and machine learning techniques for estimating the lifecycle of components in refrigeration systems, with a focus on compressors and their drive systems. The objective is to expand the monitoring of these devices in a non-invasive and automatic manner using machine learning methods. Two problems are addressed: (i) identifying the end of the tribological running-in process in compressors; and (ii) estimating the end of life of the DC-link capacitors in the converters that drive them. In the first part, an unsupervised method based on clustering and probabilistic analysis was developed, showing that indicators derived from the electric current accounted for up to 99% of valid detections. A new clustering kernel, combining a radial basis function with the Mahalanobis distance, achieved 93% accuracy for one compressor model, while the classical kernel was more effective for another model (67%). For online application, a semi-supervised self-training model optimized by multi-objective optimization algorithms was developed. In the second part, a virtual capacitance sensor based on electrical variables of the converter was presented. The method combines recursive feature extraction in the time and frequency domains and employs a long short-term memory neural network for regression. Based on 500 experimental tests, the model achieved a mean absolute error of $6,9\ \mu\text{F}$ with a standard deviation of $5,0\ \mu\text{F}$, outperforming the mean error of other approaches by 40%. The results confirm the feasibility of virtual sensing and machine learning for monitoring and predictive maintenance of the proposed components in refrigeration systems. This thesis contributes to the literature with: (i) a novel kernel for k -means clustering that combines a radial basis function with the Mahalanobis distance; (ii) an unsupervised learning method for offline detection of tribological transitions, applied to a case study of running-in identification in reciprocating compressors; (iii) a self-training approach for running-in identification; and (iv) a novel capacitance estimation method for frequency-converter capacitors based on artificial neural networks.

Keywords: Refrigeration systems. Machine learning. Steady-state detection. End-of-life estimation. Running-in. Capacitor degradation. Hermetic reciprocating compressors.

LISTA DE FIGURAS

Figura 1 – Taxa de desgaste e etapas da vida de um sistema de refrigeração, fora de escala.	34
Figura 2 – Operação e ensaios de compressores recém-manufaturados.	37
Figura 3 – Média e variabilidade da média amostral da capacidade de refrigeração escalonada em ensaios de calorímetro consecutivos.	38
Figura 4 – Subsistemas e componentes mais propensos a falhas em conversores.	40
Figura 5 – Principais componentes para pesquisa de confiabilidade em conversores.	41
Figura 6 – Comparação entre valores equidistantes utilizando distância euclidiana e de Mahalanobis para um exemplo de conjunto de dados com duas dimensões.	48
Figura 7 – Representação de um PMC.	52
Figura 8 – Representação de uma célula LSTM.	54
Figura 9 – Comparação entre sistemas de refrigeração com velocidade fixa (controle liga/desliga) e com velocidade variável (controle PI).	56
Figura 10 – Diagrama de blocos funcionais de um conversor de frequência com barramento CC.	57
Figura 11 – Exemplo de compressor e módulo conversor de frequência.	58
Figura 12 – Modelagem de capacitores: (a) circuito equivalente simplificado e (b) resposta da impedância na frequência.	59
Figura 13 – Ilustração da estrutura interna de um eletrolítico de alumínio.	60
Figura 14 – C e R_{SE} ao longo da degradação de um Al-Cap com indicação do FDV do componente de acordo com tais indicadores.	62
Figura 15 – Diagrama de tubulação e instrumentação da bancada de caracterização de amaciamento.	68
Figura 16 – Fotos da bancada de amaciamento: (a) vista em perspectiva; (b) vista lateral do circuito auxiliar; (c) compressor instrumentado.	69
Figura 17 – Corrente RMS de ensaios realizados com compressores do Modelo A.	71
Figura 18 – Corrente RMS de ensaios realizados com compressores do Modelo B.	72
Figura 19 – Representação esquemática do método proposto.	73
Figura 20 – Representação do processo de subsequenciamento de uma série temporal por janela deslizante em espaço de atraso.	76
Figura 21 – Exemplo de conjunto de dados de corrente RMS gerado pelo subsequenciamento de séries temporais de 3 ensaios do mesmo compressor ($N = 2$, $D = 10$).	77
Figura 22 – Agrupamento por k -médias e proporção de grupos: curtose da corrente de uma unidade de compressor, processada com $M = 1$, $N = 5$, e $D = 10$	78
Figura 23 – Agrupamento por k -médias e proporção de grupos: vazão mássica de uma unidade de compressor, processada com $M = 1$, $N = 5$, e $D = 1$	79

Figura 24 – Histogramas e estimações de PDF das transições de amaciamento para regime permanente detectadas em compressores do Modelo A.	85
Figura 25 – Histogramas e estimações de PDF das transições de amaciamento para regime permanente detectadas em compressores do Modelo B.	86
Figura 26 – Algoritmos de agrupamento, grandezas, métodos de detecção de transição e parâmetros de processamento em modelos remanescentes no conjunto após poda.	87
Figura 27 – Estimativa da probabilidade de regime permanente tribológico, por grandeza	89
Figura 28 – Histograma do número de modelos remanescentes no conjunto após poda, pelo tamanho da janela de amostragem.	90
Figura 29 – Estimativa da probabilidade de regime permanente tribológico, por método de agrupamento.	91
Figura 30 – Diagrama do método proposto para o desenvolvimento do modelo semissupervisionado para identificação do amaciamento.	92
Figura 31 – Diagrama do procedimento de otimização multi-objetivo e seleção de modelos baseado em avanço da FP.	97
Figura 32 – FP do processo de otimização considerando compressores do Modelo A: (a) modelos lineares e estatísticos, (b) modelos baseados em árvore, e (c) outros modelos.	99
Figura 33 – FP dos classificadores dominantes considerando compressores do Modelo A.	100
Figura 34 – Desempenho dos classificadores treinados com o Modelo A com maior CCM em validação cruzada.	101
Figura 35 – FP do processo de otimização considerando compressores do Modelo B: (a) modelos lineares e estatísticos, (b) modelos baseados em árvore, e (c) outros modelos.	101
Figura 36 – FP dos classificadores dominantes considerando compressores do Modelo B.	102
Figura 37 – Desempenho dos classificadores treinados com o Modelo B com maior CCM em validação cruzada.	103
Figura 38 – FP do processo de otimização considerando ambos os modelos de compressor: (a) modelos lineares e estatísticos, (b) modelos baseados em árvore, e (c) outros modelos.	103
Figura 39 – FP dos classificadores dominantes considerando compressores de ambos modelos.	104
Figura 40 – Desempenho dos classificadores treinados com ambos os modelos com maior CCM em validação cruzada.	105
Figura 41 – Amaciamento ao longo do tempo de acordo com autotreinamento e diferentes classificadores, com base em dados de compressores do Modelo A.	106

Figura 42 – Amaciamento ao longo do tempo de acordo com autotreinamento e diferentes classificadores, com base em dados de compressores do Modelo B.	107
Figura 43 – Amaciamento ao longo do tempo de acordo com autotreinamento e diferentes classificadores, com base em dados de compressores de ambos modelos.	108
Figura 44 – Estimação do fim do amaciamento utilizando floresta aleatória autotreinada com unidades do Modelo A de compressores e utilizando o conjunto não supervisionado.	111
Figura 45 – Estimação do fim do amaciamento utilizando floresta aleatória autotreinada com unidades do Modelo B de compressores e utilizando o conjunto não supervisionado.	112
Figura 46 – Estimação do fim do amaciamento utilizando floresta aleatória autotreinada com unidades de ambos os modelos de compressores e utilizando o conjunto não supervisionado.	113
Figura 47 – Diagrama do modelo proposto para estimação da capacitância do filtro do barramento CC de conversores de frequência.	117
Figura 48 – Diagrama da bancada experimental para ensaios de capacitância variável.	119
Figura 49 – Foto da bancada experimental para ensaios de capacitância variável.	120
Figura 50 – Função de perda ao longo do treinamento do modelo proposto.	125
Figura 51 – Estimação de capacitância utilizando o método proposto.	126
Figura 52 – EAM e EARM do método proposto para cada uma das condições de capacitância avaliadas.	127
Figura 53 – Comparação entre as estimações utilizando o método proposto e o método de Örüklü e Ağalar (2025).	130
Figura 54 – PDF estimada do erro utilizando o método proposto e o método de Örüklü e Ağalar (2025).	130

LISTA DE QUADROS

Quadro 1 – Resumo de trabalhos dos últimos cinco anos no campo de estimação de FDV de capacitores	64
Quadro 2 – Parâmetros de processamento e intervalos utilizados na otimização.	94
Quadro 3 – Classificadores e intervalos de hiperparâmetros utilizados na otimização.	95
Quadro 4 – Intervalos de busca dos hiperparâmetros para a otimização.	123
Quadro 5 – Hiperparâmetros otimizados do modelo proposto.	124
Quadro 6 – Espaços de busca de hiperparâmetros considerados para o PMC proposto por Andrade (2024).	128
Quadro 7 – Parâmetros ótimos encontrados para regressão logística.	155
Quadro 8 – Parâmetros ótimos encontrados para árvore de decisão.	156
Quadro 9 – Parâmetros ótimos encontrados para K-VMP.	156
Quadro 10 – Parâmetros ótimos encontrados para MVS linear.	157
Quadro 11 – Parâmetros ótimos encontrados para MVS-FBR.	157
Quadro 12 – Parâmetros ótimos encontrados para floresta aleatória.	158
Quadro 13 – Parâmetros ótimos encontrados para PMC.	159
Quadro 14 – Parâmetros ótimos encontrados para AdaBoost.	159
Quadro 15 – Parâmetros ótimos encontrados para Bayes ingênuo.	160
Quadro 16 – Parâmetros ótimos encontrados para ADQ.	160

LISTA DE TABELAS

Tabela 1 – Modelos de compressor utilizados em ensaios de amaciamento.	69
Tabela 2 – Número total de iterações de otimização realizadas para cada classificador.	98
Tabela 3 – Proporção de transição e progressão por classificador e modelo de compressor utilizado na otimização.	109
Tabela 4 – EAM, em valor percentual, por classificador e modelo de compressor.	110
Tabela 5 – Condições de ensaio consideradas nos ensaios de capacitância.	120
Tabela 6 – Resultados da estimação utilizando o modelo proposto.	125
Tabela 7 – Métricas de desempenho do método proposto calculadas considerando subconjuntos do conjunto de treino, com e sem <i>dropout</i>	126
Tabela 8 – Resultados dos melhores modelos de regressão para estimação da capacitância com o método de Andrade (2024) (parâmetros originais).	128
Tabela 9 – Resultados dos melhores modelos de regressão para estimação da capacitância com o método de Andrade (2024) (busca estendida).	128
Tabela 10 – Resultados dos modelos de regressão para estimação da capacitância com o método de Örüklü e Ağalar (2025) para todas as condições avaliadas.	129
Tabela 11 – EAM entre os classificadores semisupervisionados e o conjunto não supervisionado em compressores do Modelo A considerando todos os métodos de agrupamento.	162
Tabela 12 – EAM entre os classificadores semisupervisionados e o conjunto não supervisionado em compressores do Modelo B considerando todos os métodos de agrupamento.	163
Tabela 13 – EAM total entre os classificadores semisupervisionados treinado com ambos os modelos de compressor e conjuntos não supervisionados com diferentes métodos de agrupamento.	164

LISTA DE ABREVIATURAS E SIGLAS

ACP	Análise de Componentes Principais
AdaBoost	Reforço adaptativo (do inglês <i>Adaptative Boosting</i>)
ADQ	Análise Discriminante Quadrática
AISI	Instituto Americano de Ferro e Aço (do inglês <i>American Iron and Steel Institute</i>)
Al-Cap	Capacitor eletrolítico de Alumínio
ANSI	Instituto Nacional Americano de Padrões (do inglês <i>American National Standards Institute</i>)
ASHRAE	Sociedade Americana de Engenheiros de Aquecimento, Refrigeração e Condicionamento de Ar (tradução livre do inglês <i>American Society of Heating, Refrigeration and Air-conditioning Engineers</i>)
AUC	Área abaixo da curva de característica de operação do receptor (do inglês <i>Area Under the ROC Curve</i>)
CA	Corrente Alternada
CC	Corrente Contínua
CCM	Coeficiente de Correlação de Matthews
CDF	Função distribuição acumulada (do inglês <i>Cumulative Distribution Function</i>)
CMM	Conversor Modular Multinível
COF	Coeficiente de atrito (do inglês <i>Coefficient Of Friction</i>)
DEP	Densidade Espectral de Potência
EAM	Erro Absoluto Médio
EARM	Erro Absoluto Relativo Médio
ELU	Unidade linear exponencial, do inglês <i>Exponential Linear Unit</i>
EQM	Erro Quadrático Médio
FBR	Função de Base Radial
FBR-M	Função de Base Radial com distância de Mahalanobis
FDV	Fim De Vida útil
FP	Fronteira de Pareto
IGBT	transistor bipolar de porta isolada (do inglês <i>Insulated Gate Bipolar Transistor</i>)
ISO	Organização Internacional de Normalização (do inglês <i>International Organization for Standardization</i>)
K-VMP	K vizinhos mais próximos
LBP	Baixa pressão de retorno (tradução livre do inglês <i>Low Back Pressure</i>)
LSTM	Rede neural de memória longa de curto prazo (do inglês <i>Long Short Term Memory</i>)

MOSFET	Transistor de efeito de campo semiconductor de óxido metálico (do inglês <i>Metal Oxide Semiconductor Field-Effect Transistor</i>)
mRNA	ácido ribonucleico mensageiro (do inglês <i>messenger RiboNucleic Acid</i>)
MVS	Máquina de Vetores de Suporte
NBR	Norma BRasileira
NSGA-II	Algoritmo genético de ordenação não dominada II (do inglês <i>Non-dominated Sorting Genetic Algorithm II</i>)
P&D	Pesquisa e Desenvolvimento
PC	Computador pessoal (do inglês <i>Personal Computer</i>)
PDF	Função de densidade de probabilidade (do inglês <i>Probability Density Function</i>)
PI	Proporcional Integral
PMC	Perceptron com Múltiplas Camadas
ReLU	Unidade linear retificada, do inglês <i>Rectified Linear Unit</i>
RMS	Raiz do valor médio quadrático (do inglês <i>Root Mean Square</i>)
RNA	Rede Neural Artificial
RNR	Rede Neural Recorrente
ROC	Característica de operação do receptor (do inglês <i>Receiver Operating Characteristics</i>)
RPG	Regressão de Processo Gaussiano
SELU	Unidade linear exponencial escalonada, do inglês <i>Scaled Exponential Linear Unit</i>

LISTA DE SÍMBOLOS

a_G	Coeficiente do filtro recursivo do algoritmo de Goertzel
$\mathbf{a}$	Vetor de ativações de uma camada de neurônios em um Perceptron multicamadas
$\mathbf{a}_o$	Ativações da última camada oculta de um Perceptron multicamadas para regressão
b_o	Viés da unidade de saída de um Perceptron multicamadas para regressão
$\mathbf{b}$	Vetor de vieses de uma camada de neurônios em um Perceptron multicamadas
b_{hf}	Viés do estado oculto anterior para a porta de esquecimento LSTM
b_{hg}	Viés do estado oculto anterior para o candidato ao estado da célula LSTM
b_{hi}	Viés do estado oculto anterior para a porta de entrada LSTM
b_{ho}	Viés do estado oculto anterior para a porta de saída LSTM
b_{if}	Viés da entrada para a porta de esquecimento LSTM
b_{ig}	Viés da entrada para o candidato ao estado da célula LSTM
b_{ii}	Viés da entrada para a porta de entrada LSTM
b_{io}	Viés da entrada para a porta de saída LSTM
C	Capacitância
$\hat{C}$	Capacitância estimada
$\mathbf{c}$	Estado da célula LSTM
$\mathcal{C}$	Conjunto de todos os grupos
$\mathcal{C}_e$	Vetor com os grupos atribuídos a cada amostra do vetor de ensaios e
$\mathbf{c}$	Grupo para detecção de transição
D	Atraso entre amostras da janela deslizante
d_E	Distância euclidiana
d_M	Distância de Mahalanobis
F_s	Frequência de amostragem
f_d	Frequência de interesse
$\mathbf{f}$	Vetor da porta de esquecimento LSTM
$\mathbf{g}$	Candidato ao estado da célula LSTM
$\mathbf{h}$	Vetor de estados ocultos na saída da última camada de uma RNR
I_{CC}	Corrente instantânea no barramento de corrente contínua de um conversor de potência
I_{Kur}	Curtose da corrente elétrica
I_{RMS}	Valor eficaz da corrente elétrica
I_s	Corrente instantânea na saída de um conversor de potência
$I_{s,RMS}$	Valor eficaz da corrente na saída de um conversor de potência
I_{THD}	Distorção harmônica total da corrente elétrica
I_{Var}	Variância da corrente elétrica
I_σ	Desvio-padrão da corrente elétrica
$\mathbf{i}$	Vetor da porta de entrada LSTM

K^{FBR}	Kernel de função de base radial
k	Índice discreto
k_d	Índice do <i>bin</i> da transformada discreta de Fourier correspondente à frequência de interesse
k	Número de grupos de uma agrupamento
L_{SE}	Impedância série equivalente
$L(\Theta)$	Função de perda de uma rede neural artificial em função de seus parâmetros ajustáveis
l_L	Limiar inferior da proporção para o método de detecção por limiar inferior
l_U	Limiar superior da proporção para o método de detecção por limiar superior
M	Tamanho da janela do filtro de médias móveis
$\dot{m}$	Vazão mássica
$\mathfrak{M}$	Coeficiente de correlação de Matthews de uma estimação
N	Tamanho da janela deslizante
N_{FP}	Número de falsos positivos na classificação de um conjunto
N_{FN}	Número de falsos negativos na classificação de um conjunto
N_f	Tamanho da janela para transformada discreta de Fourier
N_{TP}	Número de verdadeiros positivos na classificação de um conjunto
N_{TN}	Número de verdadeiros negativos na classificação de um conjunto
N_t	Número de amostras acumuladas para extração de <i>features</i> temporais
N_X	Número de amostras em um conjunto de medições
n_c	Número de ensaios de um compressor
n_U	Número de compressores ensaiados
$\mathbf{o}$	Vetor da porta de saída LSTM
p_{CC}	Densidade espectral de potência da tensão no barramento de corrente
$p_{CC,1e}$	Densidade espectral de potência da tensão no barramento de corrente contínua na primeira harmônica da frequência de entrada de um conversor de potência
$p_{CC,1s}$	Densidade espectral de potência da tensão no barramento de corrente contínua na primeira harmônica da frequência de saída de um conversor de potência
$p_{CC,2e}$	Densidade espectral de potência da tensão no barramento de corrente contínua na segunda harmônica da frequência de entrada de um conversor de potência
$p_{CC,2s}$	Densidade espectral de potência da tensão no barramento de corrente contínua na segunda harmônica da frequência de saída de um conversor de potência
p_c	Proporção do grupo c em uma dada janela de tempo
R^2	Coeficiente de determinação
R_p	Resistência equivalente do isolamento
R_{SE}	Resistência série equivalente
$S_{1,V_{CC}}$	Soma acumulada da tensão no barramento de corrente contínua de um conversor de potência

$S_{1,\omega}$	Soma acumulada da velocidade do motor do compressor
S_{2,I_s}	Soma acumulada do quadrado da corrente na saída de um conversor de potência
$S_{2,V_{CC}}$	Soma acumulada do quadrado da tensão no barramento de corrente contínua de um conversor de potência
s_G	Estado interno do algoritmo de Goertzel
s_u	Variabilidade da média de amostral em ensaios de calorímetro
T	Instante de transição
$\bar{T}$	Estimativa a priori do instante de transição
T_e	Conjunto de todos os ensaios de uma dada unidade
T_s	Período de amostragem
t	Instante de tempo
t_S	Distribuição t de Student
t_e	Número do ensaio na ordem cronológica com 1 sendo o ensaio de amaciamento
t_{set}	Duração do período transitório natural de ensaios em compressores
U	Conjunto de todas as unidades de compressor
u	Unidade de compressor
V_{CC}	Tensão instantânea no barramento de corrente contínua de um conversor de potência
$V_{CC,max}$	Valor máximo da tensão instantânea no barramento de corrente contínua de um conversor de potência
$V_{CC,min}$	Valor mínimo da tensão instantânea no barramento de corrente contínua de um conversor de potência
$V_{CC,Pk}$	Valor pico-a-pico da tensão no barramento de corrente contínua de um conversor de potência
$V_{Osc,RMS}$	Valor eficaz da oscilação da tensão no barramento de corrente contínua de um conversor de potência
$\tilde{V}_{CC}$	Transformada discreta de Fourier da tensão no barramento de corrente contínua de um conversor de potência
$\bar{V}_{CC}$	Tensão média no barramento de corrente contínua de um conversor de potência
ν_{Lat}	Vibração no eixo lateral
$\nu_{Lat,Ass}$	Assimetria da vibração no eixo lateral
$\nu_{Lat,Kur}$	Curtose da vibração no eixo lateral
$\nu_{Lat,Pk}$	Valor de pico da vibração no eixo lateral
$\nu_{Lat,RMS}$	Valor eficaz da vibração no eixo lateral
$\nu_{Lat,Var}$	Variância da vibração no eixo lateral
$\nu_{Lon,Ass}$	Assimetria da vibração no eixo longitudinal
$\nu_{Lon,Pk}$	Valor de pico da vibração no eixo longitudinal
$\nu_{Lon,RMS}$	Valor eficaz da vibração no eixo longitudinal
$\nu_{Lon,Var}$	Variância da vibração no eixo longitudinal

$v_{\text{Lon},\sigma}$	Desvio-padrão da vibração no eixo longitudinal
$\mathbf{v}$	Pesos que conectam a última camada oculta à saída de um Perceptron multicamadas para regressão
W	Janela de tempo para proporção de grupos para detecção de transição
$\mathbf{W}$	Matriz de pesos entre entradas e neurônios em uma camada de um Perceptron multicamadas
$\mathbf{W}_{hf}$	Pesos do estado oculto anterior para a porta de esquecimento LSTM
$\mathbf{W}_{hg}$	Pesos do estado oculto anterior para o candidato ao estado da célula LSTM
$\mathbf{W}_{hi}$	Pesos do estado oculto anterior para a porta de entrada LSTM
$\mathbf{W}_{ho}$	Pesos do estado oculto anterior para a porta de saída LSTM
$\mathbf{W}_{if}$	Pesos da entrada para a porta de esquecimento LSTM
$\mathbf{W}_{ig}$	Pesos da entrada para o candidato ao estado da célula LSTM
$\mathbf{W}_{ii}$	Pesos da entrada para a porta de entrada LSTM
$\mathbf{W}_{io}$	Pesos da entrada para a porta de saída LSTM
X_{Ass}	Assimetria de um conjunto de medições
X_{Kur}	Curtose de um conjunto de medições
X_{Pk}	Valor de pico de um conjunto de medições
X_{RMS}	Valor eficaz de um conjunto de medições
X_{Var}	Variância de um conjunto de medições
X_{σ}	Desvio-padrão de um conjunto de medições
x_m	Medição de uma grandeza
$\hat{x}_m$	Medição de uma grandeza filtrada por médias móveis
$\bar{x}_m$	Média das amostras em um conjunto de medições
$\mathbf{x}$	Vetor de entradas de uma camada de neurônios em um Perceptron multicamadas
$\tilde{\mathbf{x}}$	Vetor de amostras
$\mathbf{x}_m$	Vetor de medições de uma dada grandeza
$\hat{\mathbf{x}}_m$	Vetor de amostras após janela deslizante em espaço de atraso de série temporal filtrada
y	Saída alvo de um Perceptron multicamadas para regressão
$\hat{y}$	Saída estimada por um Perceptron multicamadas para regressão
Z_C	Impedância de um capacitor
$\mathbf{z}$	Combinação linear das entradas ponderadas em um Perceptron multicamadas
Σ	Matriz de covariância
$\sigma(\cdot)$	Função sigmoide
σ_c	Desvio-padrão do conjunto de ensaios de calorímetro
σ_{FBR}	Largura do kernel de função de base radial
ω	Velocidade instantânea do motor do compressor
$\bar{\omega}$	Velocidade média do motor do compressor
$\phi(\cdot)$	Função de ativação não linear em um Perceptron multicamadas

Θ	Conjunto de parâmetros treináveis de uma rede neural artificial
$\nabla_{\Theta} L$	Gradiente da função de perda em relação aos parâmetros treináveis de uma rede neural artificial
$\odot$	Produto de Hadamard

SUMÁRIO

1	INTRODUÇÃO	33
1.1	AMACIAMENTO EM COMPRESSORES HERMÉTICOS ALTERNATIVOS	36
1.2	DETERIORAÇÃO DE CAPACITORES EM CONVERSORES DE FREQUÊNCIA	39
1.3	OBJETIVOS	41
1.3.1	Objetivo geral	41
1.3.2	Objetivos Específicos	41
1.4	ESTRUTURA DO TRABALHO	42
2	FUNDAMENTAÇÃO TEÓRICA E REVISÃO DA LITERATURA	43
2.1	AMACIAMENTO	43
2.2	MÉTODOS DE AGRUPAMENTO	45
2.2.1	k-médias	46
2.2.2	Kernel k-médias	47
2.3	APRENDIZADO SEMISSUPERVISIONADO E AUTOTREINAMENTO	49
2.4	REDES NEURAIS PARA REGRESSÃO	51
2.5	CONVERSORES DE FREQUÊNCIA PARA SISTEMAS DE REFRIGERAÇÃO	55
2.6	DEGRADAÇÃO DE CAPACITORES DE BARRAMENTO CC	58
2.6.1	Tipos e características de capacitores	58
2.6.2	Mecanismos de degradação	60
2.6.3	Estimação de vida útil restante	61
2.7	CONSIDERAÇÕES	65
3	EXTRAÇÃO DE INFORMAÇÕES DE AMACIAMENTO	67
3.1	DESENVOLVIMENTO EXPERIMENTAL	67
3.1.1	Bancada experimental	67
3.1.2	Ensaio	68
3.1.3	Análise preliminar de dados	70
3.2	ANÁLISE NÃO SUPERVISIONADA	72
3.2.1	Arquitetura de detecção de transição	74
3.2.1.1	Janela deslizante em espaço de atraso	75
3.2.1.2	Agrupamento	76
3.2.1.3	Detecção de transição	78
3.2.2	Inicialização do conjunto	80
3.2.3	Poda do conjunto	82
3.2.4	Resultados	84
3.2.4.1	Transição de amaciamento para regime permanente	84
3.2.4.2	Interpretação de <i>features</i>	86
3.3	ANÁLISE SEMISSUPERVISIONADA	92

3.3.1	Método proposto	92
3.3.2	Resultados	97
3.3.2.1	Otimização	98
3.3.2.2	Identificação de amaciamento	104
3.4	COMPARAÇÃO ENTRE ABORDAGENS	109
3.5	CONSIDERAÇÕES	112
4	ESTIMAÇÃO DE VIDA ÚTIL DE CAPACITORES	117
4.1	MÉTODO PROPOSTO	117
4.1.1	Estrutura experimental	118
4.1.2	Processamento de dados	120
4.1.3	Otimização	123
4.2	RESULTADOS	124
4.3	CONSIDERAÇÕES	131
5	CONSIDERAÇÕES FINAIS	133
5.1	CONCLUSÕES	133
5.2	SUGESTÕES PARA TRABALHOS FUTUROS	136
5.3	PUBLICAÇÕES EM CONGRESSOS E PERIÓDICOS	137
	REFERÊNCIAS	139
	APÊNDICE A – PARÂMETROS OTIMIZADOS DE MODELOS SEMISUPERVISIONADOS	155
	APÊNDICE B – COMPARAÇÃO DE ESTIMAÇÃO DO AMACIAMENTO POR UNIDADE E AGRUPAMENTO	161

1 INTRODUÇÃO

A manutenção preditiva e o prognóstico e gerenciamento de saúde de máquinas estão entre os temas de revolução da Indústria 4.0. Com o avanço do campo e de métodos de sensoriamento virtual, técnicas de monitoramento de condições e de desempenho que antes eram restritas a equipamentos industriais atualmente são viáveis também para aplicação em equipamentos comerciais de menor valor agregado (BIGGIO; KASTANIS, 2020; SOFOS *et al.*, 2020). Um exemplo de sistemas de interesse para tais aplicações são os sistemas de refrigeração, que têm sido objeto de uma crescente corrida pelo aumento de eficiência energética, sem que isso comprometa a sua vida útil. Essa busca pode ser observada, por exemplo, no consumo energético dos produtos da líder do mercado global de compressores herméticos para refrigeração, dado que dispositivos da família ES, da empresa Nidec Global Appliance, lançada em 2021, são cerca de 25% mais eficientes que modelos de capacidade similares lançados na década anterior, ambos com vida útil prevista na ordem de décadas (NIDEC GLOBAL APPLIANCE, 2021).

Pode-se observar a importância do desempenho e da operação correta de sistemas de refrigeração a partir da cadeia do frio, nome dado aos processos logísticos que envolvem transporte de produtos refrigerados, tais como vacinas, medicamentos e produtos alimentícios. Segundo fontes oficiais, entre os anos de 2021 e 2022 foram administradas mundialmente mais de 660 milhões de doses de vacinas Pfizer/BioNTech para SARS-CoV-2 (MATHIEU *et al.*, 2021). Assim como outras vacinas de ácido ribonucleico mensageiro (mRNA, do inglês *messenger RiboNucleic Acid*), as vacinas Pfizer/BioNTech devem ser armazenadas a temperaturas próximas a -70°C , mantendo-se estáveis por até 6 meses nessa condição. Uma vez descongeladas e mantidas em temperaturas superiores ($+2^{\circ}\text{C}$ a $+8^{\circ}\text{C}$), as amostras podem ser armazenadas por um máximo de 5 dias e não podem ser novamente congeladas (CROMMELIN *et al.*, 2021; SANTOS; GASPAR; SOUZA, 2021). Nesse contexto, é clara a necessidade de sistemas de refrigeração confiáveis, visto que falhas na refrigeração reduzem o tempo de armazenamento das vacinas, podendo levar à perda de lotes do produto. Mesmo para vacinas que não exigem congelamento, normalmente transportadas utilizando recipientes com gelo, a refrigeração ativa possui maior custo-benefício, reduzindo as perdas por congelamento acidental (PLEWES *et al.*, 2022; JAKOVLJEVIC *et al.*, 2022).


Assim como muitas outras aplicações, a vida útil e a confiabilidade de um sistema de refrigeração podem ser representadas pela curva apresentada na Figura 1, denominada comumente de curva da banheira. Essa curva divide o ciclo de vida do sistema em três períodos:

- amaciamento: período inicial de assentamento de características mecânicas. Esse período também é denominado na literatura de mortalidade precoce, dado que no início da vida útil o sistema está mais sujeito a falhas por erros de fabricação e montagem;
- regime permanente: período mais longo da vida útil do sistema, quando as características

de operação são relativamente constantes. Durante esse período, a taxa de falha também se mantém constante, de acordo com a probabilidade de falhas aleatórias;

- deterioração: período que sinaliza o fim da vida útil, no qual a degradação natural de um ou mais componentes faz com que a taxa de falha aumente progressivamente. A severidade da deterioração varia de acordo com as especificações do sistema, podendo, em alguns casos, ser retardada com a troca de componentes, ou até requerer a troca do sistema como um todo.

Figura 1 – Taxa de desgaste e etapas da vida de um sistema de refrigeração, fora de escala.



Fonte: autor.

Além da taxa de falha, a confiabilidade do dispositivo pode ser definida a partir da capacidade de um dispositivo em manter o desempenho previsto e atender às suas especificações funcionais durante o período de operação e sob as condições de uso estabelecidas. Esse fator pode ser observado, por exemplo, no contexto da avaliação de desempenho de compressores para refrigeração, que já é bem definida por instituições internacionais como a Organização Internacional de Normalização (ISO, do inglês *International Organization for Standardization*) na norma ISO 917 (ISO, 1989)¹ e o Instituto Nacional Americano de Padrões (ANSI, do inglês *American National Standards Institute*) e a Sociedade Americana de Engenheiros de Aquecimento, Refrigeração e Condicionamento de Ar (ASHRAE, do inglês *American Society of Heating, Refrigeration and Air-conditioning Engineers*) na norma ANSI/ASHRAE 23 (ASHRAE, 2005), e em normas nacionais como a Norma Brasileira (NBR) 13410 (ABNT, 1995). Tais normas apresentam condições e requisitos de ensaio e um desses requisitos é que os resultados sejam obtidos com o compressor operando em regime permanente, já que o comportamento do compressor durante o amaciamento pode apresentar variações transitórias de eficiência, vibração e consumo elétrico decorrentes do assentamento entre componentes mecânicos. Assim, se busca garantir que os parâmetros de desempenho medidos durante o ensaio sejam representativos da operação normal de um compressor, incluindo não apenas parâmetros mensuráveis como

¹ Atualmente suspensa, porém ainda utilizada como referência no contexto industrial.

temperatura e pressão de operação, mas também outros fatores como o estado tribológico do dispositivo (PENZ, 2011).

A análise do amaciamento em compressores para refrigeração apresenta desafios do ponto de vista de instrumentação e identificação de padrões, afetando a pesquisa e o desenvolvimento da indústria do ramo e o produto final comercializado. Sua avaliação por meio de métodos clássicos, como a análise do coeficiente de atrito (COF, do inglês *Coefficient Of Friction*) e da topografia das superfícies móveis, é impedida pela complexidade dos processos tribológicos que compõem o fenômeno e pela natureza hermética dos compressores (KHONSARI; GHATREHSAMANI; AKBARZADEH, 2021).

Características similares às indicadas para a transição de amaciamento para regime permanente em compressores podem ser observadas na transição de regime permanente para deterioração, porém de forma inversa: enquanto a primeira é resultante do assentamento de características tribológicas, a segunda ocorre quando as características antes bem definidas passam a se degradar gradualmente, resultando em variações no atrito, aumento do desgaste e alteração dos parâmetros de desempenho (WOO; PECHT; O'NEAL, 2009; CIANTAR; HADFIELD, 2004). Assim, métodos para avaliação de transições tribológicas são úteis tanto no início quanto ao final da vida útil do dispositivo.

Em termos de falhas, um dos principais fatores de risco em sistemas de refrigeração modernos é a deterioração dos componentes eletrônicos periféricos. Enquanto em compressores para sistemas de refrigeração clássicos esses periféricos são normalmente restritos a termostatos e dispositivos de partida, modelos modernos podem incluir sistemas embarcados para segurança, controle e monitoramento, tanto do compressor como do sistema como um todo (KIM; BRAUN, 2012; PÖYHÖNEN, 2021; SILVA; BRAGA; DESCHAMPS, 2025). Com a adoção crescente de compressores de velocidade variável, que são em geral mais econômicos e silenciosos que modelos de velocidade fixa, é comum que esses sistemas adicionais sejam incluídos junto ao controle embarcado do conversor de frequência, necessário para a operação de velocidade variável (SILVA; BRAGA; DESCHAMPS, 2025). Diferentemente dos mecanismos robustos do compressor, esse conversor possui componentes eletrônicos sujeitos a degradação acelerada, especialmente quando impostos a condições de alta temperatura e umidade (FALCK *et al.*, 2018; ZHAO *et al.*, 2020; NATHAN *et al.*, 2023).

Dentre os componentes do conversor de frequência, os capacitores estão entre os mais propensos à degradação precoce. Suas características construtivas, aliadas à necessidade de miniaturização do sistema embarcado do conversor de frequência e às condições adversas de operação, tornam-nos um dos principais pontos de falha do conversor, podendo levar desde a parada do sistema de refrigeração até danos irreparáveis em outros componentes (ANDRADE, 2024).

Esta tese apresenta avanços e propostas no campo de monitoramento de ciclo de vida em sistemas de refrigeração. Dadas as limitações de tempo do período de doutoramento, esses avanços foram focados em duas frentes: a detecção de transições tribológicas em compressores,

com a transição do período de amaciamento para regime permanente como caso de estudo, e a deterioração em capacitores para conversores de frequência. A Seção 1.1 contextualiza o problema da detecção não invasiva do fenômeno de amaciamento. A Seção 1.2 introduz a avaliação de deterioração e falhas em conversores de frequência, com foco na estimação de vida útil restante de capacitores. A Seção 1.3 apresenta os objetivos deste trabalho, e a Seção 1.4 descreve a estrutura do restante do documento.

1.1 AMACIAMENTO EM COMPRESSORES HERMÉTICOS ALTERNATIVOS

Admite-se na indústria que o fenômeno do amaciamento ocorre nas primeiras horas de operação dos compressores herméticos alternativos, que são um dos tipos de compressor mais comuns em aplicações de refrigeração, possuindo vida útil típica é de décadas. Alguns dos eventos tribológicos que ocorrem durante esse período inicial, como mudanças no tipo de detrito gerado e o desgaste das asperidades da superfície de contato, alteram o COF e a superfície real de contato entre peças deslizantes (BLAU, 2009). Consequentemente, tais eventos podem afetar diretamente as perdas mecânicas do sistema e indiretamente grandezas como a potência elétrica ativa consumida e a capacidade de refrigeração (JI *et al.*, 2019), que são os principais parâmetros avaliados em ensaios de desempenho em compressores para refrigeração.

Do ponto de vista do setor de pesquisa e desenvolvimento, a avaliação do compressor durante o período do amaciamento não é representativa de seu desempenho no restante da vida útil, e o foco dos ensaios é caracterizar o comportamento do compressor durante a operação normal (SCHMITZ, 2014). No contexto industrial atual, porém, não existem diretrizes que definam a transição entre tais períodos e as normas, apesar de preverem as condições de regime permanente para avaliação de desempenho, não indicam nenhum método ou diretriz para amaciamento dos dispositivos. A norma ANSI/ASHRAE 23 (ASHRAE, 2005), por exemplo, estabelece que ensaios devem ser realizados apenas após o amaciamento e que os procedimentos para tal devem seguir as orientações do fabricante. Assim, fica a cargo das próprias indústrias do ramo a definição dos protocolos de amaciamento dos produtos.


Na indústria de compressores, o procedimento de amaciamento envolve operar o dispositivo em condições específicas por um período determinado experimentalmente (MARTINS *et al.*, 2011). Esse procedimento é realizado tipicamente na indústria para Pesquisa e Desenvolvimento (P&D) antes da avaliação das características de desempenho do compressor, conforme retratado na Figura 2. Em um estudo realizado por Barros (2019), foram apresentados dados sobre a capacidade de elevação de pressão dos compressores, um parâmetro de desempenho alternativo para tais dispositivos, obtidos antes e depois do amaciamento. Os resultados mostraram que, em média, a capacidade de elevação de pressão dos compressores amaciados foi 2% maior do que a dos compressores não amaciados, o que indica uma diferença de desempenho entre os dispositivos causada por esse fenômeno. Comportamentos semelhantes também foram observados em ensaios de desempenho energético padronizados, realizados em um calorímetro.

A Figura 3 ilustra a média e a variação da média amostral da capacidade de refrigeração em três ensaios consecutivos com 33 compressores do mesmo modelo, escalonados para o intervalo [0;1]. A variabilidade da média amostral, s_u , é calculada da seguinte maneira:

$$s_u = \frac{\sigma_c t_S}{\sqrt{n_U}}, \quad (1)$$

em que σ_c é o desvio-padrão das medições, n_U é o número de compressores ensaiados e t_S é a distribuição t de Student para $n_U - 1$ graus de liberdade. Nesse estudo, utilizou-se essa distribuição com um nível de confiança bicaudal de 95%. As primeiras medições correspondem a compressores que já haviam passado pelo procedimento descrito anteriormente para amaciamento, cuja duração, definida empiricamente, mostrou-se possivelmente insuficiente para o completo assentamento das características de desempenho. As medições subsequentes foram então realizadas para avaliar o efeito de períodos mais longos de amaciamento sobre a capacidade de refrigeração.


Figura 2 – Operação e ensaios de compressores recém-manufaturados.



Fonte: autor.

Mesmo que o primeiro ensaio no calorímetro tenha sido supostamente realizado após o amaciamento da unidade, ainda foram observadas diferenças nas médias das medições sequenciais. Apesar da variação relativamente alta nos resultados, por meio de um teste t unicaudal de duas amostras com um nível de significância de 0,05, constatou-se que a média da capacidade de refrigeração na primeira repetição dos ensaios é menor do que a média do segundo ensaio e, com um nível de significância de 0,01, é menor do que a média do terceiro ensaio. Isso ocorre porque, em algumas unidades do modelo de compressor analisado, o tempo normalmente adotado no procedimento de amaciamento não é suficiente e o compressor continua a se amaciar durante os ensaios, que podem durar até 4,5 h (CORAL; FLESCHE; FLESCHE, 2019).

Figura 3 – Média e variabilidade da média amostral da capacidade de refrigeração escalonada em ensaios de calorímetro consecutivos.



Fonte: autor.

A análise convencional do amaciamento envolve considerações relativas à topografia superficial e às taxas e padrões de desgaste, bem como o COF no contato (DOWSON; TAYLOR; GODET, 1982; BLAU, 2005; KHONSARI; GHATREHSAMANI; AKBARZADEH, 2021). Apesar de certas abordagens proporem a incorporação desses fatores para a detecção do fenômeno (RUGGIERO *et al.*, 2020), tais análises são predominantemente empregadas em estudos que investigam o amaciamento em contextos específicos de interação, como quando há contato entre superfícies de composições distintas ou com formatos variados (KHONSARI; GHATREHSAMANI; AKBARZADEH, 2021). Entretanto, a aplicação desses métodos aos compressores avaliados apresenta desafios, pois esses são de natureza hermética. Logo, adotar tais métodos implicaria a ruptura do selo da unidade, tornando-a imprópria para ensaios de desempenho subsequentes. Adicionalmente, devido às variações no processo de remontagem, o compressor teria de passar por um novo período de amaciamento, exigindo uma nova avaliação do fenômeno (BLAU, 2005). Nesse cenário, os métodos mais adequados seriam aqueles que são indiretos e não invasivos, caracterizados por sua relativa escassez na literatura.

Dentre os métodos indiretos para avaliar o amaciamento, destacam-se aqueles que estimam a taxa de desgaste e de atrito no sistema, derivando informações da concentração de detritos no óleo lubrificante (LOCKWOOD; DALLEY, 1992), do perfil vibracional do conjunto (MARTIN, 1992), ou da corrente elétrica do motor responsável pelo movimento, no caso de motores elétricos (EISSENBERG; HAYNES, 1992). No entanto, cada método de detecção depende de um conhecimento prévio sobre o sistema e suas características específicas de amaciamento. Especialmente em máquinas com várias peças móveis, a interação entre os diferentes subsistemas tribológicos torna a avaliação desses casos consideravelmente mais complexa do que em situações que envolvam um único mecanismo de contato.

A análise de parâmetros potencialmente ligados ao amaciamento, aliada aos efeitos observados em experimentos com compressores, viabiliza a compreensão da influência desse fenômeno na operação do sistema e possibilita o desenvolvimento de métodos automatizados para identificar o término desse estágio. Essas abordagens, que são um dos focos deste trabalho,

podem oferecer uma indicação mais confiável do momento em que o dispositivo atinge um estado tribológico permanente, potencialmente reduzindo o desperdício de recursos nos casos em que o tempo necessário para amaciamento seja superestimado.

1.2 DETERIORAÇÃO DE CAPACITORES EM CONVERSORES DE FREQUÊNCIA

Um conversor de frequência é responsável por transformar a amplitude e a frequência da tensão fixa da rede elétrica de alimentação em Corrente Alternada (CA) em uma tensão alternada com frequência e amplitude variáveis. Esse dispositivo é utilizado em diversos setores além da indústria de refrigeração, incluindo transporte elétrico (JOY *et al.*, 2025; MURILLO-YARCE *et al.*, 2025; RANA *et al.*, 2025), acionamento de motores (SALEH *et al.*, 2025; BAHRAMI-FARD *et al.*, 2025), aplicações médicas (KHODADOOST; HAYATI; ABBASI, 2025; RUBAVATHY *et al.*, 2025), geração de energia (CHIONCEL; TIRIAN; SPUNEI, 2025; HUALDE-OTAMENDI *et al.*, 2025), entre outros.


Dentre as diversas topologias de conversor existentes, a mais utilizada em aplicações de refrigeração comercial e doméstica é realizada em etapas: primeiro, a tensão CA da rede é convertida, por um retificador, em uma tensão de Corrente Contínua (CC), que constitui o barramento CC do sistema. Em seguida, essa tensão é convertida em tensão CA com a amplitude e a frequência desejadas por um inversor. Tanto o retificador quanto o inversor introduzem oscilações no barramento CC que podem prejudicar a operação do sistema, tornando necessária a inclusão de uma etapa intermediária de filtragem realizada com capacitores (PETRUZELLA, 2013).

Buscando investigar a relevância e o impacto dos estudos de confiabilidade em conversores de frequência, Falck *et al.* (2018) realizaram uma pesquisa com 51 empresas do Centro Europeu de Eletrônica de Potência. Nessa pesquisa, além de avaliar os componentes atualmente mais propensos a falhas, os autores buscaram a visão da indústria sobre quais seriam os alvos de pesquisa mais relevantes para o futuro da confiabilidade. A Figura 4 apresenta uma análise da visão das empresas consultadas quanto à suscetibilidade a falhas dos subsistemas dos conversores de potência. Em especial, os capacitores eletrolíticos e os módulos de semicondutores de potência foram indicados como os mais propensos a falhas num contexto geral.

A Figura 5 apresenta um resumo de quais os componentes indicados como principais para a pesquisa de confiabilidade em conversores de potência. Os capacitores foram indicados por 26% dos entrevistados como sendo o segundo componente mais importante para pesquisa, superado apenas pelos módulos de semicondutores de potência.

Apesar de apresentarem um comportamento de deterioração já bem conhecido, os principais indicadores da degradação dos capacitores (capacitância e resistência série equivalente) não podem ser medidos diretamente durante a operação do conversor. Assim, tal qual o amaciamento em compressores, métodos não invasivos têm sido propostos na literatura para estimação de parâmetros indicativos do processo. Apesar de mais avançada do que a pesquisa por métodos de detecção de amaciamento, a estimação do Fim De Vida útil (FDV, também

Figura 4 – Subsistemas e componentes mais propensos a falhas em conversores.




Fonte: adaptado de Falck *et al.* (2018).

chamada de vida útil restante) de capacitores ainda é um tópico de interesse crescente tanto na indústria quanto na literatura acadêmica, com avanços recentes em diversas aplicações. Ainda assim, não foram apresentadas até o momento aplicações no campo de conversores para sistemas de refrigeração na literatura, reforçando o espaço para o desenvolvimento de técnicas voltadas para essa demanda ².

² Pesquisa realizada em 16/09/2025 nas plataformas Scopus, Google Scholar e IEEE Xplore, considerando o termo de busca "capacitor AND refrigeration AND (degradation OR "useful life")"

Figura 5 – Principais componentes para pesquisa de confiabilidade em conversores.



Fonte: adaptado de Falck *et al.* (2018).

1.3 OBJETIVOS

Esta seção formaliza os objetivos da tese, conforme é descrito a seguir.

1.3.1 Objetivo geral

Propor métodos não invasivos de aprendizado de máquina para detecção do fim do processo de amaciamento em compressores herméticos alternativos e para estimação de deterioração de capacitores em aplicações de refrigeração.

1.3.2 Objetivos Específicos

Com o intuito de atender ao objetivo geral proposto, foram elencados os objetivos específicos em duas frentes:

- desenvolver e avaliar métodos para detecção de transições tribológicas que determinem o final do período de amaciamento em compressores, por meio de:
 - determinar diretrizes para detecção do término do período de amaciamento;
 - extrair características a partir de grandezas mensuráveis de forma não invasiva;
 - desenvolver algoritmos automatizados para detecção da transição de amaciamento para regime permanente tribológico;
 - avaliar os métodos propostos em dados experimentais em uma bancada representativa da operação de compressores, utilizando métricas de classificação para dados rotulados e conceitos físicos do amaciamento para dados não rotulados;

- desenvolver métodos para estimação do FDV em capacitores eletrolíticos de conversores de frequência para sistemas de refrigeração, envolvendo:
 - identificar variáveis representativas da degradação que sejam observáveis durante a operação do conversor;
 - desenvolver modelos de regressão para estimar indicadores ou FDV a partir dos sinais coletados;
 - validar o método proposto com base em dados experimentais;
 - avaliar o método desenvolvido em comparação a outros métodos da literatura em termos de erro absoluto, relativo e coeficiente de determinação.

1.4 ESTRUTURA DO TRABALHO

O restante desta tese se estrutura em 5 capítulos. O Capítulo 2 descreve a fundamentação teórica dos materiais e métodos utilizados para o desenvolvimento deste trabalho. O Capítulo 3 apresenta o desenvolvimento de métodos de detecção do fenômeno do amaciamento baseados no agrupamento de séries temporais de ensaios com compressores, incluindo a descrição dos ensaios experimentais realizados e os resultados obtidos após a aplicação dos métodos propostos. O Capítulo 4 descreve o desenvolvimento de um novo método para estimação de FDV de capacitores em conversores de frequência para refrigeração, bem como resultados e comparação com o estado da arte. Por fim, o Capítulo 5 discorre sobre as considerações finais do autor acerca do trabalho desenvolvido e discute possíveis oportunidades para atividades futuras.

2 FUNDAMENTAÇÃO TEÓRICA E REVISÃO DA LITERATURA

Este capítulo apresenta uma revisão da literatura de temas pertinentes para o desenvolvimento deste trabalho, bem como a fundamentação teórica das técnicas utilizadas. A Seção 2.1 apresenta estudos presentes na literatura a respeito da detecção e avaliação do fenômeno do amaciamento. A Seção 2.2 apresenta uma revisão de modelos de aprendizado de máquina não supervisionado, empregados no agrupamento de dados para o método de detecção de transições descrito na Seção 3.2. A Seção 2.3 descreve métodos de aprendizado de máquina semissupervisionados, propostos como alternativa para a classificação de estado tribológico durante as transições entre o amaciamento e o regime permanente, com foco no método de autotreinamento. A Seção 2.4 introduz a aplicação de Redes Neurais Artificiais (RNAs) para regressão, com ênfase em Perceptrons com Múltiplas Camadas (PMCs) e redes neurais de memória longa de curto prazo (LSTM, do inglês *Long Short Term Memory*), que são empregadas para monitoramento de capacitores no método apresentado na Seção 4.1. A Seção 2.5 descreve a composição e o funcionamento de conversores de frequência para sistemas de refrigeração. A Seção 2.6 apresenta os principais conceitos sobre o FDV de capacitores, tais como os mecanismos e as grandezas indicativas da degradação, bem como uma revisão dos métodos recentes da literatura para estimação de FDV nesses dispositivos. Por fim, a Seção 2.7 apresenta considerações gerais a respeito da revisão de literatura descrita neste capítulo e sua conexão com o restante do trabalho.

2.1 AMACIAMENTO

Khonsari, Ghatreh Samani e Akbarzadeh (2021) apresentaram uma revisão sobre estudos de amaciamento (em inglês, *running-in*), os quais analisam o contato deslizante entre superfícies com influência mínima de outros mecanismos. O principal resultado do estudo é que as mudanças na topografia e no COF são os sinais mais claros do fenômeno. Existem também trabalhos que analisam esse comportamento de forma experimental com superfícies compostas por diferentes materiais, como as análises da superfície de contato durante o amaciamento de um tribopar AgCu-MoS₂/AgCu₁₀ apresentado por Zhang *et al.* (2022), e o trabalho realizado por Ding *et al.* (2023), que utiliza o COF como métrica para avaliar o desempenho de amaciamento de uma placa de liga de alumínio 7075 reforçada em atrito com uma esfera de aço classificado pelo Instituto Americano de Ferro e Aço (AISI, do inglês *American Iron and Steel Institute*) como AISI 52100.

A forma como um sistema é amaciado pode ter repercussões significativas na vida útil do produto. Por exemplo, na indústria automobilística, o amaciamento adequado das lonas de freio do veículo é necessário para promover um torque de frenagem uniforme e um correto assentamento da lona com sua contraparte (BLAU, 2005). Em contextos similares, estudos em motores de combustão interna também indicam relações próximas entre o amaciamento e a qualidade do produto final (BLAU, 2009).

Os métodos clássicos de análise de amaciamento envolvem o estudo de características como a topografia da superfície, a taxa e o tipo de desgaste, e o COF do contato (BLAU, 1982; KHONSARI; GHATREHSAMANI; AKBARZADEH, 2021). Embora alguns desses atributos possam ser considerados como possíveis indicadores do progresso do amaciamento em máquinas mais complexas (RUGGIERO *et al.*, 2020), eles geralmente são estudados em experimentos mais simples, tais quais esfera-sobre-plano (BLAU, 1981), esfera-sobre-disco (GRÜTZMACHER *et al.*, 2018) e pino-sobre-disco (ZHANG; ZHANG; MAI, 1996; GRÜTZMACHER *et al.*, 2018; GHATREHSAMANI; AKBARZADEH; KHONSARI, 2022). Esses estudos permitem uma maior compreensão dos efeitos do comportamento do contato deslizante durante o amaciamento sob certas condições, mas a extensão dos resultados de tais ensaios para a análise do amaciamento de dispositivos mais complexos, com várias partes móveis e superfícies de contato, é pouco útil para a detecção do fim do fenômeno. Isso ocorre principalmente porque mecanismos complexos possuem características, como o alinhamento subótimo das peças e o acoplamento dos arranjos internos, que podem modificar significativamente o comportamento durante o amaciamento quando comparado àquele analisado com base em um contato de ponto único (BLAU, 1991).

A literatura lista alguns métodos que visam identificar indiretamente o fenômeno de amaciamento em máquinas. O restante desta seção apresenta uma visão geral desses métodos, que sugerem como analisar o comportamento de amaciamento e fornecem algumas ideias sobre quais grandezas físicas relacionadas ao fenômeno podem ser medidas em ensaios não destrutivos de compressores.

Blau (2009) apresenta três atributos do comportamento do atrito ao longo do tempo que são indicadores do processo de amaciamento, a saber, a forma geral da curva, a duração de certos recursos da curva, como estados transitórios e platôs, e a magnitude das flutuações na força de atrito. Muitos fatores afetam a forma da curva, por exemplo, a composição dos materiais, a carga mecânica no contato deslizante e a lubrificação entre as superfícies, mas todos eles são dificilmente acessíveis para medição direta em dispositivos comerciais. O mesmo pode ser dito sobre o próprio COF. No entanto, em máquinas como compressores alternativos, as perdas por atrito estão intimamente relacionadas com o consumo de energia (LILIE; KRUEGER, 1990), e assim podem ser estimadas indiretamente pelo consumo do motor do compressor ao longo do tempo. O uso de tal estimativa indireta para inferir a carga mecânica de um sistema baseado em motor elétrico é apresentado por Eissenberg e Haynes (1992), que fazem uso tanto do valor médio quanto das flutuações instantâneas da corrente elétrica. O primeiro geralmente é o parâmetro mais importante, uma vez que é usado para representar a carga total média no dispositivo, que tem uma relação próxima ao COF e, conseqüentemente, com o estado de amaciamento, se as variáveis restantes forem mantidas constantes. Para motores de corrente alternada, o valor médio é substituído pela raiz do valor médio quadrático (RMS, do inglês *Root Mean Square*), também chamado de valor eficaz do sinal, mas mudanças graduais no valor RMS da corrente também podem representar mudanças no COF. Ainda assim, em compressores alternativos, esse comportamento pode ser muito sutil para detecção,

ou então mascarado pelo efeito de outras variáveis, como a pressão de sucção e de descarga e a temperatura dos componentes internos do dispositivo, que afetam significativamente o consumo de energia do compressor (HANLON, 2001).

O estudo apresentado por Martin (1992) sugere a curtose da vibração em um sistema mecânico como uma alternativa para análise de atrito. Para o amaciamento de rolamentos, o autor demonstra que, à medida que o sistema se aproxima do regime permanente tribológico, a curtose se aproxima de três, indicando assim que a distribuição do sinal de vibração se aproxima de uma distribuição normal à medida que o período de amaciamento tende ao fim. O valor RMS da vibração também está comumente associado a métodos de detecção de falhas e comportamento anômalo (AHMED; GU; BALL, 2012; GOYAL *et al.*, 2020), e, como tal, pode ser um indicador do processo de amaciamento. Por outro lado, uma vez que tanto a curtose quanto o valor RMS da vibração também estão comumente relacionados a falhas e a outros comportamentos anômalos em compressores alternativos, atualmente não existem métodos baseados em vibração na literatura que sugiram que o amaciamento possa ser distinguido de outros comportamentos anômalos em máquinas complexas.

A maioria dos principais parâmetros de desempenho dos compressores está relacionada à vazão mássica gerada pelo compressor e ao seu consumo de energia, o qual é proporcional à corrente elétrica necessária para a operação. Como consequência, a vazão mássica e a corrente são normalmente avaliadas em ensaios de desempenho (PACHECO *et al.*, 2022). Embora a literatura não apresente nenhum método de identificação de amaciamento baseado em tais parâmetros de desempenho, eles estão vinculados a grandezas físicas relacionadas ao processo de amaciamento, como temperatura e COF, e, como tal, podem ser indicadores do fenômeno.

Thaler (2021) propõe uma abordagem *cluster-than-label* para o problema de detecção do amaciamento em compressores herméticos alternativos. A abordagem envolve uma busca em grade por agrupamentos significativos de séries temporais subsequenciadas utilizando o algoritmo *k*-médias, e conceitos do fenômeno para filtragem de resultados. Os resultados obtidos no método de agrupamento são, então, utilizados para treinamento e teste de modelos supervisionados de classificação para detecção de regime permanente tribológico. Nesse trabalho, foram avaliadas séries temporais de corrente, vibração e vazão mássica obtidas em ensaios experimentais realizados em uma bancada de ciclo quente. Os resultados obtidos no trabalho, apesar de coerentes com o esperado do fenômeno do amaciamento, podem ser enviesados devido à utilização apenas do método *k*-médias para agrupamento, que, devido à forma como utiliza a distância euclidiana para minimização da variância dos elementos de cada grupo, pode gerar resultados não significativos para dados de subsequências de séries temporais (CHEN, 2005).

2.2 MÉTODOS DE AGRUPAMENTO

Técnicas de agrupamento são um dos principais tópicos no campo de aprendizado de máquina não supervisionado, lidando com a divisão de dados não rotulados em grupos

de acordo com alguma métrica de similaridade. Ao contrário dos métodos de aprendizado de máquina supervisionado, que utilizam dados previamente rotulados para modelar padrões em um conjunto de dados, os métodos de agrupamento recebem como entrada um conjunto de dados com pouca ou nenhuma informação de saída. Embora esse fator os torne inadequados para a maioria dos problemas de classificação, os métodos de agrupamento permitem a extração de padrões que possivelmente não seriam reconhecíveis por especialistas humanos ou que exigiriam um grande esforço para rotulação, desde que a interpretação dos resultados seja adequadamente realizada (DUDA; HART; STORK, 2012).

Na Seção 2.2.1, é descrito o algoritmo *k*-médias de agrupamento, um dos mais utilizados na literatura para extração de padrões de comportamento anômalo em maquinário. Já na Seção 2.2.2, é descrito o algoritmo *kernel k*-médias, que expande o modelo *k*-médias para distribuições de grupo mais complexas, bem como as funções de núcleo utilizadas neste trabalho.

2.2.1 *k*-médias

Dos muitos métodos de agrupamento disponíveis, o algoritmo *k*-médias é considerado um dos mais flexíveis tanto em aplicações quanto na pesquisa acadêmica no campo (AHMED; GU; BALL, 2012). Em sua formulação original, o algoritmo visa minimizar a soma do erro quadrático entre os elementos de um grupo e seu respectivo centroide, também chamada de inércia do conjunto. Diversas variantes e extensões do algoritmo original são apresentadas na literatura, como descrito por Jain (2010) em uma revisão de métodos de agrupamento, mas em algumas aplicações de sensoriamento e manutenção de maquinário o método *k*-médias original é suficiente para a obtenção de resultados positivos. Tais aplicações apresentam forte semelhança contextual às aplicações de detecção propostas neste trabalho e sugerem que a formulação tradicional possa ser suficiente para a extração de padrões relevantes para a detecção (UHLMANN *et al.*, 2018).

Considerando um conjunto de dados $\tilde{x} \subseteq \mathbb{R}^n$, o algoritmo *k*-médias implementa o agrupamento do conjunto em *k* grupos da seguinte forma. Inicialmente, são definidos *k* centroides, que são elementos do mesmo espaço $\mathbb{R}^n$ que o conjunto de dados. Esses centroides podem ser iniciados manualmente, aleatoriamente, ou ainda utilizando métodos de inicialização como o método *k*-médias++, que considera a distribuição estatística do conjunto de dados na definição dos centroides iniciais, com impacto na velocidade de convergência do algoritmo e no mínimo local encontrado após a convergência (ARTHUR; VASSILVITSKII, 2007).

Após a definição do conjunto inicial de centroides, o algoritmo itera os seguintes passos até a convergência:

1. associar cada vetor do conjunto de dados ao grupo definido pelo centroide mais próximo, considerando a distância euclidiana;
2. recalcular o conjunto de centroides como a média aritmética das coordenadas dos vetores de cada grupo.

O número de grupos k é um parâmetro definido pelo usuário, com grande impacto no resultado final do agrupamento (JAIN, 2010). Não existem critérios exatos para definição desse valor, porém muitas abordagens heurísticas são descritas na literatura (STEINLEY, 2006; STEINLEY; BRUSCO, 2011; HANCER; KARABOGA, 2017). Entre tais abordagens, o “método do cotovelo” (em inglês, *elbow method*) é uma abordagem já utilizada em aplicações de detecção de falhas em maquinário, e que consiste na análise da inércia final após a convergência do algoritmo e o número k de grupos (UHLMANN *et al.*, 2018). Nessa análise, o número de grupos sugerido deve ser o ponto de inflexão da curva, visto que a partir desse valor a taxa de redução no erro é gradativamente menor, enquanto a complexidade computacional do algoritmo cresce progressivamente.

2.2.2 Kernel k -médias

Para conjuntos de dados complexos e de alta dimensionalidade, a implementação original do algoritmo k -médias pode não produzir resultados significativos, visto que em alguns casos a inércia minimizada pelo algoritmo não é um bom indicador da qualidade do modelo (LI *et al.*, 2023). De modo a contornar essa limitação, o algoritmo *kernel* k -médias expande o algoritmo k -médias para um espaço de núcleo, ou *kernel*, de alta dimensão, minimizando o erro quadrático nesse espaço ao invés de fazer isso no espaço original das amostras. Nesse contexto, a função de núcleo é uma função simétrica e definida positiva que estabelece a distância entre duas amostras no espaço $\mathbb{R}^n$ em um espaço de Hilbert, possivelmente com dimensão infinita. Dentro do campo de aprendizado de máquina, funções de núcleo também são muito utilizadas no contexto de classificadores supervisionados, permitindo que modelos como os de Máquinas de Vetor de Suporte (MVS) classifiquem corretamente conjuntos que não são linearmente separáveis (GÉRON, 2019).

A adição do núcleo permite o agrupamento do conjunto mesmo quando a divisão entre grupos não é linear, contanto que seja utilizado o núcleo adequado. Não existem regras absolutas para escolha da função de núcleo e diversas opções de funções são descritas na literatura (STEINWART; CHRISTMANN, 2008). Dentre tais funções, o núcleo de Função de Base Radial (FBR) é uma escolha popular, que mostra resultados positivos também na detecção de anomalias e falhas (KHEDIRI; WEIHS; LIMAM, 2012; TAO; LI; HUANG, 2020). Esse núcleo, representado neste documento por K^{FBR} , é definido como:

$$K^{\text{FBR}}(\tilde{\mathbf{x}}_i, \tilde{\mathbf{x}}_j) = \exp \left(-\frac{d_E^2(\tilde{\mathbf{x}}_i, \tilde{\mathbf{x}}_j)}{2\sigma_{\text{FBR}}^2} \right), \quad (2)$$

em que $K^{\text{FBR}}(\tilde{\mathbf{x}}_i, \tilde{\mathbf{x}}_j)$ é a distância euclidiana entre os vetores de amostra $\tilde{\mathbf{x}}_i$ e $\tilde{\mathbf{x}}_j$, e σ_{FBR} é um parâmetro ajustável que define a largura da função radial (WANG; YEUNG; TSANG, 2007).


Apesar de a distância euclidiana ser a distância padrão na definição de K^{FBR} , o núcleo FBR também permite a utilização de diferentes definições de distância, alterando o formato da função radial. Um exemplo de distância para substituição é a distância de Mahalanobis, d_M ,

definida por:

$$d_M^2(\tilde{x}_i, \tilde{x}_j, \Sigma) = (\tilde{x}_i - \tilde{x}_j)^T \Sigma^\dagger (\tilde{x}_i - \tilde{x}_j), \quad (3)$$

com Σ sendo a matriz de covariância do conjunto de dados completo, e $\Sigma^\dagger$, sua pseudoinversa. Dessa forma, a distância de Mahalanobis leva em conta também a distribuição do conjunto de dados, compensando a distância de acordo com a covariância do conjunto. A Figura 6 apresenta uma comparação de valores equidistantes da origem utilizando distâncias euclidiana e de Mahalanobis. É possível observar na figura que as linhas de equidistância euclidiana são circulares, enquanto as linhas de equidistância de Mahalanobis são elípticas, de acordo com a covariância.

Figura 6 – Comparação entre valores equidistantes utilizando distância euclidiana e de Mahalanobis para um exemplo de conjunto de dados com duas dimensões.



Fonte: autor.

Assim como para a distância euclidiana, a distância de Mahalanobis não é uma função de núcleo por si só, por serem ambas funções semi-definida positiva. Porém, da mesma forma que ocorre com a distância euclidiana, é possível aplicar a distância de Mahalanobis na função de núcleo FBR, obtendo assim uma função definida positiva cuja base radial é também dependente da covariância do conjunto. Esse núcleo, denominado FBR-M, apresenta resultados positivos na classificação de conjuntos com distribuição desigual entre eixos (RUIZ; LÓPEZ-DE-TERUEL, 2001; WANG; YEUNG; TSANG, 2007) e outras implementações de funções de núcleo com a distância de Mahalanobis por base também foram utilizadas para agrupamento de conjuntos com tal característica (ZENG *et al.*, 2021).

2.3 APRENDIZADO SEMISSUPERVISIONADO E AUTOTREINAMENTO

Além de modelos supervisionados, que classificam conjuntos de dados a partir de um conjunto de treinamento rotulado, e modelos não supervisionados, que agrupam dados não rotulados de acordo com alguma medida de similaridade, também existem no campo de aprendizado de máquina modelos semissupervisionados, cujo treinamento permite a utilização de conjuntos em que apenas parte dos dados é rotulada. Tais modelos são úteis em situações nas quais uma parcela pequena dos dados pode ser rotulada ou em casos nos quais a distinção entre classes no conjunto é incerta e não permite a distinção por especialistas (ENGELEN; HOOS, 2020). Esse último é o caso da transição tribológica do amaciamento, visto que é possível definir que o compressor hermético inicia sua vida útil em estado de amaciamento, seguido por um longo período de regime permanente tribológico, porém com a transição entre estados não bem definida.

Os métodos de aprendizado semissupervisionado podem ser definidos de forma geral em duas categorias, de acordo com o objetivo do modelo: métodos indutivos, nos quais se busca obter um modelo final para classificação de dados; ou métodos transdutivos, nos quais o objetivo final é prever o rótulo de dados previamente não rotulados. Dentre os métodos indutivos, também é possível definir uma distinção de acordo com a forma como o modelo incorpora dados não rotulados na tarefa de classificação: métodos intrinsecamente semissupervisionados, métodos de processamento não supervisionado e métodos iterativos (ENGELEN; HOOS, 2020). Dado o objetivo de obter modelos para classificação de estado tribológico definido neste trabalho, são apresentados a seguir apenas os métodos indutivos de aprendizado semissupervisionado.

Os métodos intrinsecamente semissupervisionados são aqueles nos quais o modelo classificador empregado prevê a utilização de dados não rotulados em seu treinamento. Esses métodos normalmente são extensões de métodos supervisionados cuja função objetivo é adaptada de modo a acomodar amostras sem rótulos definidos (ENGELEN; HOOS, 2020). Alguns exemplos de extensão de métodos são as MVSs semissupervisionadas (CHAPELLE; SINDHWANI; KEERTHI, 2008) e as RNAs semissupervisionadas (ALOM *et al.*, 2019), que consideram a minimização da margem entre classes e a robustez a pequenas perturbações em suas funções objetivo, respectivamente.

No caso de métodos semissupervisionados obtidos por meio de processamento não supervisionado, modelos de aprendizado não supervisionado são utilizados para a extração de *features*, que são depois empregadas no treinamento de classificadores. Esses métodos podem ser divididos em três grupos, de acordo com a função da etapa não supervisionada: extração de *features*, como autoencoders para redução de dimensionalidade e obtenção de representações para classificação dos dados (QIAN *et al.*, 2022); agrupamento de dados para classificação, chamado popularmente de *cluster-then-label* (ZHU; GOLDBERG, 2009); e pré-treinamento, no qual a função do método é a inicialização de parâmetros do classificador (ENGELEN; HOOS, 2020).

Nos métodos iterativos de aprendizado semissupervisionado, por fim, a parcela rotulada dos dados do conjunto é inicialmente utilizada no treinamento de um ou mais modelos classificadores. Em seguida, a parcela não rotulada dos dados é classificada pelo modelo treinado, gerando pseudorrótulos para esses dados. O processo de treinamento do classificador e geração de pseudorrótulos pode ser repetido várias vezes, buscando aprimorar a qualidade das rotulações. Por fim, o conjunto de dados completo é empregado no treinamento de um modelo classificador final. Dada sua simplicidade conceitual, tais métodos podem ser desenvolvidos a partir de qualquer modelo supervisionado de classificação, de acordo com as necessidades da aplicação (TRIGUERO; GARCÍA; HERRERA, 2015).

O autotreinamento, proposto por Yarowsky (1995) para a classificação do sentido de palavras, é um dos métodos semissupervisionados iterativos mais utilizados na literatura, especialmente em casos nos quais a parcela rotulada dos dados é consideravelmente menor do que a parcela não rotulada (AMINI *et al.*, 2025). Nesse método, após o treinamento inicial de um classificador base com a parcela rotulada do conjunto de dados, esse modelo é utilizado para atribuir pseudorrótulos às amostras não rotuladas. Em seguida, as amostras pseudorrotuladas com maior confiança são incorporadas ao conjunto de treinamento, e o classificador é novamente treinado com esse conjunto expandido. A seleção das amostras a serem incorporadas é definida por uma métrica escolhida a priori, com os métodos mais comuns sendo a escolha de um número predefinido de amostras em ordem descendente de confiança, ou da incorporação de todas as amostras com confiança acima de um dado limiar predeterminado. Esse processo é repetido iterativamente até que não haja mais amostras elegíveis para rotulação ou até que um critério de parada seja atingido, como um número máximo de iterações ou a convergência do desempenho do modelo (YAROWSKY, 1995; TRIGUERO; GARCÍA; HERRERA, 2015).

A principal limitação do autotreinamento é a dependência da qualidade das primeiras previsões, já que erros nas iterações iniciais podem ser propagados e reforçados ao longo do processo (TRIGUERO; GARCÍA; HERRERA, 2015). Adicionalmente, o método de incorporação de pseudorrótulos também requer ajuste adequado: na seleção das amostras mais confiáveis, pode haver inclusão de dados de baixa confiança caso não existam bons candidatos no conjunto não rotulado; enquanto que, na incorporação por limiar, um valor de confiança excessivamente alto pode impedir a adição de novas amostras, levando à estagnação do processo. Assim, a definição da métrica de confiança e da estratégia de incorporação requer um compromisso entre a exploração e adição de novos dados e o controle do risco de propagação de rótulos incorretos.

Apesar das limitações descritas, o autotreinamento tem sido amplamente empregado em tarefas de classificação de padrões em diferentes cenários, como processamento de linguagem natural, visão computacional e monitoramento de sistemas (AMINI *et al.*, 2025). No contexto de detecção de falhas e monitoramento de equipamentos, o autotreinamento é particularmente atrativo em cenários nos quais dados rotulados de falha são escassos, mas há abundância de registros de operação normal. Nessas situações, o uso de pseudorótulos pode auxiliar na

construção de modelos mais robustos, capazes de discriminar estados intermediários ou incertos que dificilmente seriam rotulados de forma confiável por especialistas.

2.4 REDES NEURAIIS PARA REGRESSÃO

RNAs são modelos computacionais inspirados no cérebro humano, compostos por neurônios artificiais interconectados e organizados em camadas. As camadas e as ligações entre neurônios podem ser realizadas de diversas formas, de acordo com a complexidade do problema e os tipos de entradas e de saídas necessários. Em uma arquitetura do tipo *feedforward*, por exemplo, as unidades de entrada transmitem os sinais das variáveis de entrada para neurônios em camadas ocultas subsequentes, e assim por diante até a camada de saída, onde é produzida a predição final do modelo (GOODFELLOW; BENGIO; COURVILLE, 2016). Devido à sua estrutura com múltiplas camadas e funções de ativação não lineares, as RNAs conseguem modelar relações complexas e não lineares entre variáveis. Em especial, para funções contínuas tem-se a garantia de que uma rede neural com ao menos uma camada oculta suficientemente grande e uma função de ativação não polinomial pode aproximar qualquer função, conforme provado nos teoremas de aproximação universal (LESHNO *et al.*, 1993). Essa capacidade torna as RNAs especialmente atrativas para tarefas de regressão, nas quais deseja-se prever valores contínuos a partir de uma ou mais entradas.

Um dos tipos de RNA mais utilizados para regressão é o PMC, também chamado de rede *deep feedforward*, no qual cada neurônio calcula uma combinação linear de suas entradas seguida de uma função de ativação não linear nas camadas ocultas. Por exemplo, para uma camada oculta, tem-se:

$$\mathbf{z} = \mathbf{W}\mathbf{x} + \mathbf{b}, \quad (4)$$


em que $\mathbf{x}$ representa o vetor de entrada da camada de neurônios, $\mathbf{z}$ é a combinação linear das entradas, $\mathbf{W}$ é a matriz de pesos sinápticos que conecta as entradas aos neurônios, e $\mathbf{b}$ é o vetor de viés (GOODFELLOW; BENGIO; COURVILLE, 2016). A saída do neurônio é então dada por $\mathbf{a} = \phi(\mathbf{z})$, em que $\phi(\cdot)$ é uma função de ativação não linear (por exemplo, a função sigmoide ou unidade linear retificada, ReLU, do inglês Rectified Linear Unit) (WANG *et al.*, 2022). É comum também a utilização de múltiplas camadas de neurônios, que são empilhadas conectando as saídas dos neurônios de uma camada às entradas de outra. Na camada de saída destinada à regressão, costuma-se empregar uma função linear de modo que a rede produza valores contínuos diretamente na saída. Assim, a predição final $\hat{y}$ de uma rede de regressão pode ser expressa como:

$$\hat{y} = \mathbf{v}\mathbf{a}_o + b_o, \quad (5)$$

em que $\mathbf{a}_o$ são as ativações dos neurônios da última camada oculta, $\mathbf{v}$ são os pesos que conectam essa camada à saída e b_o é o viés da unidade de saída. Uma representação de um PMC para regressão é apresentada na Figura 7. Os parâmetros $\Theta = \{\mathbf{W}, \mathbf{b}, \mathbf{v}, b_o\}$ da rede devem ser ajustados de forma que $\hat{y}$ se aproxime do valor alvo y . Para isso, define-se uma função de

perda $L(\Theta)$, que é minimizada com base no conjunto de dados de treinamento da rede. Uma vez definida tal função, utiliza-se tipicamente o método de descida do gradiente em conjunto com o algoritmo da retropropagação do erro, no qual calcula-se o gradiente $\nabla_{\Theta}L$ percorrendo a rede da saída para a entrada, distribuindo o erro de predição pelos pesos nas camadas internas do modelo de acordo com sua contribuição na perda total. Esse procedimento é iterado durante múltiplas épocas de treinamento, até que a rede convirja para um mínimo local de erro ou atinja um critério de parada.

Figura 7 – Representação de um PMC.



Fonte: autor.

Para tarefas de regressão envolvendo séries temporais, como sinais de sensores ao longo do tempo, é possível explorar a correlação temporal dos dados utilizando arquiteturas diferentes de redes neurais. Uma abordagem simples é construir uma rede neural autorregressiva, com uma estrutura similar ao PMC, mas que receba como entradas os valores passados recentes de uma variável para prever o próximo valor. Contudo, esse método requer definir manualmente o número de amostras anteriores e o atraso de acordo com a aplicação (KAMALOV; GURRIB; THABTAH, 2021). Uma solução mais elegante para modelagem de sequências são as Redes Neurais Recorrentes (RNRs), que introduzem conexões que permitem à rede armazenar informação temporal internamente. Em uma RNR simples, a cada instante discreto de tempo t a rede recebe, além da entrada $x[k]$, o seu estado anterior $h[k-1]$, que intrinsecamente resume o que foi processado pela rede até $t[k-1]$, produzindo uma nova saída $\hat{y}[k]$ e atualizando seu estado $h[k]$. O estado h é chamado de estado oculto da RNR. Dessa forma, uma RNR pode

em teoria utilizar informação de muitos passos anteriores sem precisar de uma janela fixa de entradas (SCHUSTER; PALIWAL, 1997). Na prática, entretanto, as RNRs clássicas sofrem com o problema de gradientes que se atenuam ou explodem durante o treinamento, o que limita sua capacidade de memorizar dependências de longo prazo (SHEWALKAR; NYAVANANDI; LUDWIG, 2019).

Uma extensão das RNNs que endereça o problema de gradientes é a arquitetura de memória longa de curto prazo (LSTM, do inglês *Long Short Term Memory*), proposta por Hochreiter e Schmidhuber (1997). As LSTMs introduzem uma estrutura interna específica na célula recorrente, incluindo um estado de memória $c[k]$, um candidato a estado de memória $g[k]$ e três portas de controle que regulam o fluxo de informações que entram, saem e são esquecidas pela célula. Em cada passo discreto de tempo, uma célula LSTM calcula vetores porta de entrada $i[k]$, porta de esquecimento $f[k]$, candidato a estado de memória $g[k]$ e porta de saída $o[k]$, além de atualizar o estado de memória $c[k]$ e o estado oculto $h[k]$, que também é a saída da célula. As equações para atualização de uma célula LSTM são:


$$\begin{aligned}
 i[k] &= \sigma(W_{ii}x[k] + b_{ii} + W_{hi}h[k-1] + b_{hi}), \\
 f[k] &= \sigma(W_{if}x[k] + b_{if} + W_{hf}h[k-1] + b_{hf}), \\
 g[k] &= \tanh(W_{ig}x[k] + b_{ig} + W_{hg}h[k-1] + b_{hg}), \\
 o[k] &= \sigma(W_{io}x[k] + b_{io} + W_{ho}h[k-1] + b_{ho}), \\
 c[k] &= f[k] \odot c[k-1] + i[k] \odot g[k], \\
 h[k] &= o[k] \odot \tanh(c[k]),
 \end{aligned} \tag{6}$$

em que $x[k]$ é o vetor de entrada no instante tk e $h[k-1]$ é o estado oculto do passo anterior. O símbolo $\odot$ representa o produto de Hadamard, e as matrizes de pesos e vetores de viés, respectivamente W e b , representam:

- W_{ii} e b_{ii} : pesos e viés entre o vetor de entrada e a porta de entrada;
- W_{hi} e b_{hi} : pesos e viés entre o vetor de estado oculto anterior e a porta de entrada;
- W_{if} e b_{if} : pesos e viés entre o vetor de entrada e a porta de esquecimento;
- W_{hf} e b_{hf} : pesos e viés entre o vetor de estado oculto anterior e a porta de esquecimento;
- W_{ig} e b_{ig} : pesos e viés entre o vetor de entrada e o candidato a estado da célula;
- W_{hg} e b_{hg} : pesos e viés entre o vetor de estado oculto anterior e o candidato a estado da célula;
- W_{io} e b_{io} : pesos e viés entre o vetor de entrada e a porta de saída;
- W_{ho} e b_{ho} : pesos e viés entre o vetor de estado oculto anterior e a porta de saída.

A função $\sigma(\cdot)$ é a sigmoide logística, que produz valores entre 0 e 1, enquanto $\tanh(\cdot)$ é a tangente hiperbólica, que produz valores entre ± 1 . Assim, $f[k]$ controla quanto da memória anterior c será mantida, $i[k]$ controla quanta informação nova será adicionada à memória, e $o[k]$ decide que parte da memória atual, $c[k]$, influenciará o estado oculto e saída, $h[k]$. Um esquemático desse procedimento é apresentado na Figura 8. Essa arquitetura de portas permite que a célula LSTM retenha informações relevantes por longos períodos e descarte informações desnecessárias. Como resultado, uma rede LSTM pode armazenar simultaneamente padrões de curto e de longo prazo presentes na sequência (HOCHREITER; SCHMIDHUBER, 1997). Adicionalmente, assim como o PMC, várias células de LSTM podem ser empilhadas conectando a saída de uma célula à entrada da célula seguinte, aumentando a memória e a capacidade da rede de aprender parâmetros temporais mais complexos (YU *et al.*, 2019).

Figura 8 – Representação de uma célula LSTM.



Fonte: autor.

A saída da LSTM pode ser utilizada para diversas funções, desde a previsão de séries temporais, processamento de linguagem natural e sistemas ciberfísicos, até o prognóstico de falhas em sistemas energéticos e industriais (AL-SELWI *et al.*, 2024). Em problemas de regressão, as LSTMs são normalmente utilizadas para modelar dependências temporais em dados multivariados, estimando variáveis degradadas ou que não são diretamente mensuráveis a partir de sinais históricos. Devido à sua capacidade de capturar correlações espaço-temporais e reter informação de longo prazo, muitos métodos recentes em monitoramento e confiabilidade dependem de LSTMs para realizar previsão e diagnóstico. Jalayer, Orsenigo e Vercellis (2021), por exemplo, propuseram um modelo híbrido baseado em convolução e LSTM para diagnóstico de máquinas rotativas, obtendo desempenho superior ao de arquiteturas tradicionais. Outro exemplo foi proposto por Guo *et al.* (2025), que combinaram LSTM com técnicas de fusão de modelos para diagnóstico de falhas em arranjos fotovoltaicos. Aplicações como essas sugerem que a aplicação de LSTMs em métodos do estado da arte em sensoriamento virtual e

monitoramento de maquinário industrial pode ser uma boa alternativa, contanto que as séries temporais contenham informação relevante sobre o processo.

Os conceitos abordados nesta seção foram considerados neste trabalho para o desenvolvimento dos métodos supervisionados para previsão de vida útil. O Capítulo 4 detalha esse desenvolvimento, com uma LSTM utilizada para a extração de *features* temporais a partir de séries temporais de grandezas elétricas, e um PMC para regressão e estimação de capacitância em capacitores degradados.


2.5 CONVERSORES DE FREQUÊNCIA PARA SISTEMAS DE REFRIGERAÇÃO

Em sistemas de refrigeração de velocidade fixa, que foram por muitos anos a alternativa predominante, o compressor é projetado para operar constantemente em carga máxima ligado diretamente à rede elétrica. Nos casos nos quais o sistema deve operar com carga parcial, uma ocorrência comum em aplicações comerciais e domésticas, o compressor é normalmente regulado de forma liga/desliga por um termostato, que, por sua vez, é instalado no ambiente a ser refrigerado (ZAKI; EL-MORSI; ABDELAZIZ, 2024). Enquanto, por um lado, tal configuração é de simples implementação, com poucos componentes periféricos que possam ocasionar falhas na operação, por outro o fato de o compressor operar apenas em uma condição leva a perdas energéticas sempre que a carga do sistema não é máxima (APREA; MASTRULLO; RENNO, 2004; ADHIKARI *et al.*, 2012).

Sistemas de refrigeração com velocidade variável, por sua vez, permitem que a velocidade do compressor seja controlada de acordo com as condições de carga e desempenho necessárias, aumentando a eficiência energética do sistema. O controle de velocidade, realizado normalmente com uso de um conversor de frequência, permite também a redução de ruído acústico e de vibração quando o sistema não opera em carga máxima, tornando-o adequado para aplicações que envolvem o conforto humano, tais como em refrigeradores e em condicionadores de ar domésticos e comerciais (APREA; MASTRULLO; RENNO, 2009; KASSAKIAN; JAHNS, 2013).

A Figura 9 apresenta a simulação de um sistema de refrigeração simplificado, considerando um compressor de velocidade fixa (controle liga/desliga com histerese) e um compressor de velocidade variável (controlador Proporcional Integral, PI). É possível observar que ambos os sistemas são resfriados à condição desejada em tempos similares, porém, enquanto o sistema de velocidade variável permite uma resposta suave e com redução gradual da atuação, o sistema com velocidade fixa apresenta oscilações decorrentes da histerese necessária para a aplicação prática do controle liga/desliga. Além das oscilações, a partida do compressor também exige trabalho adicional por parte do motor para compensar a inércia do sistema mecânico e o diferencial de pressão existente no circuito de refrigeração, levando a um pico de consumo energético. Assim, o consumo do compressor de velocidade fixa é ampliado pelas múltiplas partidas necessárias para manutenção da temperatura, enquanto o compressor de velocidade variável requer apenas a partida inicial e opera de forma contínua, ajustando a rotação do motor conforme a demanda térmica.

Figura 9 – Comparação entre sistemas de refrigeração com velocidade fixa (controle liga/desliga) e com velocidade variável (controle PI).




Fonte: autor.

Dada a demanda por eficiência energética, a utilização de sistemas de refrigeração de velocidade variável tem aumentado nos últimos anos. Porém, enquanto em sistemas de velocidade fixa as falhas eletrônicas estão restritas majoritariamente ao compressor e ao termostato, sistemas de velocidade variável estão mais sujeitos a falhas no conversor de frequência, visto que esse subsistema possui uma arquitetura eletrônica mais complexa, composta por múltiplos estágios de conversão, controle e proteção, com maior número de componentes suscetíveis a falhas.

Apesar de a literatura apresentar topologias de conversores de frequência que permitem a conversão direta CA-CA, a sua aplicação em sistemas comerciais é rara, principalmente devido à complexidade da modulação e do dimensionamento de componentes (KOLAR *et al.*, 2008). Assim, sistemas comerciais usualmente utilizam a conversão indireta, com uma etapa intermediária em CC, idealmente desacoplando o sistema de distribuição de energia da alimentação do motor do compressor (RAZIK, 2011). A Figura 10 apresenta os três blocos funcionais de um conversor CA-CC-CA, que são descritos a seguir.

O circuito retificador é responsável pela conversão da tensão alternada proveniente da rede elétrica em uma tensão contínua pulsante, que é disponibilizada ao barramento CC. Essa conversão pode ser realizada por meio de retificadores não controlados, como a ponte de diodos, que é comumente encontrada em conversores para sistemas de refrigeração, ou de retificadores controlados, que permitem modular a forma de onda e implementar estratégias adicionais, como a correção do fator de potência. O desempenho do retificador impacta diretamente a eficiência do sistema, já que quanto mais oscilatória é a tensão do barramento, maiores são as flutuações de potência transferida para a carga e as perdas associadas à comutação e condução

Figura 10 – Diagrama de blocos funcionais de um conversor de frequência com barramento CC.



Fonte: adaptado de Franchi (2009).

dos dispositivos de potência, reduzindo a eficiência energética do conversor (KHAN; ZAFFAR; IKRAM, 2023).

O filtro do barramento CC tem como objetivo reduzir a ondulação da tensão resultante da etapa de retificação e fornecer energia armazenada para a etapa subsequente. Em geral, essa função é desempenhada por capacitores eletrolíticos, que acumulam carga e compensam variações de corrente. A escolha da configuração do filtro e das características dos capacitores influencia a magnitude da ondulação de tensão e a expectativa de vida útil do conversor, uma vez que a degradação dos capacitores está associada a alterações no desempenho elétrico do sistema (WANG; BLAABJERG, 2014). Conforme apresentado na Seção 1.2, este trabalho tem foco na avaliação de degradação e estimação de vida útil dos capacitores do barramento CC, logo esses são tratados mais detalhadamente na Seção 2.6.

O inversor de frequência corresponde à última etapa do conversor, sendo responsável por converter a tensão contínua em uma forma de onda alternada com frequência e amplitude ajustáveis. Essa tarefa é realizada por dispositivos semicondutores de potência, como transistores bipolares de porta isolada (IGBTs, do inglês *Insulated Gate Bipolar Transistors*) e transistores de efeito de campo semicondutor de óxido metálico (MOSFETs, do inglês *Metal Oxide Semiconductor Field-Effect Transistors*), operados segundo técnicas de modulação, como a modulação por largura de pulso. O controle aplicado ao inversor possibilita adequar a tensão e a frequência fornecidas a um motor de acordo com os requisitos de operação, permitindo flexibilidade no acionamento de cargas em diferentes condições (PETRUZELLA, 2013).

Em sistemas de refrigeração comerciais e domésticos é normal que todos os componentes do conversor de frequência estejam encapsulados em um mesmo módulo, como no exemplo apresentado na Figura 11. Nessa configuração, todos os subsistemas do conversor são instalados em uma mesma placa, incluindo também um sistema embarcado para controle do inversor de frequência e para outras funcionalidades relacionadas ao monitoramento e à segurança do sistema como um todo. Apesar da flexibilidade de aplicações e da facilidade logística trazidas por essa configuração, a miniaturização e o encapsulamento dos componentes também podem

gerar condições que acelerem o desgaste dos dispositivos eletrônicos, incluindo alta temperatura e umidade.

Figura 11 – Exemplo de compressor e módulo conversor de frequência.



Fonte: adaptado de Nidec Global Appliance (2020).

2.6 DEGRADAÇÃO DE CAPACITORES DE BARRAMENTO CC

Conforme apresentado anteriormente, o barramento CC é um subsistema central nos conversores de frequência utilizados em compressores de refrigeração, permitindo o desacoplamento entre a rede de alimentação CA e o circuito do motor. Na prática, porém, esse desacoplamento é apenas parcial, visto que os retificadores normalmente não produzem uma tensão constante, e que o chaveamento do inversor e as variações na carga de saída do conversor geram oscilações na tensão do barramento intermediário (MANDRIOLI *et al.*, 2021; KHAN; ZAFFAR; IKRAM, 2023). Assim, a grande maioria dos conversores possui um ou mais capacitores em seu barramento CC, que é responsável pela filtragem das ondulações de tensão e pelo fornecimento de energia instantânea para a carga. Contudo, esses capacitores estão entre os componentes mais suscetíveis a falhas por envelhecimento nos sistemas de conversores, podendo causar desde paradas de equipamento até danos secundários em outros componentes (FALCK *et al.*, 2018; WANG; BLAABJERG, 2014). Como resultado, a monitoração da condição desses capacitores e a estimativa de sua vida útil restante tornaram-se focos importantes de pesquisa em confiabilidade e manutenção preditiva de sistemas de potência.

Esta seção apresenta uma revisão acerca do FDV de capacitores para barramento CC. A Seção 2.6.1 descreve os principais tipos e características desses componentes, enquanto a Seção 2.6.2 aborda os mecanismos envolvidos em sua degradação. Por fim, a Seção 2.6.3 discute o estado da arte em métodos de estimativa de FDV de capacitores de barramento CC.

2.6.1 Tipos e características de capacitores

A Figura 12(a) apresenta o circuito equivalente de um capacitor, sendo C a sua capacitância, R_{SE} a sua resistência série equivalente, L_{SE} a sua indutância série equivalente

e R_P a resistência de seu isolamento. Como a resistência R_P costuma ser várias ordens de grandeza maior do que R_{SE} , o módulo da impedância do capacitor Z_C em função da frequência, apresentado na Figura 12(b), pode ser aproximado como (ZHAO *et al.*, 2020):


$$|Z_C(f)| = \sqrt{R_{SE}^2 + \left(2\pi f L_{SE} - \frac{1}{2\pi f C}\right)^2}. \quad (7)$$

A resposta apresentada na Equação (7) pode ser dividida em três regiões:

- Região I: baixas frequências, dominada por C ;
- Região II: médias frequências, dominada por R_{SE} ;
- Região III: altas frequências, dominada por L_{SE} .

Os limites das regiões variam de acordo com as características construtivas de cada capacitor. Quanto menor o valor de R_{SE} , menores as perdas na forma de calor no capacitor; e quanto menor o valor de L_{SE} , maior a largura da banda dominada por C .

Figura 12 – Modelagem de capacitores: (a) circuito equivalente simplificado e (b) resposta da impedância na frequência.



Fonte: adaptado de Zhao *et al.* (2020).

Diversos tipos de capacitor podem ser empregados como filtro de barramento CC, principalmente: capacitores eletrolíticos de alumínio (Al-Cap), capacitores de filme de polipropileno metalizado e capacitores cerâmicos multicamadas. Cada tecnologia apresenta características próprias, como densidade de energia, suporte a ondulação de corrente, estabilidade térmica e custo; o que determina sua adequação a diferentes faixas de potência e frequência. Os capacitores eletrolíticos de alumínio são amplamente utilizados devido à sua alta capacitância por volume e ao baixo custo por joule armazenado. Em contrapartida, exibem R_{SE} relativamente elevada e vida útil reduzida. Já os capacitores de filme possuem perdas internas baixas e maior


vida útil, porém com densidade de capacitância inferior e custo mais elevado. Capacitores cerâmicos suportam temperaturas e frequências muito altas, mas são normalmente restritos a pequenas capacitâncias (tipicamente usados em paralelo aos capacitores principais para filtrar componentes de alta frequência) (KAISER, 2011). Assim, no projeto de barramentos CC, é comum o uso de um ou mais capacitores eletrolíticos para fornecer a capacitância de sustentação necessária, ocasionalmente complementados por capacitores de filme ou cerâmicos para melhorar a filtragem em alta frequência. Essa configuração aproveita o melhor de cada tecnologia, equilibrando requisitos de energia e desempenho com considerações de custo e volume (WANG *et al.*, 2020).

Dentre as tecnologias citadas, os Al-Cap são os mais utilizados no barramento CC em conversores de frequência para compressores, já que seu baixo custo, grande disponibilidade e alta densidade de capacitância facilitam a miniaturização e a produção em massa. Porém, conforme destacado anteriormente, tais capacitores possuem vida útil reduzida, apresentando o menor índice de confiabilidade dentre todos os tipos de capacitores, segundo Wang e Blaabjerg (2014). O restante desta seção dá enfoque, portanto, aos Al-Cap, que foram também escolhidos para o desenvolvimento do projeto descrito neste documento.

2.6.2 Mecanismos de degradação

A Figura 13 apresenta a estrutura de um Al-Cap, que consiste em um cátodo e um ânodo feitos de folha de alumínio, papel separador impregnado em eletrólito e uma camada de óxido na superfície da folha de ânodo, que atua como dielétrico. O ataque químico da folha amplia a área efetiva da superfície, permitindo a alta capacitância em pequeno volume característica desse tipo de capacitor (KULKARNI *et al.*, 2011).

Figura 13 – Ilustração da estrutura interna de um eletrolítico de alumínio.



Fonte: adaptado de Kulkarni *et al.* (2011).

Com o tempo, os mesmos mecanismos construtivos que possibilitam a alta densidade de capacitância são também responsáveis por sua vida útil reduzida. O principal mecanismo

de envelhecimento é a diminuição de volume do eletrólito líquido no interior do capacitor, por evaporação ou consumo (NATHAN *et al.*, 2023). Em operação, oscilações de corrente pela resistência equivalente (R_{SE}) do capacitor causam autoaquecimento, promovendo a difusão e evaporação gradual do eletrólito do componente. Com menos eletrólito disponível, aumenta o valor de R_{SE} e diminui a capacidade de manter a molhabilidade do papel separador, resultando na redução da capacitância efetiva C (KULKARNI *et al.*, 2012). Simultaneamente, ocorrem reações de degradação do dielétrico, especialmente em temperaturas elevadas ou sob sobretensões. O dielétrico pode sofrer dissolução no eletrólito e fechamento de poros, reduzindo sua espessura efetiva e elevando a corrente de fuga. Eventualmente, imperfeições localizadas podem levar a microcurto-circuitos que consomem ainda mais o eletrólito em eventos de auto-recuperação (AMARAL, 2025). Adicionalmente, esforços mecânicos e térmicos repetidos devidos à ciclagem de carga e temperatura podem causar perda de contato nas conexões internas e gradual delaminação das folhas de alumínio, contribuindo para o aumento de R_{SE} com o envelhecimento.

A taxa de degradação apresenta forte dependência em relação à temperatura e às condições de operação. Celaya *et al.* (2011) apresentam um estudo no qual Al-Caps foram submetidos a ciclos de sobretensão, aplicando uma onda quadrada sobre os mesmos de modo a realizar continuamente os ciclos de carga e descarga e reduzindo a capacitância das amostras em até 20% em menos de 180 h. Kulkarni *et al.* (2012), por sua vez, comparam o efeito da operação dos capacitores em temperatura elevada (105 °C), mostrando que a capacitância é mais afetada do que a resistência em série nesses casos, e utilizando os resultados experimentais obtidos para a validação de modelos matemáticos do envelhecimento.

Os mecanismos descritos nesta seção resultam em alterações progressivas nas grandezas elétricas do modelo equivalente do capacitor. A redução da C desloca a frequência de ressonância, enquanto o aumento da R_{SE} eleva a impedância na região de médias frequências e intensifica as perdas por ondulação. A influência desses efeitos em outras grandezas do sistema permite que sejam desenvolvidos métodos para observação e estimação da vida útil dos capacitores, os quais são discutidos na Seção 2.6.3.


2.6.3 Estimação de vida útil restante

O critério mais adotado na indústria e na literatura como FDV de capacitores é a redução da capacitância para 80% do valor inicial (ou seja, perda de 20%) (ANDRADE, 2024). Esse critério foi estabelecido por trabalhos clássicos de confiabilidade mostrando que, a partir dessa porcentagem de perda, a taxa de degradação tende a se acelerar e o risco de falhas catastróficas (como ventilação do eletrólito ou explosão da lata) aumenta significativamente (WANG; BLAABJERG, 2014; DANG; KWAK, 2020). Além disso, a maioria dos conversores começa a apresentar desempenho insatisfatório quando a capacitância do barramento cai a esse patamar, levando a maiores ondulações de tensão CC e possível disparo de proteções.

Em paralelo, costuma-se considerar também um limite para o aumento da R_{SE} , típica-

mente o dobro do valor inicial. A elevação da resistência série além desse ponto indica que as perdas por calor tornaram-se excessivas, podendo desencadear uma espiral térmica que acelera ainda mais a degradação e pode gerar falhas por sobreaquecimento (LAHYANI *et al.*, 1998; KULKARNI *et al.*, 2011; ZHAO *et al.*, 2020). A Figura 14 mostra a evolução típica de C e R_{SE} em um Al-Cap ao longo do tempo de operação. Nota-se a redução gradual de $C(t)$ e o aumento de $R_{SE}(t)$, até atingirem os limites estabelecidos para o FDV, após o qual a taxa de redução e de aumento, respectivamente, é acelerada.

Figura 14 – C e R_{SE} ao longo da degradação de um Al-Cap com indicação do FDV do componente de acordo com tais indicadores.



Fonte: adaptado de Soliman *et al.* (2017).

Saravanakumar *et al.* (2025) propõem a divisão dos métodos de estimação de FDV em quatro categorias:

- Observação elétrica on-line: essa categoria reúne os métodos que utilizam diretamente os sinais de tensão e corrente durante a operação do sistema. A extração das grandezas de interesse a partir desses sinais pode ser realizada de diversas formas, incluindo análise de harmônicas, estimação com observador de Kalman, entre outras (RONANKI; WILLIAMSON, 2020; SLIMANI; GHANES; DJENNOUNE, 2025). Em geral, buscam a estimação a partir de variáveis já utilizadas para o controle e monitoramento dos conversores, sem a utilização de hardware adicional, mas podem também incluir a injeção de sinais e leituras adicionais de corrente (DENG *et al.*, 2020; SARAVANAKUMAR *et al.*, 2025). Adicionalmente, o desenvolvimento de tais métodos muitas vezes requer conhecimento prévio e modelagem do conversor e dos padrões de chaveamento utilizados no controle do sistema, limitando-os a aplicações específicas.
- Perfil de carga e descarga: analisam a resposta transitória dos capacitores, seja em processos naturais de carga e descarga ou em transitórios induzidos. Apesar de apresentarem boa precisão em geral, tais métodos não são aplicáveis de forma on-line, podendo apenas ser realizados durante condições específicas (desligamentos, eventos forçados ou testes programados) (XIA *et al.*, 2023; ZHAO *et al.*, 2023).

- Baseados em dados: métodos de regressão, incluindo modelos de inteligência artificial e aprendizado de máquina. Possuem a vantagem de dispensar a modelagem física do sistema, além de possibilitarem a captura de relações não lineares e a integração de múltiplas variáveis de estresse de forma simultânea. Contudo, exigem conjuntos de dados abrangentes e representativos para treinamento, estando sujeitos ao fenômeno de subajuste.
- Outros métodos: outras estratégias que não se encaixam nas categorias anteriores, normalmente utilizando grandezas que não são associadas diretamente à operação do conversor (ex.: campo magnético, volume do capacitor, deformação). Possibilitam a captura de fenômenos que as medições elétricas convencionais não conseguem detectar, fornecendo indicadores adicionais de envelhecimento. No entanto, apresentam maior custo, necessidade de instalação de hardware adicional, aumento da complexidade e, em muitos casos, dificuldade de integração em aplicações industriais reais.

O Quadro 1 apresenta um resumo dos métodos propostos para estimação de FDV de capacitores nos últimos cinco anos. Para a revisão realizada neste trabalho, os métodos da literatura foram categorizados de acordo com a classificação de Saravanakumar *et al.* (2025), incluindo também as grandezas utilizadas para a estimação e as grandezas estimadas por cada método. Adicionalmente, são apresentados no Quadro 1 a aplicação proposta nos trabalhos originais e o método de validação (simulação ou experimental) utilizados.

Pelos métodos encontrados, é possível observar que a maior parte (43%) das aplicações foi proposta para aplicações em Conversores Modulares Multinível (CMMs), que são utilizados para conversão de média e alta tensão principalmente em aplicações de geração de energia (XIA *et al.*, 2023; SARAVANAKUMAR *et al.*, 2025), e que apenas um trabalho propõe uma aplicação em conversores CA-CC-CA monofásico-trifásico, como os normalmente utilizados em sistemas de refrigeração domésticos (AL-WESABI *et al.*, 2025).

Quanto aos tipos de métodos utilizados, nota-se um crescente avanço dos métodos baseados em dados (60% dos métodos publicados em 2025) em relação aos anos anteriores (19% dos métodos publicados entre 2020 e 2024). Dentre os métodos baseados em dados encontrados, a maioria se baseia na extração de *features* para regressão. Andrade (2024) extrai o valor RMS da oscilação de tensão sobre o capacitor, que é então utilizado no treinamento de um PMC para estimação da capacitância em um conversor CA-CC-CA trifásico. AL-Wesabi *et al.* (2025) também utilizam *features* baseadas na oscilação de tensão, além de incluírem informações no domínio da frequência a partir das componentes harmônicas da oscilação de tensão do barramento CC para o treinamento de um modelo híbrido de RNAs, *gradient boosting* e regressão linear para estimação de capacitância. Por fim, Örüklü e Ağalar (2025) também propõem a utilização de *features* nos domínios do tempo e da frequência, sendo essas o valor pico-a-pico da tensão no barramento CC, a frequência fundamental e a segunda harmônica da saída do inversor, a sexta harmônica da frequência de entrada e o valor RMS da corrente

Quadro 1 – Resumo de trabalhos dos últimos cinco anos no campo de estimação de FDV de capacitores

Autor	Classificação	Grandezas medidas	Grandezas estimadas	Aplicação	Validação
Deng <i>et al.</i> (2020)	Relações elétricas	Tensão nos capacitores, corrente nos braços de submódulos e função de chaveamento	C e R_{SE}	CMM	Experimental
Miao, Lam e Pong (2020)	Outros	Campo magnético do capacitor	C , R_{SE} e temperatura do capacitor	Conversor boost	Experimental
Ronanki e Williamson (2020)	Relações elétricas	Tensão nos capacitores, corrente nos braços de submódulos	C	CMM	Experimental
Liu <i>et al.</i> (2021)	Relações elétricas	Corrente e tensão nos capacitores	C	CMM	Experimental
Xia <i>et al.</i> (2021)	Perfil de carga e descarga	Corrente e tensão nos capacitores	R_{SE}	CMM	Simulação
Zhao <i>et al.</i> (2021)	Perfil de carga e descarga	Corrente e tensão no capacitor, corrente na saída e temperatura de operação	C e R_{SE}	Conversor buck	Simulação
Shahraki <i>et al.</i> (2022)	Dados	R_{SE} e temperatura	FDV	Veículo elétrico	Simulação
Liu <i>et al.</i> (2023)	Dados	C , R_{SE} , tensão e temperatura no capacitor	Desvio no FDV	-	Simulação
Xia <i>et al.</i> (2023)	Perfil de carga e descarga	Tensão no capacitor durante transitório	R_{SE}	CMM	Experimental
Zhao <i>et al.</i> (2023)	Perfil de carga e descarga	Tensão no capacitor	C	Conversor boost	Experimental
Andrade (2024)	Dados	Valor RMS da oscilação de tensão, corrente na saída, frequência de saída	C	Conversor CA-CC-CA trifásico	Experimental
Yao <i>et al.</i> (2024)	Outros	Deformação mecânica do capacitor	FDV	-	Experimental
Xiao <i>et al.</i> (2024)	Relações elétricas	Frequência fundamental da tensão no capacitor	C	CMM	Experimental
Zoraghi-Jedi <i>et al.</i> (2024)	Relações elétricas	Tensão sobre módulos	C	CMM	Experimental
Jia <i>et al.</i> (2024)	Relações elétricas	Corrente e tensão nos capacitores	C	CMM	Simulação
Jiang <i>et al.</i> (2024)	Relações elétricas	Corrente e tensão nos capacitores	C	CMM	Experimental
AL-Wesabi <i>et al.</i> (2025)	Dados	Tensão de oscilação, tensão e harmônicas no barramento CC, corrente na saída potência	C	Conversor CA-CC-CA monofásico-trifásico	Simulação
Behrooz, Soleimanifar e Zolghadri (2025)	Dados	Corrente no MOSFET e tensão sobre o capacitor	C e R_{SE}	Conversor boost	Simulação
Öröklü e Ağalar (2025)	Dados	Tensão no capacitor e corrente na saída	C	Conversor CA-CC-CA trifásico-monofásico	Experimental
Slimani, Ghanes e Djennoune (2025)	Relações elétricas	Tensão na entrada, tensão sobre o capacitor, corrente na saída, sinal PWM de controle	C e R_{SE}	Conversor multicelular	Simulação
Roh <i>et al.</i> (2025)	Relações elétricas	Corrente e tensão no capacitor	R_{SE}	Conversor CA-CC-CA trifásico	Experimental

de saída. Essas *features* foram utilizadas no treinamento de diferentes modelos de regressão, sendo que o menor erro foi observado em modelos de Regressão de Processo Gaussiano (RPG).

Apenas dois métodos baseados em dados consideram diretamente séries temporais, sem a extração de *features*: o proposto por Shahraki *et al.* (2022), que utiliza LSTMs para estimar o FDV a partir de medições diretas de R_{SE} ; e o proposto por Liu *et al.* (2023), que utiliza LSTMs com base na progressão temporal de C e R_{SE} , bem como a tensão e temperatura aplicadas em ensaios de vida acelerados, para a previsão de desvio no FDV do capacitor. Ambos os trabalhos apresentaram resultados positivos em simulação para a estimação, indicando que a técnica pode ser utilizada para a extração de padrões temporais em sinais elétricos para estimação da vida útil do capacitor, sugerindo espaço para futuras aplicações em diferentes tipos de conversores.

2.7 CONSIDERAÇÕES

Este capítulo apresentou uma revisão da literatura sobre os fenômenos de amaciamento tribológico e degradação de componentes em sistemas eletromecânicos, com ênfase em compressores herméticos alternativos e conversores de frequência, bem como uma fundamentação dos métodos de aprendizado de máquina empregados neste trabalho, incluindo técnicas de agrupamento não supervisionado, aprendizado semissupervisionado e RNAs aplicadas à regressão e estimação de grandezas físicas.

A avaliação do fenômeno do amaciamento na literatura é majoritariamente baseada em métodos invasivos, que incluem a análise topográfica e do COF entre superfícies de contato. Esses métodos são bem definidos para tribopares, sendo utilizados principalmente em ensaios para avaliação de desgaste nesses conjuntos. Para mecanismos mais complexos e com contatos de difícil acesso, como os compressores herméticos alternativos, tais métodos de avaliação direta são dificilmente aplicáveis, sendo necessária a utilização de métodos indiretos para sensoriamento virtual do fenômeno.

Na literatura, são descritos métodos indiretos baseados na corrente elétrica e na vibração de máquinas rotativas, e estudos sugerem que o fenômeno do amaciamento em compressores para refrigeração afeta a vazão mássica gerada pela operação do dispositivo. Apesar de não poderem ser aplicados diretamente para a detecção da transição do período de amaciamento para o de regime permanente tribológico, tais métodos sugerem grandezas que podem apresentar padrões representativos dessa transição. Trabalhos anteriores utilizaram aprendizado de máquina para extração de padrões nesse contexto e mostram que o agrupamento de dados experimentais pode ser utilizado para detecção do regime permanente tribológico em compressores. Os conceitos e métodos sumarizados neste capítulo são a base das atividades de avaliação do amaciamento descritas no Capítulo 3.

Os algoritmos de agrupamento k -médias e *kernel* k -médias descritos neste capítulo foram aplicados em um método automático para detecção do término do período do amaciamento, proposto na Seção 3.2.1. Além do agrupamento, também foi desenvolvido um método de

identificação do período de amaciamento com base no autotreinamento de classificadores, que é descrito na Seção 3.3.1.

A revisão também abordou o FDV de capacitores de barramento CC, que são componentes críticos para a confiabilidade de inversores de frequência. Foram discutidos os mecanismos físicos associados à degradação de capacitores eletrolíticos de alumínio, que são utilizados como base para a definição dos critérios de FDV e para a caracterização da vida útil restante dos dispositivos. A literatura recente destaca tanto abordagens baseadas em modelos físicos, que utilizam leis empíricas e relações térmicas, quanto métodos baseados em dados, que empregam sinais elétricos e técnicas de aprendizado de máquina para a estimação dessas grandezas.

As RNAs aplicadas à regressão, em especial as arquiteturas PMC e LSTM, foram discutidas como ferramentas adequadas para a modelagem temporal de variáveis contínuas e para a estimação de parâmetros em sistemas dinâmicos. A capacidade dessas redes de capturar informações temporais as torna adequadas para a análise de sinais de maquinário, como a corrente e a tensão elétricas em inversores. Com base nesses conceitos, foi desenvolvido um método de estimação de capacitância de barramento CC utilizando aprendizado supervisionado, descrito no Capítulo 4, no qual as RNAs são empregadas para realizar sensoriamento virtual e estimar a evolução da degradação dos capacitores do sistema.

3 EXTRAÇÃO DE INFORMAÇÕES DE AMACIAMENTO

Este capítulo apresenta os desenvolvimentos e resultados do trabalho no contexto da detecção e extração de informações sobre o fenômeno do amaciamento, como a análise de dados experimentais e a extração e seleção de *features* relacionadas ao fenômeno a partir de séries temporais de medições. A Seção 3.1 descreve o desenvolvimento experimental, incluindo a bancada e o procedimento de ensaios e o conjunto de dados utilizados no projeto. A Seção 3.2 detalha a adaptação do método automático proposto por Thaler (2021) em uma abordagem off-line baseada em um conjunto de modelos não supervisionados para a detecção da transição do período de amaciamento para o regime permanente tribológico, incluindo também a interpretação de *features* possivelmente relacionadas à transição. De modo a permitir a identificação do amaciamento de forma on-line, é proposto e avaliado na Seção 3.3 um método de classificação baseado em aprendizado semissupervisionado. A Seção 3.4 apresenta uma comparação entre as abordagens de detecção propostas no capítulo. Por fim, a Seção 3.5 reúne as considerações finais do autor sobre os métodos propostos e os avanços obtidos na frente de estudos sobre a detecção não invasiva do fim do amaciamento.

3.1 DESENVOLVIMENTO EXPERIMENTAL

Esta seção descreve o procedimento experimental realizado a fim de avaliar o fenômeno do amaciamento em compressores herméticos alternativos. A Seção 3.1.1 descreve a bancada experimental na qual foram realizados os ensaios de amaciamento de compressores. A Seção 3.1.2 apresenta o conjunto de dados utilizados neste trabalho. Por fim, a Seção 3.1.3 apresenta uma análise preliminar dos dados utilizada na escolha de métodos de agrupamento e na configuração dos critérios descritos na Seção 3.2.


3.1.1 Bancada experimental

A Figura 15 apresenta o diagrama de tubulação e instrumentação da bancada de ensaios utilizada neste trabalho, tanto para análise do fenômeno do amaciamento quanto do processo de desgaste. Conceitualmente, a bancada é similar à bancada utilizada em Thaler (2021), com o compressor (①) operando em ciclo quente em condições de pressão de sucção e de descarga controladas pela válvula de sucção (②) e pela válvula de descarga (③), respectivamente. As válvulas manuais (⑧) são utilizadas para carregamento de fluido, manutenção da bancada e retorno de óleo do reservatório para o compressor, e o restante dos dispositivos demarcados são utilizados para segurança e para monitoramento de condições.

Seguindo o método experimental proposto por Thaler (2021), são medidos na bancada para fins de avaliação de estado tribológico a corrente elétrica do motor, a vazão mássica gerada pela operação do compressor e a vibração nos eixos lateral e longitudinal do dispositivo. Adicionalmente, são medidas a pressão no reservatório intermediário e as temperaturas do

ambiente, do corpo do compressor e da tubulação de descarga para monitoramento e segurança da bancada. Todo o controle, monitoramento e aquisição de dados da bancada experimental foi realizado em um programa desenvolvido em LabVIEW.

Figura 15 – Diagrama de tubulação e instrumentação da bancada de caracterização de amaciamento.



Fonte: Thaler (2021).


As Figuras 16(a) e 16(b) apresentam fotos da bancada implementada. A Figura 16(c) apresenta o compressor instrumentado, explicitando os pontos de medição de vibração nos eixos lateral e longitudinal do compressor. O procedimento de ensaio e os ensaios realizados são descritos na Seção 3.1.2.

3.1.2 Ensaios

Foram utilizados dados de ensaios com dois modelos de compressor, denominados Modelo A e Modelo B. O tempo de ensaio para cada modelo foi definido com base na análise de ensaios de desempenho em calorímetro, similares à apresentada na Seção 1.1 deste trabalho, de modo que os ensaios realizados tenham duração suficiente para garantir a captura de todo o período de amaciamento das unidades. A Tabela 1 apresenta as características de operação e os tempos de ensaio definidos para os modelos avaliados.

Os ensaios foram realizados em condição de operação ASHRAE de baixa pressão de retorno (LBP do inglês *Low Back Pressure*), definida por temperatura de evaporação de $-23,3^{\circ}\text{C}$ e por temperatura de condensação de $+54,4^{\circ}\text{C}$, comumente utilizada em ensaios de desempenho na indústria. Foram realizados 3 ensaios com cada uma das unidades, sendo o

Figura 16 – Fotos da bancada de amaciamento: (a) vista em perspectiva; (b) vista lateral do circuito auxiliar; (c) compressor instrumentado.



Fonte: Thaler (2021).

Tabela 1 – Modelos de compressor utilizados em ensaios de amaciamento.

Modelo	Fluido refrigerante	Capacidade de refrigeração (ASHRAE LBP) [W]	Duração do ensaio [h]	Unidades ensaiadas
A	R134a	56	26	4
B	R600a	110	50	6

Fonte: autor.

primeiro o ensaio de amaciamento, e os dois seguintes ensaios de referência com a unidade já em regime permanente tribológico.

As medições de vazão mássica foram realizadas com tempo de amostragem T_s de uma amostra por minuto. Já as medições de vibração e de corrente foram realizadas em alta frequência de amostragem, $F_s = 25,6$ kHz, de modo a possibilitar a extração de valores estatísticos das grandezas. Dada a longa duração dos ensaios e, conseqüentemente, a grande quantidade de dados obtidos em medições de alta frequência, as medições de corrente e de vibração foram armazenadas em bateladas, registrando 1 s de medições a cada minuto de ensaio.

Os dados obtidos nos ensaios de amaciamento e de referência foram inicialmente avaliados em análises comparativas manuais, buscando padrões que pudessem diferenciar o comportamento das unidades durante e após o amaciamento. Essa análise preliminar é descrita na Seção 3.1.3. Posteriormente, os dados foram utilizados para validação do método automático de detecção, descrito na Seção 3.2.

3.1.3 Análise preliminar de dados

Para análise preliminar, realizada utilizando o software Matlab, foram extraídas características estatísticas das medições em alta frequência de corrente e de vibração dos compressores. As características extraídas de cada vetor $\mathbf{x}_m$ com N_X amostras de medições $x_{m,i}$ e média $\bar{x}_m$ foram:

- valor RMS: $X_{\text{RMS}} = \sqrt{\frac{1}{N_X} \sum_{i=1}^{N_X} x_{m,i}^2}$; (8)

- desvio-padrão (X_σ) e variância (X_{Var}): $X_\sigma^2 = X_{\text{Var}} = \frac{1}{N_X} \sum_{i=1}^{N_X} (x_{m,i} - \bar{x}_m)^2$; (9)

- assimetria: $X_{\text{Ass}} = \frac{\frac{1}{N_X} \sum_{i=1}^{N_X} (x_{m,i} - \bar{x}_m)^3}{\sqrt{X_{\text{Var}}^3}}$; (10)

- curtose: $X_{\text{Kur}} = \frac{\frac{1}{N_X} \sum_{i=1}^{N_X} (x_{m,i} - \bar{x}_m)^4}{X_{\text{Var}}^2}$; (11)


- valor de pico: $X_{\text{Pk}} = \max(|\mathbf{x}_m|)$. (12)

As características extraídas foram avaliadas de forma comparativa para cada unidade ensaiada, buscando padrões que diferenciassem o ensaio de amaciamento dos ensaios de referência. Os padrões observados são descritos no restante desta seção.

Para as unidades do Modelo A, observou-se que o assentamento do valor RMS, da curtose e da variância da corrente elétrica é mais lento em ensaios de amaciamento do que nos

ensaios de referência. A Figura 17 apresenta o valor RMS da corrente nos ensaios de unidades desse modelo, com destaque no assentamento de ensaios de amaciamento.

Figura 17 – Corrente RMS de ensaios realizados com compressores do Modelo A.



Fonte: autor.


É possível observar que, enquanto as Unidades A1 e A3 atingem o regime permanente nos ensaios de amaciamento mais cedo (em aproximadamente 5 h e 6 h, respectivamente), as Unidades A2 e A4 atingem esse estado apenas na segunda metade do teste, em torno de 12 h e de 12,5 h, respectivamente. Também é perceptível nos sinais que, para as Unidades A1 e A3, a convergência para o valor de regime permanente nos testes de amaciamento é mais suave do que para as Unidades A2 e A4. Além das características da corrente elétrica previamente citadas, nenhum sinal visível do processo de amaciamento foi identificado nas outras grandezas medidas para essa unidade.

Considerando a relação próxima entre amaciamento e consumo de energia, tais variações no tempo de assentamento e no formato da curva podem ser indicadores fortes do fenômeno. Além disso, os dados corroboram a hipótese de que o método usual de amaciamento na indústria de compressores não é completamente apropriado para todos os modelos de compressores, já que não se ajusta à grande variação na duração do amaciamento entre diferentes unidades de um único modelo. Uma vez que está claro que o transitório das características relacionadas à corrente elétrica é mais longo nos testes de amaciamento, os instantes de transição detectados algoritmicamente devem refletir essas observações, se a corrente for uma boa representante do processo de amaciamento, ou serem maiores do que aqueles definidos preliminarmente, se o assentamento das grandezas derivadas da corrente for apenas parte do fenômeno. De maneira conservadora, esses instantes de transição preliminares foram definidos como 4 h para as Unidades A1 e A3; e 10 h para as Unidades A2 e A4. Esses valores foram considerados

posteriormente no desenvolvimento de modelos de detecção do amaciamento, descrito na Seção 3.2.3.

Diferentemente dos ensaios com unidades do Modelo A, não foram observados padrões em unidades do Modelo B que pudessem indicar o amaciamento. A Figura 18 exemplifica essa observação, apresentando o valor RMS da corrente elétrica nos ensaios realizados. Apesar de os dados de algumas unidades, como as Unidades B1, B2 e B5, sugerirem uma diferença no tempo de assentamento de ensaios de amaciamento e de referência, o mesmo não pôde ser observado em outros compressores. Assim, para unidades desse modelo, não foram definidas transições para regime permanente tribológico a priori.

Figura 18 – Corrente RMS de ensaios realizados com compressores do Modelo B.




Fonte: autor.

3.2 ANÁLISE NÃO SUPERVISIONADA

Para avaliar características relacionadas ao processo de amaciamento e detectar automaticamente a transição para o regime permanente tribológico nos dados de operação real do compressor, um método baseado em conjunto não supervisionado foi desenvolvido com base no método proposto por Thaler (2021). Uma visão desse método é apresentada na Figura 19 e todos os seus passos são descritos nesta seção.

Figura 19 – Representação esquemática do método proposto.



Fonte: autor.

A principal entrada do método são séries temporais de dados experimentais do compressor, tanto durante o período de amaciamento do compressor quanto durante sua operação em regime permanente tribológico. Esses dados são idealmente compostos por medições das diferentes grandezas indicadas na literatura de amaciamento descritas na Seção 2.1, como características da corrente elétrica, vibração e vazão mássica.

Para cada grandeza física medida, os dados experimentais são processados, agrupados e analisados em busca de padrões que possam indicar uma transição do estado de amaciamento para o de regime permanente. O processamento das séries temporais é realizado utilizando subsequenciamento em janela deslizante no espaço de atraso, que são então agrupadas utilizando um algoritmo não supervisionado. A biblioteca desenvolvida para processamento dos dados foi implementada em linguagem Python, e foi disponibilizada como um repositório aberto na plataforma Github (THALER, 2025). Com base na proporção de agrupamentos ao longo do tempo, foram desenvolvidos três métodos de detecção de transição que indicam mudanças permanentes no comportamento do compressor e estimam o momento em que essa mudança ocorreu. O conjunto formado por esses processos define a arquitetura de detecção de transição proposta, que é descrito na Seção 3.2.1.

Todos os processos que compõem a arquitetura de detecção de transição requerem alguns parâmetros previamente definidos. Esses parâmetros são divididos em três grupos: os parâmetros de processamento, relacionados ao processamento em janela deslizante no espaço de atraso; os parâmetros de agrupamento, relacionados ao modelo de agrupamento; e os parâmetros de detecção, relacionados à detecção da transição em si. Após o procedimento, esse procedimento irá ou retornar o instante em que a transição ocorreu, ou não retornará instante

algum, indicando que não houve transição ou que a escolha de parâmetros foi inadequada para a tarefa. Da forma como é proposto, esse método só é capaz de detectar transições de ocorrência única, o que não afeta a detecção de amaciamento para regime permanente tribológico, mas deve ser levado em consideração ao aplicar o método em outros contextos.

Escolher uma única combinação de parâmetros de processamento é uma tarefa complexa, já que cada parâmetro não possui necessariamente uma relação clara com os resultados de agrupamento. Em vez de escolher heurísticamente uma combinação de parâmetros de processamento que possa detectar padrões especificamente relacionados à transição do estado de amaciamento para regime permanente, um espaço de parâmetros maior é definido com base em ensaios preliminares com dados experimentais e no período transitório natural de um determinado modelo de compressor. Um modelo de detecção é, então, inicializado para cada combinação de grandeza física e parâmetros de processamento, formando um conjunto de detectores de transição baseados em agrupamento. O espaço de parâmetros e a inicialização do conjunto são detalhadamente descritos na Seção 3.2.2.

Até a inicialização do conjunto de métodos de detecção não são consideradas suposições a priori sobre qual padrão os modelos do conjunto detectariam. Apesar de ser possível que certas combinações de parâmetros detectem a transição de amaciamento para regime permanente tribológico, outras podem detectar diferentes anomalias nos dados ou até mesmo nenhuma transição. Para direcionar o conjunto à detecção da transição desejada, mas ainda assim evitar a introdução de vieses nos resultados, uma etapa de eliminação automatizada de elementos do conjunto, denominada de etapa de poda, foi desenvolvida para eliminar modelos que não atendam a critérios gerais simples, como não detectar transições em ensaios de amaciamento e detectar transições em ensaios de referência. Os critérios concebidos para a poda são descritos na Seção 3.2.3.

Após a poda, tanto as combinações de parâmetros dos modelos remanescentes do conjunto quanto a transição detectada por cada um desses modelos são analisadas. As combinações de parâmetros são empregadas para interpretação de *features*, procurando informações como qual grandeza física resultou no maior número de modelos de detecção válidos e quanto os parâmetros de filtragem e atraso afetaram as detecções de transição. Especialmente em relação aos instantes de transição, os resultados de detecção do conjunto são analisados levando em consideração as conclusões obtidas no processo de interpretação de *features*, fornecendo a probabilidade de regime permanente tribológico para cada instante em um ensaio específico. Os resultados obtidos para validação após a aplicação do método de detecção proposto nos dados experimentais de compressores do modelos A e B são discutidos separadamente na Seção 3.2.4.

3.2.1 Arquitetura de detecção de transição

A arquitetura de detecção de transição foi projetada com o objetivo de detectar transições de ocorrência única em dados de séries temporais, e implementada integralmente me

linguagem Python. Ela recebe como entrada um conjunto de séries temporais, que são medições de uma única grandeza em vários ensaios de longa duração, sendo que o primeiro ensaio é suficientemente longo para conter todo o período de amaciamento. Como saída, a arquitetura proposta estima um instante de transição para cada uma das séries temporais de entrada. Se não for capaz de estimar um instante, ela retorna uma indicação de que o ensaio não continha uma transição.

A arquitetura de detecção de transição é composto por três partes: o processamento das séries temporais para vetores de amostras, realizado a partir de um algoritmo de janela deslizante em espaço de atraso; o algoritmo de agrupamento, que divide os vetores de amostras sub-sequenciados em um número predefinido de grupos; e a detecção de transição em si, que busca por padrões nos dados agrupados com base em regras para transições de ocorrência única. Esses processos são descritos nas seções 3.2.1.1, 3.2.1.2 e 3.2.1.3, respectivamente.

3.2.1.1 Janela deslizante em espaço de atraso


Embora se possa assumir que os padrões relacionados ao amaciamento estejam contidos nas séries temporais, eles ocorrem apenas durante um intervalo finito e desconhecido do ensaio. Por essa razão, o agrupamento não pode ser realizado sobre toda a série temporal, sendo necessário segmentar os dados em subsequências por meio do método de janela deslizante. Portanto, para dividir os dados em subsequências foi empregado o método de janela deslizante. A fim de compreender também as dinâmicas mais lentas nos vetores de amostras, a janela deslizante é executada em um espaço de atraso, tendo como parâmetros o comprimento de janela N e o atraso D . Uma vez que os dados experimentais geralmente contêm ruído, que pode afetar negativamente o resultado do agrupamento, os dados originais das séries temporais também são filtrados com um filtro de média móvel antes do subsequenciamento com janela de filtragem M .

Os vetores de amostra processados, $\hat{x}_m$, podem então ser definidos como:

$$\begin{aligned}\hat{x}_m[k] &= [\hat{x}_m[k], \hat{x}_m[k-D], \hat{x}_m[k-2D], \dots, \hat{x}_m[k-(N-1)D]], \\ \hat{x}_m[k] &= \frac{1}{M} \sum_{j=0}^{M-1} x_m[k-j],\end{aligned}\tag{13}$$

em que $\hat{x}_m[k]$ é o valor filtrado pela média móvel e $x_m[k]$ é a medição de uma grandeza física no instante de tempo tk . A Figura 20 ilustra o processamento dos dados brutos em vetores de observação filtrados. Devido ao pico de corrente de partida e ao período transitório natural em ensaios de compressores (CORAL; FLESCHE; FLESCHE, 2019), apenas os dados adquiridos após a primeira hora de operação são considerados para análise, e $k=1$ é definido como o instante de medição de 1 h. Para valores associados a instantes de tempo em que $k < M$, o comprimento da janela de média móvel é reduzido para k . Além disso, o vetor de amostra $\hat{x}_m[k]$ é definido apenas para $k > (N-1)D$.

Figura 20 – Representação do processo de subsequenciamento de uma série temporal por janela deslizante em espaço de atraso.




Fonte: autor.

Após o subsequenciamento, algumas propriedades específicas surgem no conjunto de dados devido ao sinal original atingir o regime permanente. Uma dessas propriedades é que, à medida que o sinal se aproxima do regime permanente em um dado instante k , o vetor de amostra resultante $\hat{x}_m[k]$ se aproxima da linha de igualdade do espaço N -dimensional, uma vez que em regime permanente $\hat{x}_m[k] \approx \hat{x}_m[k-1] \approx \dots \approx \hat{x}_m[k-(N-1)D]$. Essa propriedade faz com que um grande número de vetores esteja localizado próximo à linha de igualdade, enquanto os pontos relativos às primeiras horas de operação do compressor estão mais dispersos no espaço. Tanto o período transitório natural dos ensaios de compressores quanto o fenômeno de amaciamento ocorrem nessas primeiras horas, sendo que este dura mais tempo do que o primeiro e ocorre apenas no primeiro ensaio de cada unidade. Um exemplo desse aspecto é apresentado na Figura 21, que mostra o conjunto de dados gerado após o processamento dos dados de séries temporais de um ensaio de amaciamento e dois ensaios em regime permanente tribológico de um determinado compressor, quando subsequenciados com parâmetros $N = 2$ e $D = 10$. Os dados apresentados na figura mostram que, após aproximadamente 5 h, os vetores atingem a linha de igualdade (linha tracejada na Figura 21), movendo-se apenas relativamente próximos ao valor de regime permanente em todas as N dimensões após esse período.

3.2.1.2 Agrupamento

Na etapa de agrupamento da arquitetura de detecção de transição, são necessários como parâmetros o método de agrupamento, os centroides iniciais, que para o algoritmo k -médias são inicializados usando o método k -médias++ (ARTHUR; VASSILVITSKII, 2007), e o número de

Figura 21 – Exemplo de conjunto de dados de corrente RMS gerado pelo subsequenciamento de séries temporais de 3 ensaios do mesmo compressor ($N = 2$, $D = 10$).



Fonte: autor.

grupos de agrupamento, k , que nos algoritmos k -médias e *kernel* k -médias deve ser fornecido antecipadamente. Neste trabalho, os grupos são denominados Grupo 1 até Grupo k , em ordem cronológica de aparecimento nos ensaios de amaciamento. Para implementação dos métodos de agrupamento foram utilizadas a classe *KMeans* da biblioteca *scikit-learn* (PEDREGOSA *et al.*, 2011) e a classe *KernelKMeans* da biblioteca *tslearn* (TAVENARD *et al.*, 2020), com a implementação do núcleo FBR-M realizada também em linguagem Python pelo autor.

Os grupos resultantes são, então, analisados, avaliando a capacidade do agrupamento em fornecer indicadores de transições. Para isso, a proporção de grupos em uma determinada janela de tempo é considerada como uma medida da distribuição de grupos ao longo de cada instante de ensaio. Essa proporção p_c de um grupo c em um instante dado k é definida como:


$$p_c[k] = \frac{\text{count}(c, \mathfrak{C}_e[k - W/T_s])}{W/T_s}, \quad (14)$$

em que $\mathfrak{C}_e$ é um vetor contendo os grupos atribuídos a cada observação do ensaio e , W é a janela de proporção em minutos, que necessariamente é um valor múltiplo de T_s , e $\text{count}(c, \mathfrak{C}_e[k - W/T_s])$ é o número de ocorrências de c nos últimos W minutos. Deve-se observar que $p_c[k]$ só é definida para $k > W/T_s$.

A Figura 22 mostra um exemplo de agrupamento pelo método k -médias e a análise da proporção de grupos para a curtose da corrente da Unidade A3, bem como a proporção de grupos para cada hora de ensaio. Nesse agrupamento, processado com $k = 3$, $M = 1$, $N = 5$ e $D = 10$, é possível observar que o Grupo 3 ocorre desde o início dos ensaios nos quais se sabe que o compressor está em estado estacionário tribológico, apresentados na figura como

Referência 1 e Referência 2. No entanto, nos ensaios de amaciamento, o mesmo grupo é identificado apenas após 12 h de ensaio, corroborando as observações preliminares descritas na Seção 3.1.3.

Figura 22 – Agrupamento por k -médias e proporção de grupos: curtose da corrente de uma unidade de compressor, processada com $M = 1$, $N = 5$, e $D = 10$.



Fonte: autor.


Apesar de alguns resultados serem facilmente interpretáveis, a maioria das combinações de parâmetros ou não gera agrupamentos relevantes, ou sugere padrões que não podem ser atribuídos ao fenômeno de amaciamento. Um exemplo de resultado inadequado de agrupamento é apresentado na Figura 23, que mostra o agrupamento de dados da mesma unidade de compressor da Figura 22, ainda com $k = 3$, mas dessa vez com dados de vazão mássica processados com $M = 1$, $N = 5$ e $D = 1$. Nesse caso, nenhum dos grupos apresenta um padrão que se ajuste ao comportamento esperado de amaciamento, com pouca ou nenhuma semelhança entre os ensaios de referência e nenhuma diferença clara entre os ensaios de referência e o agrupamento de amaciamento.

Uma vez que a análise completa de um espaço de busca composto por tantos parâmetros exigiria muito esforço para ser feita manualmente, alguns métodos automáticos foram desenvolvidos para determinar um possível instante de transição de ocorrência única. Esses métodos de detecção de transição são descritos na próxima seção.

3.2.1.3 Detecção de transição

Com base na proporção de grupos em um instante de ensaio específico, três métodos automatizados foram propostos por Thaler (2021) e utilizados neste trabalho, considerando padrões simples desenhados pelo modelo de agrupamento que podem estar relacionados ao

Figura 23 – Agrupamento por k -médias e proporção de grupos: vazão mássica de uma unidade de compressor, processada com $M = 1$, $N = 5$, e $D = 1$.



Fonte: autor.

fim do processo de amaciamento. Esses métodos, implementados em linguagem Python, são descritos abaixo.

Método **I**, denominado método do grupo dominante, define que o instante de transição T é tal que:

$$\begin{aligned} \text{I: } \forall k \in \{W/T_s, \dots, k_f\} \forall j \in \{0; 1, \dots, k_f - k\} \forall i \in \mathcal{C} - \{c\}, \\ T = (\min(t[k])) \parallel p_c[k+j] > p_i[k+j], \end{aligned} \quad (15)$$

em que k_f é o índice do último instante de ensaio, p_c e t são as proporções do grupo e os respectivos instantes de medição, respectivamente, e $\mathcal{C}$ é o conjunto de todos os grupos no ensaio. Em outras palavras, esse método considera que o compressor atinge o regime permanente tribológico quando a proporção de um determinado grupo c nos últimos W minutos é maior do que a proporção de todos os outros grupos. Conceitualmente, esse método considera que a transição para regime permanente é indicada pela prevalência de um único grupo c .

O Método **II**, denominado método do limiar superior, considera que o compressor está em regime permanente tribológico quando a proporção de um determinado grupo c nos últimos W minutos é maior do que um limiar superior l_U . Esse método é baseado na hipótese de que a ocorrência frequente do grupo c pode indicar o fim do período de amaciamento, mesmo que ele não seja o grupo predominante. Dois submétodos derivam desse conceito: o Método **II.a**, definido na Equação (16), que assume que o instante de transição detectado é o primeiro no qual a proporção do grupo excede o limiar; e o Método **II.b**, definido na Equação (17), que assume que o instante de transição é aquele em que a proporção do grupo excede o limiar,

desde que permaneça acima desse valor até o final do ensaio.

$$\begin{aligned} \text{II.a: } l_U &\in [0; 1) \forall k \in \{W/T_s, \dots, k_f\}, \\ T &= \min(t[k]) \parallel p_c[k] > l_U, \end{aligned} \quad (16)$$

$$\begin{aligned} \text{II.b: } l_U &\in [0; 1) \forall k \in \{W/T_s, \dots, k_f\} \forall j \in \{0, 1, \dots, k_f - k\}, \\ T &= \min(t[k]) \parallel p_c[k+j] > l_U. \end{aligned} \quad (17)$$

Por fim, o Método **III**, chamado de método do limiar inferior, assume que a transição ocorre quando a proporção de um determinado grupo c nos últimos W minutos se torna menor do que um limiar l_L . Essa suposição é baseada na hipótese de que a fase final do processo de amaciamento é representada por um único grupo, e à medida que esse grupo se torna menos frequente, o dispositivo entra em regime permanente tribológico. Como acontece com o Método **II**, dois submétodos derivam desse conceito: o Método **III.a**, apresentado na Equação (18), que assume que o instante de transição detectado é o primeiro em que a proporção do grupo é inferior ao limiar; e o Método **III.b**, apresentado na Equação (19), que assume que o instante de transição é aquele em que a proporção do grupo é inferior ao limiar, desde que permaneça abaixo desse valor até o final do ensaio.

$$\begin{aligned} \text{III.a: } l_L &\in (0; 1] \forall k \in \{W/T_s, \dots, k_f\}, \\ T &= \min(t[k]) \parallel p_c[k] < l_L, \end{aligned} \quad (18)$$

$$\begin{aligned} \text{III.b: } l_L &\in (0; 1] \forall k \in \{W/T_s, \dots, k_f\} \forall j \in \{0, 1, \dots, k_f - k\}, \\ T &= \min(t[k]) \parallel p_c[k+j] < l_L. \end{aligned} \quad (19)$$

Todos os métodos utilizados requerem a definição prévia da janela de tempo W e do grupo c antes de sua aplicação. Além disso, os Métodos **II** e **III** requerem que os limiares l_U e l_L , respectivamente, sejam previamente definidos. O algoritmo completo de detecção de transição, desde o processamento dos dados até a detecção em si, é descrito no Algoritmo 1, com os parâmetros M , D , N e W definidos previamente.

3.2.2 Inicialização do conjunto

Para formar um conjunto de modelos de detecção coerentes com o comportamento teórico do processo de amaciamento, um espaço de parâmetros é proposto, e cada combinação de parâmetros nesse espaço resulta em um modelo de detecção de transição diferente. Esse espaço de parâmetros pode ser subdividido em três partes: os parâmetros de processamento, relacionados ao processamento de séries temporais usando a janela deslizante no espaço atrasado; os parâmetros de agrupamento, relacionados aos algoritmos não supervisionados usados para agrupar as séries temporais subamostradas; e os parâmetros de detecção de transição, relacionados ao método usado para detectar transições nos dados agrupados.

O intervalo de parâmetros de processamento M , N e D deve ser definido previamente, sendo que cada combinação de parâmetros dentro do espaço de parâmetros é aplicada para

Algoritmo 1 Algoritmo para detecção de transições em dados de compressor por meio de agrupamento k -médias/*kernel* k -médias

Entradas: dados de ensaios x_i de uma única grandeza e respectivo instante de aquisição t_i , com i variando de 1 a n_c ensaios de uma única unidade de compressor, período de amostragem dos dados de ensaio T_s , janela de filtragem M , comprimento do vetor N , atraso D , algoritmo de agrupamento, número de grupos k , método de detecção de transição, janela de proporção W , grupo de interesse c e limiares l_U ou l_L , dependendo do método de detecção de transição

Saída: instante de transição detectado T_i para cada ensaio i de 1 a n_c

Processamento dos dados:

- 1: **para** $i \leftarrow 1$ **até** n_c **faça**
- 2: Filtrar dados do ensaio i usando filtro de média móvel;
- 3: Aplicar sequenciamento de janela deslizante no espaço de atraso para formar $\hat{x}_{mi}$, conforme proposto na Equação (13);
- 4: Descartar elementos de t_i menores que $(N-1)DT_s$;
- 5: **fim para**
- 6: Concatenar todos os $\hat{x}_{mi}$ em uma única matriz de dimensão $\hat{x}_m L \times N$, em que:

$$L = \sum_{e=1}^{n_c} t_e D(N-1)/T_s$$
, com t_e sendo a duração do e -ésimo ensaio;

Agrupamento e proporções de grupos:

- 7: Agrupar os vetores de amostra em $\hat{x}_m$ usando os algoritmos k -médias ou *kernel* k -médias, para k grupos;
- 8: Dividir o resultado do agrupamento em c_i para cada ensaio i , de acordo com a linha $\hat{x}_{mi}$ correspondente;
- 9: **para** $i \leftarrow 1$ **até** n_c **faça**
- 10: Avaliar a proporção do grupo c individualmente para cada ensaio i como na Equação (14);
- 11: Atualizar t_i para os instantes definidos de p_{c_i} ;
- 12: **fim para**

Detecção de transição:

- 13: **para** $i \leftarrow 1$ **até** n_c **faça**
 - 14: Detectar a transição T_i usando um dos métodos de detecção propostos na Seção 3.2.1.3, com parâmetros W e c , além de l_L ou l_U , quando aplicáveis;
 - 15: Retorna o resultado T_i ;
 - 16: **fim para**
-

cada uma das grandezas possivelmente relacionadas ao fenômeno de amaciamento. Conforme pode ser inferido pela Equação (13), o comprimento de tempo de um dado vetor de amostra é definido como $(N-1)DT_s$, em que T_s é o período de amostragem dos dados. O intervalo escolhido para os parâmetros de processamento deve ser capaz de extrair informações tanto de dinâmicas de curto prazo (valores pequenos de N e D) quanto de longo prazo (valores grandes de N e D). No entanto, como janelas de tempo maiores também aumentam o tempo de inicialização antes que o primeiro vetor de amostra $\hat{x}_m(1)$ seja definido, algumas combinações de parâmetros podem ultrapassar o período transitório dos ensaios, ou até mesmo o período de amaciamento. Para evitar isso, o comprimento máximo de tempo do vetor de amostra deve ser definido com base no período transitório natural do equipamento, que geralmente é conhecido com base no modelo do compressor.

Para o agrupamento dos vetores de amostra, os parâmetros variáveis do conjunto são o algoritmo de agrupamento utilizado e o número de grupos k . Neste trabalho, foram utilizados o algoritmo k -médias clássico; o algoritmo *kernel* k -médias com núcleo FBR; e uma nova proposta de *kernel* k -médias com núcleo FBR adaptado para a distância de Mahalanobis, mas outros métodos de agrupamento também podem ser utilizados.

Quanto ao algoritmo de detecção de transição em si, o espaço de parâmetros contém os métodos de detecção de transição, valores para a janela de proporção W e, quando necessário, um conjunto de limiares I_U e/ou I_L . Uma vez que o conjunto é inicializado com uma combinação de todo o espaço de parâmetros, ele pode conter um grande número de modelos. No entanto, isso não deve afetar negativamente a viabilidade computacional do conjunto, uma vez que os próprios modelos não são computacionalmente caros e a maioria deles não deve produzir resultados significativos. Portanto, para minimizar o viés manual o máximo possível, todos os modelos são considerados na etapa de inicialização do conjunto, sendo podados em seguida com base nos conceitos gerais descritos na Seção 3.2.3.

3.2.3 Poda do conjunto

Com o objetivo de distinguir modelos que resultam em transições de estado significativas de maneira imparcial e automatizada, algumas diretrizes foram definidas com base nos conceitos do fenômeno de amaciamento e na análise preliminar dos dados dos ensaios. Esses critérios são definidos da seguinte forma.

O Critério **C1** estabelece que a condição *regime permanente* deve ser detectada em todos os ensaios. Esse critério foi estabelecido com base na proposição de que todos os ensaios realizados são longos o suficiente para que o compressor alcance o regime permanente tribológico.

O Critério **C2** determina que o instante de transição de *amaciamento* para *regime permanente* nos ensaios de amaciamento deve ocorrer sempre depois do que nos ensaios de referência. Essa proposição deve ser sempre verdadeira para métodos de detecção eficazes, uma vez que o processo de amaciamento ocorre apenas uma vez na vida útil do dispositivo. Mesmo

que a arquitetura de detecção possa associar o estado transitório no início de um ensaio ao período de amaciamento, tal associação não deve interferir na detecção correta nos ensaios de amaciamento.

O Critério **C3** estabelece que, nos ensaios de referência, a transição de estado detectada não deve exceder a duração do transitório natural associado ao assentamento dos ensaios do compressor, que pode levar até 90 min em bancadas de ensaio de compressores (PENZ *et al.*, 2012). Como algumas combinações de parâmetros de processamento podem levar até 4 h desde o início do ensaio para gerar vetores de amostra válidos para o agrupamento, um limite superior de 5 h foi definido para a detecção do instante de transição nos ensaios de referência.

Por fim, o critério **C4** é definido com base em observações preliminares sobre o tempo de assentamento das grandezas. Esse critério não é obrigatório, mas permite a inclusão de limites previamente conhecidos para a detecção da transição. Deve-se notar que esse critério leva em consideração apenas o limite inferior da transição, uma vez que o objetivo deste trabalho é detectar mudanças de comportamento que, se detectáveis, devem ocorrer em instantes semelhantes ou posteriores aos detectados pela análise de especialistas. Um exemplo de tal análise é a apresentada na Seção 3.1.3, que mostra um caso em que o tempo de assentamento das quantidades relacionadas à corrente elétrica durante o amaciamento é distinguível do tempo de assentamento após o fenômeno. Dessa forma, o tempo de assentamento do ensaio de amaciamento define o primeiro instante em que o compressor poderia estar em regime permanente tribológico.

Os critérios propostos podem ser descritos também de forma compacta como:

$$\begin{aligned}
 \mathbf{C1}: & \forall u \in U \forall t_e \in T_e \exists x_m \in \mathbb{R}_+^*, T_{u,t_e} = x_m; \\
 \mathbf{C2}: & \forall u \in U \forall t_e \in T_e : t_e \geq 2, T_{u,1} > T_{u,t_e}; \\
 \mathbf{C3}: & \forall u \in U \forall t_e \in T_e : t_e \geq 2, T_{u,t_e} \leq t_{\text{set}}; \\
 \mathbf{C4}: & \forall u \in U, T_{u,1} \geq \bar{T}_{u,1};
 \end{aligned} \tag{20}$$

em que T_{u,t_e} é o instante de transição detectado do t_e -ésimo ensaio da unidade u , t_{set} é o comprimento do regime transitório natural dos ensaios do compressor, e $\bar{T}_{u,1}$ é o instante de transição para o regime permanente mais cedo possível da unidade u . Se não for possível estimar nenhum $\bar{T}_{u,1}$ na análise preliminar, esse critério não se aplica.

No processo de poda, são eliminados do conjunto todos os elementos que não atenderem a um ou mais dos critérios citados anteriormente. Apesar de o processo ser projetado para lidar com ensaios sem transição, deve haver pelo menos um ensaio no conjunto de dados de cada unidade que contenha uma transição. Além disso, devido à natureza não supervisionada do método e ao grande número de combinações de parâmetros empregados, outros eventos não relacionados ao amaciamento nos ensaios experimentais também podem afetar alguns dos resultados de detecção. Portanto, embora a arquitetura de detecção de transição proposta não exija vários ensaios para produzir resultados, é altamente recomendável inserir ensaios de várias unidades, para que o comportamento anômalo individual de uma determinada unidade

não influencie o processo de poda e, conseqüentemente, os resultados e a análise finais.

Considerando um amplo espaço de parâmetros para a inicialização do conjunto descrito na Seção 3.2.2, o método de poda também pode ser empregado para interpretar quantidades e parâmetros possivelmente relacionados ao processo de amaciamento, analisando o espaço de parâmetros dos modelos restantes no conjunto após a poda. A aplicação dessa análise em alguns dos dados experimentais apresentados na Seção 3.1.2 e os resultados preliminares obtidos são apresentados na Seção 3.2.4.

3.2.4 Resultados

Esta seção apresenta a interpretação dos resultados da aplicação do método proposto na Seção 3.2.1 aos dados de ensaios experimentais apresentados na Seção 3.1.2. A Seção 3.2.4.1 detalha o conjunto final de modelos obtido e os instantes de transição para o regime permanente tribológico detectados pelos modelos. A Seção 3.2.4.2 descreve o processo de interpretação de características, inferindo sobre a relação entre detecção de amaciamento, quantidades físicas e parâmetros de detecção de transição.

3.2.4.1 Transição de amaciamento para regime permanente

A fim de se ajustar ao regime transitório natural do modelo do compressor em ensaios de desempenho, mantendo ao mesmo tempo um baixo custo computacional, o seguinte espaço de parâmetros de processamento foi escolhido:

- $M = \{1; 5; 10; 20; 40; \dots; 180\}$ amostras;
- $N = \{1; 2; \dots; 7\}$ amostras;
- $D = \{1; 3; 5; 10; 20; 40; \dots; 180\}$ amostras.


Também com base no regime transitório e dado que a primeira hora de medições do ensaio não é considerada para essa análise, o comprimento máximo do vetor de amostras foi definido como 3 h. Assim, combinações de parâmetros que resultaram em um tempo maior do que esse limite não foram consideradas na inicialização do conjunto.

O número de grupos k foi definido como 3 para todas as quantidades físicas usando o método *elbow*. Quanto ao algoritmo de detecção de transição em si, o espaço de parâmetros foi definido para a janela W como 30 min, 60 min, 90 min e 120 min; e para o conjunto de limiares l_U como 0; 0,1; ...; 0,9 para o Método II e l_L como 0,1; 0,2; ...; 1 para o Método III.

Nessa análise foram considerados como grandezas a vazão mássica e o valor RMS, a curtose e a variância da corrente elétrica e da vibração nos eixos lateral e longitudinal do compressor. Uma vez que todas as combinações de parâmetros foram consideradas na inicialização do conjunto, a implementação do método resultou em 2656800 resultados de detecção. Após a poda do conjunto com o método descrito na Seção 3.2.3, um total de 1959

combinações foi considerado relevante para unidades do Modelo A, e 1446 combinações para o Modelo B. Uma vez que cada uma dessas combinações resulta em instantes de detecção para as unidades, todos esses resultados podem ser analisados em conjunto. Para avaliar a probabilidade de transição em um determinado instante, a função de densidade de probabilidade (PDF, do inglês *Probability Density Function*) dos resultados foi estimada usando a estimativa de densidade por núcleo, com largura de banda de 0,5 h, definida de acordo com a faixa de erro considerada aceitável para a detecção de transições de amaciamento. A Figura 24 apresenta o histograma (eixos da esquerda) e a PDF estimada (eixos da direita) para as Unidades A1 a A4.

Figura 24 – Histogramas e estimções de PDF das transições de amaciamento para regime permanente detectadas em compressores do Modelo A.




Fonte: autor.

As PDFs estimadas mostram que, para cada unidade do Modelo A, há um instante de transição significativamente mais provável. Além disso, esse instante mais provável de transição coincide com a análise preliminar do valor RMS da corrente, indicando assim que o tempo de acomodação desse valor está provavelmente relacionado à duração do processo de amaciamento.

Na Figura 25, por sua vez, são apresentados os histogramas e PDFs das unidades de compressores do Modelo B. Assim como nas unidades do Modelo A é possível observar que as unidades B1, B3 e B5 apresentaram picos bem definidos, sendo que para essas unidades os picos estão localizados próximos a 10 h. As outras unidades, porém, apresentaram dois ou mais picos, sugerindo que o conjunto detectou múltiplos padrões indicando a transição. Tal

análise também reforça a diferença entre modelos observada na Seção 3.1.3, com frequência de transições detectadas significativas em até 30 h no caso da Unidade B4.

Figura 25 – Histogramas e estimções de PDF das transições de amaciamento para regime permanente detectadas em compressores do Modelo B.



Fonte: autor.


Uma análise mais detalhada dos efeitos das escolhas de grandezas, de parâmetros e de métodos foi possibilitada pela estimativa de probabilidade obtida a partir dos resultados de detecção do conjunto, comparando resultados de diferentes combinações de parâmetros. Essa análise é apresentada na Seção 3.2.4.2.

3.2.4.2 Interpretação de *features*

A Figura 26 apresenta uma visão geral dos parâmetros e das características que resultaram em modelos de detecção possivelmente significativos para o amaciamento. A porcentagem de modelos válidos foi interpretada como um indicador de quão bem um determinado conjunto de parâmetros foi capaz de distinguir padrões nos dados em relação às outras escolhas, visto

que uma percentagem menor significa que menos combinações usando essa escolha eram adequadas ao fenómeno após a poda.

Figura 26 – Algoritmos de agrupamento, grandezas, métodos de detecção de transição e parâmetros de processamento em modelos remanescentes no conjunto após poda.



Fonte: autor.

A análise mostra que a grande maioria dos modelos de detecção válidos utilizou o algoritmo *kernel* k -médias com função FBR-M no caso de compressores do Modelo A. Já no caso dos compressores do Modelo B o resultado foi o inverso, com agrupamentos por k -médias responsáveis por 45% das detecções. A análise também mostra que uma grande percentagem dos modelos aceites foi baseada em grandezas derivadas da corrente elétrica no motor do compressor (97% para o Modelo A e 99% para o Modelo B). As grandezas predominantes foram o valor RMS e a variância da corrente elétrica (I_{RMS} e I_{Var} , respectivamente) da corrente elétrica, com aquela predominando no conjunto treinado para o Modelo A e esta predominando no conjunto do Modelo B. Para o Modelo A, o restante das detecções foi realizado com base na curtose da corrente elétrica I_{Kur} e da vibração no eixo lateral do compressor $v_{Lat,Kur}$, bem como nos dados de vazão mássica $\dot{m}$. Já para o Modelo B, o restante das detecções foi realizado com base no valor RMS e na variância da vibração no eixo lateral do compressor ($v_{Lat,Var}$

e $v_{\text{Lat,Var}}$, respectivamente). Na Figura 26, todas as grandezas relativas à vibração no eixo lateral foram agrupadas sob o símbolo v_{Lat} para melhor visualização.


A influência da escolha da grandeza física no instante de detecção pode ser observada na Figura 27, que apresenta a probabilidade de regime permanente, obtida pela integração da PDF, chamada de função de distribuição cumulativa (CDF, do inglês Cumulative Distribution Function), para as escolhas de parâmetros válidas. Como mostrado, para todas as unidades do Modelo A, os modelos com I_{RMS} e I_{Var} apresentam resultados semelhantes, enquanto os outros modelos mostram resultados consideravelmente divergentes nas Unidades A1 e A4. Também para a Unidade A1, os modelos com I_{Kur} e com $v_{\text{Lat,Kur}}$ só atingiram alta probabilidade (acima de 0,75) de regime permanente por volta de 20 h de ensaio, com o mesmo ocorrendo para os modelos com $\dot{m}$ e com $v_{\text{Lat,Kur}}$ na Unidade A4. Isso sugere que essa escolha pode ser mais adequada para aplicações mais conservadoras. No entanto, dado que esses modelos produziram apenas 3% dos resultados aceitos, eles também podem ser considerados como modelos menos confiáveis, e essa diferença na confiança deve ser levada em consideração ao escolher grandezas para a detecção de amaciamento.

Para as unidades de compressor do Modelo B, observa-se um comportamento mais disperso entre as grandezas avaliadas, com diferenças mais pronunciadas entre as detecções obtidas a partir das variáveis de corrente e de vibração em algumas unidades. As unidades B1 e B2 apresentaram detecções praticamente coincidentes entre I_{RMS} e I_{Var} , indicando boa consistência entre essas grandezas elétricas. Nas demais unidades, entretanto, nota-se maior variação entre as curvas, especialmente para os modelos baseados em vibração lateral ($v_{\text{Lat,RMS}}$ e $v_{\text{Lat,Var}}$), que em alguns casos antecipam a detecção do término do amaciamento em até 15 h em relação às grandezas elétricas, e na Unidade B2 detectam a transição aproximadamente 15 h após as demais. De modo geral, os resultados do Modelo B reforçam a predominância das grandezas derivadas da corrente elétrica como indicadores mais consistentes e robustos, tanto pela menor dispersão temporal observada quanto pela sua estabilidade entre diferentes unidades de compressor.

Ao combinar os parâmetros D e N , é possível avaliar quais comprimentos de janela $((N-1)DT_s)$ foram capazes de produzir a maioria dos modelos válidos. A Figura 28 mostra a frequência de detecções pelo comprimento da janela de amostragem para ambos os modelos de compressores. É possível observar que, enquanto para o Modelo A existe uma frequência maior de detecções em janelas curtas (menor ou igual a 20 min), para o Modelo B a maior parte das detecções ocorre em janelas maiores ou iguais a 80 min. Tal comportamento sugere uma dinâmica mais lenta dos padrões de amaciamento no Modelo B, o que é corroborado pelo fato de que, conforme a Figura 26, o conjunto resultante desses compressores favoreceu parâmetros D , M e N maiores do que no conjunto podado de acordo com os compressores do Modelo A.

A Figura 29 apresenta uma comparação dos resultados de acordo com os três diferentes métodos de agrupamento avaliados. Para as unidades A1, A2 e A3, é possível observar resul-

Figura 27 – Estimativa da probabilidade de regime permanente tribológico, por grandeza




Fonte: autor.

tados próximos entre os métodos *kernel k*-médias com funções FBR e FBR-M, cujas curvas apresentam transições concentradas em intervalos semelhantes de tempo. O método *k*-médias clássico apresenta uma dinâmica similar aos outros métodos ao final desses ensaios, porém no caso da Unidade A1 esse apresenta uma curva menos inclinada do que os demais, sugerindo uma transição mais gradual. Para a Unidade A4, os três métodos apresentam resultados divergentes, com o método *kernel k*-médias com funções FBR finalizando a transição entre 3 h e 5 h após os demais.

Por sua vez, nos compressores do Modelo B é possível observar que, enquanto para as Unidades B1 e B2 os três métodos apresentaram resultados próximos, para as demais o método FBR-M frequentemente produz curvas mais suaves e transições tardias. Tal diferença sugere que o agrupamento com distância de Mahalanobis tende a ser mais conservador em

Figura 28 – Histograma do número de modelos remanescentes no conjunto após poda, pelo tamanho da janela de amostragem.




Fonte: autor.

conjuntos com maior variabilidade, reduzindo a probabilidade de falsos positivos em detecções precoces. Em contrapartida, o método k -médias comum demonstra maior sensibilidade inicial, mas menor consistência entre unidades.

Analisando os métodos de detecção de transição aplicados sobre os dados agrupados, somente os modelos que aplicaram os Métodos **II** e **III** permaneceram após a poda, com o Método **II.a** responsável pela maioria das detecções aceitas no Modelo A (70%) e o Método **III.a** responsável pela maior parte das detecções aceitas no Modelo B (96%). Tais métodos foram então escolhidos como mais adequados para a detecção de amaciamento ao usar como indicadores I_{RMS} e I_{Var} . Quando $\dot{m}$ é usado como indicador, o único método que conseguiu extrair transições válidas foi o Método **III.a**. Usar apenas $\dot{m}$ ou valores derivados da vibração lateral como indicadores deve ser realizado com cautela, pois é menos provável que produzam resultados válidos do que as escolhas anteriormente citadas.

Visto que os conjuntos descritos neste capítulo não podem ser utilizados para avaliação on-line do fenômeno do amaciamento, um método alternativo é proposto na Seção 3.3. Após a implementação desse método, os conjuntos não supervisionados desenvolvidos nesta seção foram utilizados como base comparativa para avaliação dos resultados do método alternativo, que é descrita na Seção 3.4.

Figura 29 – Estimativa da probabilidade de regime permanente tribológico, por método de agrupamento.



Fonte: autor.

3.3 ANÁLISE SEMISSUPERVISIONADA


Conforme descrito anteriormente, o método não supervisionado proposto na Seção 3.2 é uma alternativa válida apenas para identificação off-line do fenômeno do amaciamento, não podendo ser aplicado diretamente na linha de produção. Adicionalmente, a construção em grade do conjunto não supervisionado limita a escalonabilidade do modelo, visto que o número de elementos do conjunto cresce exponencialmente de acordo com a dimensão dos parâmetros de processamento.

De modo a contornar as limitações do conjunto não supervisionado, é proposto nesta seção um método de aprendizado semissupervisionado para identificação não invasiva do fenômeno do amaciamento em compressores. Tal método, baseado em um modelo otimizado de autotreinamento, é apresentado na Seção 3.3.1 junto com a descrição das métricas utilizadas e do procedimento de otimização empregado. Os resultados da aplicação desse método nos dados apresentados na Seção 3.1 são descritos e discutidos na Seção 3.3.2.

3.3.1 Método proposto

A Figura 30 apresenta um diagrama do método proposto para otimização, treinamento e avaliação de modelos semissupervisionados para detecção on-line do amaciamento. O método possui como entradas os dados experimentais e o espaço de busca para a otimização de hiperparâmetros, e a saída do modelo é um classificador binário treinado e avaliado.

Figura 30 – Diagrama do método proposto para o desenvolvimento do modelo semissupervisionado para identificação do amaciamento.



Fonte: autor.

Para a avaliação do método foram utilizados os dados experimentais descritos na Seção 3.1, tal qual para o método descrito na Seção 3.2. No caso do método semissupervisionado, porém, foi incluída uma etapa adicional de rotulação de dados, que foram rotulados para cada unidade de compressor de acordo com as seguintes proposições:

- classe “não amaciado”: dados das primeiras 5 horas do ensaio de amaciamento da unidade;
- sem rótulo, ou “desconhecido”: dados entre 5 horas e o fim do ensaio de amaciamento da unidade;

- classe “amaciado”: dados dos ensaios de referência, já com a unidade amaciada.

Uma unidade de cada modelo de compressor foi separada para teste do classificador, e, portanto, não foi utilizada nem na otimização de hiperparâmetros nem na etapa de treinamento. As unidades de teste foram escolhidas aleatoriamente, com as unidades A2 e B3 selecionadas, respectivamente, como teste do Modelo A e do Modelo B.

Assim como no modelo não supervisionado, as seguintes *features* temporais foram extraídas dos dados da vibração e da corrente elétrica do motor: curtose, variância e valor RMS. Tais *features* foram subsequenciadas utilizando o mesmo processamento por janela deslizante em espaço de atraso descrito na Seção 3.2.1.1. A escolha de *feature* e os parâmetros de processamento foram otimizados juntamente com os hiperparâmetros do classificador e do modelo semissupervisionado, e o espaço de busca considerado é apresentado no Quadro 2.

Em comparação com o espaço de parâmetros utilizado na construção do conjunto não supervisionado, descrito na Seção 3.2.4.1, destacam-se algumas diferenças:

- o limite superior do número de *features* N foi aumentado para 150 amostras, visto que o modelo semissupervisionado não está sujeito às limitações dimensionais do conjunto não supervisionado;
- existe um desbalanceamento significativo entre as classes “amaciado” e “não amaciado”, visto que cada unidade é rotulada com pelo menos 40 h de dados “amaciado”, em contraste com apenas 5 h “não amaciado”. Assim, foi incluída no processo de otimização a possibilidade de subamostragem aleatória da classe majoritária, de modo que o conjunto de treino possua a mesma quantidade de dados de ambas as classes (YANG *et al.*, 2024);
- foi incluída na otimização a possibilidade de redução de dimensionalidade por Análise de Componentes Principais (ACP). Essa técnica estatística busca uma transformação linear que concentre a variância do conjunto de dados em poucas dimensões, transformando variáveis possivelmente correlacionadas em um novo conjunto de variáveis ortogonais chamadas componentes principais. Uma vez realizada a transformação, o conjunto de dados pode ser representado em um espaço de menor dimensão, preservando a maior variabilidade possível e reduzindo redundâncias, o que tende a simplificar o processo de treinamento dos modelos e a mitigar problemas relacionados à multicolinearidade (GREENACRE *et al.*, 2022). Quando a ACP é selecionada pelo otimizador, é possível também definir o número de componentes principais, que pode ser escolhido entre 1, restando apenas a dimensão com maior variância, até N , quando a dimensão do conjunto é a mesma após o processamento, porém sem colinearidade entre *features*.

Além dos parâmetros de préprocessamento, também foi definido um espaço de busca para o limiar de inclusão no autotreinamento. Como descrito na Seção 2.3, esse limiar define a confiança mínima de classificação necessária para que uma dada observação seja pseudorrotulada e utilizada na próxima iteração de treino do modelo de autotreinamento.

Quadro 2 – Parâmetros de processamento e intervalos utilizados na otimização.

Parâmetro	Intervalo	Tipo
Grandeza utilizada	Mesmas que Seção 3.2	Categórico
Janela de médias móveis (M)	[1; 180]	Inteiro
Número de <i>features</i> (N)	[1; 150]	Inteiro
Atraso entre amostras (D)	[1; atraso máx. ³]	Inteiro
Balanceamento de classes	{subamostragem, nenhum}	Categórico
Redução de dimensionalidade ACP	{sim, não}	Categórico
Número de componentes ACP	[1; N] (apenas se ACP=sim)	Inteiro
Limiar de decisão do autotreinamento	[0,05; 0,99]	Real

Dadas as limitações do autotreinamento, foram escolhidos para este trabalho classificadores que possuam a capacidade de retornar não apenas a classificação das observações, mas também uma estimativa da confiabilidade da classificação, utilizada para o pseudorrotulamento dos dados. Foram utilizados neste trabalho as implementações de classificadores da biblioteca *sklearn*, bem como a implementação dessa biblioteca para autotreinamento (PEDREGOSA *et al.*, 2011). O Quadro 3 apresenta os classificadores, bem como o espaço de busca de hiperparâmetros. O espaço de busca para cada modelo foi definido heurísticamente, tendo em vista as limitações computacionais do equipamento utilizado.

Dado o desbalanceamento de classes descrito anteriormente, métricas globais como a exatidão, que representa a proporção de casos corretamente previstos, possuem uma tendência inerente à classe majoritária (GUO *et al.*, 2017). Para conjuntos desbalanceados, existem métricas menos sujeitas a essa tendência, como a área abaixo da curva de característica de operação do receptor (ROC, do inglês *Receiver Operating Characteristics*), também chamada de AUC (do inglês *Area Under the ROC Curve*), o F -score e o Coeficiente de Correlação de Matthews (CCM) (GUO *et al.*, 2017). Para selecionar uma métrica para aplicação neste trabalho, foi realizado um estudo preliminar, considerando a capacidade de um classificador do tipo floresta aleatória de replicar os resultados apresentados na Seção 3.2.4.

O estudo desenvolvido como parte desta pesquisa e publicado em Thaler *et al.* (2022) apontou o CCM como o mais adequado para a aplicação em avaliação do amaciamento. Assim, essa métrica, representada como $\mathfrak{M}$, foi também escolhida para o modelo semissupervisionado, sendo definida por:

$$\mathfrak{M} = \frac{N_{TP}N_{TN} - N_{FP}N_{FN}}{\sqrt{(N_{TP} + N_{FN})(N_{TP} + N_{FP})(N_{TN} + N_{FP})(N_{TN} + N_{FN})}},$$

com N_{TP} sendo o número de verdadeiros positivos da classificação, N_{TN} , o número de verdadeiros negativos, N_{FP} , o de falsos positivos e N_{FN} , o de falsos negativos. Esse coeficiente é uma aplicação do coeficiente phi para classificadores, correlacionando a classe real com a classe

³ O atraso máximo é definido com base em N de modo que o comprimento da janela não ultrapasse 180 min, tal qual descrito na Seção 3.2.2.

Quadro 3 – Classificadores e intervalos de hiperparâmetros utilizados na otimização.

Classificador	Hiperparâmetro	Intervalo	Tipo
Regressão logística	Parâmetro de regularização	$[10^{-4}; 10^2]$	Real
	Nº máx. de iterações	1000	Fixo
Árvore de decisão	Profundidade máx.	[3; 50]	Inteiro
	Nº mín. de amostras para divisão	[2; 200]	Inteiro
	Nº mín. de amostras por folha	[1; 100]	Inteiro
	Nº máx. de atributos considerados	{sqrt, log2, sem limite}	Categórico
K Vizinhos Mais Próximos (K-VMP)	Nº de vizinhos	[3; 100]	Inteiro
	Peso da distância	{uniforme, distância}	Categórico
	Métrica de distância	{euclideana, Manhattan, Minkowski}	Categórico
	Parâmetro da distância Minkowski	{1; 2; 3} (apenas se Minkowski)	Inteiro
MVS Linear	Parâmetro de regularização	$[10^{-5}; 10^3]$	Real
	Nº máx. de iterações	5000	Fixo
MVS com núcleo FBR (MVS-FBR)	Parâmetro de regularização	$[10^{-5}; 10^3]$	Real
	Largura do núcleo	$[10^{-10}; 10^1]$	Real
	Nº máx. de iterações	5000	Fixo
Floresta aleatória	Nº de árvores	[10; 200]	Inteiro
	Profundidade máx.	[3; 20]	Inteiro
	Nº mín. de amostras para divisão	[2; 20]	Inteiro
	Nº mín. de amostras por folha	[1; 10]	Inteiro
	Nº máx. de atributos considerados	{sqrt, log2, sem limite}	Categórico
	Uso de amostragem <i>bootstrap</i>	{sim, não}	Categórico
PMC	Nº de camadas ocultas	[1; 3]	Inteiro
	Neurônios por camada	[10; 200]	Inteiro
	Função de ativação	{ReLU, tanh, logística}	Categórico
	Tx. de aprendizado	$[10^{-6}; 10^{-2}]$	Real
	Estratégia de tx. de aprendizado	{constante, invscaling, adaptativo}	Categórico
	Nº máx. de iterações	600	Fixo
AdaBoost	Nº de estimadores	[10; 200]	Inteiro
	Tx. de aprendizado	[0,01; 2,00]	Real
Bayes ingênuo	Suavização da variância	$[10^{-12}; 10^{-6}]$	Real
Análise Discriminante Quadrática (ADQ)	Parâmetro de regularização	[0; 1]	Real

predita (MATTHEWS, 1975), resultando em um valor entre $[-1;1]$, em ordem crescente de desempenho (CHICCO; JURMAN, 2020). Nota-se que existem quatro singularidades possíveis no cálculo do CCM:

- todas as observações são da classe positiva ($N_{TN} = N_{FP} = 0$);
- todas as observações são da classe negativa ($N_{TP} = N_{FN} = 0$);
- todos os resultados classificados como positivos ($N_{TN} = N_{FN} = 0$);
- todos os resultados classificados como negativos ($N_{TP} = N_{FP} = 0$).


As duas primeiras singularidades podem ser evitadas uma vez que se garanta que o conjunto de dados utilizado para avaliação contenha ambas as classes. As condições restantes, porém, dependem da capacidade do modelo de classificar observações em mais do que uma classe, e não podem ser garantidas a priori. Assim, de modo a evitar a instabilidade numérica de análises futuras, estabeleceu-se uma condição de que, se todos os dados são classificados em uma única classe, o CCM é dado como zero.

Além do CCM como métrica final para avaliação do modelo, a utilização do autotreinamento também permite a extração de métricas baseadas no pseudorrotulamento do conjunto de treino. Neste trabalho, considerando desejável que um modelo seja capaz de classificar o máximo de dados ainda nas iterações de treino, foi incluída também a métrica da proporção de dados classificados ao fim do autotreinamento, com o objetivo do otimizador sendo a maximização de ambas as métricas.

O procedimento de otimização realizado para cada modelo de classificador é apresentado na Figura 31. Para otimização multiobjetivo (CCM e proporção de dados classificados ao fim do autotreinamento) foi escolhido o algoritmo genético de ordenação não dominada II (NSGA-II, do inglês *Non-dominated Sorting Genetic Algorithm II*), que é um algoritmo evolucionário multiobjetivo que combina ordenação não dominada, medida de diversidade e elitismo para obter uma aproximação da Fronteira de Pareto (FP). Neste trabalho foi utilizada para otimização a biblioteca Optuna, desenvolvida em linguagem Python, com população de 50 indivíduos, probabilidade de mutação de 10 % e probabilidade de *crossover* de 90% (OZAKI; WATANABE; YANASE, 2025). A FP, por sua vez, é o conjunto das soluções de um problema de otimização multiobjetivo que não são dominadas por nenhuma outra, ou seja, não é possível melhorar um objetivo sem piorar ao menos um dos demais.

Assim, a cada iteração do otimizador, é sugerido um novo conjunto de parâmetros, que são utilizados para realizar o processamento do conjunto de treino. Esses dados são separados por unidade de compressor para validação cruzada, de modo que, para um conjunto de treino composto por n_U , são realizadas n_U dobras de treino e validação, com 1 unidade diferente para validação e $n_U - 1$ para treino para cada dobra. De cada dobra, são extraídos o CCM da validação e a proporção de dados rotulados no autotreinamento, e o resultado da iteração de validação cruzada é a média geométrica de cada uma das métricas.

Figura 31 – Diagrama do procedimento de otimização multi-objetivo e seleção de modelos baseado em avanço da FP.



Fonte: autor.

Foram definidos dois possíveis critérios para o término do processo de otimização:

- número de iterações desde o último avanço da FP (GUTIERREZ; ADAMATTI; BRAVO, 2019);
- número total de iterações.

Os limites de iteração foram definidos heurísticamente, sendo definido um máximo de 200 iterações sem avanço da FP, e de 300000 iterações totais.

Por fim, os modelos com melhor CCM de cada classificador foram selecionados para avaliação com conjunto de teste. O teste dos modelos foi realizado considerando apenas os dados já rotulados da unidade de compressor de teste (primeiras 5 h com a classe “não amaciado” e ensaios de referência com a classe “amaciado”), sobre os quais foi calculado o CCM.

O procedimento proposto foi então aplicado para cada um dos classificadores do Quadro 3 utilizando os dados experimentais de amaciamento. Os resultados obtidos são apresentados a seguir, na Seção 3.3.2

3.3.2 Resultados

Esta seção apresenta os resultados da aplicação do método semissupervisionado descrito na Seção 3.3.1 em dados experimentais de amaciamento em compressores (descritos na Seção 3.1). Tais resultados são divididos em duas partes: os resultados do processo de otimização multi-objetivo, apresentados na Seção 3.3.2.1; e os resultados da detecção do amaciamento

ao longo do tempo, considerando os melhores modelos da otimização, que por sua vez são apresentados na Seção 3.3.2.2.

3.3.2.1 Otimização

A Tabela 2 apresenta o número de iterações realizadas para cada modelo, considerando 3 diferentes conjuntos de dados: apenas compressores do Modelo A, apenas compressores do Modelo B e ambos os modelos de compressores. Foi realizada uma inicialização do algoritmo NSGA-II para cada modelo de compressor e de classificador. As células destacadas em vermelho indicam que o processo de otimização não pode ser completado para aquele classificador, por limitação de memória disponível no caso de MVS-FBR, e limitações de tempo de otimização nos demais casos. Ambos os problemas observados são decorrentes do aumento de observações com a inclusão de compressores do Modelo B, que possui mais unidades ensaiadas e ensaios mais longos. Nesses casos, foi considerada a FP das iterações realizadas, mesmo que os modelos resultantes sejam subótimos. Fora os classificadores destacados, todos os modelos atingiram o critério de parada por estagnação da FP.

Tabela 2 – Número total de iterações de otimização realizadas para cada classificador.


Classificador	Iterações de otimização realizadas		
	Modelo A	Modelo B	Ambos modelos
Regressão logística	259512	134109	5516
Árvore de decisão	7729	6744	778
K-VMP	116775	21777	13077
MVS linear	20146	1155	1472
MVS-FBR	5067	2149	11
Floresta aleatória	3000	4587	100
PMC	4047	1282	91
AdaBoost	2134	3839	900
Bayes ingênuo	2127	1039	1947
ADQ	9265	1138	3617

Na Figura 32 são apresentadas as FPs da otimização de classificadores com compressores do Modelo A. A fim de facilitar a visualização das FPs, os classificadores foram divididos em três grupos:

- (a): modelos lineares e estatísticos - regressão logística, MVS linear, Bayes ingênuo e ADQ;
- (b): modelos baseados em árvore - árvore de decisão, floresta aleatória e AdaBoost;
- (c): outros modelos - K-VMP, MVS-FBR e PMC.

É possível inferir a partir da Figura 32 que a regressão logística apresentou o melhor CCM, porém ao custo de menor proporção do conjunto de treino rotuladas (26% no pior caso). O restante das FPs do grupo (a) foi dominado pela regressão logística, isto é, foi inferior às demais

Figura 32 – FP do processo de otimização considerando compressores do Modelo A: (a) modelos lineares e estatísticos, (b) modelos baseados em árvore, e (c) outros modelos.




Fonte: autor.

tanto em CCM quanto em proporção de observações rotuladas, com exceção da MVS linear, que apresentou alta proporção de observações rotuladas (mais de 90%) com menos penalidade ao CCM. Dentre os modelos do grupo (b), boa parte da FP de árvore de decisão foi dominada pelos outros modelos, enquanto os três modelos do grupo (c) apresentaram desempenho similar entre si. A Figura 33 apresenta um panorama geral da FP para a otimização com compressores do Modelo A, destacando uma FP com os modelos não dominados. Destacam-se nos extremos da FP os classificadores por regressão logística, com alto CCM e baixa capacidade de rotulação do conjunto de treino, e os classificadores K-VMP, com o desempenho inverso. Também se destaca o desempenho equilibrado do classificador MVS linear, próximo aos melhores modelos considerando ambas as métricas.

Para análise do desempenho dos classificadores na unidade de compressor para teste foi selecionada, para cada tipo de classificador, a combinação de parâmetros que resultou no maior CCM de validação, visto que essa métrica é mais representativa da capacidade do modelo de classificação correta dos dados. Os hiperparâmetros desses modelos não são discutidos nesta seção por questão de brevidade, mas podem ser consultados no Apêndice A. A Figura 34 apresenta uma comparação das métricas obtidas na validação, treino e teste dos modelos. É possível observar que a proporção de dados classificados em validação foi próxima da proporção de treino em todos os modelos, e que muitos modelos apresentaram CCM de treino ainda considerável forte (maior do que 0,7, segundo Ratner (2009)). O CCM de teste, por outro lado, foi próximo de zero para todos os classificadores, sugerindo que nenhum dos modelos foi capaz de classificar o conjunto de teste. Uma discussão mais aprofundada desses resultados é apresentada na Seção 3.3.2.2, juntamente com uma análise temporal dos resultados de treino

Figura 33 – FP dos classificadores dominantes considerando compressores do Modelo A.



Fonte: autor.


e de teste.

A Figura 35 apresenta a FP dos classificadores otimizados para compressores do Modelo B. Todos os classificadores foram capazes de rotular uma grande proporção dos dados de treino (maior que 90%), mas nenhum dos modelos avaliados atingiu um CCM que pudesse ser considerado forte (maior do que 0,7). Os classificadores por regressão logística e por floresta aleatória apresentaram os resultados mais bem equilibrados, com boas proporções rotuladas e os maiores CCMs dentre os modelos avaliados. Nota-se também a alta densidade de resultados próximos uns aos outros para classificadores regressão logística e ADQ, atribuídos à inicialização única do otimizador NSGA-II.

Comparando a FP de todos os modelos, os sete modelos da FP dos classificadores de regressão logística dominaram todos os outros classificadores, tanto em proporção de observações rotuladas como em CCM. A Figura 36 ressalta essa dominância, destacando os valores da FP dos classificadores de regressão logística.


A Figura 37 apresenta as métricas de desempenho do modelo com maior CCM de cada classificador otimizado, cujos hiperparâmetros podem ser consultados no Apêndice A. Assim como no Modelo A, a proporção de observações rotuladas foi similar nos processos de validação e de treino para todos os classificadores. Porém, em contraste aos classificadores do Modelo A apresentados anteriormente, a maioria dos classificadores do Modelo B apresentou um forte CCM no conjunto de teste, sendo até maior que o CCM de treino e de validação no caso dos classificadores Bayes ingênuo, ADQ, árvore de decisão, floresta aleatória, AdaBoost e PMC. Dentre esses classificadores, destacam-se os modelos Bayes ingênuo, floresta aleatória e AdaBoost, que classificaram perfeitamente a parte rotulada do conjunto de testes. Pode-se observar também que o modelo de regressão logística, cuja FP dominou todos os outros

Figura 34 – Desempenho dos classificadores treinados com o Modelo A com maior CCM em validação cruzada.




Fonte: autor.

Figura 35 – FP do processo de otimização considerando compressores do Modelo B: (a) modelos lineares e estatísticos, (b) modelos baseados em árvore, e (c) outros modelos.



Fonte: autor.

Figura 36 – FP dos classificadores dominantes considerando compressores do Modelo B.



Fonte: autor.


modelos, obtive o pior CCM de treino e de teste por classificar todas as observações com a mesma classe, conforme detalhado posteriormente na Seção 3.3.2.2.

Por fim, foi realizada a otimização dos classificadores utilizando ambos os modelos de compressores, e a Figura 38 apresenta as FPs resultantes desse processo. Todos os classificadores apresentaram CCM abaixo de 0,5, sugerindo baixa capacidade de classificação correta. Tais resultados reforçam as observações descritas na Seção 3.1, sugerindo que o comportamento de amaciamento é significativamente diferente entre modelos de compressores, de modo que o aumento na quantidade e na variedade de dados com a adição de mais modelos não é refletido em uma melhora na capacidade de classificação dos modelos. Assim como para o Modelo B, nota-se uma alta concentração de resultados para alguns modelos, tais como ADQ e MVS linear, também atribuídos à inicialização única do otimizador NSGA-II. Destaca-se também que, conforme apresentado na Tabela 2, o desempenho dos classificadores de MVS-FBR, K-VMP, floresta aleatória, PMC e AdaBoost não necessariamente é representativo da capacidade de classificação desses modelos, visto que não foi possível realizar um número de iterações de otimização suficiente para atender aos critérios de otimização propostos.

A Figura 39 apresenta a FP considerando todos os modelos classificadores. Mesmo com número reduzido de iterações realizadas, o modelo de K-VMP figura entre os modelos dominantes, juntamente com os classificadores ADQ e MVS linear. Nesse caso, o maior CCM foi obtido com classificadores ADQ, sugerindo que esse classificador pode ser potencialmente superior aos demais em termos de generalização para diferentes modelos de compressores. Ainda assim, vale notar que o CCM máximo de validação observado ainda é menor do que o observado com o treinamento individual dos modelos.


A Figura 40 apresenta as métricas de desempenho dos classificadores com maior CCM

Figura 37 – Desempenho dos classificadores treinados com o Modelo B com maior CCM em validação cruzada.




Fonte: autor.

Figura 38 – FP do processo de otimização considerando ambos os modelos de compressor: (a) modelos lineares e estatísticos, (b) modelos baseados em árvore, e (c) outros modelos.



Fonte: autor.

Figura 39 – FP dos classificadores dominantes considerando compressores de ambos modelos.



Fonte: autor.

em validação cruzada. Nota-se que o único resultado com CCM maior que 0,7 foi obtido no conjunto de treino pelo classificador de floresta aleatória, que resultou em CCM próximo a 0,8. Todos os outros modelos apresentaram CCM inferior a 0,5, chegando a $-0,2$ no caso do classificador MVS linear. Os parâmetros desses modelos podem ser consultados no Apêndice A.


Os modelos com melhor CCM de cada classificador foram também avaliados ao longo do tempo, tal qual a análise realizada com o conjunto não supervisionado na Seção 3.2.4.1. Essas análises complementam as métricas gerais discutidas nesta seção, e são apresentadas na Seção 3.3.2.2.

3.3.2.2 Identificação de amaciamento

Buscando emular a identificação on-line do fenômeno do amaciamento, os classificadores com melhor CCM dentre os modelos otimizados descritos na Seção 3.3.2.1 foram aplicados de forma temporal nos dados de amaciamento. Assim, para cada nova observação ao longo do tempo, os classificadores fornecem uma estimativa de classe, bem como uma métrica da confiabilidade da decisão. Essa métrica é chamada nesta seção de probabilidade de amaciamento, e equivale à confiança com a qual um dado classificador estima a observação como “amaciado”, com 0% indicando confiança total de que a observação pertence à classe “não amaciado”, e 100% indicando confiança total na classificação como “amaciado”. De modo a suavizar a resposta dos classificadores, os resultados apresentados nesta seção também foram processados com um filtro de médias móveis de 20 amostras alinhado à direita, de modo a ser implementável em aplicações reais.

A Figura 41 apresenta os resultados dos métodos treinados com dados apenas de compressores do Modelo A. São apresentados na figura apenas os ensaios de amaciamento,

Figura 40 – Desempenho dos classificadores treinados com ambos os modelos com maior CCM em validação cruzada.



Fonte: autor.


que são o foco deste trabalho, com a área marcada com fundo cinza indicando o período rotulado a priori como “não amaciado” (duração de ensaio inferior a 5 h).

As curvas de estimação do amaciamento corroboram as métricas apresentadas na Figura 34, destacando classificações condizentes das unidades utilizadas para autotreinamento dos modelos (com a exceção da Unidade A3, na qual apenas o modelo por K-VMP apresentou resultados condizente), enquanto todas as observações da unidade de teste foram classificadas como “amaciado”. Duas hipóteses principais são consideradas como possíveis causas desse comportamento:

1. sobreajuste do classificador;
2. conjunto de teste não representado no conjunto de treino.

Dentre as possíveis causas para o comportamento observado, considera-se que a baixa diversidade de dados no conjunto de treino seja o principal fator determinante, já que a validação cruzada por compressor naturalmente favorece modelos mais generalistas que consigam classificar adequadamente um compressor com base nos dados das outras unidades. No caso do Modelo A, o conjunto de treino é composto por apenas três unidades, o que restringe a variabilidade das condições operacionais e tribológicas representadas durante o aprendizado.

Figura 41 – Amaciamento ao longo do tempo de acordo com autotreinamento e diferentes classificadores, com base em dados de compressores do Modelo A.




Fonte: autor.

Além disso, como discutido na Seção 3.1, as análises preliminares indicaram diferenças significativas entre as unidades quanto ao tempo de assentamento e à dinâmica das *features* extraídas, sugerindo que os classificadores podem ter se ajustado a padrões específicos dessas unidades em vez de caracterizar o fenômeno de amaciamento de forma geral.

A hipótese de que o desempenho dos classificadores está relacionado à diversidade do conjunto de treino é reforçada também pelos resultados observados com o treino utilizando compressores do Modelo B, apresentado na Figura 42, cujo conjunto de treino possui 5 unidades. Nesse caso, observa-se uma resposta condizente no conjunto de teste para a maioria dos classificadores, com a exceção da regressão logística, que classifica todas as observações como próximas de 60% do amaciamento, e do K-VMP, que atribui 100% de amaciamento ainda na segunda hora de ensaio. Dentre as unidades de treino, observa-se nas Unidades B1 e B6 uma classificação pouco condizente com o fenômeno do amaciamento, já que os modelos atribuem grande probabilidade de amaciamento também logo no início do ensaio, possivelmente em razão de características individuais dessas unidades. A Unidade B1, em especial, foi a unidade que apresentou o menor ruído experimental e o assentamento mais suave na análise preliminar descrita na Seção 3.1, reforçando o impacto das diferenças entre unidades no treinamento dos modelos. Quanto à unidade de teste, a Unidade B3, observou-se nesse caso uma classificação mais condizente com a transição esperada para a grande maioria dos classificadores, com o ensaio iniciando próximo a 0% de probabilidade de amaciamento e terminando próximo a 100%.

Figura 42 – Amaciamento ao longo do tempo de acordo com autotreinamento e diferentes classificadores, com base em dados de compressores do Modelo B.



Fonte: autor.


Por fim, a Figura 43 apresenta a probabilidade ao longo do tempo para classificadores otimizados com unidades de ambos os modelos de compressores. Nesse caso, observou-se que, enquanto alguns classificadores como árvore de decisão, floresta aleatória e MVS-FBR apresentaram mudanças bruscas na classificação, outros modelos como regressão logística, AdaBoost e MVS linear apresentaram uma resposta próxima de constante para a maioria das unidades.

Como análise geral da progressão temporal das classificações, foram definidas duas métricas:

- unidades com transição: proporção de unidades nas quais há alternância entre não amaciado (probabilidade de “amaciado” menor do que 50%) e amaciado (probabilidade de “amaciado” maior do que 50%);
- unidades com progressão: proporção de unidades nas quais pelas primeiras 5 h o ensaio é estimado como não-amaciado, e o último instante de ensaio é estimado como amaciado.

A Tabela 3 apresenta um comparativo das métricas temporais para cada um dos modelos otimizados, com os melhores resultados de cada métrica destacados em negrito. O

Figura 43 – Amaciamento ao longo do tempo de acordo com autotreinamento e diferentes classificadores, com base em dados de compressores de ambos modelos.



Fonte: autor.

único modelo que apresentou transições para todas as unidades foi o modelo treinado com MVS-FBR, que também apresentou alta proporção de modelos com progressão condizente com o fenômeno do amaciamento (80% das unidades). Os resultados desse classificador, porém, não foram refletidos quando treinado individualmente com unidades do Modelo A, sugerindo que a otimização e o treinamento das MVS-FBR requerem uma maior variedade de dados para que possam obter resultados condizentes. Por outro lado, os modelos de floresta aleatória apresentaram a maior proporção de resultados de estimacão condizentes com o fenômeno do amaciamento para todos os casos: 50% quando treinado com unidades do Modelo A, 50% com o Modelo B, junto com os classificadores AdaBoost, Bayes ingênuo e MVS-FBR, e 80% com ambos os modelos, tal qual o classificador MVS-FBR.

Tabela 3 – Proporção de transição e progressão por classificador e modelo de compressor utilizado na otimização.

Classificador	Modelo A		Modelo B		Ambos modelos	
	Trans. [%]	Prog. [%]	Trans. [%]	Prog. [%]	Trans. [%]	Prog. [%]
ADQ	25	0	33	33	0	0
AdaBoost	75	25	50	50	10	0
Bayes ingênuo	25	0	50	50	20	0
Floresta aleatória	50	50	50	50	90	80
K-VMP	50	25	17	17	80	10
PMC	25	0	33	33	0	0
MVS-FBR	50	0	50	50	100	80
MVS linear	25	0	67	33	0	0
Regressão logística	25	0	0	0	10	0
Árvore de decisão	75	25	50	33	80	60

Tendo em vista tanto as análises de métricas de otimização descritas na Seção 3.3.2.1 quanto as análises temporais descritas nesta seção, conclui-se que o classificador mais adequado para identificação do amaciamento em compressores herméticos alternativos é o modelo de floresta aleatória. Ainda assim, destaca-se que outros modelos, em especial o MVS-FBR, apresentaram desempenho similar com maior variedade de dados e também se mostram promissores para análises futuras após mais ensaios com diferentes unidades e modelos de compressores.

Uma vez que o método semissupervisionado de classificação foi validado experimentalmente, propõe-se também uma comparação desse com a abordagem não supervisionada, apresentada anteriormente na Seção 3.2. Essa análise foi realizada considerando os resultados temporais dos modelos apresentados nesta seção e é descrita a seguir, na Seção 3.4.

3.4 COMPARAÇÃO ENTRE ABORDAGENS

Esta seção apresenta a comparação entre o método baseado em conjunto não supervisionado descrito na Seção 3.2 e o método baseado em classificadores com autotreinamento descrito na Seção 3.3 para avaliação do processo de amaciamento. O principal objetivo da

análise é avaliar a capacidade dos classificadores de replicar de forma on-line os resultados do conjunto não supervisionado, que opera apenas de forma off-line.

A Tabela 4 apresenta o Erro Médio Absoluto (EAM) da probabilidade de amaciamento, em valor percentual, entre os métodos propostos para os modelos de compressores avaliados. As colunas marcadas com a letra "I" indicam que o autotreinamento foi realizado considerando apenas o respectivo compressor, e as colunas marcadas com a letra "A" indicam que o autotreinamento foi realizado considerando ambos os modelos de compressores. É possível observar que o classificador de floresta aleatória apresentou menor EAM em todos os casos, com o menor erro identificado nas unidades do Modelo B, quando treinado apenas com compressores do mesmo modelo. Esse resultado é condizente com as análises realizadas na Seção 3.3.2, nas quais os modelos de floresta aleatória figuraram entre os modelos com melhores métricas e mostraram os perfis de detecção mais condizentes com o fenômeno do amaciamento. Observa-se, também, que a classificação média do Modelo A foi mais do que 10% pior do que a do Modelo B, e que a melhor classificação do Modelo A foi resultado do autotreinamento com unidades de ambos os modelos. Tais observações sugerem que a maior quantidade e variedade de dados no conjunto favorece a classificação desse modelo e que o número atual de ensaios com o Modelo A pode não ser suficiente para o treinamento adequado dos métodos. Uma avaliação do erro individual para cada unidade de compressor ensaiada é apresentada no Apêndice B deste trabalho.


Tabela 4 – EAM, em valor percentual, por classificador e modelo de compressor.

Classificador	Modelo A		Modelo B		Ambos modelos
	I	A	I	A	
Regressão logística	36,99	27,49	33,73	16,39	20,83
MVS linear	45,34	28,65	34,76	19,83	23,36
Bayes ingênuo	43,69	59,12	28,15	76,36	69,47
ADQ	41,23	30,31	13,84	29,53	29,84
Árvore de decisão	34,29	27,03	13,79	19,02	22,23
Floresta aleatória	31,85	26,35	12,53	14,29	19,12
AdaBoost	39,06	31,53	19,88	29,68	30,42
K-VMP	38,15	40,18	17,71	47,53	44,59
MVS FBR	40,07	37,21	32,16	20,12	26,96
PMC	40,12	46,04	15,40	41,51	43,32

As Figuras 44 e 45 mostram a comparação entre a probabilidade de regime permanente estimada pela floresta aleatória treinada com os modelos A e B, respectivamente, e as detecções obtidas pelo conjunto não supervisionado. Para o Modelo A, apesar de todas as detecções por floresta aleatória terminarem o ensaio indicando o fim do amaciamento, observa-se um comportamento extremo dos classificadores, que indicam abruptamente o amaciamento ou nas primeiras horas de ensaio (Unidades A2 e A3) ou nas últimas (Unidades A1 e A4). Para o Modelo B, apesar de também ocorrerem detecções antecipadas nas Unidades B1, B4 e

B6, os resultados das Unidades B2, B3 e B5 foram próximos, com menos de 3 h entre o regime permanente pela floresta aleatória e pelo conjunto não supervisionado. Essa diferença de comportamento entre os modelos sugere que conjuntos iniciais com maior representatividade de padrões de transição tendem a produzir classificadores autotreinados com respostas mais coerentes em relação às detecções não supervisionadas.


Figura 44 – Estimação do fim do amaciamento utilizando floresta aleatória autotreinada com unidades do Modelo A de compressores e utilizando o conjunto não supervisionado.



Fonte: autor.

As estimativas apresentadas na Figura 46 correspondem ao modelo de floresta aleatória autotreinada a partir de unidades combinadas dos Modelos A e B, utilizando o conjunto não supervisionado. De forma geral, observa-se uma redução da variabilidade das previsões em comparação aos modelos treinados separadamente, com maior convergência entre as detecções supervisionadas e não supervisionadas. As previsões de fim de amaciamento ocorrem de forma consistente para as Unidades A1, A3, B1 e B5. Na Unidade A2, foi observado o resultado mais divergente entre métodos, já que o modelo de floresta aleatória não detectou a transição para o regime permanente em nenhum instante do ensaio. No caso das Unidades A4, B4 e B6, foi observada detecção adiantada pelo modelo semissupervisionado, com o agravante que na Unidade A4 o modelo classificou o final do ensaio como não amaciado. A Unidade B2 apresentou um tempo similar para a detecção de regime permanente em ambos os métodos, porém com alternância entre amaciado e não amaciado para o modelo de floresta aleatória em alguns instantes do ensaio. Por fim, na Unidade B3 houve atraso de 10 h na detecção com o modelo semissupervisionado. Quando comparado com o resultado do treinamento por modelos individuais, os comportamentos observados sugerem que a inclusão de amostras de ambos os modelos melhora a generalização do classificador, reduzindo a tendência a detecções extremas, mas também sugere que podem ser necessários mais ensaios para melhorar o desempenho dos modelos.

Figura 45 – Estimação do fim do amaciamento utilizando floresta aleatória autotreinada com unidades do Modelo B de compressores e utilizando o conjunto não supervisionado.



Fonte: autor.


3.5 CONSIDERAÇÕES

Foram desenvolvidos dois métodos para avaliação do fenômeno do amaciamento em compressores: um método baseado em um conjunto de modelos não supervisionados para detecção de transições tribológicas únicas e um método baseado em classificadores semissupervisionados, treinados utilizando o método do autotreinamento. Ambos os métodos foram aplicados para detecção da transição entre o período de amaciamento e o regime permanente tribológico em compressores herméticos alternativos.

O conjunto utilizado no método não supervisionado é composto por modelos que incluem diversos parâmetros de processamento e algoritmos de agrupamento, incluindo uma nova aplicação do núcleo FBR-M para agrupamento utilizando o algoritmo *kernel k*-médias. O método é realizado de forma off-line, a partir de ensaios realizados com o compressor em processo de amaciamento e já em regime permanente tribológico. De modo a descartar os modelos do conjunto que não detectam transições, ou que detectam transições não condizentes com a transição do amaciamento para o regime permanente, é realizada a poda do conjunto a partir de critérios básicos que definem o fenômeno.

O método semissupervisionado foi desenvolvido com base na otimização de dez diferentes modelos classificadores, treinados com autotreinamento e pseudorrotulagem por limiar

Figura 46 – Estimação do fim do amaciamento utilizando floresta aleatória autotreinada com unidades de ambos os modelos de compressores e utilizando o conjunto não supervisionado.



Fonte: autor.

de confiança. Os parâmetros de processamento e os hiperparâmetros dos classificadores foram otimizados utilizando o algoritmo NSGA-II de otimização multiobjetivo, buscando otimizar a proporção rotulada durante o autotreinamento e o CCM em validação cruzada. O processo de escolha do CCM como métrica foi apresentado no XXIV Congresso Brasileiro de Automática e publicado nos anais do evento sob a seguinte entrada:

THALER, G., MENEGALI, J. V. B., NASCIMENTO, A. S. B. de S., PACHECO, A. L. S., FLESCHE, R. C. C., MACHADO, J. P. Z. Efeito da seleção de métricas de desempenho em modelos de aprendizado supervisionado para detecção de amaciamento em compressores. *In: ANAIS DO XXIV CONGRESSO BRASILEIRO DE AUTOMÁTICA*. Fortaleza: SBA, 2022.

Os métodos desenvolvidos foram aplicados em dados de ensaios de compressores obtidos em uma bancada experimental, considerando a corrente elétrica do motor, a vibração e a vazão mássica gerada pela operação do compressor. Foram avaliados para detecção do amaciamento dados de dez unidades de compressores, sendo quatro unidades do Modelo A e seis unidades do Modelo B. O desenvolvimento do núcleo FBR-M e a análise não supervisionada do amaciamento nas unidades de compressores do Modelo A foram publicados no periódico *Advanced Engineering Informatics*, com fator de impacto 9,9, sob a entrada:

THALER, G., NASCIMENTO, A. S. B. de S., PACHECO, A. L. S., FLESCHE, R. C. C. Unsupervised-ensemble-based method for automatic running-in information extraction in reciprocating compressors. **Advanced Engineering Informatics**, v. 62, p. 102841, 2024. ISSN 1474-0346. DOI: <https://doi.org/10.1016/j.aei.2024.102841>.

Parte dos resultados da análise semissupervisionada do amaciamento foram também apresentados na Conferência Internacional de Compressores do ano de 2024, e publicados nos anais do evento:

MACHADO, J. L., THALER, G., FLESCHE, R. C. C. Semi-Supervised Learning Algorithm for Running-in Analysis on Compressors. *In: INTERNATIONAL COMPRESSOR ENGINEERING CONFERENCE*. West Lafayette, EUA: Purdue University Press, 2024.

A análise dos métodos mostrou que o conjunto não supervisionado foi capaz de identificar o término do amaciamento tribológico em todas as unidades avaliadas, com predominância das grandezas derivadas da corrente elétrica, especialmente o valor eficaz e a variância. As grandezas de vibração apresentaram menor frequência de detecção, mas mostraram potencial complementar para identificação de variações locais durante o processo de amaciamento. O método semissupervisionado, por sua vez, reproduziu de forma satisfatória as detecções obtidas pelo conjunto não supervisionado. Entre os classificadores avaliados, a *floresta aleatória* apresentou um dos melhores CCM dentre os classificadores, e o menor EAM quando comparado com o método não supervisionado (aproximadamente 20% quando considerando todas as unidades

avaliadas). Apesar de apresentar um resultado adequado para boa parte dos compressores, o método apresentou problemas de detecção antecipada em parte das unidades, e ainda requer ajuste e novos ensaios para validação.

De forma geral, os resultados obtidos confirmam o potencial dos métodos propostos para detecção automática e não intrusiva do amaciamento em compressores herméticos alternativos. Atividades futuras relacionadas ao aprimoramento dos métodos são apresentadas na forma de sugestões no Capítulo 5.


4 ESTIMAÇÃO DE VIDA ÚTIL DE CAPACITORES

Este capítulo descreve o trabalho realizado e os resultados obtidos no contexto de estimação de vida útil de capacitores para conversores de potência CA-CC-CA para compressores de refrigeração. A Seção 4.1 descreve o método proposto, incluindo a bancada e o conjunto de dados utilizados no projeto, o procedimento para processamento de dados de entrada, o modelo de RNA utilizado e o processo de otimização de hiperparâmetros. A Seção 4.2 apresenta os resultados obtidos com a aplicação do método, bem como comparações com outros métodos do estado da arte para estimação de capacitância. Por fim, a Seção 4.3 apresenta as considerações finais do autor sobre o trabalho realizado e os resultados obtidos.

4.1 MÉTODO PROPOSTO

A Figura 47 apresenta um diagrama conceitual do modelo proposto para estimação da capacitância do filtro do barramento CC de conversores de frequência. As entradas do método foram escolhidas com base na literatura sobre métodos de estimação de FDV em capacitores, porém com a limitação de utilizar apenas variáveis que já sejam normalmente utilizadas para controle e monitoramento do conversor. Conforme apresentado na Seção 2.6.3, as principais grandezas elétricas utilizadas para estimação são a tensão e corrente no barramento CC (V_{CC} e I_{CC} , respectivamente) e a corrente na saída do conversor (I_s). Adicionalmente, para conversores de frequência utilizado no controle de motores, Andrade (2024) propõe a utilização da velocidade rotacional do motor (ω). Assim, essas quatro grandezas foram selecionadas como entradas para o modelo, que tem como saída a estimativa da capacitância $\hat{C}$.

Figura 47 – Diagrama do modelo proposto para estimação da capacitância do filtro do barramento CC de conversores de frequência.



Fonte: autor.

Inicialmente são adquiridas medições experimentais de grandezas relacionadas ao conversor de potência e ao motor. Para este trabalho, foi adaptada a bancada experimental desenvolvida por Santana (2025), que é descrita na Seção 4.1.1, juntamente com uma apresentação dos ensaios realizados e dos dados experimentais obtidos. Essas medições são, então, normalizadas e processadas de três formas, que são elencadas abaixo e descritas na Seção 4.1.2.

1. *Features* temporais: valor médio da velocidade do motor do compressor ($\bar{\omega}$), valor eficaz da oscilação de tensão no barramento CC ($V_{Osc,RMS}$) e da corrente elétrica de saída do conversor ($I_{s,RMS}$) e tensão pico-a-pico do barramento CC, conforme proposto por Andrade (2024) e por Örüklü e Ağalar (2025).
2. *Features* no domínio da frequência: magnitude de potência da tensão no barramento CC na primeira e na segunda harmônicas da frequência de entrada ($p_{CC,1e}$ e $p_{CC,2e}$, respectivamente) e da frequência de saída do conversor ($p_{CC,1s}$ e $p_{CC,2s}$, respectivamente). Embora propostas por Örüklü e Ağalar (2025), no trabalho original os autores propõem a utilização das harmônicas de maior amplitude na Densidade Espectral de Potência DEP, enquanto neste trabalho foram utilizadas apenas as duas primeiras harmônicas de modo a simplificar o cálculo computacional. Essa escolha não mostrou grande impacto em avaliações preliminares.
3. Séries temporais: I_{CC} , I_s e V_{CC} . São processadas utilizando LSTM multicamadas, com as saídas sendo o vetor de estado oculto da última camada da LSTM, $\mathbf{h}$. Apesar de existirem trabalhos na literatura que utilizam LSTMs para monitoramento de componentes e estimação de grandezas, conforme descrito nas seções 2.4 e 2.6.3, segundo a pesquisa do autor a aplicação dessas na estimação de capacitância é uma contribuição original deste trabalho.


Após processamento, as variáveis extraídas são concatenadas e utilizadas como entrada de um PMC, cuja saída é $\hat{C}$, obtida a partir da combinação linear dos neurônios da última camada oculta, equivalente a uma função de ativação linear. Os hiperparâmetros do PMC, bem como da LSTM foram obtidos a partir da otimização em validação cruzada, como descrito na Seção 4.1.3.

4.1.1 Estrutura experimental

Assim como em outros métodos baseados em dados, o método proposto requer um conjunto de observações que seja expressivo da operação real do inversor, preferencialmente em um amplo intervalo de condições de operação. Neste trabalho, essas informações foram obtidos experimentalmente a partir da adaptação da bancada desenvolvida e descrita por Santana (2025), que é apresentada nesta seção juntamente com o procedimento de ensaio e os dados obtidos.

Um diagrama conceitual da bancada de ensaios utilizada é apresentado na Figura 48. Um conversor CA-CC-CA é conectado à rede elétrica monofásica e a um motor de corrente contínua sem escovas de compressor com potência nominal de 149 W em condição ASHRAE LBP com velocidade de 3600 RPM. O eixo do motor elétrico é acoplado a um freio de histerese, controlado por uma fonte CC, que é utilizado para a emulação de carga (MACHADO; FLESCH, 2025). A carga aplicada sobre o motor é controlada utilizando um controlador proporcional integral derivativo com base na medição de potência realizada com um wattímetro. A comunicação com o conversor de frequência foi realizada utilizando uma biblioteca proprietária em linguagem Python da empresa Nidec Global Appliance, que foi incorporada em um programa em LabVIEW para controle, monitoramento e aquisição de dados na bancada experimental.

Figura 48 – Diagrama da bancada experimental para ensaios de capacitância variável.




Fonte: autor.

Para possibilitar a avaliação do sistema com diferentes capacitâncias, os capacitores originais do conversor, com capacitância total de 1000 μF , foram substituídos por uma jiga de testes automática, capaz de variar a capacitância em intervalos discretos de forma on-line. Tanto o controle da jiga quanto do freio de histerese foram realizados utilizando um computador pessoal (PC, do inglês *Personal Computer*), que também foi utilizado para a comunicação e o controle do conversor, para a aquisição de dados e para o monitoramento dos ensaios. Uma foto da bancada completa implementada é apresentada na Figura 49.

A Tabela 5 apresenta as condições nas quais foram realizados os ensaios experimentais. Para cada condição de potência de carga foram realizados 2 ensaios, com exceção das condições de 80 W e 130 W, nas quais foram realizados 3 ensaios, totalizando 500 ensaios. As capacitâncias de 777 μF e 889 μF , destacadas em negrito na tabela, foram reservadas para o conjunto de teste do estimador (20% do conjunto total), com o restante sendo utilizado no desenvolvimento, treino e validação do modelo.

Para cada ensaio, foram adquiridas 1×10^5 amostras de V_{CC} , I_{CC} e I_s com taxa de aquisição F_s de 100 kHz, utilizando o wattímetro PZ4000. A taxa elevada de aquisição foi escolhida de modo a permitir, por meio de subamostragem, avaliar a frequência de aquisição ótima para processamento por LSTM, conforme descrito na Seção 4.1.2. Para ω , foram

Figura 49 – Foto da bancada experimental para ensaios de capacitância variável.



Fonte: autor.

Tabela 5 – Condições de ensaio consideradas nos ensaios de capacitância.

Grandeza	Condições testadas
Frequência de saída do conversor	40 Hz, 45 Hz, 50 Hz, 55 Hz e 60 Hz
Potência de carga	80 W, 130 W, 180 W e 230 W
Capacitância	689 μF , 734 μF , 777 μF , 817 μF , 854 μF , 889 μF , 919 μF , 947 μF , 974 μF e 1000 μF

utilizadas estimativas realizadas pelo próprio sistema embarcado do conversor, com 60 amostras obtidas por ensaio com F_s de 60 Hz. Embora nesta seção a aquisição de dados tenha sido realizada majoritariamente de forma externa ao conversor, na Seção 4.1.2 são apresentadas alternativas on-line para processamento das medições para que seja possível realizar a estimativa de capacitância usando os recursos computacionais do conversor de frequência.

4.1.2 Processamento de dados

Esta seção apresenta o procedimento proposto para processamento das medições brutas e extração de *features*. Apesar de neste trabalho o processamento ter sido realizado de forma off-line em um PC utilizando a linguagem Python de programação, os métodos descritos a seguir foram escolhidos tendo em vista a aplicação embarcada em conversores de potência, considerando tanto limitações de processamento quanto de memória.

De modo a reduzir o uso de memória, foram utilizados majoritariamente algoritmos recursivos para processamento de variáveis. Um exemplo é o cálculo de $\bar{\omega}$, para o qual se

propõe o uso de um acumulador que atualize a soma da velocidade $S_{1,\omega}$ a cada iteração, i.e. $S_{1,\omega}[k] = S_{1,\omega}[k-1] + \omega[k]$. Assim, o cálculo de $\bar{\omega}$ pode ser realizado apenas a cada N_t amostras, tal que:

$$\bar{\omega}[N_t] = \frac{S_{1,\omega}[N_t]}{N_t}. \quad (21)$$

Um método similar ao cálculo de $\bar{\omega}$ foi utilizado para $I_{s,\text{RMS}}$, com a diferença de que a soma acumulada S_{2,I_s} é referente ao valor quadrático de I_s . A corrente $I_{s,\text{RMS}}$ é, então, obtida a partir da relação:

$$I_{s,\text{RMS}}[N_t] = \frac{1}{\sqrt{N_t}} \sqrt{S_{2,I_s}[N_t]}. \quad (22)$$

O cálculo recursivo de $V_{\text{Osc},\text{RMS}}$, por sua vez, exige acumuladores tanto para a soma ($S_{1,V_{\text{CC}}}$) quanto para a soma quadrática ($S_{2,V_{\text{CC}}}$). Uma vez acumuladas N_t amostras, a tensão média do barramento $\bar{V}_{\text{CC}}$ é calculada utilizando uma relação análoga àquela da Equação (21):

$$\bar{V}_{\text{CC}}[N_t] = \frac{S_{1,V_{\text{CC}}}[N_t]}{N_t}. \quad (23)$$

Considerando que a oscilação da tensão no instante tk é dada por $V_{\text{CC}} - \bar{V}_{\text{CC}}$, a equação do valor RMS apresentada na Seção 3.1.3 pode ser manipulada conforme apresentado na Equação (24) de modo a obter uma relação que dependa apenas de $\bar{V}_{\text{CC}}$ e de $S_{2,V_{\text{CC}}}$ na amostra N_t .

$$\begin{aligned} V_{\text{Osc},\text{RMS}}[N_t] &= \sqrt{\frac{(V_{\text{CC}}[1] - \bar{V}_{\text{CC}}[N_t])^2 + (V_{\text{CC}}[2] - \bar{V}_{\text{CC}}[N_t])^2 + \dots + (V_{\text{CC}}[N_t] - \bar{V}_{\text{CC}}[N_t])^2}{N_t}} \\ &= \sqrt{\frac{(V_{\text{CC}}[1]^2 \dots + V_{\text{CC}}[N_t]^2) - 2\bar{V}_{\text{CC}}[N_t](V_{\text{CC}}[1] \dots + V_{\text{CC}}[N_t]) + N_t \bar{V}_{\text{CC}}[N_t]^2}{N_t}} \\ &= \sqrt{\frac{S_{2,V_{\text{CC}}}}{N_t} - 2\bar{V}_{\text{CC}}^2 + \bar{V}_{\text{CC}}^2} \\ &= \frac{1}{\sqrt{N_t}} \sqrt{S_{2,V_{\text{CC}}}[N_t] - N_t \bar{V}_{\text{CC}}[N_t]^2}. \end{aligned} \quad (24)$$

O valor de $V_{\text{CC},\text{Pk}}[N_t]$ depende dos valores máximo e mínimo da tensão do barramento CC ($V_{\text{CC},\text{max}}$ e $V_{\text{CC},\text{min}}$, respectivamente), que podem ser calculados como:

$$V_{\text{CC},\text{max}}[k] = \max(V_{\text{CC},\text{max}}[k-1], V_{\text{CC}}[k]), \quad (25)$$

$$V_{\text{CC},\text{min}}[k] = \min(V_{\text{CC},\text{min}}[k-1], V_{\text{CC}}[k]), \quad (26)$$

de forma recursiva. Assim, $V_{\text{CC},\text{Pk}}[N_t]$ pode ser obtido trivialmente como:

$$V_{\text{CC},\text{Pk}}[N_t] = V_{\text{CC},\text{max}}[N_t] - V_{\text{CC},\text{min}}[N_t]. \quad (27)$$

Quanto à estimação da DEP, diversos algoritmos recursivos são propostos na literatura (CHAUHAN; SINGH, 2022). Dado que neste trabalho são estimadas as potências de no

máximo quatro frequências ($p_{CC,1e}$, $p_{CC,2e}$, $p_{CC,1s}$ e $p_{CC,2s}$, quando a frequência de saída é diferente da frequência de entrada), optou-se pelo algoritmo de Goertzel original, que permite estimar *bins* da DEP sem as limitações de amostras mínimas de outros algoritmos como a transformada rápida de Fourier recursiva (SORENSEN; BURRUS, 1993). A priori, dada uma frequência desejada f_d e uma frequência de amostragem $F_s > 2f_d$, de modo a atender ao critério de amostragem de Nyquist, escolhe-se um número de amostras N_f tal que o índice do *bin* desejado, k_d , seja inteiro, conforme a Equação (28):

$$k_d = \left(\frac{N_f f_d}{F_s} \right). \quad (28)$$

Tal qual na transformada discreta de Fourier, N_f é diretamente proporcional à resolução na frequência da DEP, o que deve ser levado em conta caso o sinal de interesse possua outras componentes com potência significativa próximas a f_d .

Então, para cada amostra k , aplica-se ao sinal desejado um filtro ressonante recursivo de segunda ordem, com parâmetro a_G sintonizado de acordo com a frequência desejada. Considerando V_{CC} como o sinal de entrada, o estado filtrado s_G é dado por:

$$s_G[k] = V_{CC}[k] + a_G s_G[k-1] - s_G[k-2], \quad (29)$$

$$a_G = 2 \cos \left(\frac{2\pi f_d}{F_s} \right), \quad (30)$$

com condições iniciais $s_G[0] = s_G[-1] = 0$.

Uma vez que sejam realizadas N_f medições e iterações do filtro, é possível obter o valor da transformada discreta de Fourier da tensão do barramento CC, $\tilde{V}_{CC}$, na frequência f_d (índice k_d), tal que:

$$\tilde{V}_{CC}[k_d] = s_G[N_f] - e^{-i \frac{2\pi f_d}{F_s}} s_G[N_f - 1]. \quad (31)$$

No método proposto neste trabalho, a variável de interesse não é o valor complexo da transformada discreta de Fourier, mas sim a potência p_{CC} do sinal na frequência desejada. Essa pode ser obtida sem a necessidade de cálculos trigonométricos a partir da relação descrita na Equação (32):

$$p_{CC}[k_d] = |\tilde{V}_{CC}[k_d]|^2 = s_G[N_f]^2 + s_G[N_f - 1]^2 - a_G s_G[N_f] s_G[N_f - 1]. \quad (32)$$

Por fim, idealmente a LSTM também pode ser calculada de forma recursiva, aplicando o procedimento descrito na Seção 2.4 a cada nova medição das variáveis de entrada e atualizando os estados das camadas de acordo com a Equação (6). Essa alternativa, porém, exige uma grande quantidade de cálculos a cada iteração para a arquitetura adotada (8 multiplicações matriciais, 3 produtos de Hadamard, 3 funções de ativação sigmoide e 2 tangentes hiperbólicas, além de adições vetoriais). Assim, optou-se neste trabalho por primeiro armazenar os valores das medições em *buffers*, para que o processamento da LSTM seja realizado posteriormente em batelada, de acordo com a disponibilidade de processamento do conversor. Dadas as limitações

de memória para armazenamento dos dados, o tamanho do *buffer* foi incluído como um parâmetro da otimização do modelo. A otimização desse e de outros parâmetros é descrita na Seção 4.1.3.

4.1.3 Otimização

A otimização dos parâmetros do método proposto foi realizada utilizando o algoritmo estimador de Parzen com estrutura em árvore (WATANABE, 2025), implementado por meio da biblioteca Optuna em linguagem Python, enquanto o treinamento e avaliação das RNAs foi implementado com a biblioteca PyTorch. Como objetivo da otimização foi escolhida a minimização do Erro Quadrático Médio (EQM) da validação cruzada no conjunto de dados de treino descritos na Seção 4.1.1. A validação foi realizada utilizando três dobras em grupos, com os conjuntos de treino contendo valores de capacitância distintos dos valores de validação em todas as dobras de modo a mitigar o sobreajuste dos modelos durante a otimização.

O Quadro 4 apresenta o espaço de busca dos hiperparâmetros. Conforme descrito nas Seções 4.1.1 e 4.1.2, os dados utilizados para a LSTM neste trabalho foram adquiridos em alta frequência (F_s de 100 kHz) de forma a possibilitar a avaliação da redução de F_s por subamostragem. Assim, foram definidos limites para o comprimento máximo das sequências de entrada da LSTM com base nas limitações de *buffer* do conversor utilizado, bem como a proporção de subamostragem, de tal modo que o valor máximo de subamostragem (1000) equivale a uma F_s de 100 Hz.

Foi considerado um amplo espaço de busca tanto para os hiperparâmetros da LSTM quanto para os do PMC. Embora um grande número de dimensões para as camadas e estados ocultos seja um possível gargalo em termos de processamento embarcado, considerou-se neste trabalho que esses processos podem ser divididos em etapas e realizados de forma não prioritária, de acordo com a disponibilidade de processamento do conversor, uma vez que as outras grandezas tenham sido processadas conforme descrito na Seção 4.1.2.

Quadro 4 – Intervalos de busca dos hiperparâmetros para a otimização.

Hiperparâmetro	Intervalo	Tipo
Subamostragem	[1; 1000]	Inteiro
Comprimento da sequência	[10; 360]	Inteiro
Número de camadas LSTM	[1; 3]	Inteiro
Dimensão do estado oculto LSTM	[2; 128]	Inteiro
Número de camadas da PMC	[1; 3]	Inteiro
Dimensão da i -ésima camada oculta da PMC	[2; 128]	Inteiro
Taxa de <i>dropout</i>	[0,20; 0,90]	Real
Função de ativação	{ReLU, tanh, sigmoide, <i>leaky</i> ReLU}	Categórico
Taxa de aprendizado	[10^{-5} ; 10^{-2}]	Real

Além da validação cruzada por grupos, duas outras estratégias foram implementadas para reduzir o sobreajuste do modelo: a utilização de uma taxa de *dropout* no treinamento das redes, desativando aleatoriamente uma fração dos neurônios da rede e forçando o modelo a aprender representações mais generalistas e menos dependentes de combinações específicas de observações; e a parada antecipada do treinamento quando não há uma melhora significativa na métrica de validação após um dado número de épocas. Para este trabalho, a métrica de validação foi calculada a cada 5 épocas de treinamento, e a parada antecipada ocorre quando, após 100 épocas, não há melhora de pelo menos 10^{-4} no EQM, considerando as saídas normalizadas para média zero e desvio-padrão unitário. Caso não ocorra a parada antecipada, as redes LSTM e PMC são treinadas por 500 épocas para cada dobra de validação cruzada.

Como critério de parada do processo de otimização, foi estabelecido um número máximo de 500 iterações do otimizador sem avanço no objetivo. O resultado do processo de otimização é apresentado na Seção 4.2, juntamente com a avaliação do modelo otimizado nos conjuntos de treino e de teste.

4.2 RESULTADOS

Foram realizadas 4584 iterações do processo de otimização até atingir o critério de parada. O Quadro 5 apresenta os parâmetros ótimos encontrados para o modelo. A subamostragem de 708 indica que a frequência de amostragem final da série temporal é de aproximadamente 140 Hz, com comprimento da sequência de 50 amostras.


Quadro 5 – Hiperparâmetros otimizados do modelo proposto.

Hiperparâmetro	Valor
Subamostragem	708
Comprimento da sequência	50
Número de camadas LSTM	3
Dimensão do estado oculto LSTM	40
Número de camadas do PMC	2
Dimensão da 1ª camada oculta PMC	106
Dimensão da 2ª camada oculta PMC	116
Taxa de <i>dropout</i>	0,2
Função de ativação	tanh
Taxa de aprendizado	0,002

Uma vez definidos os parâmetros ótimos, o modelo foi treinado considerando o conjunto total de treino. Foram utilizados nesse treinamento os mesmos critérios de avaliação e de parada do processo de otimização. A Figura 50 apresenta a função de perda ao longo do treinamento do modelo, considerando 10% do conjunto de treino para validação.

O modelo treinado foi aplicado no conjunto de testes de modo a avaliar a capacidade de estimação do modelo frente a cenários de capacitância diferentes daqueles utilizados no treino. A Figura 51 apresenta o resultado das estimações para os conjuntos de treinamento

Figura 50 – Função de perda ao longo do treinamento do modelo proposto.



Fonte: autor.

e de teste, com a abscissa indicando o valor real de capacitância e a ordenada indicando a capacitância estimada pelo modelo. É possível observar que as estimativas, em geral, estão próximas da linha ideal, com a maior dispersão sendo observada no conjunto de treinamento, nos ensaios com capacitância real de 974 μF .


A Tabela 6 apresenta métricas do erro na estimação de capacitância usando o método proposto. É possível observar bons resultados em todas as métricas, como o EAM abaixo de 10 μF tanto no conjunto de treinamento quanto no conjunto de teste, e o Erro Absoluto Relativo Médio (EARM) inferior a 1% em ambos os conjuntos. Em ambas essas métricas, o resultado de estimação foi melhor no conjunto de teste do que no conjunto de treinamento. Quanto ao R^2 , o resultado encontrado foi melhor no conjunto de treinamento do que no conjunto de teste, indicando possíveis *outliers* na estimação do conjunto de teste com maior erro.

Tabela 6 – Resultados da estimação utilizando o modelo proposto.

Conjunto	EAM (μF)	EARM (%)	R^2
Treino	8,51	0,97	0,987
Teste	6,92	0,83	0,976

A distribuição dos erros por condição de capacitância, apresentada na Figura 52, indica que o desempenho inferior da estimação do conjunto de treino é fortemente influenciado

Figura 51 – Estimação de capacitância utilizando o método proposto.



Fonte: autor.

pelos resultados nas duas maiores capacitâncias avaliadas (974 μF e 1000 μF), nas quais o erro é significativamente mais elevado em comparação às demais condições. Esse efeito local provoca um aumento do erro médio global do conjunto de treino, e pode ser causado tanto por uma deficiência do modelo em altas capacitâncias, quanto por observações anômalas nessas condições.


Para verificar o impacto das condições superiores no desempenho global do conjunto de treino, a Tabela 7 apresenta as métricas calculadas desconsiderando as condições de capacitância mais elevadas. Nessa análise, observa-se que as diferenças entre treino e teste diminuem substancialmente, corroborando que o aumento do erro no treino decorre desses casos específicos. Ademais, o valor de *dropout* utilizado no modelo contribui para uma leve degradação das métricas de treino, o que é esperado devido à sua função de regularização e prevenção de sobreajuste.

Tabela 7 – Métricas de desempenho do método proposto calculadas considerando subconjuntos do conjunto de treino, com e sem *dropout*.

Limite superior (μF)	Dropout 0,2			Sem dropout		
	EAM (μF)	EARM (%)	R^2	EAM (μF)	EARM (%)	R^2
Sem limite	8,51	0,94	0,987	7,74	0,88	0,991
980	7,25	0,85	0,992	7,12	0,83	0,992
950	6,93	0,84	0,991	6,87	0,82	0,991

De modo a avaliar o desempenho do modelo proposto em relação ao estado da arte em

Figura 52 – EAM e EARM do método proposto para cada uma das condições de capacitância avaliadas.



Fonte: autor.

estimação de capacitância em conversores, os resultados obtidos foram comparados com outras duas abordagens baseadas em dados publicadas recentemente: o PMC proposto por Andrade (2024); e os métodos regressores propostos por Örüklü e Ağalar (2025). A configuração desses modelos é descrita a seguir.

Andrade (2024) propõe um PMC utilizando como entradas $V_{\text{Osc,RMS}}$, $I_{\text{s,RMS}}$, $\bar{\omega}$ e a frequência de saída do conversor. A configuração dos hiperparâmetros da rede é avaliada em uma busca em grade, com o espaço de busca original apresentado no Quadro 6, onde as siglas ELU e SELU indicam, respectivamente, as funções de ativação por unidades lineares exponenciais (do inglês *Exponential Linear Units*) e por unidades lineares exponenciais escalonadas (do inglês *Scaled Exponential Linear Units*). Dados os limites da otimização realizada para o método proposto neste trabalho (Quadro 4), foi realizada também uma busca estendida para o modelo de Andrade (2024), considerando PMCs de maior complexidade. Os limites da busca estendida também são apresentados no Quadro 6. Tal qual no trabalho original, os modelos das buscas em grade são treinados considerando EAM como métrica de perda e com parada antecipada, sendo que o treinamento é encerrado após 500 épocas sem avanço de pelo menos 1% na função de perda.

A Tabela 8 apresenta os resultados do melhor modelo para cada métrica, considerando o espaço de busca original proposto por Andrade (2024). É possível observar que o desempenho dos modelos foi pior do que o método proposto em todas as métricas avaliadas, com o EAM

Quadro 6 – Espaços de busca de hiperparâmetros considerados para o PMC proposto por Andrade (2024).

Hiperparâmetro	Busca original	Busca estendida
Função de ativação	{ELU, ReLU, SELU}	{ELU, ReLU, SELU}
Número de camadas ocultas	{1, 2}	{2, 3, 4, 5}
Neurônios por camada oculta	{8, 16, 32}	{16, 32, 64, 128}
Otimizador	{Adam, RMSProp}	{Adam, RMSProp}

de todos os modelos acima de 10 μF e o EARM acima de 1%. Na busca estendida, foi possível observar um ganho marginal nos resultados do conjunto de treino, conforme apresentado na Tabela 9, mas pouca melhora nos resultados do conjunto de teste.

Tabela 8 – Resultados dos melhores modelos de regressão para estimação da capacitância com o método de Andrade (2024) (parâmetros originais).

Modelo	EAM (μF)		EARM (%)		R^2	
	Treino	Teste	Treino	Teste	Treino	Teste
SELU/2/32/RMSprop	11,39	11,90	1,31	1,36	0,965	0,958
SELU/2/16/Adam	12,08	11,54	1,39	1,32	0,962	0,959
SELU/2/8/RMSprop	13,84	11,98	1,59	1,37	0,959	0,962

Tabela 9 – Resultados dos melhores modelos de regressão para estimação da capacitância com o método de Andrade (2024) (busca estendida).

Modelo	EAM (μF)		EARM (%)		R^2	
	Treino	Teste	Treino	Teste	Treino	Teste
ReLU/5/64/RMSprop	9,80	11,51	1,13	1,33	0,970	0,958
SELU/2/32/RMSprop	12,03	11,55	1,38	1,31	0,963	0,961
ELU/4/64/RMSprop	12,75	11,80	1,45	1,35	0,962	0,962

Öröklü e Ağalar (2025) propõem seis modelos de regressão, com as entradas sendo $I_{s,RMS}$, o valor pico-a-pico da tensão no barramento CC, e os três maiores picos do DEP da tensão do barramento CC, que no caso da publicação original foram a frequência fundamental da saída e suas 2ª e 5ª harmônicas. Os autores então utilizaram as configurações de modelos de regressão predefinidas do software MATLAB, concluindo que a RPG obteve a melhor capacidade de estimação.

A Tabela 10 apresenta os resultados obtidos aplicando o método de Öröklü e Ağalar (2025) no conjunto experimental de dados descrito na Seção 4.1.1. O menor erro de treino foi obtido com a RNA com uma camada oculta com 100 neurônios e função de ativação ReLU, indicada como ReLU/1/100 na tabela. Além dos 6 modelos propostos por Öröklü e Ağalar (2025), também foi avaliado um PMC com os hiperparâmetros resultantes da otimização descrita na Seção 4.1.3 (2 camadas com 106 e 116 neurônios, respectivamente, e função de ativação tanh), que obteve o pior resultado dentre os modelos considerados.


Tabela 10 – Resultados dos modelos de regressão para estimação da capacitância com o método de Örüklü e Ağalar (2025) para todas as condições avaliadas.

Modelo	EAM (μF)		EARM (%)		R^2	
	Treino	Teste	Treino	Teste	Treino	Teste
RNA (ReLU/1/100)	9,43	11,97	1,07	1,45	0,985	0,909
RPG	11,74	11,60	1,34	1,41	0,974	0,906
RNA (ReLU/3/10)	13,56	12,80	1,54	1,56	0,966	0,899
Regressão por vetores de suporte com núcleo FBR	14,94	35,66	1,75	4,40	0,973	0,420
Comitê de árvores com <i>bagging</i>	18,06	39,36	2,15	4,87	0,936	-0,008
Regressão linear	18,51	15,99	2,18	1,94	0,946	0,853
PMC otimizado	35,85	46,46	4,30	5,48	0,806	-0,047

Nenhum dos modelos propostos por Örüklü e Ağalar (2025) superou o método apresentado na Seção 4.1 nas métricas avaliadas. Em relação ao melhor modelo daqueles autores, o EAM de treino do método proposto foi 8,5% menor, enquanto no conjunto de teste a redução atingiu 40,5%. A Figura 53 mostra a comparação entre a distribuição das estimações obtidas pelo método proposto e pela RNA com uma única camada de 100 neurônios e ativação ReLU. Nota-se que a RNA apresenta distribuição significativamente mais dispersa, especialmente na cauda superior, ao passo que o método proposto produz distribuições mais concentradas em torno da linha ideal, em particular para capacitâncias inferiores a 900 μF .


A Figura 54 apresenta uma estimação da PDF para o erro considerando a RNA de Örüklü e Ağalar (2025) e o método proposto, na qual é possível observar a menor dispersão das estimações do método proposto especialmente no conjunto de testes. Foi observado desvio padrão de 7,5 μF e de 5,0 μF para o erro absoluto do método proposto nos conjuntos de treinamento e de teste, respectivamente, e de 9,2 μF e de 11,9 μF para o método de Örüklü e Ağalar (2025). De modo a avaliar se essa diferença de desempenho é significativa foi conduzida uma análise estatística em dois passos. Inicialmente, aplicou-se o teste de normalidade de Shapiro–Wilk, o qual indicou que as diferenças entre os métodos não seguem uma distribuição gaussiana, consequentemente sugerindo a necessidade de um teste não paramétrico para comparação. Assim, empregou-se o teste de Wilcoxon para amostras pareadas, cujo resultado permite rejeitar a hipótese nula de igualdade de desempenho entre os métodos com elevado nível de confiança (valor $p \approx 2 \times 10^{-6}$). Assim, conclui-se que o método proposto apresenta desempenho significativamente superior ao de Örüklü e Ağalar (2025) na estimação da capacitância sob as condições experimentais de teste avaliadas.

Figura 53 – Comparação entre as estimações utilizando o método proposto e o método de Örüklü e Ağalar (2025).



Fonte: autor.

Figura 54 – PDF estimada do erro utilizando o método proposto e o método de Örüklü e Ağalar (2025).



Fonte: autor.

4.3 CONSIDERAÇÕES

Este capítulo apresentou o desenvolvimento e a avaliação de um modelo para estimação da capacitância de capacitores eletrolíticos de barramento CC em conversores de frequência aplicados ao acionamento de compressores herméticos alternativos para refrigeração. O método proposto combina extração recursiva de variáveis nos domínios do tempo e da frequência com representação de séries temporais por redes LSTM, integrando essas informações a um PMC otimizado para regressão. O processamento foi projetado considerando restrições de aplicações embarcadas, com o uso de subamostragem e estratégias de *buffer* que permitem reduzir a complexidade computacional sem comprometer a precisão do modelo.

A abordagem foi validada a partir de 500 ensaios experimentais planejados com diferentes condições de carga, frequência e valores de capacitância, incluindo capacitâncias reservadas exclusivamente para teste. O modelo resultante apresentou desempenho elevado, com EAM de $6,5\ \mu\text{F}$, EARM a 1% e R^2 acima de 0,97 no conjunto de teste. Esses resultados superaram significativamente métodos de referência avaliados no mesmo banco de dados, apresentando EAM no conjunto de teste 40% inferior ao melhor método da literatura avaliado.

Os resultados obtidos demonstram que o método é capaz de estimar com precisão superior aos métodos da literatura a capacitância em condições operacionais variadas, utilizando apenas sinais já disponíveis no conversor. Assim, o estimador proposto representa uma ferramenta adequada para o monitoramento do estado dos capacitores, um dos principais limitadores de confiabilidade de conversores de frequência do tipo CA-CC-CA. O método proposto e os resultados descritos neste capítulo estão sendo compilados em um artigo para periódico internacional, com previsão de submissão em janeiro de 2026.

5 CONSIDERAÇÕES FINAIS

Esta tese explorou o monitoramento de ciclo de vida de componentes selecionados de um sistema de refrigeração, especificamente a detecção do amaciamento em compressores herméticos alternativos e a estimação da capacitância do filtro do barramento CC em conversores de frequência CA-CC-CA para identificação de FDV. A Seção 5.1 discorre sobre os resultados e objetivos atingidos, e a Seção 5.2 apresenta sugestões de trabalhos futuros. Por fim, a Seção 5.3 apresenta uma lista das publicações desenvolvidas pelo autor durante o período de doutorado que, apesar de não estarem diretamente relacionadas ao tema desta tese, ainda estão ligadas aos campos de sensoriamento virtual e de ensaios com compressores para sistemas de refrigeração.

5.1 CONCLUSÕES

Foram explorados trabalhos na literatura relacionados à detecção do amaciamento e à estimação do FDV de capacitores eletrolíticos, indicados entre os componentes menos confiáveis de conversores de frequência. Essa revisão evidenciou a carência de métodos de avaliação do amaciamento em mecanismos complexos, com apenas uma aplicação em compressores herméticos encontrada, publicada pelo autor desta tese em trabalho anterior (THALER, 2021). Para a estimação de FDV em capacitores, foram identificados dois principais indicadores da degradação: R_{SE} e C . Dada a dificuldade de medição desses fatores durante a operação do conversor, a literatura apresenta diversos métodos para sua estimação não invasiva, com destaque para métodos baseados em dados e aprendizado de máquina.

Para avaliação do amaciamento, inicialmente foi desenvolvida uma extensão do método proposto por Thaler (2021), resultando em um método baseado em conjunto não supervisionado, no qual a detecção do término do amaciamento foi tratada como um problema de agrupamento de dados de vazão mássica e de características estatísticas da corrente elétrica e da vibração no compressor. O método emprega vetores de predição formados por janelas deslizantes em espaço de atraso, que são utilizados para agrupamento e, posteriormente, para detecção de transição com base na proporção de grupos por janela de tempo. Por fim, a probabilidade de fim do amaciamento é obtida por meio da CDF das detecções após a poda do conjunto a partir de critérios fenomenológicos, com a influência de cada parâmetro na detecção podendo ser avaliada a partir da distribuição de parâmetros nos elementos restantes do conjunto.

Quando aplicado em dados experimentais de dez unidades de dois modelos diferentes de compressor, o método baseado em conjunto não supervisionado demonstrou boa concordância com a interpretação física do fenômeno e com os indicativos de regime permanente observados em análise gráfica. A curtose e o valor RMS da corrente elétrica destacaram-se como as variáveis mais indicativas da transição de regime, apresentando comportamento consistente entre unidades do mesmo modelo. Quanto aos métodos de agrupamento mais efetivos, destacaram-se

as abordagens de *kernel k*-médias com núcleo FBR e com o novo núcleo FBR-M, desenvolvido neste trabalho a partir da aplicação da distância de Mahalanobis ao agrupamento. O primeiro foi responsável pela maioria das detecções no Modelo B de compressores (45%) e apenas por 2% no Modelo A, enquanto o núcleo FBR-M apresentou comportamento inverso, respondendo por 93% das detecções no Modelo A e 18% no Modelo B.

De modo a permitir a detecção on-line do amaciamento, foi proposto um método baseado em classificadores com treinamento semissupervisionado, utilizando autotreinamento e otimização multiobjetivo NSGA-II dos hiperparâmetros. Essa abordagem permite a atualização iterativa do modelo com base em critérios de confiança, possibilitando a inclusão controlada de novas amostras no conjunto rotulado à medida que o classificador atinge maior confiabilidade. Para isso, os dados provenientes de diferentes unidades foram organizados em blocos temporais equivalentes aos utilizados na formação do conjunto não supervisionado, e empregados na inicialização dos modelos supervisionados considerando a priori que apenas as primeiras cinco horas do primeiro ensaio de cada unidade representam o compressor não amaciado. A otimização multiobjetivo foi utilizada para obter modelos com alto CCM e, ao mesmo tempo, ampliar a proporção de dados pseudorrotulados.

Os resultados da avaliação experimental do método semissupervisionado mostraram uma diferença significativa no desempenho dos classificadores entre modelos de compressores. No caso do Modelo A, apesar de alguns classificadores apresentarem bom desempenho na validação cruzada por unidades (CCM maior do que 0,7), esse desempenho não se refletiu no conjunto de teste para nenhum classificador. Já para o Modelo B, o comportamento observado foi o inverso, já que nenhum classificador atingiu 0,7 no CCM de treino, mas a maioria dos classificadores apresentou bom desempenho no conjunto de testes. Analisando a progressão temporal da estimação do fim do amaciamento, os classificadores de floresta aleatória e MVS-FBR apresentaram a maior proporção de ensaios condizentes com o esperado do processo transitório para regime permanente.

Os métodos não supervisionado e semissupervisionado foram comparados em termos de diferença de estimação da probabilidade do amaciamento dos compressores. Nessa comparação, o modelo autotreinado de floresta aleatória apresentou a menor diferença média em comparação ao conjunto não supervisionado, com EAM de 31,8% e 12,5% quando treinado e aplicado em unidades dos Modelos A e B, respectivamente. No caso do Modelo A, essa diferença pode ser reduzida para 26,35% quando o classificador é treinado com dados de ambos os modelos de compressor, ao custo de um desempenho levemente inferior na classificação de dados do Modelo B, aumentando o EAM desse modelo para 14,3%. Considerando ambos os modelos de compressor, o EAM obtido entre métodos foi de 19,12%.

Para identificar o FDV de capacitores em conversores de frequência, foi proposto um método de sensoriamento virtual baseado em aprendizado de máquina, combinando *features* de métodos da literatura com uma rede LSTM multicamadas para a extração de *features* de séries temporais para produzir as entradas de um PMC, que, por sua vez, é responsável por

estimar a capacitância, um dos principais indicativos do FDV do capacitor. Os hiperparâmetros do modelo foram obtidos por otimização do EQM da validação por grupos, que incluiu também estratégias de *dropout* e de parada antecipada para reduzir o sobreajuste do modelo.

O método proposto para estimação foi avaliado experimentalmente a partir de dados de 500 ensaios, realizados com 10 valores de capacitância em diferentes condições de frequência de saída e de carga no motor de compressor controlado. Os resultados mostraram que o modelo apresentou EAM de 6,9 μF no conjunto de teste, superando em 40% outros métodos do estado da arte baseados em dados. A análise dos resíduos indicou erro distribuído de forma aproximadamente normal ao longo das diferentes condições operacionais, com as estimações mais dispersas sendo observadas em condições próximas à capacitância nominal. Em conjunto com a formulação de baixo custo computacional proposta, esses resultados indicam que o modelo é adequado para aplicação em sistemas de monitoramento embarcado, constituindo uma alternativa prática para avaliação contínua do FDV de capacitores em conversores CA-CC-CA para sistemas de refrigeração, foco deste trabalho, quanto para outros conversores que requerem barramento CC filtrado.

Os métodos e resultados apresentados nesta tese demonstram a viabilidade de estratégias baseadas em aprendizado de máquina e sensoriamento virtual para o diagnóstico e prognóstico dos componentes selecionados de sistemas de refrigeração. Os métodos propostos para a identificação do término do amaciamento em compressores herméticos apresentam boas perspectivas para o estudo do fenômeno, fornecendo uma base para a caracterização da transição apenas com assunções fenomenológicas básicas a priori. Já o método de sensoriamento virtual desenvolvido para estimação do FDV de capacitores demonstrou capacidade de inferir um dos principais indicadores do estado de degradação do componente de forma não invasiva, confirmando o potencial da combinação entre aprendizado profundo e variáveis elétricas acessíveis. Em conjunto, os resultados obtidos reforçam a aplicabilidade de modelos baseados em dados para monitoramento e manutenção preditiva de sistemas de refrigeração, contribuindo para a consolidação de soluções de diagnóstico mais acessíveis, interpretáveis e compatíveis com os princípios da Indústria 4.0.

Com base nos objetivos propostos na Seção 1.3.2 foi realizada uma avaliação do trabalho realizado nesta tese. Abaixo são elencados os objetivos propostos com o trabalho realizado para sua conclusão.

- determinar diretrizes para detecção do término do período de amaciamento: foram determinados comportamentos esperados com base na literatura sobre o amaciamento e em dados industriais, tais como ocorrência única, duração máxima esperada e assentamento de características tribológicas;
- extrair características a partir de grandezas mensuráveis de forma não invasiva: todas as *features* utilizadas neste trabalho para estimação do amaciamento em compressores podem ser extraídas a partir de variáveis externamente mensuráveis durante a operação

do sistema de refrigeração;

- desenvolver algoritmos automatizados para detecção da transição de amaciamento para regime permanente tribológico: foram desenvolvidos um método baseado em conjunto não supervisionado para detecção off-line da transição e um método semissupervisionado para detecção on-line do fenômeno;
- avaliar os métodos propostos em dados experimentais em uma bancada representativa da operação de compressores, utilizando métricas de classificação para dados rotulados e conceitos físicos do amaciamento para dados não rotulados: foram utilizados dados experimentais de dez compressores, a partir dos quais os métodos propostos foram avaliados considerando métricas objetivas (CCM) e subjetivas com base no comportamento esperado dada a literatura sobre o fenômeno do amaciamento;
- identificar variáveis representativas da degradação que sejam observáveis durante a operação do conversor: foram selecionadas *features* para a estimação que são mensuráveis pelo próprio conversor de frequência, sendo elas derivadas da velocidade de operação do motor acionado, da tensão e da corrente do barramento CC, e da corrente de saída do conversor;
- desenvolver modelos de regressão para estimar indicadores ou FDV a partir dos sinais coletados: foi desenvolvido um método baseado em RNAs para estimação da capacitância do capacitor, elencado na literatura como um dos indicadores do FDV do dispositivo;
- validar o método proposto com base em dados experimentais: o método proposto foi validado a partir de dados extraídos de uma bancada que permitiu avaliar o sistema em diferentes condições de capacitância, carga e frequência de operação;
- avaliar o método desenvolvido em comparação a outros métodos da literatura em termos de erro absoluto, relativo e coeficiente de determinação: o método proposto apresentou resultados superiores a dois métodos do estado da arte da literatura em estimação de capacitância em conversores para todas as métricas avaliadas.

A avaliação realizada verificou que os métodos desenvolvidos e os resultados obtidos são suficientes para considerar como atingidos os objetivos específicos definidos na proposta desta tese. Adicionalmente, verificou-se que os métodos desenvolvidos cumprem integralmente o objetivo geral de propor métodos não invasivos de aprendizado de máquina para detecção do fim do processo de amaciamento em compressores herméticos alternativos e para estimação de deterioração de capacitores em aplicações de refrigeração.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Trabalhos futuros podem expandir e aprimorar os resultados obtidos neste estudo, sendo recomendadas as seguintes ações:

- realizar novos ensaios de amaciamento com diferentes modelos de compressor, a fim de ampliar a base experimental e fortalecer a generalização dos modelos propostos;
- validar a utilização dos métodos propostos para a avaliação do amaciamento em outras transições tribológicas, como a transição de regime permanente para deterioração ao final da vida útil do compressor;
- implementar outras técnicas de agrupamento para a geração de elementos do conjunto não supervisionado de detecção de transições e avaliar as técnicas de acordo com métricas de agrupamento;
- avaliar técnicas de engenharia de *features* para extração de características relacionadas ao amaciamento e a outros fenômenos tribológicos;
- incorporar estratégias de explicabilidade e análise de sensibilidade para aprimorar a interpretabilidade física dos modelos de estimação de transições e de FDV;
- avaliar de forma sistemática o custo computacional dos métodos desenvolvidos para cada etapa (treinamento, teste e inferência on-line) da aplicação;
- expandir o método de estimação de FDV para outros componentes do conversor de frequência;
- implementar os métodos desenvolvidos em sistemas embarcados de monitoramento em tempo real, explorando sua integração a plataformas de controle de compressores e conversores de frequência;
- formalizar a avaliação de incerteza e repetibilidade das estimativas virtuais segundo os princípios da metrologia e do Guia para a expressão de incerteza em medições (JCGM, 2008), de modo a consolidar o uso industrial dos sensores virtuais propostos com garantias metrológicas.

5.3 PUBLICAÇÕES EM CONGRESSOS E PERIÓDICOS

Além dos trabalhos diretamente relacionados a esta tese, apresentados na Seção 3.5, também foram realizadas outras atividades e colaborações no contexto de sensoriamento virtual e de automação de ensaios de compressores. As publicações resultantes desses trabalhos são apresentadas nesta seção, em ordem cronológica de publicação.

MACHADO, J. P. Z., FLESCHE, R. C. C., SCHAEFER, M. M., THALER, G. Aplicação de sistema de aquecimento de rolamentos para redução de variabilidade de ensaios em motores de corrente contínua sem escovas. *In: ANAIS DO XXIV CONGRESSO BRASILEIRO DE AUTOMÁTICA*. Fortaleza: SBA, 2022.

MONTIBELLER, C., THALER, G., FLESCHE, R. C. C., MACHADO, J. P. Z., LUDWIG, G. H.. Automatic Test Stand to Impose Operating Suction and Discharge Conditions on Compressors. *In: INTERNATIONAL COMPRESSOR ENGINEERING CONFERENCE*. West Lafayette, EUA: Purdue University Press, 2024.

DE SANTANA, R. H., MACHADO, J. L., MACHADO, J. P. Z., THALER, G., FLESCHE, R. C. C. Técnicas de sensoriamento virtual para estimação não invasiva de vazão de líquidos. *In: ANAIS DO ROG.e* 2024. Rio de Janeiro: IBP, 2024.

MACHADO, J. P. Z., THALER, G., PACHECO, A. L. S., FLESCHE, R. C. C. Impact of Angular Speed Calculation Methods from Encoder Measurements on the Test Uncertainty of Electric Motor Efficiency. **Metrology**, v. 4, n. 2, p. 164–180, 2024. ISSN 2673-8244. DOI: 10.3390/metrology4020011.

THALER, G., MACHADO, J. P. Z., FLESCHE, R. C. C., TAVEIRA, V. de C. Estimativa não invasiva de velocidade durante a partida de compressores a partir de medições de vibração. *In: ANAIS DO XVII SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI)*. São João del Rei: SBA, 2025.

MACHADO, J. P. Z., SCHWEDERSKY, B. B., FLESCHE, R. C. C., THALER, G. Detecção de defeitos relacionados com fio de cobre na fabricação de motores elétricos utilizando visão computacional. *In: ANAIS DO XVII SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI)*. São João del Rei: SBA, 2025.

THALER, G., MACHADO, J. P. Z., FLESCHE, R. C. C., PACHECO, A. L. S. Metrologically Interpretable Soft-Sensing Technique for Non-Invasive Liquid Flow Estimation from Vibration Data. **Metrology**, v. 5, n. 1, 2025. ISSN 2673-8244. DOI: 10.3390/metrology5010006.

PEREIRA, G. da F.; FLESCHE, R. C. C.; THALER, G. Induction heating using MPC and state estimation for safe acceleration of compressor tests. **Control Engineering Practice**, v. 159, p. 106317, 2025. ISSN 0967-0661. DOI: <https://doi.org/10.1016/j.conengprac.2025.106317>.

REFERÊNCIAS

- ADHIKARI, R. S. *et al.* Energy Savings through Variable Speed Compressor Heat Pump Systems. **Energy Procedia**, v. 14, p. 1337–1342, jan. 2012. ISSN 1876-6102. DOI: 10.1016/j.egypro.2011.12.1098.
- AHMED, M.; GU, F.; BALL, A. D. Fault detection of reciprocating compressors using a model from principles component analysis of vibrations. **Journal of Physics: Conference Series**, v. 364, n. 1, 2012. ISSN 17426596. DOI: 10.1088/1742-6596/364/1/012133.
- ALOM, Md Zahangir *et al.* A state-of-the-art survey on deep learning theory and architectures. **Electronics (Switzerland)**, v. 8, n. 3, 2019. DOI: 10.3390/electronics8030292.
- AMARAL, Acácio M. R. Enhancing Power Converter Reliability Through a Logistic Regression-Based Non-Invasive Fault Diagnosis Technique. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 15, n. 13, p. 6971, jan. 2025. ISSN 2076-3417. DOI: 10.3390/app15136971.
- AMINI, Massih-Reza *et al.* Self-Training: A Survey. **Neurocomputing**, v. 616, p. 128904, fev. 2025. ISSN 0925-2312. DOI: 10.1016/j.neucom.2024.128904.
- ANDRADE, Mateus Abreu de. **Método de estimação on-line da capacitância do barramento CC em inversores de frequência trifásicos**. 2024. Diss. (Mestrado) – Programa de Pós-Graduação em Engenharia de Automação e Sistemas, Universidade Federal de Santa Catarina, Florianópolis, SC.
- APREA, C.; MASTRULLO, R.; RENNO, C. Determination of the Compressor Optimal Working Conditions. **Applied Thermal Engineering**, v. 29, n. 10, p. 1991–1997, jul. 2009. ISSN 13594311. DOI: 10.1016/j.applthermaleng.2008.10.002.
- APREA, C.; MASTRULLO, R.; RENNO, C. Fuzzy Control of the Compressor Speed in a Refrigeration Plant. **International Journal of Refrigeration**, v. 27, n. 6, p. 639–648, set. 2004. ISSN 0140-7007. DOI: 10.1016/j.ijrefrig.2004.02.004.
- ARTHUR, David; VASSILVITSKII, Sergei. K-means++: the advantages of careful seeding. **Proceedings of the Annual ACM-SIAM Symposium on Discrete Algorithms**, 07-09-January-2007, p. 1027–1035, 2007.
- ASHRAE. **ANSI/ASHRAE 23: methods of testing for rating positive displacement refrigerant compressors and condensing units**. Atlanta, 2005.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 13410: condições de ensaio para determinação da capacidade de refrigeração nominal de compressores herméticos e semi-herméticos para refrigeração**. Rio de Janeiro, 1995.

BAHRAMI-FARD, Milad *et al.* Integrated Induction Motor Drive for Variable Speed Industrial Applications. **IEEE Transactions on Power Electronics**, v. 40, n. 5, p. 7176–7188, 2025. DOI: 10.1109/TPEL.2025.3532880.

BARROS, Vinícius Trombin. **Desenvolvimento de ferramentas baseadas em redes neurais artificiais para inferência de parâmetros de desempenho de compressores herméticos por meio de ensaios de capacidade de elevação de pressão**. 2019. Diss. (Mestrado) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, SC.

BEHROOZ, Ali; SOLEIMANIFAR, Amirmahdi; ZOLGHADRI, Mohammad Reza. Regression-Based Machine Learning Approaches for Capacitor Condition Monitoring in Boost PFC Converter. *In*: 2025 16th Power Electronics, Drive Systems, and Technologies Conference (PEDSTC). Teerã, Irã: IEEE, fev. 2025. P. 1–5. DOI: 10.1109/PEDSTC65486.2025.10911914.

BIGGIO, Luca; KASTANIS, Iason. Prognostics and Health Management of Industrial Assets: Current Progress and Road Ahead. **Frontiers in Artificial Intelligence**, v. 3, p. 1–24, nov. 2020. ISSN 26248212. DOI: 10.3389/frai.2020.578613.

BLAU, Peter J. An investigation of the unlubricated friction and wear break-in behavior of a dual-phase steel. **Wear**, v. 72, n. 1, p. 67–80, 1981. ISSN 00431648. DOI: 10.1016/0043-1648(81)90284-2.

BLAU, Peter J. **Friction science and technology**: from concepts to applications. 2. ed. Boca Raton, USA: CRC Press, 2009. P. 436. ISBN 978-1-4200-5404-0.

BLAU, Peter J. On the nature of running-in. **Tribology International**, v. 38, 11-12 SPEC. ISS., p. 1007–1012, 2005. ISSN 0301679X.

BLAU, Peter J. Running-in: art or engineering? **Journal of Materials Engineering**, v. 13, n. 1, p. 47–53, 1991. ISSN 09317058.

BLAU, Peter J. Studies of the friction transients during break-in of sliding metals. *In*: DOWSON, D. *et al.* (Ed.). **The Running-in Process in Tribology: Proceeding of the 8th Leed–Lyon Symposium on Tribology, Held in the Institute National des Science Appliquées de Lyon, France, 8–11 September 1981**. Oxford, Reino Unido: Butterworth-Heinemann, 1982. P. 175–183. ISBN 978-0-408-01226-3. DOI: 10.1016/B978-0-408-01226-3.50038-X.

CELAYA, Jose *et al.* A Model-based Prognostics Methodology for Electrolytic Capacitors Based on Electrical Overstress Accelerated Aging. *In*: ANNUAL CONFERENCE OF THE PHM SOCIETY 2011. Montreal, Canada: PHM Society, set. 2011.

CHAPELLE, Olivier; SINDHWANI, Vikas; KEERTHI, Sathya S. Optimization Techniques for Semi-Supervised Support Vector Machines. **Journal of Machine Learning Research**, v. 9, n. 7, p. 203–233, 2008.

CHAUHAN, Abhishek; SINGH, Ksh Milan. Recursive sliding DFT algorithms: A review. **Digital Signal Processing: A Review Journal**, v. 127, 2022. DOI: 10.1016/j.dsp.2022.103560. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85129464143&doi=10.1016%2fj.dsp.2022.103560&partnerID=40&md5=f817031c15c2a6e4ac5a11d3c5a18823>.

CHEN, J.R. Making subsequence time series clustering meaningful. *In*: FIFTH IEEE INTERNATIONAL CONFERENCE ON DATA MINING (ICDM'05). Houston, EUA: IEEE, 2005. DOI: 10.1109/ICDM.2005.91.

CHICCO, Davide; JURMAN, Giuseppe. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. **BMC Genomics**, v. 21, n. 1, p. 1–13, 2020. ISSN 14712164. DOI: 10.1186/s12864-019-6413-7.

CHIONCEL, Cristian Paul; TIRIAN, Gelu-Ovidiu; SPUNEL, Elisabeta. The Behavior of Wind Turbines Equipped with Induction Generators and Stator Converters Under Significant Variations in Wind Speed. **Applied Sciences (Switzerland)**, v. 15, n. 14, 2025. DOI: 10.3390/app15147700.

CIANTAR, Christopher; HADFIELD, Mark. A study of tribological durability with associated environmental impacts of a domestic refrigerator. **Materials & Design**, v. 25, n. 4, p. 331–341, 2004. ISSN 0261-3069. DOI: <https://doi.org/10.1016/j.matdes.2003.10.016>.

CORAL, Rodrigo; FLESCHE, Carlos Alberto; FLESCHE, Rodolfo Cesar Costa. Measurement of refrigeration capacity of compressors with metrological reliability using artificial neural networks. **IEEE Transactions on Industrial Electronics**, v. 66, n. 12, p. 9928–9936, 2019. ISSN 15579948.

CROMMELIN, Daan J.A. *et al.* Addressing the Cold Reality of mRNA Vaccine Stability. **Journal of Pharmaceutical Sciences**, Elsevier Ltd, v. 110, n. 3, p. 997–1001, 2021. ISSN 15206017. DOI: 10.1016/j.xphs.2020.12.006.

DANG, Hoang-Long; KWAK, Sangshin. Review of Health Monitoring Techniques for Capacitors Used in Power Electronics Converters. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 20, n. 13, p. 3740, jan. 2020. ISSN 1424-8220. DOI: 10.3390/s20133740.

DENG, Fujin *et al.* Capacitor ESR and C Monitoring in Modular Multilevel Converters. **IEEE Transactions on Power Electronics**, v. 35, n. 4, p. 4063–4075, abr. 2020. ISSN 0885-8993, 1941-0107. DOI: 10.1109/TPEL.2019.2939185.

- DING, Cong *et al.* Running-in performance of 7075 aluminum alloy strengthened by burnishing technology. **Journal of Mechanical Science and Technology**, v. 37, n. 5, p. 2545–2553, 2023. ISSN 19763824. DOI: 10.1007/s12206-023-0430-9.
- DOWSON, D.; TAYLOR, C.M.; GODET, M. The running-in process in tribology. *In*: 8. LEEDS-LYON SYMPOSIUM ON TRIBOLOGY. Oxford, Reino Unido: Butterworth-Heinemann, 1982. P. 264.
- DUDA, R.O.; HART, P.E.; STORK, D.G. **Pattern Classification**. New York, USA: Wiley, 2012. ISBN 9781118586006.
- EISSENBERG, D.M.; HAYNES, H.D. Motor-current signature analysis. *In*: ASM handbook, volume 18: friction, lubrication, and wear technology. Materials Park, EUA: ASM International, 1992. ISBN 978-1-62708-141-2.
- ENGELLEN, Jesper E. van; HOOS, Holger H. A survey on semi-supervised learning. **Machine Learning**, Springer US, v. 109, n. 2, p. 373–440, 2020. ISSN 15730565. DOI: 10.1007/s10994-019-05855-6.
- FALCK, Johannes *et al.* Reliability of Power Electronic Systems: An Industry Perspective. **IEEE Industrial Electronics Magazine**, v. 12, n. 2, p. 24–35, jun. 2018. ISSN 1941-0115. DOI: 10.1109/MIE.2018.2825481.
- FRANCHI, Claiton Moro. **Inversores de Frequência: teoria e aplicações**. 2a. São Paulo: Érica, 2009.
- GÉRON, Aurélien. **Hands-on machine learning with scikit-learn, Keras, and TensorFlow**. 2. ed. Sebastopol, EUA: O'Reilly Media, 2019. ISBN 9781492032649.
- GHATREHSAMANI, Sahar; AKBARZADEH, Saleh; KHONSARI, M.M. Experimentally verified prediction of friction coefficient and wear rate during running-in dry contact. **Tribol. Int.**, v. 170, p. 107508, 2022. ISSN 0301-679X. DOI: 10.1016/j.triboint.2022.107508.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Cambridge, EUA: The MIT Press, 2016. ISBN 0262035618.
- GOYAL, Deepam *et al.* Support vector machines based non-contact fault diagnosis system for bearings. **Journal of Intelligent Manufacturing**, Springer US, v. 31, n. 5, p. 1275–1289, 2020. ISSN 15728145. DOI: 10.1007/s10845-019-01511-x.
- GREENACRE, Michael *et al.* Principal Component Analysis. **Nature Reviews Methods Primers**, v. 2, n. 1, p. 100, dez. 2022. ISSN 2662-8449. DOI: 10.1038/s43586-022-00184-w.

GRÜTZMACHER, Philipp G. *et al.* Effects of Multi-Scale Patterning on the Run-In Behavior of Steel-Alumina Pairs under Lubricated Conditions. **Adv. Eng. Mater.**, v. 20, n. 1, p. 1700521, jan. 2018. ISSN 14381656. DOI: 10.1002/adem.201700521.

GUO, Fuyan *et al.* Research on Fault Diagnosis Method for Photovoltaic Array Based on Model Fusion. **Electrical Engineering**, v. 107, n. 6, p. 8189–8199, jun. 2025. ISSN 1432-0487. DOI: 10.1007/s00202-025-02963-6.

GUO, Haixiang *et al.* Learning from class-imbalanced data: review of methods and applications. **Expert Systems with Applications**, Elsevier Ltd, v. 73, p. 220–239, 2017. ISSN 09574174.

GUTIERREZ, Juan Carlos Ticona; ADAMATTI, Daniela Santini; BRAVO, Juan Martin. A New Stopping Criterion for Multi-Objective Evolutionary Algorithms: Application in the Calibration of a Hydrologic Model. **Computational Geosciences**, v. 23, n. 6, p. 1219–1235, dez. 2019. ISSN 1573-1499. DOI: 10.1007/s10596-019-09870-3.

HANCER, Emrah; KARABOGA, Dervis. A comprehensive survey of traditional, merge-split and evolutionary approaches proposed for determination of cluster number. **Swarm and Evolutionary Computation**, v. 32, p. 49–67, 2017. DOI: 10.1016/j.swevo.2016.06.004.

HANLON, Paul C. **Compressor handbook**. 1. ed. New York, USA: McGraw-Hill Education, 2001. P. 720. ISBN 0-07-026005-2.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long Short-Term Memory. **Neural Computing**, MIT Press, Cambridge, MA, USA, v. 9, n. 8, p. 1735–1780, nov. 1997. ISSN 0899-7667. DOI: 10.1162/neco.1997.9.8.1735.

HUALDE-OTAMENDI, Mikel *et al.* Power converter for ultra low-frequency and low-voltage energy harvesters. **Micro and Nano Systems Letters**, v. 13, n. 1, 2025. DOI: 10.1186/s40486-025-00229-1.

ISO. **ISO 917:1989 – Testing of refrigerant compressors**. Geneva, 1989.

JAIN, Anil K. Data clustering: 50 years beyond K-means. **Pattern Recognition Letters**, Elsevier B.V., v. 31, n. 8, p. 651–666, 2010. ISSN 01678655. DOI: 10.1016/j.patrec.2009.09.011.

JAKOVLJEVIC, Mihajlo *et al.* Future health spending forecast in leading emerging BRICS markets in 2030: health policy implications. **Health Research Policy and Systems**, BioMed Central, v. 20, n. 1, p. 1–15, 2022. ISSN 14784505. DOI: 10.1186/s12961-022-00822-5.

JALAYER, Masoud; ORSENIGO, Carlotta; VERCELLIS, Carlo. Fault Detection and Diagnosis for Rotating Machinery: A Model Based on Convolutional LSTM, Fast Fourier and Continuous Wavelet Transforms. **Computers in Industry**, v. 125, p. 103378, fev. 2021. ISSN 0166-3615. DOI: 10.1016/j.compind.2020.103378.

Jl, Lantian *et al.* Investigation on the Performance Improvement of the Scroll Compressor by DLC Film. *In*: 1. DOI: 10.1088/1757-899X/604/1/012078.

JIA, Zan *et al.* An Improved Submodule Capacitor Condition Monitoring Method for Modular Multilevel Converters Considering Switching States. **Journal of Modern Power Systems and Clean Energy**, v. 12, n. 6, p. 2071–2080, nov. 2024. ISSN 2196-5420. DOI: 10.35833/MPCE.2024.000056.

JIANG, Huijie *et al.* A Capacitance Monitoring Strategy Based on Offset Error Compensation for Modular Multilevel Converters. **Energies**, Multidisciplinary Digital Publishing Institute, v. 17, n. 7, p. 1771, jan. 2024. ISSN 1996-1073. DOI: 10.3390/en17071771.

JOINT COMMITTEE FOR GUIDES IN METROLOGY. **Guide to the Expression of Uncertainty in Measurement**. Sèvres, 2008. (JCGM 100:2008).

JOY, E.R. *et al.* Chapter 4 - Power converter topologies for electric vehicle chargers: Future technology, challenges, and trends. *In*: KUMAR, Abhishek *et al.* (Ed.). **Handbook on New Paradigms in Smart Charging for E-Mobility**. [S.l.]: Elsevier, 2025. P. 121–157. ISBN 978-0-323-95201-9. DOI: 10.1016/B978-0-323-95201-9.00004-4.

KAISER, Cletus J. **The Capacitor Handbook: A Comprehensive Guide for Correct Component Selection in All Circuit Applications — Know What to Use When and Where**. 2. ed. Fresno, EUA: C J Publishing, 2011. P. 142. ISBN 9780962852534.

KAMALOV, Firuz; GURRIB, Ikhlās; THABTAH, Fadi. Autoregressive and neural network models: a comparative study with linearly lagged series. *In*: 2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT). Barein (Online): IEEE, 2021. P. 175–180. DOI: 10.1109/3ICT53449.2021.9581812.

KASSAKIAN, John G.; JAHNS, Thomas M. Evolving and Emerging Applications of Power Electronics in Systems. **IEEE Journal of Emerging and Selected Topics in Power Electronics**, v. 1, n. 2, p. 47–58, jun. 2013. ISSN 2168-6785. DOI: 10.1109/JESTPE.2013.2271111.

KHAN, Akbar Ali; ZAFFAR, Nauman Ahmad; IKRAM, Muhammad Jahangir. DC-Link Ripple Reduction for Parallel Inverter Systems by a Novel Formulation Using Multiple Space Vector-Based Interleaving Schemes. **Electronics**, Multidisciplinary Digital Publishing Institute, v. 12, n. 6, p. 1496, jan. 2023. ISSN 2079-9292. DOI: 10.3390/electronics12061496.

KHEDIRI, Issam Ben; WEIHS, Claus; LIMAM, Mohamed. Kernel k-means clustering based local support vector domain description fault detection of multimodal processes. **Expert Systems with Applications**, Elsevier Ltd, v. 39, n. 2, p. 2166–2171, 2012. ISSN 09574174. DOI: 10.1016/j.eswa.2011.07.045.

KHODADOOST, Mehrnaz; HAYATI, Mohsen; ABBASI, Hamed. Design of a class E inverter with stabilized output power using artificial neural network for applications in biomedical implants. **Scientific Reports**, v. 15, n. 1, 2025. DOI: 10.1038/s41598-025-15990-x.

KHONSARI, M.M.; GHATREHSAMANI, Sahar; AKBARZADEH, Saleh. On the running-in nature of metallic tribo-components: a review. **Wear**, Elsevier B.V., 474–475, Dec. 2020, p. 203871, 2021. ISSN 00431648.

KIM, Woohyun; BRAUN, James E. Virtual Refrigerant Mass Flow and Power Sensors for Variable-Speed Compressors. *In*: INTERNATIONAL COMPRESSOR ENGINEERING CONFERENCE. EUA: Purdue University Press, 2012.

KOLAR, J. W. *et al.* The Essence of Three-Phase AC/AC Converter Systems. *In*: 2008 13th International Power Electronics and Motion Control Conference. Poznan, Poland: IEEE, set. 2008. P. 27–42. DOI: 10.1109/EPEPMC.2008.4635241.

KULKARNI, Chetan *et al.* Prognostics Techniques for Capacitor Degradation and Health Monitoring. *In*: PROCEEDINGS OF MARCON 2011. Knoxville, EUA: MARCON, 2011.

KULKARNI, Chetan S. *et al.* Physics Based Electrolytic Capacitor Degradation Models for Prognostic Studies under Thermal Overstress. **PHM Society European Conference**, v. 1, n. 1, jul. 2012. ISSN 2325-016X. DOI: 10.36001/phme.2012.v1i1.1423.

LAHYANI, A. *et al.* Failure Prediction of Electrolytic Capacitors during Operation of a Switchmode Power Supply. **IEEE Transactions on Power Electronics**, v. 13, n. 6, p. 1199–1207, nov. 1998. ISSN 1941-0107. DOI: 10.1109/63.728347.

LESHNO, Moshe *et al.* Multilayer feedforward networks with a nonpolynomial activation function can approximate any function. **Neural Networks**, v. 6, n. 6, p. 861–867, 1993. DOI: 10.1016/S0893-6080(05)80131-5.

LI, Miaomiao *et al.* Simple multiple kernel k-means with kernel weight regularization. **Information Fusion**, p. 101902, 2023. ISSN 1566-2535. DOI: <https://doi.org/10.1016/j.inffus.2023.101902>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S156625352300218X>.

LILIE, D. E. B.; KRUEGER, Manfred. Friction Losses Measurements on a Reciprocating Compressor Mechanism. *In*: INTERNATIONAL Compressor Engineering Conference. West Lafayette, USA: [s.n.], 1990. P. 241–749.

LIU, Chengkai *et al.* Submodule Capacitance Monitoring Strategy for Phase-Shifted Carrier Pulsewidth-Modulation-Based Modular Multilevel Converters. **IEEE Transactions on Industrial Electronics**, v. 68, n. 9, p. 8753–8767, set. 2021. ISSN 0278-0046, 1557-9948. DOI: 10.1109/TIE.2020.3014572.

LIU, Hao *et al.* Long-Term Prediction of Multistress Accelerated Aging of Capacitors by Long Short-Term Memory Network. **IEEE Transactions on Instrumentation and Measurement**, v. 72, p. 1–6, 2023. ISSN 1557-9662. DOI: 10.1109/TIM.2021.3076837.

LOCKWOOD, F.E.; DALLEY, R. Lubricant analysis. *In*: ASM handbook, volume 18: friction, lubrication, and wear technology. Materials Park, EUA: ASM International, 1992. ISBN 978-1-62708-141-2.

MACHADO, João Paulo Zomer; FLESCHE, Rodolfo César Costa. Differential Efficiency Testing Method for Power Drive Systems With Measurement Uncertainty Analysis. **IEEE Transactions on Instrumentation and Measurement**, v. 74, p. 1–9, 2025. DOI: 10.1109/TIM.2025.3606023.

MANDRIOLI, Riccardo *et al.* Prediction of DC-Link Voltage Switching Ripple in Three-Phase Four-Leg PWM Inverters. **Energies**, Multidisciplinary Digital Publishing Institute, v. 14, n. 5, p. 1434, jan. 2021. ISSN 1996-1073. DOI: 10.3390/en14051434.

MARTIN, H.R. Vibration analysis. *In*: ASM handbook, volume 18: friction, lubrication, and wear technology. Materials Park, EUA: ASM International, 1992. ISBN 978-1-62708-141-2.

MARTINS, Erick F. *et al.* Conception of a test bench to generate known and controlled conditions of refrigerant mass flow. **ISA Transactions**, Elsevier Ltd, v. 50, n. 3, p. 513–520, 2011. ISSN 00190578.

MATHIEU, Edouard *et al.* A global database of COVID-19 vaccinations. **Nature Human Behaviour**, Springer US, v. 5, n. 7, p. 947–953, 2021. ISSN 23973374. DOI: 10.1038/s41562-021-01122-8. Disponível em: <http://dx.doi.org/10.1038/s41562-021-01122-8>.

MATTHEWS, B.W. Comparison of the predicted and observed secondary structure of T4 phage lysozyme. **Biochimica et Biophysica Acta (BBA) - Protein Structure**, v. 405, n. 2, p. 442–451, 1975. ISSN 0005-2795. DOI: [https://doi.org/10.1016/0005-2795\(75\)90109-9](https://doi.org/10.1016/0005-2795(75)90109-9).

MIAO, Wenchao; LAM, K. H.; PONG, Philip W. T. Online Monitoring of Aluminum Electrolytic Capacitors in Photovoltaic Systems by Magnetoresistive Sensors. **IEEE Sensors Journal**, v. 20, n. 2, p. 767–777, jan. 2020. ISSN 1558-1748. DOI: 10.1109/JSEN.2019.2945943.

MURILLO-YARCE, Duberney *et al.* A Modular Power Converter Topology to Interface Removable Batteries with 400 V and 800 V Electric Powertrains. **Electronics (Switzerland)**, v. 14, n. 2, 2025. DOI: 10.3390/electronics14020215.

NATHAN, Leema Prasila Arokia *et al.* Review of Condition Monitoring Methods for Capacitors Used in Power Converters. **Microelectronics Reliability**, v. 145, p. 115003, jun. 2023. ISSN 0026-2714. DOI: 10.1016/j.microrel.2023.115003.

NIDEC GLOBAL APPLIANCE. **Catálogo de compressores embraco/Nidec 2021**. 2021. Disponível em: <https://products.embraco.com/compressors>. Acesso em: 8 out. 2022.

NIDEC GLOBAL APPLIANCE. **Compressores Inverter: entenda essa realidade**. 2020. Disponível em: <https://www.embraco.com/blog/compressores-inverter-entenda-essa-realidade/>. Acesso em: 2 set. 2025.

ÖRÜKLÜ, Kerim; AĞALAR, Şener. Machine Learning-Based Condition Monitoring for DC-Link Capacitors in AC/DC/AC Converters. **IEEE Transactions on Industrial Electronics**, v. 72, n. 4, p. 4227–4237, abr. 2025. ISSN 1557-9948. DOI: 10.1109/TIE.2024.3454814.

OZAKI, Yoshihiko; WATANABE, Shuhei; YANASE, Toshihiko. OptunaHub: A Platform for Black-Box Optimization. **arXiv preprint arXiv:2510.02798**, 2025.

PACHECO, A. L. S. *et al.* Tool based on artificial neural networks to obtain cooling capacity of hermetic compressors through tests performed in production lines. **Expert Syst. Appl.**, v. 194, p. 116494–116510, mai. 2022. DOI: 10.1016/j.eswa.2021.116494.

PEDREGOSA, F. *et al.* Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

PENZ, Cesar A. *et al.* Fuzzy–Bayesian network for refrigeration compressor performance prediction and test time reduction. **Expert Systems with Applications**, v. 39, n. 4, p. 4268–4273, 2012. ISSN 0957-4174.

PENZ, Cesar Alberto. **Procedimentos para prover confiabilidade ao uso de inteligência artificial em ensaios de desempenho de compressores herméticos de refrigeração**. 2011. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina.

PETRUZELLA, Frank. **Motores Elétricos e Acionamentos: Série Tekne**. Porto Alegre: Bookman, 2013.

PLEWES, Katherine *et al.* Cost, health impacts and cost effectiveness of iceless refrigeration in India's last-mile vaccine cold chain delivery. **Transactions of The Royal Society of Tropical Medicine and Hygiene**, December 2022, p. 310–312, 2022. ISSN 0035-9203. DOI: 10.1093/trstmh/trac115.

PÖYHÖNEN, Santeri. **Variable-Speed-Drive-Based Monitoring and Diagnostic Methods for Pump, Compressor, and Fan Systems**. 2021. Tese (Doutorado) – Lappeenranta–Lahti University of Technology LUT.

QIAN, Jinchuan *et al.* A review on autoencoder based representation learning for fault detection and diagnosis in industrial processes. **Chemometrics and Intelligent Laboratory**

Systems, v. 231, p. 104711, 2022. ISSN 0169-7439. DOI: <https://doi.org/10.1016/j.chemolab.2022.104711>.

RANA, Mohammed Masud *et al.* Comprehensive Review on the Charging Technologies of Electric Vehicles (EV) and Their Impact on Power Grid. **IEEE Access**, v. 13, p. 35124–35156, 2025. DOI: 10.1109/ACCESS.2025.3538663.

RATNER, Bruce. The correlation coefficient: its values range between +1/-1, or do they? **Journal of Targeting, Measurement and Analysis for Marketing**, v. 17, p. 139–142, jun. 2009. DOI: 10.1057/jt.2009.5.

RAZIK, Hubert. **Handbook of Asynchronous Machine with Variable Speed**. Londres, Reino Unido: ISTE, 2011.

ROH, Chan *et al.* A Study on Equivalent Series Resistance Estimation Compensation for DC-Link Capacitor Life Diagnosis of Propulsion Drive in Electric Propulsion Ship. **Processes**, Multidisciplinary Digital Publishing Institute, v. 13, n. 2, p. 291, fev. 2025. ISSN 2227-9717. DOI: 10.3390/pr13020291.

RONANKI, Deepak; WILLIAMSON, Sheldon S. Failure Prediction of Submodule Capacitors in Modular Multilevel Converter by Monitoring the Intrinsic Capacitor Voltage Fluctuations. **IEEE Transactions on Industrial Electronics**, v. 67, n. 4, p. 2585–2594, abr. 2020. ISSN 1557-9948. DOI: 10.1109/TIE.2019.2912771.

RUBAVATHY, S. Jaanaa *et al.* A comparative study of AVC-PDM and AVC-PWM based cyclo-inverter fed induction heating systems. **Results in Engineering**, v. 25, 2025. DOI: 10.1016/j.rineng.2025.104402.

RUGGIERO, Alessandro *et al.* Accurate measurement of reciprocating kinetic friction coefficient through automatic detection of the running-in. **IEEE Transactions on Instrumentation and Measurement**, v. 69, n. 5, p. 2398–2407, 2020. ISSN 15579662.

RUIZ, Alberto; LÓPEZ-DE-TERUEL, Pedro E. Nonlinear kernel-based statistical pattern analysis. **IEEE Transactions on Neural Networks**, v. 12, n. 1, p. 16–32, 2001. ISSN 10459227. DOI: 10.1109/72.896793.

SALEH, S.A. *et al.* On the Performance of the Frequency-Selective Grounding in Induction Motor Variable Frequency Drives. **IEEE Transactions on Industry Applications**, 2025. DOI: 10.1109/TIA.2025.3585084.

SANTANA, Rafael Heidemann de. **Estimação da capacitância do barramento CC em conversor de frequência**. 2025. Monografia (Graduação em Engenharia Elétrica) – Universidade Federal de Santa Catarina, Florianópolis, SC.

SANTOS, Alexandre F.; GASPAR, Pedro D.; SOUZA, Heraldo J.L. de. Refrigeration of COVID-19 vaccines: Ideal storage characteristics, energy efficiency and environmental impacts

of various vaccine options. **Energies**, v. 14, n. 7, 2021. ISSN 19961073. DOI: 10.3390/en14071849.

SARAVANAKUMAR, R. *et al.* Condition Monitoring of Submodule Capacitors in Modular Multilevel Converters—A Review. **Journal of Energy Storage**, v. 134, p. 117954, out. 2025. ISSN 2352-152X. DOI: 10.1016/j.est.2025.117954.

SCHMITZ, Filipe. **Desenvolvimento e validação experimental de um padrão de intercomparação para verificação de bancadas de ensaio de eficiência energética de compressores de refrigeração na indústria**. 2014. Diss. (Mestrado) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina.

SCHUSTER, M.; PALIWAL, K.K. Bidirectional recurrent neural networks. **IEEE Transactions on Signal Processing**, v. 45, n. 11, p. 2673–2681, 1997. DOI: 10.1109/78.650093.

AL-SELWI, Safwan Mahmood *et al.* RNN-LSTM: From applications to modeling techniques and beyond—Systematic review. **Journal of King Saud University - Computer and Information Sciences**, v. 36, n. 5, p. 102068, 2024. ISSN 1319-1578. DOI: <https://doi.org/10.1016/j.jksuci.2024.102068>.

SHAHRAKI, Ameneh Forouzandeh *et al.* Using LSTM Neural Network to Predict Remaining Useful Life of Electrolytic Capacitors in Dynamic Operating Conditions. **Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability**, SAGE Publications, v. 237, n. 1, p. 16–28, 2022. ISSN 1748-006X. DOI: 10.1177/1748006X221087503.

SHEWALKAR, Apeksha; NYAVANANDI, Deepika; LUDWIG, Simone A. Performance Evaluation of Deep neural networks Applied to Speech Recognition: RNN, LSTM and GRU. **Journal of Artificial Intelligence and Soft Computing Research**, v. 9, n. 4, p. 235–245, 2019. DOI: 10.2478/jaiscr-2019-0006.

SILVA, Willian T. F. D. da; BRAGA, Vitor M.; DESCHAMPS, Cesar J. Performance Analysis of a Reciprocating Refrigeration Compressor Under Variable Operating Speeds. **Machines**, v. 13, n. 7, 2025. ISSN 2075-1702. DOI: 10.3390/machines13070609.

SLIMANI, Boukhalfa Nait; GHANES, Malek; DJENNOUNE, Said. High-Gain Adaptive Observer for Floating Voltages Estimation and Capacitor Aging Monitoring in Multicell Converters. **Engineering Science and Technology, an International Journal**, v. 65, p. 102036, mai. 2025. ISSN 2215-0986. DOI: 10.1016/j.jestch.2025.102036.

SOFOS, Marina *et al.* **Innovations in Sensors and Controls for Building Energy Management: Research and Development Opportunities Report for Emerging Technologies**. Golden, CO (United States), fev. 2020. P. 1–110. DOI: 10.2172/1601591. Disponível em: <https://www.osti.gov/servlets/purl/1601591/>.

SOLIMAN, Hammam *et al.* Artificial Neural Network Based DC-link Capacitance Estimation in a Diode-Bridge Front-End Inverter System. *In: 2017 IEEE 3rd International Future Energy Electronics Conference and ECCE Asia (IFEEEC 2017 - ECCE Asia)*. [S.l.: s.n.], jun. 2017. P. 196–201. DOI: 10.1109/IFEEEC.2017.7992442.

SORENSEN, H.V.; BURRUS, C.S. Efficient computation of the DFT with only a subset of input or output points. **IEEE Transactions on Signal Processing**, v. 41, n. 3, p. 1184–1200, 1993. DOI: 10.1109/78.205723.

STEINLEY, Douglas; BRUSCO, Michael J. Choosing the number of clusters in K-means clustering. **Psychological Methods**, v. 16, n. 3, p. 285–297, mai. 2011. ISSN 1939-1463. DOI: 10.1037/a0023346.

STEINLEY, Douglas. K-means clustering: A half-century synthesis. **British Journal of Mathematical and Statistical Psychology**, v. 59, n. 1, p. 1–34, mai. 2006. ISSN 00071102. DOI: 10.1348/000711005X48266.

STEINWART, Ingo; CHRISTMANN, Andreas. **Support vector machines**. New York, NY: Springer New York, 2008. (Information Science and Statistics). ISBN 978-0-387-77241-7. DOI: 10.1007/978-0-387-77242-4.

TAO, Chen; LI, Tianhao; HUANG, Jiapeng. Kernel Choice in One-Class Support Vector Machines for Novelty and Outlier Detection. *In: 2020 2nd International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)*. [S.l.: s.n.], 2020. P. 116–120. DOI: 10.1109/MLBDBI51377.2020.00026.

TAVENARD, Romain *et al.* Tslern, A Machine Learning Toolkit for Time Series Data. **Journal of Machine Learning Research**, v. 21, n. 118, p. 1–6, 2020. Disponível em: <http://jmlr.org/papers/v21/20-091.html>.

THALER, Gabriel. **delayedsw: Preprocess data using delayed space sliding window**. Florianópolis: GitHub, 2025. <https://github.com/ThalerG/delayedsw>. Disponível em: <https://github.com/ThalerG/delayedsw>. Acesso em: 21 nov. 2025.

THALER, Gabriel. **Desenvolvimento de métodos não invasivos para avaliação do processo de amaciamento de compressores herméticos alternativos**. 2021. Diss. (Mestrado) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina.

THALER, Gabriel *et al.* Efeito da seleção de métricas de desempenho em modelos de aprendizado supervisionado para detecção de amaciamento em compressores. *In: ANAIS DO XXIV CONGRESSO BRASILEIRO DE AUTOMÁTICA*. Fortaleza: SBA, 2022.

TRIGUERO, Isaac; GARCÍA, Salvador; HERRERA, Francisco. Self-labeled techniques for semi-supervised learning: taxonomy, software and empirical study. **Knowledge and**

Information Systems, v. 42, n. 2, p. 245–284, fev. 2015. ISSN 0219-3116. DOI: 10.1007/s10115-013-0706-y.

UHLMANN, Eckart *et al.* Cluster identification of sensor data for predictive maintenance in a selective laser melting machine tool. **Procedia Manufacturing**, Elsevier B.V., v. 24, p. 60–65, 2018. ISSN 23519789.

WANG, Defeng; YEUNG, Daniel S.; TSANG, Eric C.C. Weighted Mahalanobis distance kernels for support vector machines. **IEEE Transactions on Neural Networks**, v. 18, n. 5, p. 1453–1462, 2007. ISSN 10459227. DOI: 10.1109/TNN.2007.895909.

WANG, Haoran *et al.* An Overview of Capacitive DC-Links-Topology Derivation and Scalability Analysis. **IEEE Transactions on Power Electronics**, v. 35, n. 2, p. 1805–1829, 2020. DOI: 10.1109/TPEL.2019.2920257.

WANG, Huai; BLAABJERG, Frede. Reliability of Capacitors for DC-Link Applications in Power Electronic Converters—An Overview. **IEEE Transactions on Industry Applications**, v. 50, n. 5, p. 3569–3578, set. 2014. ISSN 1939-9367. DOI: 10.1109/TIA.2014.2308357.

WANG, Qi *et al.* A Comprehensive Survey of Loss Functions in Machine Learning. **Annals of Data Science**, v. 9, n. 2, p. 187–212, abr. 2022. ISSN 2198-5812. DOI: 10.1007/s40745-020-00253-5.

WATANABE, Shuhei. Tree-Structured Parzen Estimator: Understanding Its Algorithm Components and Their Roles for Better Empirical Performance. arXiv, arXiv:2304.11127, set. 2025. DOI: 10.48550/arXiv.2304.11127. arXiv: 2304.11127 [cs].

AL-WESABI, Ibrahim *et al.* Capacitance Estimation Algorithm Based on DC-link Voltage Ripples Using Hybrid Machine Learning Techniques in Power Electronics Converters. **Results in Engineering**, v. 27, p. 106216, set. 2025. ISSN 2590-1230. DOI: 10.1016/j.rineng.2025.106216.

WOO, Seong-woo; PECHT, Michael; O'NEAL, Dennis L. Reliability design and case study of a refrigerator compressor subjected to repetitive loads. **International Journal of Refrigeration**, v. 32, n. 3, p. 478–486, 2009. ISSN 0140-7007. DOI: <https://doi.org/10.1016/j.ijrefrig.2008.07.006>.

XIA, Hongjian *et al.* Capacitor Condition Monitoring for Modular Multilevel Converter Based on Charging Transient Voltage Analysis. **IEEE Transactions on Power Electronics**, v. 38, n. 3, p. 3847–3856, mar. 2023. ISSN 1941-0107. DOI: 10.1109/TPEL.2022.3219291.

XIA, Hongjian *et al.* Condition Monitoring for Capacitors in Modular Multilevel Converter Based on High-frequency Transient Analysis. *In: 2021 IEEE Energy Conversion Congress and Exposition (ECCE)*. [S.l.: s.n.], out. 2021. P. 5342–5347. DOI: 10.1109/ECCE47101.2021.9595469.

XIAO, Qian *et al.* Submodule Capacitance Monitoring Approach for the MMC With Asymptotically Converged Error. **IEEE Transactions on Industrial Electronics**, v. 71, n. 5, p. 4330–4339, mai. 2024. ISSN 1557-9948. DOI: 10.1109/TIE.2023.3288171.

YANG, Cynthia *et al.* Impact of Random Oversampling and Random Undersampling on the Performance of Prediction Models Developed Using Observational Health Data. **Journal of Big Data**, v. 11, n. 1, p. 7, jan. 2024. ISSN 2196-1115. DOI: 10.1186/s40537-023-00857-7.

YAO, Bo *et al.* Remaining Useful Life Prediction of Aluminum Electrolytic Capacitor with a Strain-based Health Indicator. *In*: 2024 IEEE Applied Power Electronics Conference and Exposition (APEC). [S.l.: s.n.], fev. 2024. P. 2438–2442. DOI: 10.1109/APEC48139.2024.10509289.

YAROWSKY, David. Unsupervised Word Sense Disambiguation Rivaling Supervised Methods. *In*: 33RD Annual Meeting of the Association for Computational Linguistics. Cambridge, Massachusetts, USA: Association for Computational Linguistics, jun. 1995. P. 189–196. DOI: 10.3115/981658.981684.

YU, Lu *et al.* A Novel Hierarchical Algorithm for Bearing Fault Diagnosis Based on Stacked LSTM. **Shock and Vibration**, v. 2019, n. 1, p. 2756284, 2019. DOI: <https://doi.org/10.1155/2019/2756284>.

ZAKI, Omar M.; EL-MORSI, Mohamed; ABDELAZIZ, Omar. Unlocking energy savings and emissions reduction: A comparative study of fixed-speed and variable-speed room air conditioners in high ambient temperature environments. **Science and Technology for the Built Environment**, v. 30, n. 2, p. 153–171, 2024. DOI: 10.1080/23744731.2023.2291006.

ZENG, Shan *et al.* Kernelized Mahalanobis Distance for Fuzzy Clustering. **IEEE Transactions on Fuzzy Systems**, v. 29, n. 10, p. 3103–3117, 2021. ISSN 19410034. DOI: 10.1109/TFUZZ.2020.3012765.

ZHANG, Xin *et al.* Tracing the evolution of contact area during the running-in process of AgCu-MoS₂ composite. **Tribology International**, Elsevier Ltd, v. 174, March, p. 107739, 2022. ISSN 0301679X. DOI: 10.1016/j.triboint.2022.107739. Disponível em: <https://doi.org/10.1016/j.triboint.2022.107739>.

ZHANG, Zhenfang; ZHANG, Liangchi; MAI, Yiu Wing. The running-in wear of a steel/SiCp-Al composite system. **Wear**, v. 194, n. 1-2, p. 38–43, 1996. ISSN 00431648. DOI: 10.1016/0043-1648(95)06671-3.

ZHAO, Zhaoyang *et al.* An Online Parameters Monitoring Method for Output Capacitor of Buck Converter Based on Large-Signal Load Transient Trajectory Analysis. **IEEE Journal of Emerging and Selected Topics in Power Electronics**, v. 9, n. 4, p. 4004–4015, ago. 2021. ISSN 2168-6785. DOI: 10.1109/JESTPE.2020.2964068.

ZHAO, Zhaoyang *et al.* An Overview of Condition Monitoring Techniques for Capacitors in DC-Link Applications. **IEEE Transactions on Power Electronics**, v. 36, n. 4, p. 3692–3716, set. 2020. ISSN 1941-0107. DOI: 10.1109/TPEL.2020.3023469.

ZHAO, Zhaoyang *et al.* Online DC-Link Capacitance Monitoring for Digital-Controlled Boost PFC Converters Without Additional Sampling Devices. **IEEE Transactions on Industrial Electronics**, v. 70, n. 1, p. 907–920, jan. 2023. ISSN 0278-0046, 1557-9948. DOI: 10.1109/TIE.2022.3153825.

ZHU, Xiaojin; GOLDBERG, Andrew B. **Introduction to Semi-Supervised Learning**. [S.l.]: Morgan & Claypool Publishers, 2009. (Synthesis Lectures on Artificial Intelligence and Machine Learning). DOI: <http://dx.doi.org/10.2200/S00196ED1V01Y200906AIM006>.

ZORAGHI-JEDI, Mahsa *et al.* Capacitance Health Monitoring in the Modular Multilevel Converter Using a Method with Minimum Number of Sensors and Computational Burden. **International Journal of Circuit Theory and Applications**, v. 52, n. 12, p. 6343–6361, 2024. ISSN 1097-007X. DOI: 10.1002/cta.4057.

APÊNDICE A – PARÂMETROS OTIMIZADOS DE MODELOS SEMISUPERVISIONADOS

Este apêndice apresenta os parâmetros de processamento e os hiperparâmetros dos classificadores autotreinados com maior CCM em validação cruzada após o processo de otimização descrito na Seção 3.3.1. Os limites da otimização para cada modelo são apresentados nos Quadros 2 e 3. Esses classificadores foram treinados com dados de compressores em ensaios de amaciamento e em ensaios de referência, com validação cruzada por unidade, de tal modo que para cada dobra da validação uma unidade do conjunto de treino é separada para o conjunto de validação, e o número de dobras é o número de unidades disponíveis.

Quadro 7 – Parâmetros ótimos encontrados para regressão logística.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{Lon,RMS}$	I_{Var}	$v_{Lon,\sigma}$
Tamanho da janela	37	149	82
Janela de médias móveis	1	30	19
Balanceamento de classes	nenhum	subamostragem	nenhum
Atraso entre amostras	5	1	2
Redução de dim. ACP	sim	não	não
Nº de componentes ACP	24	–	–
Parâmetro de regularização	94,43	0,00442	34,62
Limiar de decisão do autotreinamento	0,933	0,470	0,537

Quadro 8 – Parâmetros ótimos encontrados para árvore de decisão.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{\text{Lon,RMS}}$	I_{σ}	I_{Var}
Tamanho da janela	55	71	12
Janela de médias móveis	23	1	20
Balanceamento de classes	nenhum	nenhum	subamostragem
Atraso entre amostras	2	2	14
Redução de dim. ACP	sim	sim	sim
Nº de componentes ACP	3	41	3
Profundidade máx.	41	6	13
Nº mín. de amostras para divisão	160	48	193
Nº mín. de amostras por folha	100	84	96
Nº máx. de atributos considerados	log2	sem limite	raiz quadrada
Limiar de decisão do autotreinamento	0,399	0,435	0,466

Quadro 9 – Parâmetros ótimos encontrados para K-VMP.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{\text{Lon,RMS}}$	$v_{\text{Lon,Ass}}$	$v_{\text{Lat,Ass}}$
Tamanho da janela	31	98	50
Janela de médias móveis	1	1	3
Balanceamento de classes	nenhum	nenhum	subamostragem
Atraso entre amostras	6	1	1
Redução de dim. ACP	não	não	sim
Nº de componentes ACP	–	–	30
Nº de vizinhos	93	15	99
Peso da distância	distância	uniforme	uniforme
Métrica de distância	Manhattan	Minkowski	Minkowski
Parâmetro da métrica Minkowski (p)	–	3	2
Limiar de decisão do autotreinamento	0,788	0,304	0,884

Quadro 10 – Parâmetros ótimos encontrados para MVS linear.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{\text{Lon,Var}}$	I_{σ}	$v_{\text{Lon,RMS}}$
Tamanho da janela	77	140	76
Janela de médias móveis	5	19	30
Normalização/escala	sim	não	sim
Balanceamento de classes	subamostragem	subamostragem	subamostragem
Atraso entre amostras	2	1	2
Redução de dim. ACP	não	sim	sim
Nº de componentes ACP	–	1	8
Parâmetro de regularização (C)	$1,54 \times 10^{-5}$	912,47	3,17
Limiar de decisão do autotreinamento	0,221	0,354	0,378

Quadro 11 – Parâmetros ótimos encontrados para MVS-FBR.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{\text{Lon,RMS}}$	$\dot{m}$	$v_{\text{Lat,Pk}}$
Tamanho da janela	145	137	40
Janela de médias móveis	29	28	23
Balanceamento de classes	nenhum	nenhum	subamostragem
Atraso entre amostras	1	1	3
Redução de dim. ACP	sim	não	sim
Nº de componentes ACP	17	–	24
Parâmetro de regularização	63,83	34,47	3,62
Largura do núcleo	0,00215	$7,06 \times 10^{-5}$	9,38
Limiar de decisão do autotreinamento	0,078	0,963	0,718

Quadro 12 – Parâmetros ótimos encontrados para floresta aleatória.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{\text{Lon,RMS}}$	I_{Var}	I_{Var}
Tamanho da janela	147	85	51
Janela de médias móveis	19	13	30
Balanceamento de classes	nenhum	nenhum	subamostragem
Atraso entre amostras	1	2	2
Redução de dim. ACP	sim	não	sim
Nº de componentes ACP	16	–	13
Nº de árvores	166	166	52
Profundidade máx.	9	3	17
Nº mín. de amostras para divisão	20	8	11
Nº mín. de amostras por folha	4	7	6
Nº máx. de atributos considerados	raiz quadrada	nenhum	log2
Uso de amostragem <i>bootstrap</i>	não	sim	não
Limiar de decisão do autotreinamento	0,405	0,145	0,566

Quadro 13 – Parâmetros ótimos encontrados para PMC.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{\text{Lon,RMS}}$	I_{σ}	I_{σ}
Tamanho da janela	25	4	39
Janela de médias móveis	8	2	13
Balanceamento de classes	nenhum	nenhum	subamostragem
Atraso entre amostras	7	32	3
Redução de dim. ACP	não	não	sim
Nº de componentes ACP	–	–	16
Nº de camadas ocultas	2	2	2
Neurônios por camada	160, 138	44, 41	140, 42
Função de ativação	relu	logística	relu
Parâmetro de regularização	$4,50 \times 10^{-5}$	$2,35 \times 10^{-5}$	$4,93 \times 10^{-6}$
Estratégia de tx. de aprendizado	adaptativo	constante	adaptativo
Limiar de decisão do autotreinamento	0,287	0,790	0,892

Quadro 14 – Parâmetros ótimos encontrados para AdaBoost.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{\text{Lon},\sigma}$	I_{Var}	I_{Kur}
Tamanho da janela	146	135	149
Janela de médias móveis	30	13	18
Balanceamento de classes	subamostragem	nenhum	nenhum
Atraso entre amostras	1	1	1
Redução de dim. ACP	não	não	não
Nº de estimadores	80	24	184
Taxa de aprendizado	0,163	0,0723	0,228
Limiar de decisão do autotreinamento	0,172	0,233	0,415

Quadro 15 – Parâmetros ótimos encontrados para Bayes ingênuo.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{\text{Lon,RMS}}$	I_{THD}	$\dot{m}$
Tamanho da janela	7	5	41
Janela de médias móveis	15	28	12
Normalização/escala	não	sim	sim
Balanceamento de classes	nenhum	subamostragem	subamostragem
Atraso entre amostras	26	32	4
Redução de dim. ACP	sim	sim	sim
Nº de componentes ACP	1	2	4
Suavização da variância	$4,65 \times 10^{-12}$	$2,88 \times 10^{-11}$	$6,95 \times 10^{-10}$
Limiar de decisão do autotreinamento	0,116	0,263	0,331

Quadro 16 – Parâmetros ótimos encontrados para ADQ.

Hiperparâmetro	Modelo A	Modelo B	Ambos os modelos
Grandeza utilizada	$v_{\text{Lon},\sigma}$	I_{σ}	$v_{\text{Lon},\text{Pk}}$
Tamanho da janela	4	54	21
Janela de médias móveis	26	7	29
Balanceamento de classes	nenhum	nenhum	subamostragem
Atraso entre amostras	50	3	6
Redução de dim. ACP	não	sim	não
Nº de componentes ACP	–	1	–
Parâmetro de regularização	0,763	0,373	0,112
Armazenamento da matriz de covariância	não	sim	não
Limiar de decisão do autotreinamento	0,0981	0,154	0,310

APÊNDICE B – COMPARAÇÃO DE ESTIMAÇÃO DO AMACIAMENTO POR UNIDADE E AGRUPAMENTO

Este apêndice apresenta a diferença entre os modelos de classificação semissupervisionados e o conjunto não supervisionado na estimação da probabilidade de amaciamento de compressores ao longo do ensaio de amaciamento, em valor percentual. Assumindo o valor obtido pelo conjunto não supervisionado como verdadeiro, essa diferença é expressa neste apêndice como o EAM entre um dado classificador, treinado com apenas um modelo ("I") ou com ambos os modelos de compressores ("A"), e a estimação não supervisionada.

A comparação apresentada na Tabela 11 foi obtida considerando apenas a estimação do amaciamento em unidades do Modelo A. Em termos do EAM para todos os ensaios, o modelo de floresta aleatória apresentou o melhor resultado, com EAM de 26,35% quando o classificador é treinado com ambos os modelos de compressor. Conforme descrito na Seção 3.3.1, a Unidade A2 compõe o conjunto de teste do classificador, e foi a única das unidades do Modelo A na qual o EAM foi menor quando o classificador é treinado somente com compressores do mesmo modelo. Nessa unidade, os melhores resultados foram observados com os classificadores por regressão linear e K-VMP. Apesar de o K-VMP ter apresentado também os melhores resultados em outros dois casos (Unidade A3 com treinamento pelo Modelo A e Unidade A4 com treinamento por ambos os modelos), o EAM desse classificador quando considerando todas as unidades ainda foi significativamente maior do que o do classificador por floresta aleatória.

A Tabela 11 apresenta os resultados obtidos considerando a estimação do amaciamento em unidades do Modelo B. Assim como no Modelo A, o classificador por floresta aleatória apresentou o melhor resultado geral, com EAM de 12,53% e de 14,29% quando treinado com unidades do mesmo modelo e com ambos os modelos, respectivamente. Porém, ao contrário do Modelo A, todas as unidades exceto a Unidade B6 apresentaram menor erro quando treinados apenas com compressores do mesmo modelo, sugerindo que essas unidades já estão bem representadas no conjunto de treino, e que a inclusão das unidades do Modelo A no treino prejudica a capacidade de especialização do modelo. A maioria dos classificadores obteve o melhor resultado em pelo menos um dos casos avaliados, exceto os classificadores AdaBoost, K-VMP e PMC. Parte do desempenho inferior desses métodos pode ser atribuída à utilização de modelos subótimos, já que, conforme descrito na Seção 3.3.2.1, o processo de otimização não pôde ser concluído para esses três classificadores. Ainda assim, nota-se que o processo de otimização do melhor classificador observado (floresta aleatória) também não foi concluído, sugerindo que os resultados inferiores dos classificadores previamente citados também derivam de limitações dos próprios modelos de aprendizado.

Por fim, a Tabela 13 apresenta os resultados dividindo o conjunto não supervisionado por método de agrupamento e comparando-os com os classificadores semissupervisionados treinados com ambos os modelos de compressor. Os conjuntos com agrupamento por *k*-médias

Tabela 11 – EAM entre os classificadores semisupervisionados e o conjunto não supervisionado em compressores do Modelo A considerando todos os métodos de agrupamento.

Classificador	A1		A2		A3		A4		Total	
	I	A	I	A	I	A	I	A	I	A
Regressão logística	57,65	18,4	35,51	36,67	15,35	12,82	39,43	42,05	36,99	27,49
MVS linear	66,72	18,77	37,21	37,57	32,60	16,12	44,84	42,14	45,34	28,65
Bayes ingênuo	66,71	44,40	37,06	51,30	26,12	74,92	44,85	65,88	43,69	59,12
ADQ	65,97	21,58	37,44	38,78	17,82	15,67	43,70	45,21	41,23	30,31
Árvore de decisão	53,28	13,83	39,64	51,30	15,84	3,25	28,39	39,75	34,29	27,03
Floresta aleatória	49,45	7,32	37,57	51,31	13,27	2,83	27,12	43,94	31,85	26,35
AdaBoost	52,42	24,78	39,05	41,63	28,13	21,19	36,63	38,51	39,06	31,53
K-VMP	66,71	33,00	35,37	54,73	5,68	62,94	44,85	10,06	38,15	40,18
MVS-FBR	63,08	42,08	37,79	47,42	17,57	26,22	41,84	33,11	40,07	37,21
PMC	66,71	45,60	36,34	45,03	12,74	51,87	44,68	41,64	40,12	46,04

Tabela 12 – EAM entre os classificadores semisupervisionados e o conjunto não supervisionado em compressores do Modelo B considerando todos os métodos de agrupamento.

Classificador	B1		B2		B3		B4		B5		B6		Total	
	I	A	I	A	I	A	I	A	I	A	I	A	I	A
Regressão logística	31,33	9,04	33,94	8,59	35,09	19,80	34,27	18,93	35,26	14,12	32,51	27,89	33,73	16,39
MVS linear	8,25	13,72	77,04	15,85	40,57	21,39	32,51	20,39	21,92	18,68	28,25	28,96	34,76	19,83
Bayes ingênuo	85,17	85,18	13,17	80,59	6,26	73,18	26,19	74,09	8,09	80,31	30,00	64,82	28,15	76,36
ADQ	8,19	9,97	12,18	80,46	7,87	21,79	19,10	20,87	7,04	14,67	28,69	29,39	13,84	29,53
Árvore de decisão	8,88	12,41	9,84	29,70	7,60	19,55	19,52	18,01	7,78	1,37	29,15	33,07	13,79	19,02
Floresta aleatória	8,20	2,57	5,18	18,94	9,00	18,94	19,03	16,05	5,40	2,50	28,38	26,76	12,53	14,29
AdaBoost	16,90	27,56	16,32	27,30	17,28	31,10	22,60	29,36	16,22	30,77	29,93	31,99	19,88	29,68
K-VMP	10,25	85,44	10,68	12,60	21,81	32,67	17,31	77,14	15,85	15,04	30,36	62,29	17,71	47,53
MVS-FBR	85,18	9,75	33,61	14,25	18,35	29,00	12,91	41,03	13,70	12,36	29,19	14,33	32,16	20,12
PMC	11,38	43,61	11,32	41,13	9,91	42,61	21,09	41,57	7,97	44,32	30,72	35,80	15,40	41,51

e por kernel k -médias com núcleo FBR-M apresentaram menor diferença quando comparados com o classificador por floresta aleatória, da mesma forma que o conjunto formado por todos os métodos de agrupamento. O único caso em que a floresta aleatória não apresentou o menor EAM foi no caso do conjunto formado por modelos de agrupamento por kernel k -médias com núcleo FBR, o qual foi mais próximo do classificador por regressão logística. Ainda assim, os resultados mais próximos foram obtidos entre o conjunto não supervisionado com todos os métodos de agrupamento e o classificador autotreinado por floresta aleatória. Esse resultado corrobora as conclusões apresentadas na Seção 3.5, sugerindo que o conjunto com múltiplos métodos de agrupamento é uma boa alternativa para estimação da transição entre estados tribológicos e que o classificador com floresta aleatória é, dentre os classificadores avaliados, o mais adequado para replicar de forma on-line os resultados do conjunto não supervisionado.

Tabela 13 – EAM total entre os classificadores semisupervisionados treinado com ambos os modelos de compressor e conjuntos não supervisionados com diferentes métodos de agrupamento.

Classificador	k -médias	Núcleo FBR	Núcleo FBR-M	Todos
Regressão logística	22,22	19,70	22,79	20,83
MVS linear	25,26	22,69	24,27	23,36
Bayes ingênuo	67,46	71,65	67,52	69,47
ADQ	30,81	28,64	31,88	29,84
Árvore de decisão	23,68	23,05	22,08	22,23
Floresta aleatória	20,73	20,79	19,56	19,12
AdaBoost	31,88	30,04	28,94	30,42
K-VMP	44,46	45,98	43,41	44,59
MVS-FBR	28,80	26,19	27,09	26,96
PMC	43,60	42,97	40,93	43,32