



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS FLORIANÓPOLIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE AUTOMAÇÃO E
SISTEMAS

Mateus Abreu de Andrade

**Método de estimação on-line da capacitância do barramento CC em inversores
de frequência trifásicos**

Florianópolis
2024

Mateus Abreu de Andrade

**Método de estimação on-line da capacitância do barramento CC em inversores
de frequência trifásicos**

Dissertação submetida ao Programa de Pós-Graduação
em Engenharia de Automação e Sistemas da Uni-
versidade Federal de Santa Catarina para a obten-
ção do título de mestre em Engenharia de Automa-
ção e Sistemas.

Orientador: Prof. Rodolfo César Costa Flesch, Dr.

Florianópolis
2024

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

Andrade, Mateus Abreu

Método de estimação on-line da capacitância do barramento
CC em inversores de frequência trifásicos / Mateus Abreu
Andrade ; orientador, Rodolfo César Costa Flesch, 2024.
84 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Engenharia de Automação e Sistemas, Florianópolis, 2024.

Inclui referências.

1. Engenharia de Automação e Sistemas. 2. Estimação de
vida útil. 3. Eletrônica de potência. 4. Capacitores
eletrolíticos. 5. Redes neurais artificiais. I. Flesch,
Rodolfo César Costa. II. Universidade Federal de Santa
Catarina. Programa de Pós-Graduação em Engenharia de
Automação e Sistemas. III. Título.

Mateus Abreu de Andrade

Método de estimação on-line da capacitância do barramento CC em inversores de frequência trifásicos

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

Prof. Daniel Ferreira Coutinho, Dr.
Departamento de Automação e Sistemas

Prof. Marcelo Ricardo Stemmer, Dr.
Departamento de Automação e Sistemas

Antonio Luiz Schalata Pacheco, Dr.
Instituto de Eletrônica de Potência

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

Coordenação do Programa de
Pós-Graduação

Prof. Rodolfo César Costa Flesch, Dr.
Orientador

Florianópolis, 2024.

Este trabalho é dedicado aos meus queridos familiares,
amigos e colegas de trabalho.

AGRADECIMENTOS

Aos meus familiares, em especial à minha mãe, pelo suporte, incentivo e apoio.

Ao professor orientador, Rodolfo C. C. Flesch, pela paciência e oportunidade de poder me guiar neste trabalho, com análises críticas essenciais para o desenvolvimento do método proposto e resultados obtidos.

Aos colegas de trabalho, Odair Rosa, Daniel Borba, Murilo Koerich e César Lafuente pelo direto envolvimento com o trabalho, exemplos de competência profissional e motivação. Em especial ao Deivid Faria pelas diversas discussões e estudos sobre confiabilidade, degradação de componentes eletrônicos e evolução dos resultados do método proposto com as estratégias avaliadas e utilizadas.

À WEG S. A., pela oportunidade de utilizar todos os laboratórios, equipamentos, produtos e componentes necessários para o desenvolvimento deste trabalho. Caso o acesso a esses recursos não fosse cedido, inviabilizaria o desenvolvimento do presente trabalho.

A todos os meus amigos, em especial ao Antônio Bordini, Cláudio Gnoatto, Luan Fiorio e à Carina Yoshimura pelo suporte. O contato com vocês durante todo esse processo foi essencial à motivação e dedicação necessárias para a conclusão desta etapa muito importante na minha vida.

*"The proper function of man is to live, not to exist.
I shall not waste my days in trying to prolong them.
I shall use my time."
(LONDON, 1916)*

RESUMO

Capacitores eletrolíticos do barramento de corrente contínua (CC) são uma das principais fontes de falhas em conversores eletrônicos de potência. Métodos tradicionais de monitoração desses capacitores requerem componentes adicionais, que aumentam o custo total do projeto. O presente trabalho propõe e valida experimentalmente um método alternativo que requer apenas implementações de software e utiliza rede neural artificial (RNA) para realizar a estimativa da capacitância do barramento CC em inversores de frequência trifásicos com retificador a diodos. Utilizando como dados de entrada grandezas no domínio do tempo, a RNA é treinada com dados obtidos de uma jiga de capacitores desenvolvida e avaliada com amostras de capacitores degradadas por sobretemperatura. Os experimentos foram realizados em diversas condições de operação e em todas elas o erro absoluto de predição foi menor que 2,67%, mostrando que o método proposto é capaz de monitorar o nível de degradação do banco de capacitores do barramento CC de inversores de frequência.

Palavras-chave: Monitoração de vida útil; Eletrônica de potência; Capacitores eletrolíticos; Estimativa de vida útil; Redes neurais artificiais.

ABSTRACT

Direct current (DC) link electrolytic capacitors are one of the components most prone to fail in power electronics converters. The traditional capacitor condition monitoring methods require extra hardware, which translates as an increased cost. This work proposes and experimentally evaluates an alternative software-based condition monitoring method that uses an artificial neural network (ANN) to predict the capacitance of the DC-link capacitor bank in three-phase front-end diode rectifier motor drives. Based on time-domain parameters, the ANN is trained with a printed circuit board capacitor jig and evaluated with aged samples. Experiments were conducted in several operating conditions and the absolute prediction errors were all less than 2.67%, showing that the proposed method is able to monitor the degradation level of the dc-link capacitor bank in variable frequency drives.

Keywords: Condition monitoring. Power electronics. Electrolytic capacitors. Degradation estimation. Artificial neural networks.

LISTA DE FIGURAS

Figura 1 – Respostas de vida útil típica de sistemas eletrônicos de potência.	17
Figura 2 – Respostas sobre componentes/subsistemas mais suscetíveis a falhas em campo.	18
Figura 3 – Taxa de proporção dos componentes mais importantes para pesquisa de confiabilidade.	19
Figura 4 – Comparação de desempenho das principais tecnologias de capacitores utilizados em barramento CC.	20
Figura 5 – Curva de degradação da capacitância ao longo do tempo de operação.	20
Figura 6 – Classificação dos métodos de monitoração de condição de capacitores.	21
Figura 7 – Diagrama de decisão de métodos de monitoração do barramento CC.	22
Figura 8 – Representação de esquema de injeção de sinal para estimação de capacitância e R_{SE} do barramento CC	23
Figura 9 – Diagrama simplificado de um inversor de frequência.	28
Figura 10 – Formas de onda da Ponte de Graetz.	30
Figura 11 – Flutuações de tensão e de corrente no barramento CC.	30
Figura 12 – Estrutura do capacitor eletrolítico.	31
Figura 13 – Modelo simplificado equivalente de capacitores.	32
Figura 14 – Impedância na frequência de capacitores.	33
Figura 15 – Representação da estrutura equivalente com resistores e capacitores de um Al-Cap.	34
Figura 16 – Capacitância por temperatura em 300 Hz e 10 kHz.	34
Figura 17 – Capacitância e R_{SE} por temperatura em 10 kHz.	35
Figura 18 – Degradação de capacitância por sobretemperatura a 105 °C para capacitância nominal de 2200 μ F.	37
Figura 19 – Diagrama de blocos do experimento de degradação por sobretensão.	37
Figura 20 – Diminuição de capacitância no tempo para degradação por sobretensão.	38
Figura 21 – Representação de redes neurais: (a) biológica; (b) artificial.	39
Figura 22 – Representação da Equação (2) e Equação (3)	39
Figura 23 – Representação da estrutura de uma MLP.	41
Figura 24 – Representação de funções de ativação não lineares.	45
Figura 25 – Representação das funções de ativação lineares para valores positivos.	45
Figura 26 – Representação do algoritmo de retropropagação para o cálculo de $w_{55}^{(2)}$	49
Figura 27 – Modelos de RNA com: (a) subajuste, (b) treinamento balanceado e (c) sobreajuste.	50

Figura 28 – Representação da divisão dos dados disponíveis em conjuntos de treinamento, validação e teste.	51
Figura 29 – Representação da divisão dos dados disponíveis para validação cruzada <i>k-fold</i> com $K = 5$	52
Figura 30 – Técnica de parada antecipada para evitar sobreajuste.	53
Figura 31 – Parâmetros dependentes da variação de capacitância e de carga.	55
Figura 32 – Estrutura de blocos para obtenção da tensão RMS de oscilação do barramento CC.	58
Figura 33 – Ilustração de cálculo do valor instantâneo da tensão de oscilação do barramento CC.	58
Figura 34 – Banco capacitivo original e modificado com PCI.	59
Figura 35 – Banco capacitivo modificado com PCI fora da amostra utilizada.	59
Figura 36 – Conjunto de dados de treinamento.	61
Figura 37 – Mapa de calor de correlação linear das variáveis de entrada e de saída.	62
Figura 38 – Vida útil em função da temperatura ambiente e da ondulação de corrente.	64
Figura 39 – Degradação das amostras de capacitores no tempo em câmara térmica.	66
Figura 40 – Banco capacitivo de amostras degradadas de 296,47 μF e 255,27 μF	67
Figura 41 – Conjunto de dados de teste.	68
Figura 42 – Coeficiente de determinação com e sem validação cruzada para função de ativação para otimizador Adam.	71
Figura 43 – Coeficiente de determinação com e sem validação cruzada para função de ativação para otimizador RMS.	72
Figura 44 – Coeficiente de determinação e erro de predição para o conjunto de teste da MLP escolhida para a utilização no método.	74

LISTA DE TABELAS

Tabela 1 – Especificações do inversor de frequência utilizado.	56
Tabela 2 – Especificações do motor utilizado.	56
Tabela 3 – Especificações do capacitor.	63
Tabela 4 – Informações de vida útil do capacitor.	63
Tabela 5 – Capacitância das amostras após a degradação acelerada.	65
Tabela 6 – Comparativo de desempenho das configurações de MLP com o otimizador Adam.	70
Tabela 7 – Comparativo de desempenho das configurações de MLP com o otimizador RMSprop.	70
Tabela 8 – Erros absolutos de predição para o banco capacitivo de 255,27 μF	73
Tabela 9 – Erros absolutos de predição para o banco capacitivo de 296,47 μF	75
Tabela 10 – Erros absolutos de predição para o banco capacitivo de 330,00 μF	75

LISTA DE ABREVIATURAS E SIGLAS

Al-Cap	Capacitor Eletrolítico de Alumínio
CA	Corrente Alternada
CC	Corrente Contínua
ELU	Unidade linear exponencial, do inglês <i>Exponential Linear Unit</i>
FDV	Fim de Vida
MLP	Perceptron de múltiplas camadas, do inglês <i>Multilayer Perceptron</i>
MSE	Erro quadrático médio, do inglês <i>Mean Squared Error</i>
PCI	Placa de Circuito Impresso
PWM	Modulação por largura de pulso, do inglês <i>Pulse Width Modulation</i>
RELU	Unidade linear retificada, do inglês <i>Rectified Linear Unit</i>
RMS	Valor eficaz, do inglês <i>Root Mean Square</i>
RNA	Rede Neural Artificial
SELU	Unidade linear exponencial escalada, do inglês <i>Scaled Exponential Linear Unit</i>
tanh	Função tangente hiperbólica

LISTA DE SÍMBOLOS

R_{SE}	Resistência série equivalente
R^2	Coeficiente de determinação
C_S	Capacitância série
L_{SE}	Indutância série equivalente
f_{cf}	Frequência da componente fundamental
T	Período
f_{DAQ}	Frequência do sistema de aquisição de dados
X_n	Número de amostras
Δt	Janela de tempo

SUMÁRIO

1	INTRODUÇÃO	16
1.1	COMPONENTE DE ESTUDO	17
1.2	REVISÃO DE MÉTODOS DE MONITORAÇÃO	19
1.3	OBJETIVOS	24
1.3.1	Objetivo geral	24
1.3.2	Objetivos específicos	24
1.4	PUBLICAÇÕES RESULTANTES	24
1.5	ESTRUTURA DO DOCUMENTO	24
2	FUNDAMENTAÇÃO TEÓRICA	26
2.1	MOTORES ELÉTRICOS	26
2.2	INVERSOR DE FREQUÊNCIA	27
2.2.1	Diodo retificador	29
2.2.2	Flutuação de tensão do barramento CC	29
2.3	CAPACITORES ELETROLÍTICOS	31
2.3.1	Estrutura	31
2.3.2	Modelo equivalente	32
2.3.3	Efeito de temperatura e frequência	33
2.3.4	Modos de falha	35
2.3.5	Modos de degradação acelerada	35
2.4	<i>MULTILAYER PERCEPTRON</i>	38
2.4.1	Propagação direta	40
2.4.2	Função de ativação	42
2.4.3	Retropropagação	46
2.4.4	Sobreajuste e subajuste	49
2.4.4.1	Validação cruzada	50
2.4.4.2	Parada antecipada	52
2.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO	52
3	DADOS DE TREINAMENTO E DE TESTE	54
3.1	ANÁLISE DAS GRANDEZAS	54
3.2	CONFIGURAÇÃO DO SISTEMA	55
3.3	MEDIÇÃO E USO DAS GRANDEZAS	56
3.3.1	Tensão RMS de oscilação do barramento CC	57
3.3.2	Capacitância do barramento CC	57
3.4	DADOS DE TREINAMENTO	60
3.5	DADOS DE TESTE	62
3.5.1	Características do capacitor original	62
3.5.2	Métodos de degradação acelerada	63

3.5.3	Aquisição dos dados de teste	65
3.6	CONSIDERAÇÕES FINAIS DO CAPÍTULO	66
4	AVALIAÇÃO DAS REDES E ANÁLISE DE RESULTADOS	69
4.1	TREINAMENTO DA MLP	69
4.2	VALIDAÇÃO CRUZADA	70
4.3	RESULTADOS EXPERIMENTAIS	73
4.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO	74
5	CONSIDERAÇÕES FINAIS	76
	REFERÊNCIAS	78

1 INTRODUÇÃO

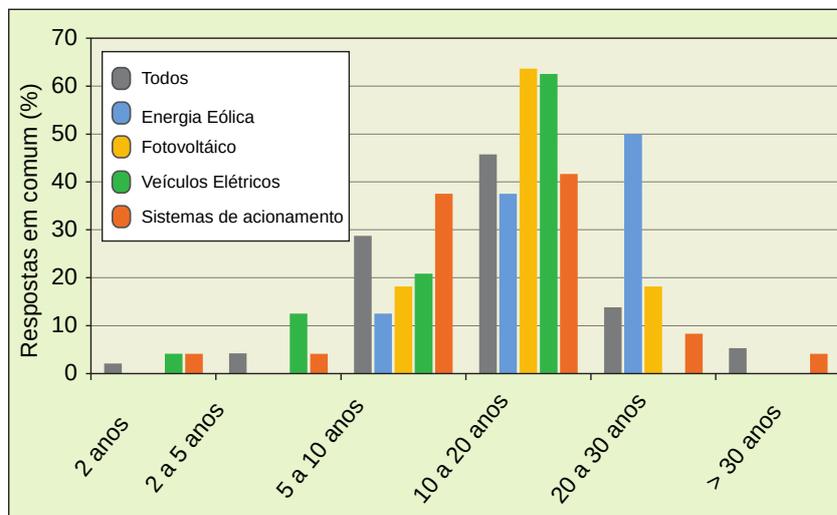
Sistemas eletrônicos de potência são elementos relevantes para o contínuo desenvolvimento em aplicações de diversas áreas emergentes, tais como sistemas de acionamento, transporte elétrico, energias renováveis e equipamentos na área da saúde (WANG; LISERRE; BLAABJERG, 2013). A sua operação confiável e segura, segundo o tempo de vida útil projetado, é um requisito importante para evitar que sistemas maiores deixem de operar por conta de eventuais falhas nos módulos de potência (KASSAKIAN; JAHNS, 2013). Todavia, o maior desafio no que se refere à confiabilidade de sistemas eletrônicos se encontra nas particularidades dos diferentes estressores para as várias áreas de aplicação, como: temperatura, umidade, vibração, radiação e interferência eletromagnética (BAKER *et al.*, 2014).

Diversos componentes em sistemas eletrônicos de potência ao falharem resultam não só em elevados custos de manutenção, mas, principalmente, na inoperação do sistema em riscos de segurança. Os principais desses componentes são semicondutores, capacitores, elementos magnéticos, circuitos integrados e sensores. De modo a identificar os componentes mais críticos, foi realizada uma pesquisa voltada à indústria em colaboração com as empresas pertencentes ao Centro de Eletrônica de Potência da Europa (FALCK *et al.*, 2018). Inicialmente, foram questionadas as principais áreas de interesse e tempos de vida útil projetado das soluções desenvolvidas pelas empresas participantes. É possível observar na Figura 1 que vida útil abaixo de cinco anos não é uma prática comum, porém, uma meta de cinco a vinte anos é predominante para as áreas avaliadas. Os resultados dessa pesquisa realizada em 2018 concordam com um estudo realizado em 2011 em relação à confiabilidade de sistemas eletrônicos por Shaoyong Yang *et al.* (2011) e os tempos de vida útil identificados por Wang *et al.* (2013). Portanto, é possível inferir que as expectativas de vida útil de sistemas eletrônicos de potência em suas diferentes áreas de aplicação não tiveram mudanças significativas na última década.

Outro tópico investigado por Falck *et al.* (2018) foi em relação aos elementos em sistemas eletrônicos de potência mais suscetíveis a falha, no qual os mais críticos foram semicondutores e capacitores eletrolíticos, conforme apresentado na Figura 2. Na sequência, estão os capacitores de filme, capacitores cerâmicos, semicondutores de interface, componentes eletromecânicos, dispositivos de proteção, sistemas de refrigeração e ventilação. Em relação às diferentes áreas de aplicação, os resultados apresentam pouca diferença, porém os capacitores se destacam como elementos de falha em veículos elétricos, elementos mecânicos e eletromecânicos (FALCK *et al.*, 2018).

Quais componentes seriam cruciais para estudos de confiabilidade foi outra questão avaliada por Falck *et al.* (2018), tomando como os principais agentes os es-

Figura 1 – Respostas de vida útil típica de sistemas eletrônicos de potência.



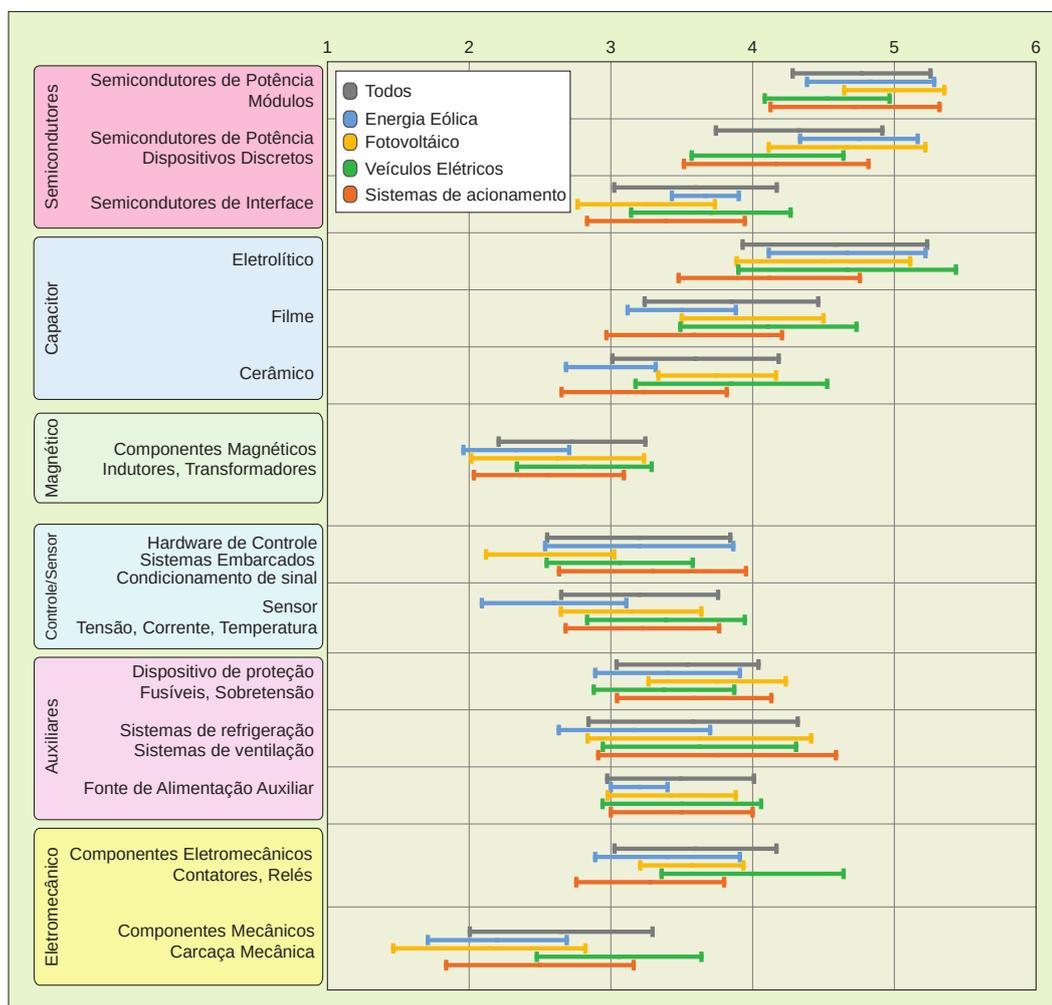
Fonte: Adaptado de Falck *et al.* (2018)

tressores, mecanismos e modos de falha. Conforme apresentado na Figura 3, os semicondutores de potência e capacitores formam a maioria dos componentes com maior incidência de falha. Dos capacitores citados nas repostas, os eletrolíticos e os de filme foram os mais representativos. Outro fato relevante é que, em algumas das repostas, não foi indicado um componente em específico, mas sugerido o estudo para aplicações expostas a ambientes agressivos, em especial aqueles com alta temperatura ou umidade.

1.1 COMPONENTE DE ESTUDO

Como base para definição do componente cuja vida útil deseja-se monitorar, utilizou-se a combinação dos resultados anteriormente apresentados e discutidos dos tópicos abordados pela pesquisa, como: vida útil, estressores críticos, componentes ou subsistemas mais suscetíveis a falha em campo, componentes mais importantes para pesquisa e abordagens ou métodos para melhorar a confiabilidade. Dessa forma, foram escolhidos os capacitores eletrolíticos de alumínio (Al-Cap) utilizados no barramento de Corrente Contínua (CC) de inversores de frequência industriais trifásicos de baixa tensão com retificador a diodos para monitoração de forma on-line, tendo a capacitância como critério de vida útil por meio de uma solução totalmente em software utilizando grandezas já medidas em inversores comerciais. Essas características são atrativas para aplicações na indústria, já que apenas 13% dos participantes da pesquisa referenciada na seção anterior acreditam que a atual quantidade e foco das linhas de pesquisa nessa área não são adequadas para as necessidades de aplicação

Figura 2 – Respostas sobre componentes/subsistemas mais suscetíveis a falhas em campo.

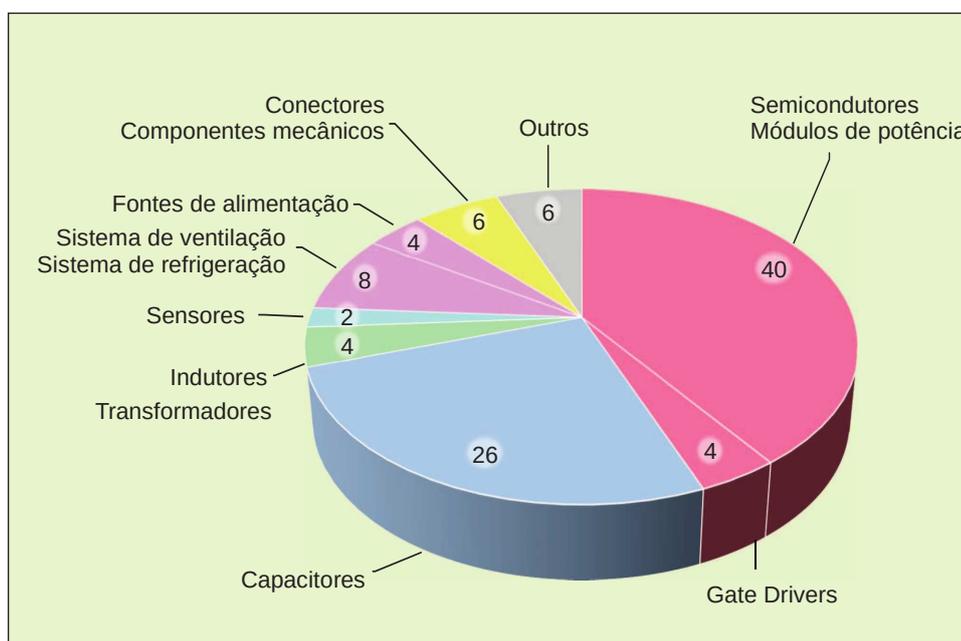


Fonte: Adaptado de Falck *et al.* (2018)

na indústria (FALCK *et al.*, 2018).

Al-Cap, capacitores de filme de polipropileno metalizado e capacitores cerâmicos multicamadas são utilizados em barramento CC para minimizar a ondulação de tensão e balancear as diferenças instantâneas de energia entre a fonte e a carga. A escolha por Al-Cap em conversores de frequência se deve pela sua alta densidade energética e menor custo por joule, entretanto, são os que apresentam menor índice de confiabilidade, de acordo com Wang e Blaabjerg (2014) e conforme ilustrado na Figura 4. Isso se deve principalmente à natural elevação de temperatura provocada pela circulação de corrente através da sua Resistência série equivalente (R_{SE}), tendo como consequência a evaporação do eletrólito e as reações eletroquímicas que resultam na degradação da camada de óxido e diminuição da capacitância (WANG; BLAABJERG, 2014). Portanto, é pertinente a monitoração da saúde dos Al-Cap, já que sua falha não

Figura 3 – Taxa de proporção dos componentes mais importantes para pesquisa de confiabilidade.



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

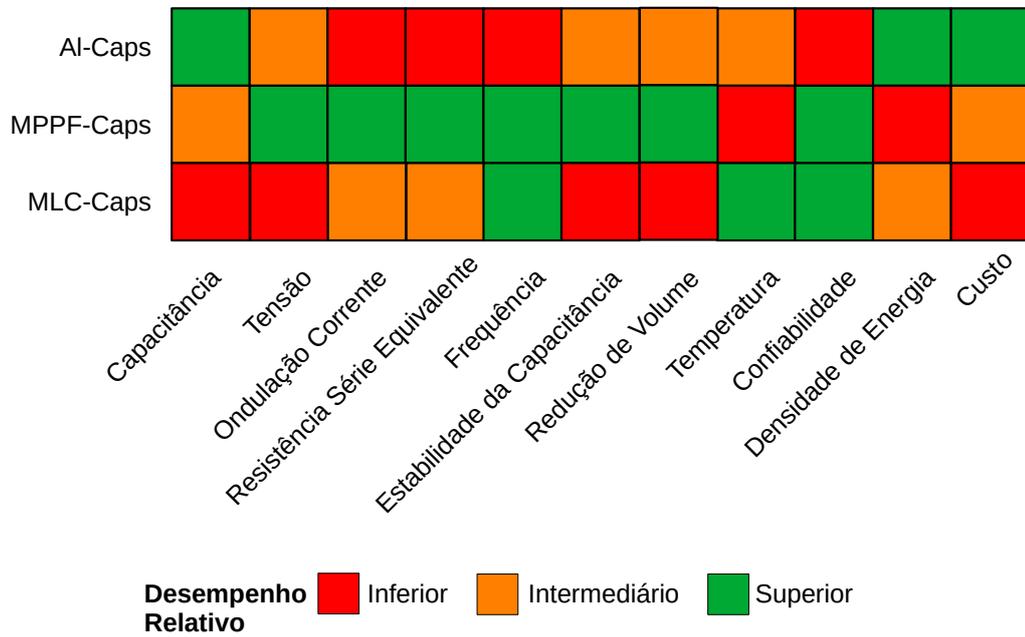
só afeta diretamente a operação segura de todo o sistema, mas principalmente pode provocar grandes perdas financeiras.

Em relação à escolha da capacitância como grandeza de monitoração e estimação da vida útil, a mesma se justifica por um critério amplamente aceito para o fim de vida de Al-Cap ser a redução de 20% do seu valor inicial (LAHYANI *et al.*, 1998). O intervalo de monitoração corresponde ao valor inicial e o de Fim De Vida (FDV), conforme ilustrado na Figura 5, em que a escolha do valor para FDV é baseado em dois aspectos: a degradação do capacitor se torna consideravelmente rápida após atingir tal valor e o sistema eletrônico de potência não irá funcionar adequadamente nestas condições (SOLIMAN; WANG; BLAABJERG, 2016). Além dos aspectos de confiabilidade, como as perdas listadas, as chances de ruptura e explosão aumentam quando se opera em condições que extrapolam o FDV (LAHYANI *et al.*, 1998).

1.2 REVISÃO DE MÉTODOS DE MONITORAÇÃO

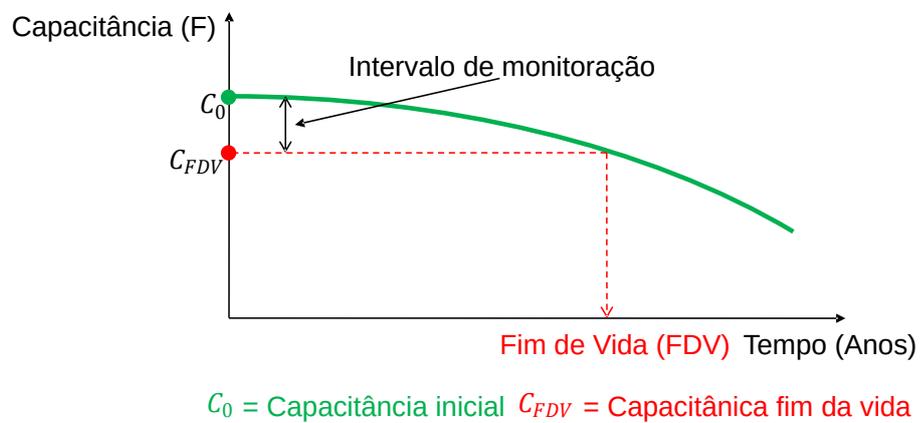
Como critério para a determinação do método de monitoração da capacitância do barramento CC por uma solução totalmente em software, tomou-se como base as análises realizadas por Soliman, Wang e Blaabjerg (2016) e Zhao *et al.* (2020) dos métodos desenvolvidos nessa área nas últimas duas décadas para conversores eletrônicos de potência. É importante ressaltar que não só na pesquisa anteriormente

Figura 4 – Comparação de desempenho das principais tecnologias de capacitores utilizados em barramento CC.



Fonte: Adaptado de Wang e Blaabjerg (2014)

Figura 5 – Curva de degradação da capacitância ao longo do tempo de operação.

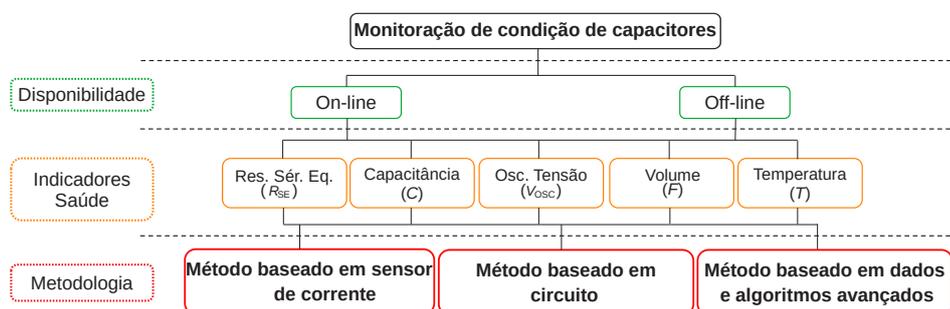


Fonte: Adaptado de Soliman *et al.* (2017b)

apresentada em Falck *et al.* (2018), mas também nos estudos apresentados por Soliman, Wang e Blaabjerg (2016) e Zhao *et al.* (2020) enfatiza-se o fato de grande parte dos métodos desenvolvidos serem dificilmente adotados pela indústria por conta da sua complexidade, aumento de custo para o produto e outros problemas relevantes das estratégias utilizadas.

Para realizar a análise dos métodos de monitoração de capacitores, os mesmos são classificados em três perspectivas, conforme apresentado na Figura 6. A primeira perspectiva é a disponibilidade. Se o indicador de saúde do componente pode ser obtido durante a sua operação normal, o método é classificado como on-line e, caso seja necessária uma interrupção, ele é classificado como off-line. A segunda perspectiva está relacionada ao tipo de indicador de saúde utilizado como base para o método. Por fim, a terceira perspectiva avalia os métodos para se obter o indicador em específico, os quais estão divididos em três categorias: método baseado em sensor de oscilação de corrente, método baseado em modelo de circuito e método baseado em dados e algoritmos avançados.

Figura 6 – Classificação dos métodos de monitoração de condição de capacitores.

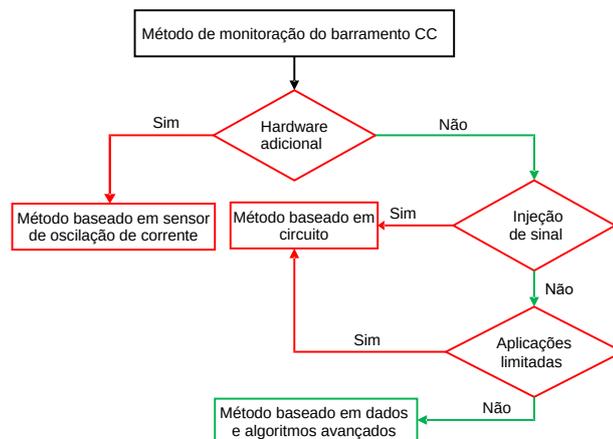


Fonte: Adaptado de Soliman, Wang e Blaabjerg (2016)

De modo a determinar a classificação do método desenvolvido neste trabalho, fez-se uso de uma diagrama de decisão, conforme Figura 7, segundo as seguintes perspectivas: disponibilidade, indicadores de saúde e metodologias apresentados na Figura 6. No primeiro nó, o critério avaliado é a necessidade ou não de hardware adicional. A sua não necessidade é um grande atrativo para a indústria, por não só poder ser aplicado para novos produtos, mas para os que já estão em campo nas suas diferentes aplicações e tempo de uso por meio de atualização de software. Logo, dado que uma das prioridades é a aplicação na indústria, optou-se pelo desenvolvimento de um método que não necessitasse de hardware adicional.

Uma vez que não se deseja utilizar hardware adicional, os próximos nós diferenciam a necessidade de injeção de sinal ou se estão limitados a aplicações específicas, para determinar se o método é baseado em circuito. Para esses tipos de métodos em

Figura 7 – Diagrama de decisão de métodos de monitoração do barramento CC.

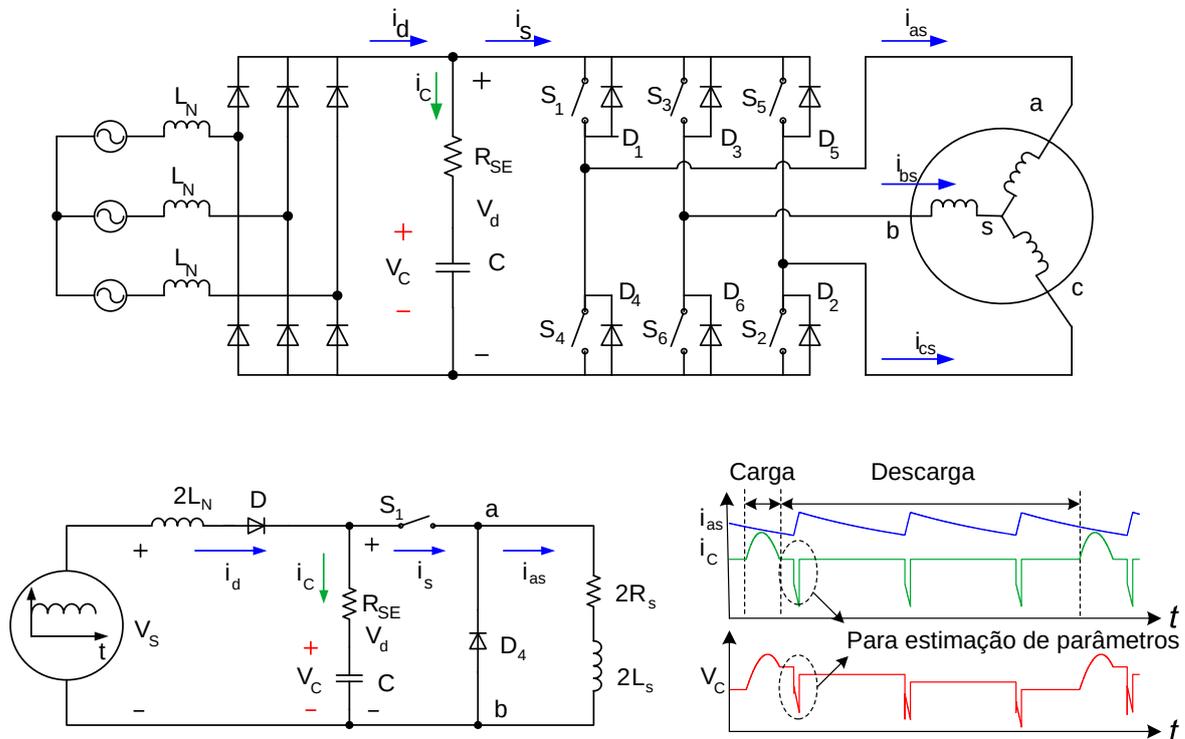


Fonte: Adaptado de Soliman *et al.* (2017b).

inversores de frequência, os estudos que se destacam diferenciam-se pela injeção do sinal de forma on-line ou off-line. Com o motor parado (off-line), em Sang Bin Lee *et al.* (2010) o método baseia-se em acionar a chave S_6 , e em S_1 aplicar um sinal de frequência e largura de pulso fixas para avaliar os sinais de tensão e corrente do barramento CC de modo a realizar a estimação da capacitância e R_{SE} , conforme o circuito equivalente ilustrado na Figura 8. A estimação dos parâmetros é realizada por meio dos picos de tensão e de corrente gerados durante os períodos de carga e de descarga dos capacitores do barramento CC nos enrolamentos a e b do motor de indução. Dado que os valores de capacitância e R_{SE} são sensíveis à temperatura, utiliza-se a estimação da resistência estática do motor em equilíbrio térmico para compensação das variáveis estimadas. A mesma estratégia é aplicada em Kwang-Woon Lee *et al.* (2008), porém, para sistemas monofásicos.

Já em Abo-Khalil e Dong-Choon Lee (2008) e Pu *et al.* (2009) (on-line), a tensão de entrada de Corrente Alternada CA é retificada pela técnica de modulação por largura de pulso (PWM, do inglês *Pulse Width Modulation*), o que permite que sejam estimados os parâmetros dos capacitores do barramento CC por meio da injeção de um sinal (CA) em Abo-Khalil e Dong-Choon Lee (2008) e de um sinal de tensão em Pu *et al.* (2009). Na condição de sem carga ou em modo regenerativo, um sinal de corrente CA com uma frequência menor que a da rede de entrada (30 Hz) é injetado no sinal PWM do retificador de modo a induzir oscilações de tensão no barramento CC. Feito isso, a tensão e a corrente CC nos capacitores em 30 Hz são extraídas e estima-se a capacitância por meio do algoritmo de mínimos quadrados recursivo. Portanto, apesar de hardware adicional não ser necessário para a aplicação do método, o mesmo não só fica limitado ao caso com retificadores com PWM, mas principalmente às condições de operar sem carga ou em modo regenerativo para estimação dos parâmetros.

Figura 8 – Representação de esquema de injeção de sinal para estimação de capacitância e R_{SE} do barramento CC



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

Em função das limitações dos métodos discutidos nos parágrafos anteriores, optou-se pela escolha dos métodos baseados em dados e algoritmos avançados para o desenvolvimento do método proposto neste trabalho, de modo a satisfazer os requisitos desejados e minimizar as limitações anteriormente apresentadas. Dos métodos já existentes nessa categoria, destacam-se os desenvolvidos por Soliman *et al.* (2017a) e Kamel, Biletskiy e Chang (2015), que utilizam Rede Neural Artificial (RNA) e Sistema de Inferência *Fuzzy* Adaptativo, respectivamente. Ambos os métodos partem primeiro da escolha das variáveis de entrada disponíveis que possuem maior correlação com o dado de saída que se deseja estimar - valores de tensão ou corrente de entrada, saída ou barramento CC para entrada e capacitância ou R_{SE} do barramento CC como saída. Feito isso, são realizadas a análise das condições de operação e a aquisição dos dados de treinamento – diferentes condições de carga, operação e valores de capacitância do barramento CC. Logo, o sistema é treinado com esses dados e otimizado para as suas diferentes configurações de acordo com o resultado dos indicadores de desempenho avaliados – coeficiente de determinação (R^2), erro quadrático médio e acurácia. Uma vez satisfeito o desempenho estabelecido, testa-se o sistema desenvolvido com dados não treinados e, caso a variável de saída não corresponda para

as condições de operação avaliadas, reinicia-se o processo com a análise crítica das variáveis de entrada escolhidas e condições de operação dos dados de treinamento.

1.3 OBJETIVOS

1.3.1 Objetivo geral

Considerando os requisitos desejados e análises realizadas neste capítulo, o objetivo geral desta pesquisa de dissertação é propor um método de estimação da vida útil de capacitores eletrolíticos em barramento CC em inversores de frequência industriais trifásicos de baixa tensão com retificador a diodos. Isso é feito por meio da estimação da sua capacitância com uso de uma RNA. Para a aplicação deste método, não há necessidade de hardware adicional ou condições de operação especiais consideradas invasivas para aplicações na indústria.

1.3.2 Objetivos específicos

De modo a cumprir o objetivo geral, os seguintes objetivos específicos são listados:

- estudar os efeitos da diminuição da capacitância em barramento CC de inversores de frequência industriais trifásicos de baixa tensão com retificador a diodos;
- estudar e desenvolver uma solução que permita a variação da capacitância do barramento CC dentro do intervalo de monitoração;
- estudar e aplicar métodos de degradação acelerada de capacitores eletrolíticos de alumínio;
- estudar e desenvolver diferentes estruturas de RNA para estimação de problemas de regressão;
- estudar e aplicar métodos de avaliação de desempenho e robustez de RNAs.

1.4 PUBLICAÇÕES RESULTANTES

Os resultados parciais obtidos durante o desenvolvimento deste trabalho foram publicados em formato de artigos no XVI Simpósio Brasileiro de Automação Inteligente (ANDRADE; FLESCHE; NAKIRIMOTO, 2023) e no XVII Congresso Brasileiro de Eletrônica de Potência (ANDRADE; FLESCHE, 2023).

1.5 ESTRUTURA DO DOCUMENTO

O presente trabalho é dividido em cinco capítulos. No Capítulo 2, é realizada a fundamentação teórica sobre os elementos e conceitos utilizados para a análise e

o desenvolvimento do método proposto. No Capítulo 3, são analisados os critérios e as considerações para a obtenção dos dados de treinamento. No Capítulo 4, são desenvolvidas diferentes propostas perceptron de multicamadas (MLP, do inglês *Multi-layer Perceptron*) e são avaliadas as suas limitações para a estimação da capacitância do barramento CC. Por fim, no Capítulo 5, são feitas as considerações finais e são apresentadas perspectivas a respeito do método proposto de acordo com as suas limitações e resultados obtidos.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta uma base teórica para a compreensão dos conceitos e das teorias mais relevantes para a análise e o desenvolvimento do método proposto. Inicia-se pela descrição dos dois principais componentes do sistema de potência, motores elétricos na Seção 2.1 e inversores de frequência na Seção 2.2, com apresentação dos seus principais elementos, do seu funcionamento e o comportamento do barramento CC para esse tipo de aplicação. Na sequência, apresentam-se as principais características mecânicas, elétricas e os modos de falha de AI-Cap na Seção 2.3. Por último, é feita uma breve descrição dos principais fundamentos sobre MLP na Seção 2.4, com a explicação dos elementos essenciais da sua estrutura, processo de treinamento e métricas utilizadas para avaliar o seu desempenho.

2.1 MOTORES ELÉTRICOS

Motores elétricos são utilizados para converter energia elétrica em energia mecânica. Normalmente trabalham utilizando a interação entre campos eletromagnéticos, porém, existem motores baseados em outros fenômenos eletromecânicos, como as forças eletrostáticas, mas que não são abordados neste trabalho. O princípio de funcionamento de um motor eletromagnético é a existência de uma força mecânica em todo fio que conduz corrente elétrica, quando imerso em um campo magnético, sendo essa força descrita pela Força de Lorentz, a qual é perpendicular ao fio e ao campo magnético (PETRUZELLA, 2013). O motor conta com um elemento giratório, o rotor, o qual gira porque os fios e o campo magnético ficam distribuídos de modo que um torque seja gerado sobre a linha central do rotor (PETRUZELLA, 2013). Em geral, os motores são classificados de acordo com o tipo de energia usada (CC ou CA) e o seu princípio de funcionamento. Nos parágrafos a seguir são apresentados os principais tipos de motores elétricos de corrente contínua e de corrente alternada.

Motores de corrente contínua precisam de uma fonte de CC, ou de um dispositivo que converta CA em CC para o seu acionamento. O motor de corrente contínua é composto de duas estruturas magnéticas: estator e rotor. O estator é composto de uma estrutura ferromagnética com polos salientes aos quais são enroladas as bobinas que formam o campo, ou de um ímã permanente. Já em motores tradicionais com escovas, o rotor é um eletroímã constituído de um núcleo de ferro com enrolamentos em sua superfície que são alimentados por um sistema mecânico de comutação. Esse sistema é formado por um comutador conectado aos enrolamentos do motor e escovas fixas que são ligadas aos terminais de alimentação (LOBOSCO; DIAS, 1988). O propósito do comutador é inverter a corrente na fase de rotação apropriada de forma a que o conjugado desenvolvido seja sempre na mesma direção. A necessidade de manutenção do conjunto escova e comutador encontrado em motores CC é relevante

se comparada à manutenção de motores de CA. Dessa forma, seu uso fica restrito a aplicações em que as exigências de controle de torque e velocidade compensem o seu custo elevado de instalação e manutenção, como em guindastes, transportadores e elevadores (PETRUZELLA, 2013). No que se refere a motores de corrente alternada, devido à distribuição da energia elétrica ser normalmente em CA, é a tecnologia de motor dominante atualmente, pois representa mais de 90% da capacidade de motores instalados (PETRUZELLA, 2013). Os principais tipos de motores de CA são os motores síncronos e os motores assíncronos de indução.

Como o nome sugere, motor síncrono funciona a uma velocidade constante desde a condição sem carga até a carga máxima. Assim como nos motores de indução, a velocidade de um motor síncrono é determinada pelo número de pares de polos e pela frequência de linha (FRANCHI, 2018). A sua operação se resume a aplicação de uma tensão CA nos enrolamentos do estator para produzir um campo magnético girante e a aplicação de tensão CC nos enrolamentos do rotor para gerar um segundo campo magnético (FRANCHI, 2018). Dessa forma, o rotor se comporta como um ímã e é atraído pelo campo rotativo do estator. Essa atração exerce um torque no rotor e o faz girar na velocidade síncrona do campo girante do estator. O rotor não necessita da indução magnética a partir do campo do estator para a sua excitação. Como resultado, o motor tem escorregamento zero em relação ao motor de indução, que requer escorregamento para produzir torque (PETRUZELLA, 2013).

Os motores CA assíncronos de indução mais usados, em sua grande maioria, têm a configuração gaiola de esquilo, assim chamada por causa da gaiola de alumínio ou de cobre embutida dentro do rotor de ferro laminado (PETRUZELLA, 2013). O seu funcionamento baseia-se no princípio da formação de campo magnético rotativo produzido no estator pela passagem da corrente alternada em suas bobinas, cujo fluxo, por efeito de sua variação, se desloca em volta do motor, gerando neste correntes induzidas que tendem a se opor ao campo rotativo. O motor em nenhuma hipótese atinge a velocidade do campo rotativo, pois, do contrário, não haveria geração de correntes induzidas (MAMEDE FILHO, 2007). Quando o motor está girando sem a presença de carga no eixo mecânico, o rotor desenvolve uma velocidade angular muito próxima à velocidade síncrona do campo girante do estator. Ao adicionar carga mecânica ao eixo, o rotor diminui a sua velocidade, diferença essa chamada de escorregamento. Portanto, tanto para controle de torque e velocidade, diversas estratégias de controles são utilizadas para compensar estes efeitos (MAMEDE FILHO, 2007).

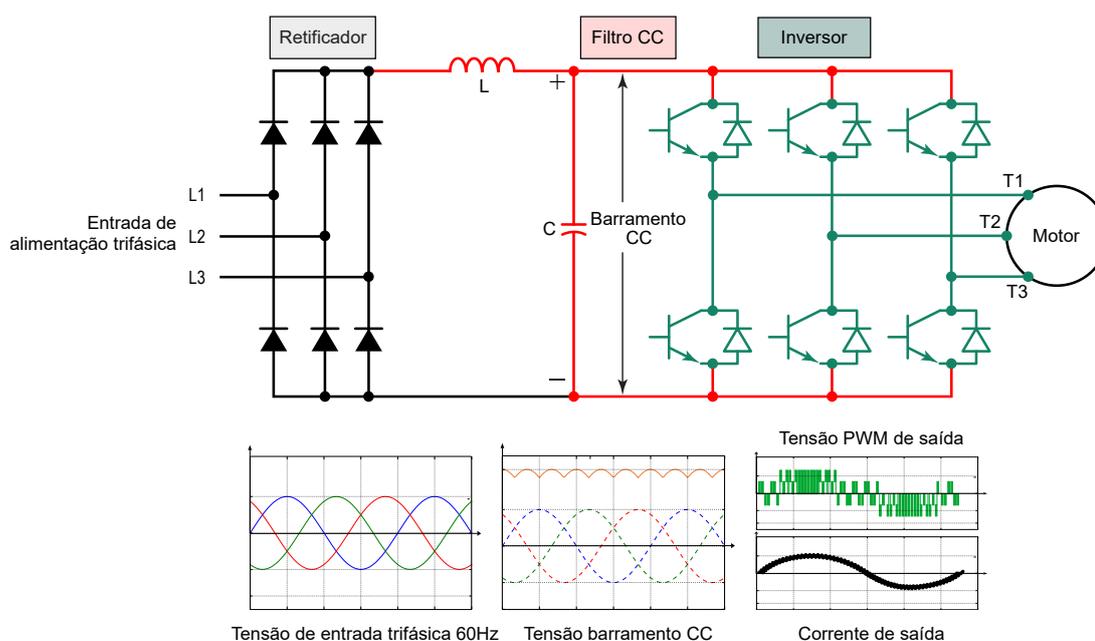
2.2 INVERSOR DE FREQUÊNCIA

O sistema de acionamento de velocidade de um motor CA é geralmente formado por um motor CA, um inversor de frequência e uma interface de operação. A unidade de acionamento de frequência variável do motor de saída, ou de velocidade

variável, é mais conhecida pelo nome inversor de frequência. Em geral, os motores trifásicos são preferidos em relação aos motores monofásicos, por conta da sua maior eficiência em potências maiores e não necessidade de circuito auxiliar para partida, então é mais comum encontrar comercialmente inversores trifásicos que monofásicos. Os motores projetados para velocidade fixa na tensão principal de operação são frequentemente utilizados, mas certas melhorias no projeto de motores padrão oferecem maior confiabilidade e melhor desempenho quando são acionados por inversores de frequência (PETRUZELLA, 2013). Apesar de o inversor de frequência ser responsável pela conversão da tensão CC em tensão CA, comercialmente é comum chamar o conjunto composto por inversor de frequência, retificador e barramento CC apenas de inversor. Essa nomenclatura também é a empregada neste trabalho. Desta forma, um diagrama simplificado de um inversor de frequência é mostrado na Figura 9, tendo os três principais componentes detalhados abaixo:

- Retificador: retifica a potência CA trifásica de entrada e a converte em CC;
- Filtro CC (barramento CC): suaviza a tensão CC retificada;
- Inversor: comuta a tensão CC ligando-a e desligando-a tão rapidamente que o motor recebe uma tensão pulsante que é semelhante a uma tensão CA. A taxa de comutação é controlada para variar a frequência da tensão CA equivalente aplicada ao motor.

Figura 9 – Diagrama simplificado de um inversor de frequência.



Fonte: Adaptado de Petruzella (2013)

Para se obter a velocidade síncrona de rotação de um motor de indução em

função da frequência de acionamento elétrico, pode-se empregar a relação dada por:

$$n_s = \frac{60f}{\frac{p}{2}} = \frac{120f}{p}, \quad (1)$$

na qual n_s é a velocidade síncrona de rotação do motor (em rotações por minuto), p é o número de polos do motor e f é a frequência de acionamento elétrico (em hertz). A constante 120 que aparece na Equação (1) é utilizada para converter as unidades (1 Hz equivale a 60 rpm) e para evitar usar o número de par de polos na equação, que é o que efetivamente define a relação entre as variáveis.

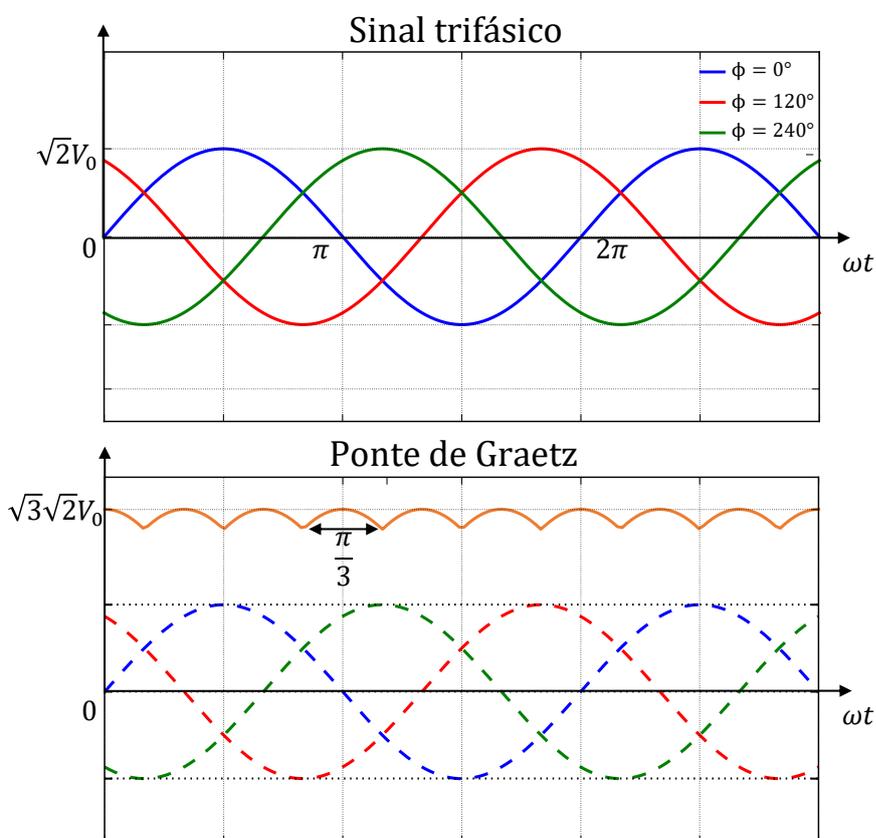
2.2.1 Diodo retificador

A retificação é o processo de conversão de CA para CC. Como os diodos permitem o fluxo de corrente em apenas um sentido, eles são usados como retificadores. Existem diversas maneiras de conectar os diodos para fazer um retificador que converta CA em CC (PETRUZELLA, 2013). Conforme apresentado no bloco retificador da Figura 9, a ponte de Graetz é uma das estruturas mais empregadas na indústria em inversores de frequência de alimentação trifásica, a qual pode ser considerada como uma associação série de dois retificadores trifásicos de ponto médio (BARBI, 2006). Ao observar a Figura 10, é possível estabelecer as seguintes conclusões a respeito da sua estrutura para um sinal trifásico de entrada defasado em 120° : cada diodo conduz durante um intervalo de 120° ; existem sempre dois diodos em condução, um no grupo positivo e outro no grupo negativo do conversor; ocorre uma comutação a cada 60° ; e a frequência da componente fundamental da tensão é igual a seis vezes a frequência da tensão de alimentação.

2.2.2 Flutuação de tensão do barramento CC

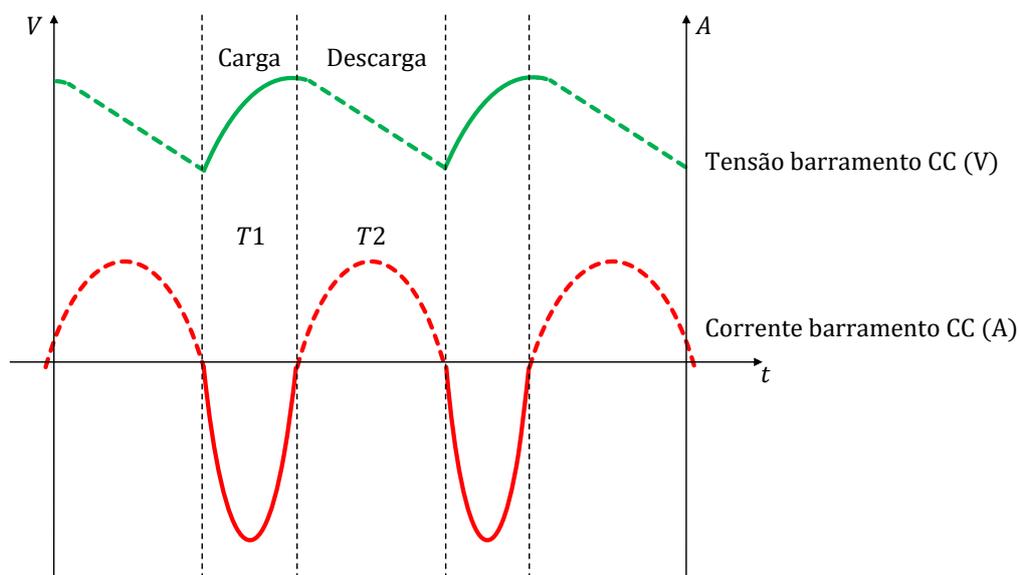
No barramento CC, existem flutuações naturais de tensão por conta das perdas de tensão nos diodos da ponte retificadora quando o inversor está em operação. A oscilação de tensão representa as condições de variação de energia na mudança da direção de corrente no barramento CC nos momentos de carga e de descarga dos capacitores, conforme ilustrado na Figura 11. Quando a corrente é negativa, há corrente entrando no capacitor, entretanto, quando a corrente é positiva, há corrente saindo do capacitor. O período T1 corresponde ao ciclo em que os capacitores absorvem energia, quando a tensão no barramento CC é maior que a dos capacitores. Quando a tensão chega em seu pico, a tensão do barramento CC começa a diminuir e a carga passa a ser alimentada pela energia armazenada nos capacitores, correspondendo ao período T2. Além disso, durante o processo de descarga, o barramento CC não pode fornecer energia para a rede CA de forma reversa (LU *et al.*, 2009).

Figura 10 – Formas de onda da Ponte de Graetz.



Fonte: Adaptado de Barbi (2006).

Figura 11 – Flutuações de tensão e de corrente no barramento CC.



Fonte: Adaptado de Meng e Zhang (2020).

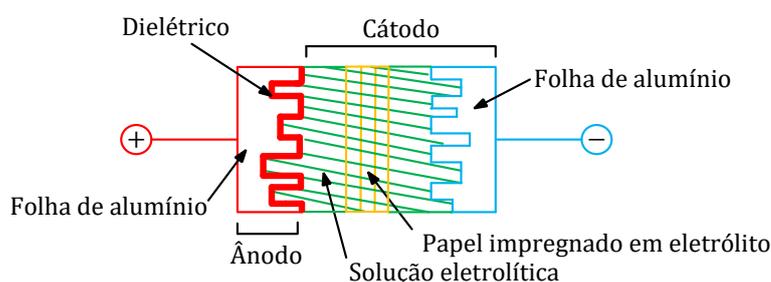
2.3 CAPACITORES ELETROLÍTICOS

Os Al-Cap são dispositivos passivos de armazenamento de energia, tendo como seus princípios de operação processos eletroquímicos. São amplamente utilizados na eletrônica de potência, principalmente para formar barramentos CC, a fim de balancear as diferenças instantâneas de energia entre a fonte e a carga e de minimizar a ondulação de tensão no barramento (WANG; BLAABJERG, 2014). Dessa forma, na Seção 2.3.1 é apresentada a estrutura desse tipo de capacitor, na Seção 2.3.2 é apresentado um modelo equivalente, na Seção 2.3.3 são discutidos os efeitos de temperatura sobre esse tipo de capacitor, na Seção 2.3.4 são apresentados os principais modos de falha e, na Seção 2.3.5, são detalhados os modos de degradação.

2.3.1 Estrutura

Um capacitor eletrolítico de alumínio é construído com duas camadas de materiais eletricamente condutores separadas por uma camada dielétrica. Um eletrodo, chamado de ânodo, com polaridade positiva, é formado por uma folha de alumínio com uma superfície ampliada por processos de cauterização. A camada de óxido de alumínio é formada sobre essa folha e usada como dielétrico. O contra eletrodo, chamado de cátodo, com polaridade negativa, é um líquido condutivo, chamado de eletrólito operacional. Uma segunda folha de alumínio, chamada folha de cátodo, serve como uma grande área de contato para a passagem de corrente para o eletrólito operacional (ALVES, 2019). A Figura 12 apresenta a construção básica de um Al-Cap.

Figura 12 – Estrutura do capacitor eletrolítico.



Fonte: Adaptado de Chetan Kulkarni *et al.* (2011a).

Uma vez que os capacitores eletrolíticos têm um líquido como cátodo, os mesmos também são chamados de molhados ou capacitores não-sólidos. O líquido tem o benefício de preencher os pequenos poços de cauterização, sendo essa uma característica vantajosa para encaixe na estrutura do ânodo. As duas folhas de alumínio de alta pureza são isoladas por separadores de papel, os quais possuem duas diferentes finalidades, tanto como recipiente para o eletrólito através dos poros do papel absor-

vente, como também como um separador para evitar curtos-circuitos elétricos (ALVES, 2019).

2.3.2 Modelo equivalente

Na Figura 13, é apresentado um modelo equivalente simplificado de capacitores, em que C_S corresponde à capacitância série equivalente, que é o parâmetro mais significativo para o componente e que está relacionado com a grandeza capacitância elétrica, em função de sua área, distância entre materiais condutores e constante dielétrica equivalente entre os materiais. Como o capacitor eletrolítico de alumínio é enrolado em forma de bobina, esse enrolamento de metais aparece representado como uma indutância série equivalente, ou L_{SE} . As imperfeições do contato entre terminais e folhas de alumínio, condutividade do eletrólito impregnado no papel e a espessura do óxido de alumínio, aparecem representadas como a R_{SE} , ou, resistência série equivalente (TORKI; JOUBERT; SARI, 2023).

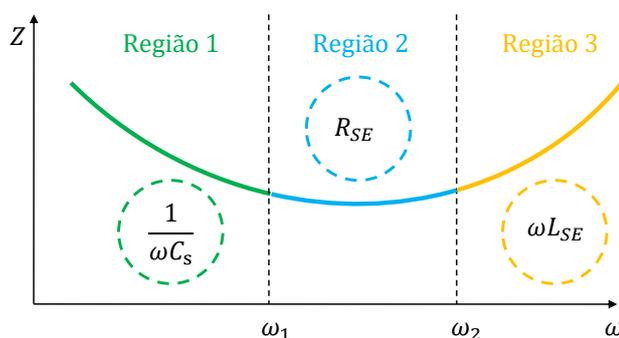
Como consequência, as características de impedância de capacitores eletrolíticos na frequência possuem formato em U, conforme observado na Figura 14. Para regiões de baixa frequência (Região 1), a impedância diminui de forma inversamente proporcional com a frequência, característica esta similar ao capacitor ideal. Já com o aumento da frequência (Região 2), há um aumento da predominância de R_{SE} resultante de indutâncias parasitas, resistividade eletrolítica e outros fatores que fazem com que a impedância se distancie do capacitor ideal e alcance um valor mínimo. A frequência na qual a impedância possui valor mínimo é denominada de frequência auto-ressonante, em que a impedância é igual a R_{SE} . Ao passo que se distancia da frequência auto-ressonante, as características do capacitor eletrolítico se alteram de capacitor para indutor e a impedância passa a aumentar. Por fim, em regiões de frequência muito maiores que o ponto de ressonância (Região 3), as características de impedância são dominadas por indutâncias parasitas (KAISER, 2012).

Figura 13 – Modelo simplificado equivalente de capacitores.



Fonte: Adaptado de Wang e Blaabjerg (2014).

Figura 14 – Impedância na frequência de capacitores.



Fonte: Adaptado de Wang e Blaabjerg (2014).

2.3.3 Efeito de temperatura e frequência

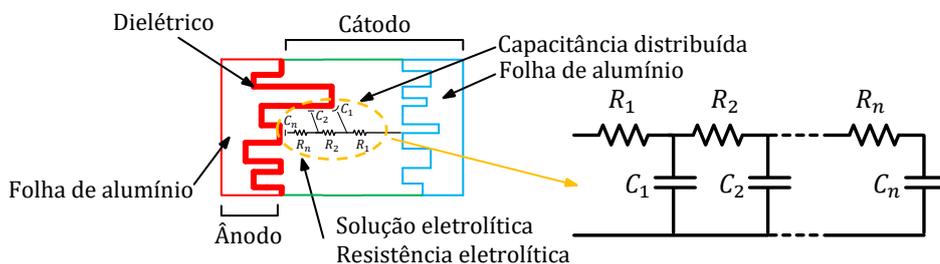
A capacitância em Al-Cap depende da temperatura e da frequência de operação. Esse efeito pode ser compreendido a partir do circuito equivalente na solução eletrolítica, em que há o aumento da capacitância com o incremento de temperatura devido a mudanças da resistência do eletrólito, porém, a sua diminuição com a frequência (PRYMAK *et al.*, 2008). Na Figura 15, é possível observar a rede de resistores e capacitores que se forma internamente na solução eletrolítica de um Al-Cap, na qual os elementos resistivos representam a resistência eletrolítica e os elementos capacitivos a capacitância distribuída. Em baixas frequências, as capacitâncias distribuídas respondem de forma eficiente aos estímulos elétricos e o valor de capacitância é próximo ao especificado pelo fabricante. Entretanto, com o aumento da frequência, as constantes de tempo C_{τ_n} das associações das redes de resistores $R_1 + R_2 + R_3 + \dots + R_n$ e capacitores $(C_{n-1}, C_{n-2}, C_{n-3}, \dots)$,

$$\begin{aligned} C_{\tau_1} &= C_1 R_1, \\ C_{\tau_2} &= C_2 (R_1 + R_2), \\ C_{\tau_n} &= C_n (R_1 + R_2 + \dots + R_n), \end{aligned}$$

excedem os períodos da frequência dos estímulos elétricos aplicados. Ou seja, com o aumento da frequência, o período do estímulo elétrico diminui e mais elementos capacitivos param de responder. Dessa forma, a capacitância aparente decai com o aumento da frequência (PRYMAK *et al.*, 2008).

Mais importante que entender os efeitos da temperatura e da frequência na capacitância de Al-Cap é avaliar o seu efeito combinado. Em Sundararajan *et al.* (2019), são realizados ensaios de medição da capacitância em cinco amostras em 300 Hz e 10 kHz com variação de temperatura de 25 °C a 75 °C, com incrementos de 10 °C. Verifica-se que para altas frequências, a variação de capacitância por temperatura se

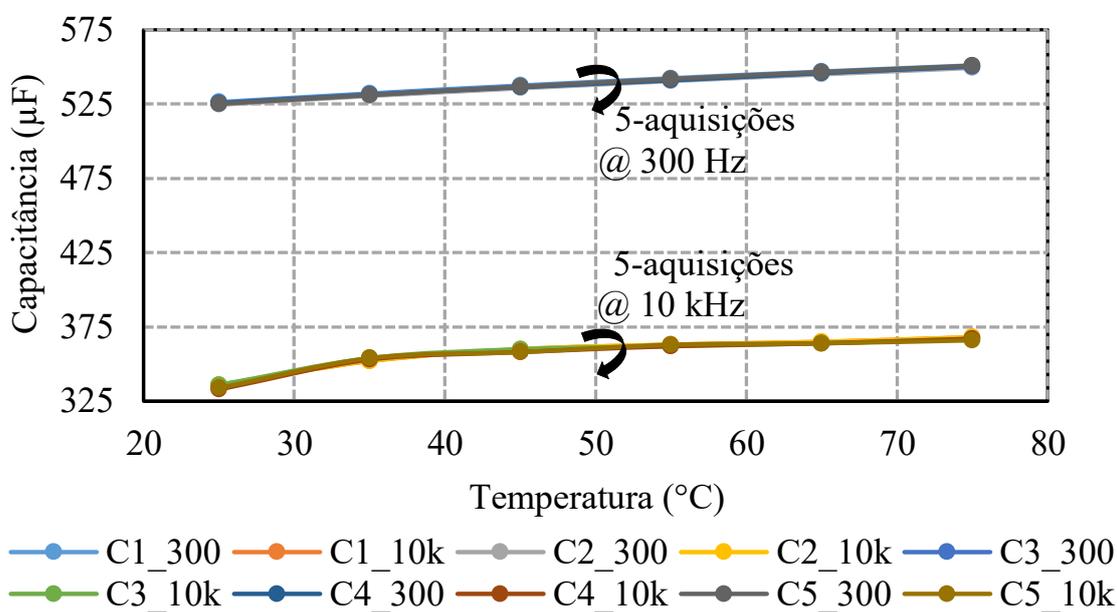
Figura 15 – Representação da estrutura equivalente com resistores e capacitores de um Al-Cap.



Fonte: Adaptado de Prymak *et al.* (2008).

torna não linear. Essa relação pode ser explicada pelo efeito ilustrado na Figura 15, dado que a constante de tempo depende parcialmente da resistência eletrolítica, a qual possui uma relação não linear com a temperatura (DOU; XU; BERDUQUE, 2008). Os resultados do ensaio podem ser observados na Figura 16.

Figura 16 – Capacitância por temperatura em 300 Hz e 10 kHz.

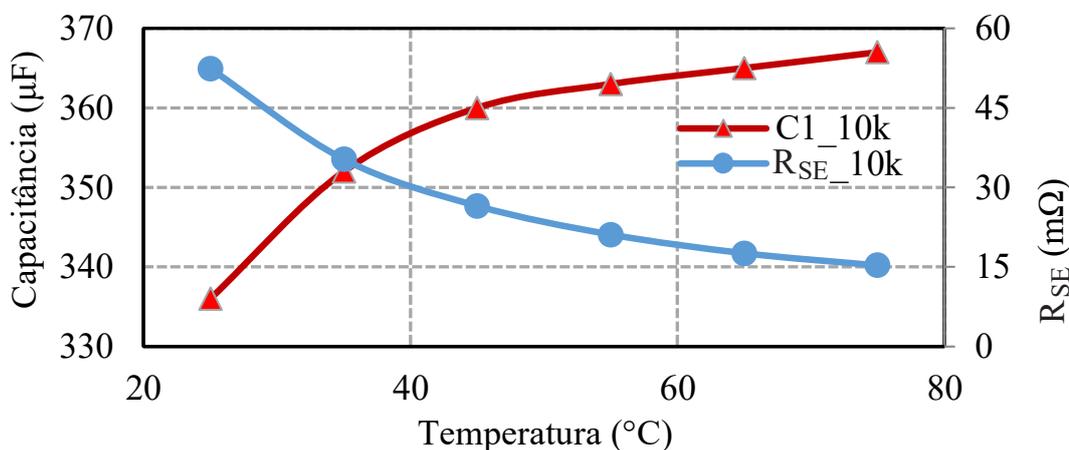


Fonte: Adaptado de Sundararajan *et al.* (2019).

Na Figura 17, é possível observar uma diminuição não linear da R_{SE} com a temperatura e o correspondente aumento não linear da capacitância da amostra C1 em 10 kHz. Portanto, para qualquer mudança de temperatura em R_{SE} , tem-se um efeito correspondente na capacitância em altas frequências. Entretanto, em baixas frequências, a mudança em R_{SE} não afeta a capacitância pelas mesmas razões explicadas a respeito da Figura 15. Dessa forma, para se obter uma relação linear de capaci-

tância com a temperatura sem precisar considerar os efeitos de R_{SE} que se alteram com a degradação do componente, o capacitor deve operar em baixas frequências (SUNDARARAJAN *et al.*, 2019).

Figura 17 – Capacitância e R_{SE} por temperatura em 10 kHz.



Fonte: Adaptado de Sundararajan *et al.* (2019).

2.3.4 Modos de falha

Os modos de falha de Al-Cap podem ser classificados em falhas catastróficas ou de desgaste. Em uma falha catastrófica, o capacitor perde completamente a sua função. Já em falhas por desgaste, o capacitor se deteriora gradualmente com o tempo em relação as suas características elétricas originais nos limites de tolerância e operação do fabricante. As suas principais causas advêm de um efeito combinando de estresse térmico, elétrico, mecânico e do ambiente onde estão inseridos (WANG; BLAABJERG, 2014).

O principal mecanismo de desgaste é a evaporação do eletrólito, potencializado com aumento de temperatura interna por conta de oscilação de corrente, temperatura externa maior que a interna ou sobretensão (KULKARNI, C. S. *et al.*, 2012). Com a sua evaporação, a condutividade entre os eletrodos diminui por conta da diminuição de eletrólito. Outros modos de falha ocorrem por ruptura ou explosão do capacitor por excessiva pressão interna, falha de curto-circuito ou circuito aberto por estresse mecânico repetitivo nos seus terminais (LEE, K.-W. *et al.*, 2008).

2.3.5 Modos de degradação acelerada

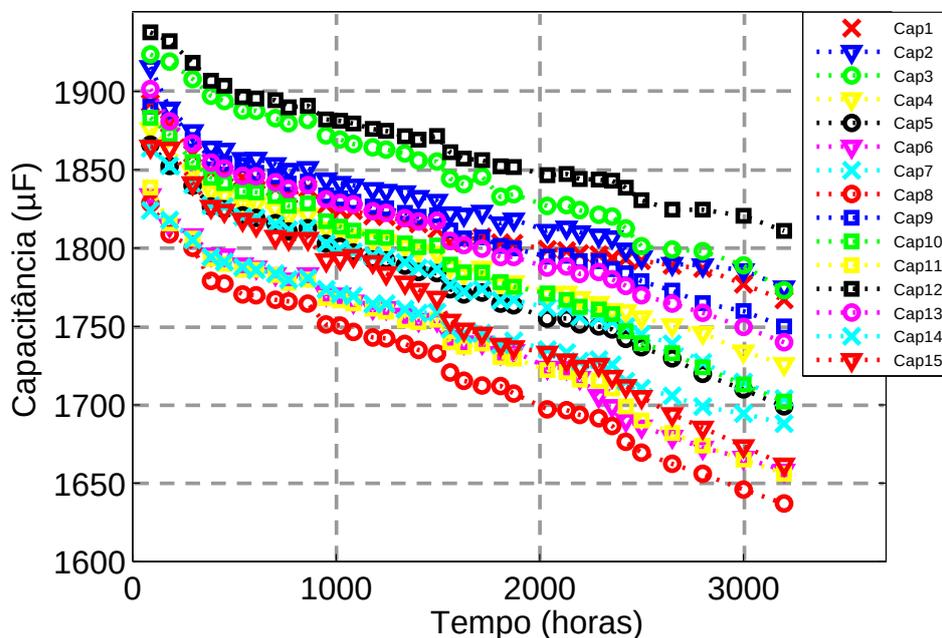
Um Al-Cap tem o seu desempenho fortemente afetado pelas suas condições de operação, como tensão, corrente, frequência e temperatura ambiente. A circulação de corrente durante os ciclos de carga e descarga do capacitor causa aumento de

temperatura interna. O calor gerado é transmitido do seu núcleo para a superfície do capacitor, porém, nem todo calor gerado é dissipado. O excesso de calor resulta em aumento de temperatura interna do capacitor e tem como consequência a evaporação do eletrólito e gradual degradação (CELAYA *et al.*, 2011). De forma similar, em casos nos quais o capacitor opera em alta temperatura ambiente, a superfície do capacitor tem temperatura maior que a do seu núcleo, fazendo com o que o calor se desloque na direção oposta, aumentando a temperatura interna e fazendo com que ocorra a evaporação do eletrólito (KULKARNI, C. *et al.*, 2011b). Dessa forma, a evaporação do eletrólito é causada tanto pelo aumento da temperatura interna como da temperatura externa. Ou seja, ambos os fenômenos levam ao mesmo modo de degradação, causado tanto por estresse elétrico como por térmico (IKONOPISOV, 1977).

Em Chetan S Kulkarni *et al.* (2012) é apresentado um exemplo de degradação por sobretemperatura, em que as condições de armazenamento em alta temperatura foram utilizadas como base para o desenvolvimento do método. Para isso, quinze amostras de capacitores foram armazenadas em uma câmara climática em temperatura controlada acima das especificações de temperatura de armazenamento de 85 °C informadas pelo fabricante. Todas as amostras utilizadas são do mesmo lote, possuem capacitância nominal de 2200 μF , tensão de operação de 10 V e temperatura máxima de operação de 105 °C. O aumento de temperatura se deu por incrementos de 25 °C a cada 15 min até que o valor desejado de 105 °C fosse atingido. Esse procedimento foi adotado para minimizar as possibilidades de choque térmico durante a variação de temperatura. Após o ensaio das quinze amostras por mais 3000 h, a mesma estratégia de incremento de temperatura foi aplicada para o decremento até a temperatura ambiente para realizar a medição de capacitância a cada 90 h aproximadamente. Na Figura 18 é possível observar os trinta e quatro pontos de medição ao longo do processo de degradação da capacitância no tempo.

Já em Chetan Kulkarni *et al.* (2011b) é descrito um exemplo de degradação por ciclos de sobretensão, no qual uma onda quadrada é aplicada ao capacitor de modo a realizar os ciclos de carga e descarga de forma contínua. Todas as amostras utilizadas são do mesmo lote, possuem capacitância nominal de 2200 μF , tensão de operação de 10 V, corrente máxima de 1 A e temperatura máxima de operação de 105 °C. Não é apresentado o nível de sobretensão aplicado. Uma vez que as constantes de tempo de carga e de descarga estão diretamente relacionadas com a capacitância, na etapa inicial de degradação do banco capacitivo de seis amostras, os capacitores realizam a carga e descarga de forma simultânea. Entretanto, com o tempo e degradação, os tempos de carga e de descarga variam para cada capacitor, mesmo que todos os capacitores sejam submetidos às mesmas condições de degradação. Dessa forma, para cada capacitor em teste, a sua tensão é monitorada nos ciclos de carga e de descarga. Na Figura 19, é possível observar o diagrama do método proposto de degradação

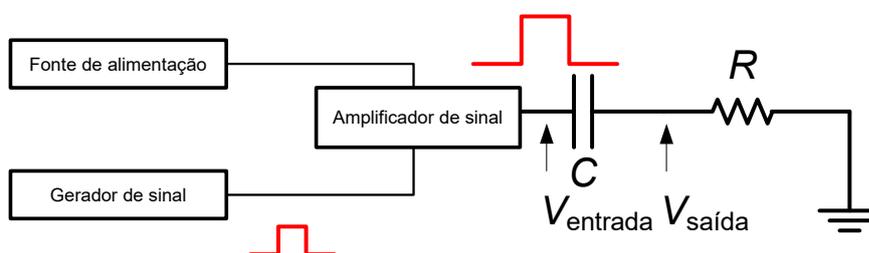
Figura 18 – Degradação de capacitância por sobretemperatura a 105 °C para capacitância nominal de 2200 μF .



Fonte: Adaptado de Chetan S Kulkarni *et al.* (2012).

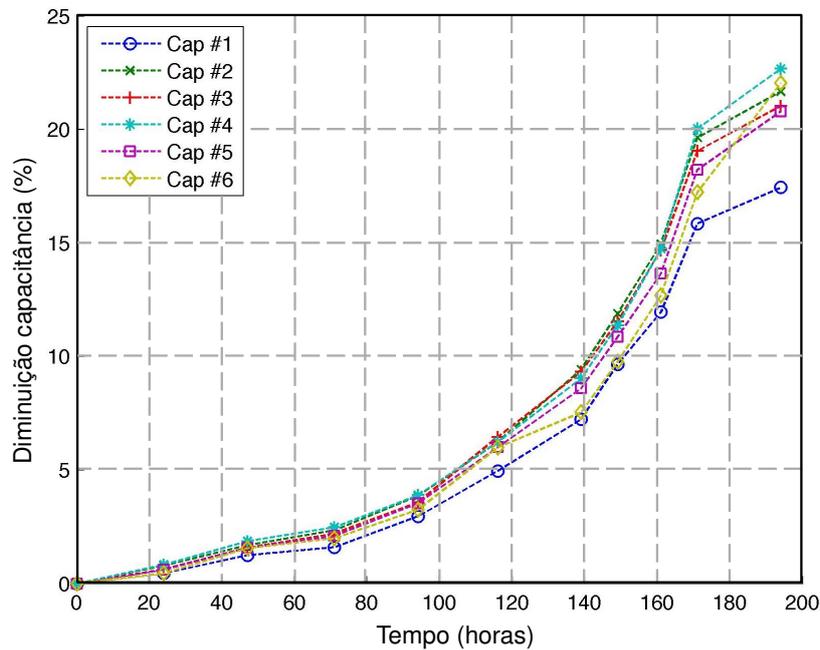
por sobretensão. As medições de capacitância foram realizadas a cada 16 h a 20 h do total de 180 h de ensaio, dando origem aos onze pontos de medição ao longo do processo de degradação ilustrados na Figura 20. Os autores enfatizam que o processo de degradação foi realizado em uma câmara climática com controle de temperatura em 25 °C.

Figura 19 – Diagrama de blocos do experimento de degradação por sobretensão.



Fonte: Adaptado de Chetan Kulkarni *et al.* (2011b).

Figura 20 – Diminuição de capacitância no tempo para degradação por sobretensão.



Fonte: Adaptado de Chetan Kulkarni *et al.* (2011b).

2.4 MULTILAYER PERCEPTRON

Modelos de redes neurais artificiais foram originalmente projetados para modelar o funcionamento das redes neurais biológicas, as quais fazem parte do cérebro humano. O cérebro é responsável pelo sistema de decisão do ser humano, que é resultado da interação de milhões de neurônios conectados. O cérebro possui múltiplas camadas de neurônios, os quais tipicamente interagem entre si em estruturas de processamento paralelo, ou seja, cada neurônio recebe informações dos neurônios das camadas anteriores e envia informações para os demais neurônios das camadas posteriores, conforme ilustrado na Figura 21 (HAYKIN, 1998).

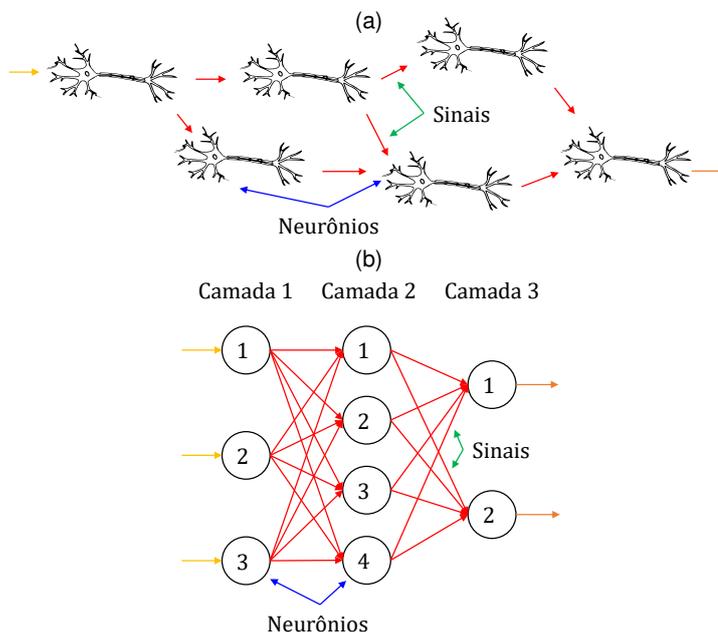
As propriedades dos neurônios e de suas interconexões foram capturadas em modelos matemáticos simples, conhecidos como redes neurais artificiais, que até hoje constituem um dos paradigmas de aprendizado de máquina mais empregados. A seguir, é descrito o modelo de um neurônio artificial, o qual pode ser matematicamente expresso na forma:

$$a = \sum_{i=1}^M w_i x_i + b, \quad (2)$$

$$y = f(a), \quad (3)$$

nas quais x_1, \dots, x_M representam os M sinais de entrada, w_1, \dots, w_M são variáveis contínuas denominadas pesos, os quais representam o poder das sinapses associadas,

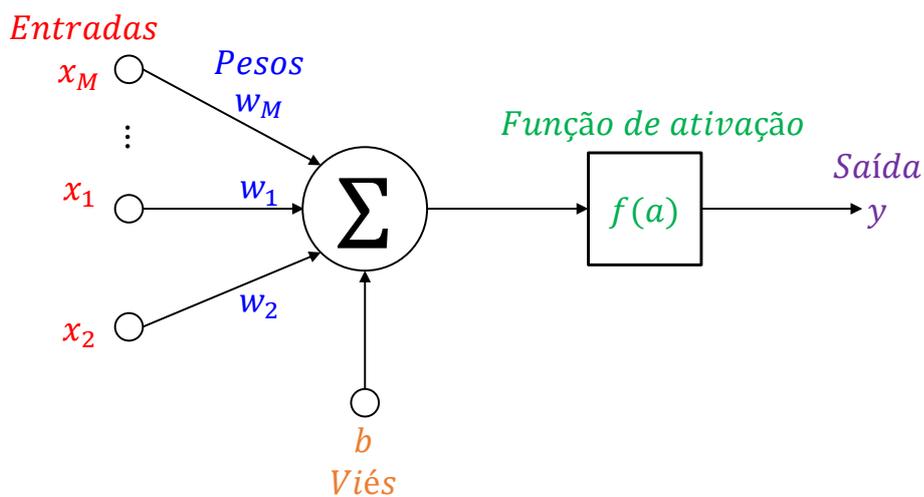
Figura 21 – Representação de redes neurais: (a) biológica; (b) artificial.



Fonte: Adaptado de Mendonça *et al.* (2019).

e b é o viés, do inglês, *bias*. A quantidade a é denominada pré-ativação e a saída y é denominada ativação. A formulação matemática apresentada na Equação (2) e na Equação (3) representa o modelo de um neurônio artificial e pode ser ilustrada pelo diagrama da Figura 22 em (b) (JO, 2023).

Figura 22 – Representação da Equação (2) e Equação (3)



Fonte: de autoria própria.

A história das RNAs pode ser amplamente dividida em três momentos distintos

de acordo com o nível de sofisticação das redes, avaliado de acordo com o número de camadas de processamento. Um dos modelos mais importantes de uma camada de processamento, conforme apresentado na Figura 22, é o perceptron, proposto por Rosenblatt (1958), no qual a função de ativação $f(\cdot)$ é uma função degrau, na forma:

$$f(a) = \begin{cases} 0, & \text{se } a \leq 0, \\ 1, & \text{se } a > 0. \end{cases} \quad (4)$$

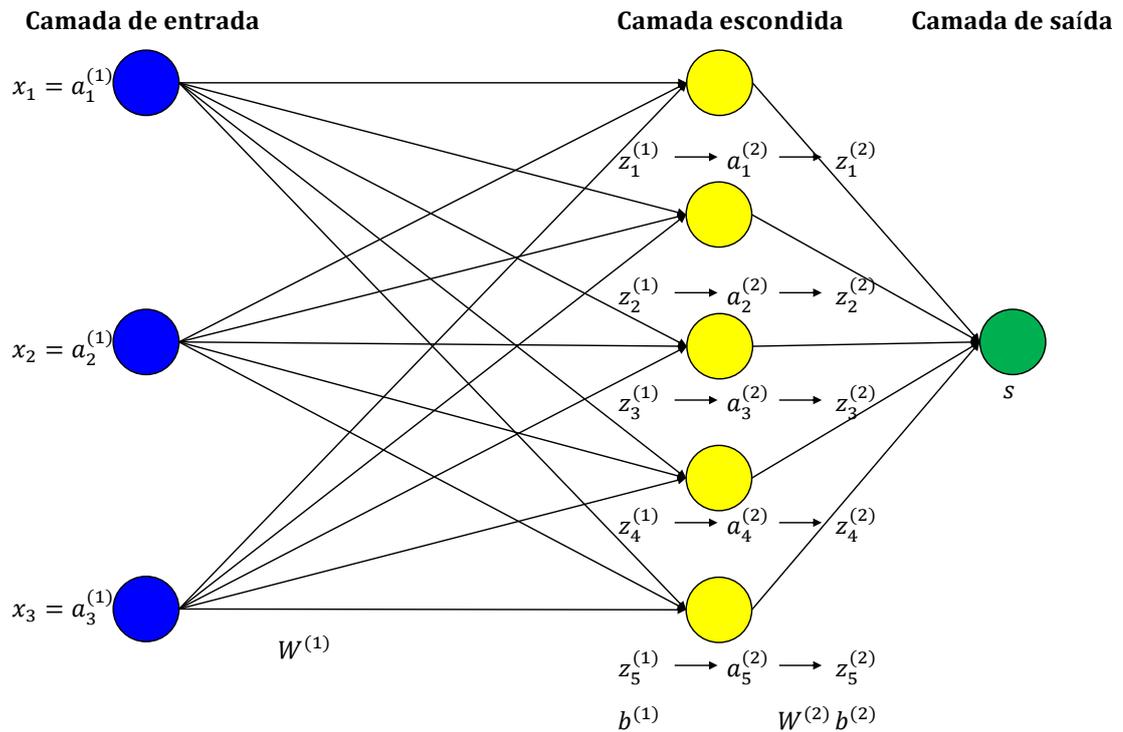
Isso pode ser visto como um modelo simplificado de neurônio que é ativado se e somente se o somatório de pré-ativação da Equação (2) é maior que zero. Para o treinamento do perceptron, Rosenblatt (1958) desenvolveu um algoritmo específico que possui a propriedade de que se existe um conjunto de ganhos nos quais o perceptron pode obter uma classificação perfeita dos dados de treinamento, então há uma garantia que o algoritmo irá encontrar uma solução em um número finito de iterações. Em um perceptron, mesmo que uma configuração possuísse múltiplas camadas de processamento, somente uma dessas camadas era treinada com os dados, portanto, os perceptrons são considerados como uma rede neural de uma camada (BISHOP, 2006). Dada essa limitação de uma camada do perceptron, outros autores propuseram o treinamento de uma rede neural com múltiplas camadas e funções de ativação sigmóides ou lineares em vez da degrau utilizada na formulação original do perceptron, entretanto, não sabiam como treinar um modelo com essa configuração. O resultado desta proposição foi o livro de Rumelhart, Hinton e Williams (1986), no qual o clássico MLP é introduzido. Esse modelo pode ser descrito por: (i) uma função linear que agrega os valores de entrada, (ii) mais de uma camada com pesos ajustáveis, (iii) funções de ativação lineares e não lineares, (iv) função custo ou perda para computação do erro, e (v) um processo de aprendizado para ajuste dos pesos da rede, denominado algoritmo de retropropagação do erro. Cada item listado é detalhado nas seções a seguir no que se refere a problemas de regressão utilizando MLP.

Para simplificar a análise e a apresentação dos conceitos, uma estrutura de rede neural de três camadas é utilizada como exemplo. Essa rede tem três unidades sinápticas na camada de entrada, cinco neurônios na camada intermediária (também chamada de camada escondida) e um neurônio na camada de saída, conforme ilustrado na Figura 23.

2.4.1 Propagação direta

Na etapa de propagação direta, uma entrada é aplicada à camada de entrada e seu efeito se propaga pela rede até que uma saída seja produzida. Em um MLP, a função linear de agregação dos dados de entrada tipicamente é a mesma do perceptron, porém, há algumas diferenças por conta das múltiplas camadas e da ativação dos neurônios. Conforme ilustrado na Figura 23, as unidades sinápticas que estão

Figura 23 – Representação da estrutura de uma MLP.



Fonte: de autoria própria.

representados em azul são responsáveis por receber os dados de entrada, porém não realizam processamento. Assim, a equação para os dados de entrada x_i é representada por:

$$x_i = a_i^{(1)}, i \in 1,2,3,$$

na qual as ativações $a_i^{(1)}$ são iguais aos dados de entrada. Ao seguir para a próxima camada, a camada escondida, os valores finais de ativação estão representados pelos neurônios $a_i^{(2)}$ na cor amarela, ativados por $z_i^{(1)}$, conforme a equação:

$$z^{(1)} = W^{(1)}a^{(1)} + b^{(1)},$$

$$W^{(1)} = \begin{bmatrix} W_{11}^{(1)} & W_{12}^{(1)} & W_{13}^{(1)} & W_{14}^{(1)} & W_{15}^{(1)} \\ W_{21}^{(1)} & W_{22}^{(1)} & W_{23}^{(1)} & W_{24}^{(1)} & W_{25}^{(1)} \\ W_{31}^{(1)} & W_{32}^{(1)} & W_{33}^{(1)} & W_{34}^{(1)} & W_{35}^{(1)} \end{bmatrix},$$

$$a^{(1)} = \begin{bmatrix} a_1^{(1)} \\ a_2^{(1)} \\ a_3^{(1)} \end{bmatrix},$$

$$a^{(2)} = f(z^{(1)}),$$

em que W^1 representa a matriz de pesos e $b^{(1)}$ é um vetor de vies com a mesma estrutura de z^1 . As ativações de $a_i^{(2)}$ são processadas por funções de ativação f , as

quais são detalhadas na Seção 2.4.2. Por fim, a camada de saída, representada pelo neurônio s em verde, tem seu valor de predição de saída ativado por $z_i^{(2)}$, conforme a equação:

$$z^{(2)} = \mathbf{W}^{(2)} \mathbf{a}^{(2)} + \mathbf{b}^{(2)},$$

$$\mathbf{W}^{(2)} = \begin{bmatrix} W_{11}^{(2)} & W_{21}^{(2)} & W_{31}^{(2)} & W_{41}^{(2)} & W_{51}^{(2)} \end{bmatrix},$$

$$\mathbf{a}^{(2)} = \begin{bmatrix} a_1^{(2)} \\ a_2^{(2)} \\ a_3^{(2)} \\ a_4^{(2)} \\ a_5^{(2)} \end{bmatrix},$$

$$s = f \left(z^{(2)} \right).$$

Da mesma forma que na propagação da camada de entrada para a camada escondida, $\mathbf{W}^{(2)}$ representa a matriz de pesos, $\mathbf{b}^{(2)}$ é o viés e a ativação da saída s é processada por uma função de ativação f , que não necessariamente é a mesma da camada anterior.

2.4.2 Função de ativação

De acordo com cada tipo de problema, como regressão ou classificação, diferentes funções de ativação são utilizadas para se obter melhores resultados. A seguir, são apresentadas as principais funções de ativação lineares e não lineares utilizadas na literatura, com foco em problemas de regressão (HUANG *et al.*, 2019).

- **Identidade:** a função linear identidade é definida pela Equação (5):

$$f(x) = x. \quad (5)$$

- **Sigmoide:** a função sigmoide às vezes é referenciada como função logística. É uma função real diferenciável limitada, definida para valores de entrada reais, com derivadas positivas em todos os lugares e algum grau de suavidade. Uma das suas vantagens é o intervalo de sua imagem, existente entre 0 e 1. Ela é definida pela Equação (6):

$$f(x) = \frac{1}{(1 + e^{-x})}. \quad (6)$$

No entanto, a função de ativação sigmoide apresenta desvantagens relevantes, tais como: gradientes com potencial de serem acentuadamente amortecidos durante o processo de retropropagação das camadas ocultas mais profundas para as camadas de entrada durante o treinamento, saturação de gradientes, convergência lenta do treinamento e saída não centralizada em

zero, tendo como consequência a propagação de atualizações de gradientes em direções diferentes. Outras formas de função de ativação, incluindo a função tangente hiperbólica, foram propostas para remediar algumas dessas desvantagens sofridas pela função de ativação sigmoide (HAN; MORAGA, 1995).

- **Tangente hiperbólica:** a função tangente hiperbólica (\tanh) é outra função não linear muito usada no contexto de RNA. As suas principais vantagens frente à função sigmoide são ser concentrada em zero e ter a sua imagem entre os valores -1 e $+1$. A função é definida pela Equação (7):

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (7)$$

A função tangente hiperbólica tornou-se preferida em comparação com a função sigmoide, uma vez que tipicamente proporciona um desempenho de treinamento superior para MLPs. No entanto, a função \tanh não conseguiu resolver o problema do gradiente evanescente sofrido pelas funções sigmoide durante o treinamento de redes com múltiplas camadas. Com essa função, uma grande mudança no valor de entrada resulta em uma pequena mudança no valor de saída. Isso resulta em valores de gradiente próximos de zero. Como os valores de gradiente podem se aproximar de zero, a função \tanh sofre com problemas de gradiente desvanecente. O problema do gradiente desvanecente motivou mais pesquisas sobre funções de ativação, o que levou ao desenvolvimento da função de ativação linear retificada (RELU, do inglês *Rectified Linear Unit*) (NWANKPA *et al.*, 2018).

- **RELU:** a função RELU é linear para todos os valores positivos e zero para todos os valores negativos, definida pela Equação (8):

$$f(x) = \begin{cases} x, & \text{se } x > 0, \\ \max(0, x), & x \leq 0. \end{cases} \quad (8)$$

A função de ativação RELU oferece desempenho e generalização superiores em aprendizado profundo em comparação com as funções de ativação sigmoide e tangente hiperbólica (ZEILER *et al.*, 2013). A RELU representa uma função quase linear e, portanto, preserva as propriedades dos modelos lineares que os tornaram fáceis de otimizar com métodos de descida de gradiente. Por essa função possuir derivada zero para valores negativos e derivada um para valores positivos, o problema do gradiente evanescente é contornado. Ou seja, quando o gradiente atinge zero para os valores negativos, a função RELU não converge para um mínimo, o que resulta em um neurônio inativo durante a retropropagação.

A principal vantagem de usar RELU em computação é que esse tipo de função garante uma computação mais rápida, uma vez que não envolve cálculos exponenciais e divisões, resultando em um aprimoramento geral na velocidade de computação. Entretanto, a RELU tem uma limitação significativa de que ela é por vezes frágil durante o treinamento, levando a que alguns gradientes tendam a zero. Isso resulta em alguns neurônios ficando inativos, causando a falta de ativação nas atualizações de peso em pontos de dados futuros, o que acaba prejudicando o aprendizado, já que neurônios inativos fornecem uma ativação zero (GOODFELLOW; BENGIO; COURVILLE, 2016).

- **ELU**: a função unidade linear exponencial (ELU, do inglês *Exponential Linear Unit*) é uma variação da RELU na qual, para valores positivos de x , a função é a identidade, porém, para valores menores que zero, tem comportamento regido pela Equação (9):

$$f(x) = \begin{cases} x, & \text{se } x > 0, \\ a(e^x - 1), & x \leq 0. \end{cases} \quad (9)$$

A principal vantagem da ELU é que ela pode aliviar o problema do gradiente evanescente, utilizando a identidade para valores positivos e melhorando as características de aprendizado. Por possuir valores negativos, permite aproximar a ativação média da unidade mais perto de zero, reduzindo, assim, a complexidade computacional e melhorando a velocidade de aprendizado. A ELU é uma boa alternativa à RELU, pois reduz os deslocamentos de viés ao aproximar a ativação média a zero durante o treinamento. Entretanto, uma limitação da ELU é ela que não possui valores centralizados em zero (CLEVERT; UNTERTHINER; HOCHREITER, 2015).

- **SELU**: a função unidade linear exponencial escalonada (SELU, do inglês *Scaled Exponential Linear Unit*) é uma variante da ELU, que tem a principal vantagem de garantia que a saída sempre será padronizada devido ao seu comportamento auto-normalizador por conta do fator λ . Ou seja, para valores positivos de x é a identidade, todavia, para valores menores que zero, tem comportamento regido pela Equação (10):

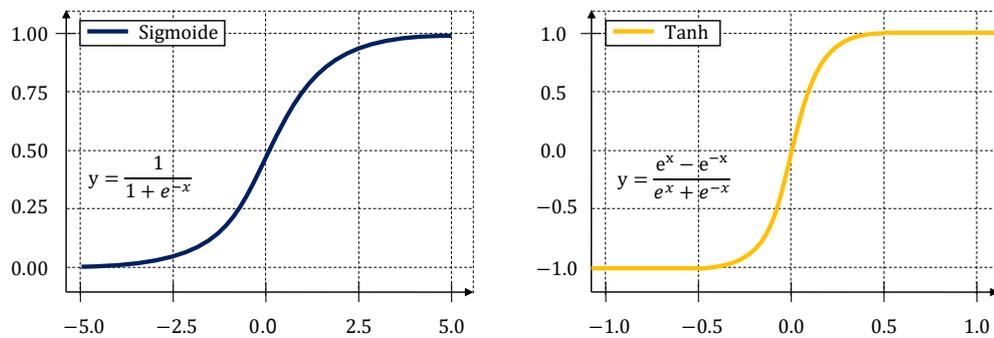
$$f(x) = \begin{cases} \lambda x, & \text{se } x > 0, \\ \lambda a(e^x - 1), & x \leq 0. \end{cases} \quad (10)$$

Ela possui uma média próxima de zero e variância unitária, que converge para média zero e variância unitária ao ser propagada por várias camadas durante o treinamento da rede, tornando-a adequada para aplicações

de aprendizado profundo. Com uma regularização forte, ela aprende eficientemente características robustas. Por fim, a SELU não é afetada por problemas de gradiente evanescente, explosão de gradiente e permite a construção de mapeamentos com propriedades que levam a redes neurais auto-normalizadoras, o que não pode ser obtido com funções de ativação como RELU, sigmoide e tangente hiperbólica (KLAMBAUER *et al.*, 2017).

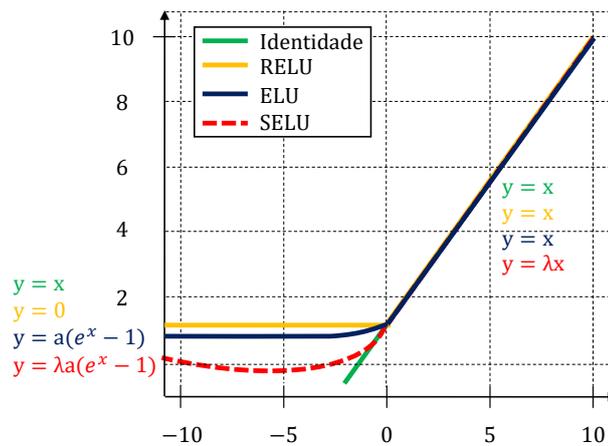
Na Figura 24 e na Figura 25, é possível observar a representação das funções de ativação apresentadas nos parágrafos anteriores, bem como a apresentação da suas equações.

Figura 24 – Representação de funções de ativação não lineares.



Fonte: Adaptado de Nwankpa *et al.* (2018).

Figura 25 – Representação das funções de ativação lineares para valores positivos.



Fonte: Adaptado de Nwankpa *et al.* (2018).

2.4.3 Retropropagação

A solução para o problema de treinar uma MLP com mais de uma camada tipicamente faz uso de cálculo diferencial e aplicação de métodos de otimização baseados em gradiente. Uma importante mudança para permitir a aplicação desses métodos foi a substituição da função degrau da formulação original do perceptron por funções de ativação que são continuamente diferenciáveis em quase todos os lugares e com um gradiente não nulo para todos os pontos ou valores de entrada diferentes de zero. Outra mudança fundamental foi a introdução de funções de erro diferenciáveis que definem quão bem uma escolha dada de valores de parâmetros prevê ou classifica as variáveis de saída do conjunto de treinamento. Com essas mudanças em relação ao perceptron, na MLP se faz uso de uma função de erro na qual as derivadas em relação a cada neurônio podem ser avaliadas (JO, 2023).

O processo de treinamento de uma MLP para a tarefa de regressão consiste no ajuste dos seus pesos com exemplos de dados rotulados e posteriormente na avaliação do seu poder de predição com a apresentação de dados não vistos, denominados dados de teste. O treinamento por retropropagação é um dos tipos de algoritmo mais populares para treinamento de uma MLP, o qual pode ser sintetizado em duas operações: propagação direta, do inglês *feedforward*, e retropropagação, do inglês *backpropagation*. Conforme já apresentado, na etapa de propagação direta, uma entrada é aplicada à camada de entrada e seu efeito se propaga pela rede até que uma saída seja produzida. O valor de saída real da rede é, então, comparado à saída esperada, e um sinal de erro é calculado para cada um dos nós de saída. Uma vez que todos os nós ocultos contribuíram, em certa medida, para os erros evidentes na camada de saída, os sinais de erro da saída são transmitidos de volta da camada de saída para cada nó na camada oculta que contribuiu imediatamente para a camada de saída. Esse processo é, então, repetido, camada por camada, até que cada nó na rede tenha recebido um sinal de erro que descreve sua contribuição relativa para o erro total, processo este denominado de retropropagação (JO, 2023). Uma vez que o sinal de erro para cada nó é determinado, os erros são, então, utilizados pelos nós para atualizar os valores de cada peso de conexão até que a rede convirja para um estado que permita a codificação de todos os dados de treinamento. Cada passo de um ciclo de propagação e retropropagação é chamado de época. O algoritmo de retropropagação procura o valor mínimo da função de erro no espaço de pesos usando uma técnica chamada regra delta ou gradiente descendente. Os pesos que minimizam a função de erro são considerados uma solução para o problema de aprendizado (JO, 2023).

No processo de treinamento, a última etapa consiste na avaliação da saída de predição s em relação a uma saída y esperada. A saída y pertence a um conjunto de treinamento (x, y) , no qual x é a entrada. A análise do poder de predição de uma

MLP se faz por meio de uma função de custo. Esta função é utilizada por otimizadores para reduzir o erro das previsões a cada época com ajuste dos pesos e viés utilizando o algoritmo de retropropagação. O nível de ajuste é determinado pelos gradientes da função de custo em relação a esses parâmetros.

A função de perda mais comum para problemas de regressão é a de erro quadrático médio (MSE, do inglês, *Mean Squared Error*) (BISHOP, 2006). Nessa função, a perda aumenta com o quadrado da distância entre o valor real e o valor previsto, conforme:

$$MSE = \frac{1}{n} \sum_{i=1}^{i=n} (y_i - \hat{y}_i)^2,$$

em que n é o número total de previsões a serem analisadas, y_i é o valor real da i -ésima previsão e \hat{y}_i é o valor previsto.

No presente trabalho, os otimizadores utilizados são todos baseados no método de otimização do gradiente descendente, o qual é um dos mais popularmente utilizados na tarefa de otimizar uma MLP. O gradiente de uma função $P(x_1, x_2, \dots, x_m)$ em relação a um ponto x é um vetor das derivadas parciais de P em x conforme a equação:

$$\frac{\partial P}{\partial x} = \left[\frac{\partial P}{\partial x_1}, \frac{\partial P}{\partial x_2}, \dots, \frac{\partial P}{\partial x_m} \right],$$

A derivada de uma função P mede a sensibilidade à mudança do valor da função (valor de saída) em relação a uma mudança em seu argumento x (valor de entrada). Ou seja, o gradiente mostra o quanto o parâmetro x precisa mudar na direção positiva ou negativa para minimizar P . Para o cálculo desses gradientes, utiliza-se uma técnica chamada de regra da cadeia. Para um peso único w_{jk}^l , o gradiente é calculado pela regra da cadeia como:

$$\frac{\partial P}{\partial w_{jk}^l} = \frac{\partial P}{\partial z_j^l} \frac{\partial z_j^l}{\partial w_{jk}^l}.$$

sendo, por definição,

$$z_j^l = \sum_{k=1}^m w_{jk}^l a_k^{l-1} + b_j^l.$$

Assim, a derivada parcial é dada por

$$\frac{\partial z_j^l}{\partial w_{jk}^l} = a_k^{l-1},$$

que resulta em

$$\frac{\partial P}{\partial w_{jk}^l} = \frac{\partial P}{\partial z_j^l} a_k^{l-1}.$$

De forma similar, o mesmo pode ser aplicado para b_j^l :

$$\frac{\partial P}{\partial b_j^l} = \frac{\partial P}{\partial z_j^l} \frac{\partial z_j^l}{\partial b_j^l},$$

porém, nesse caso,

$$\frac{\partial z_j^l}{\partial b_j^l} = 1,$$

o que resulta em

$$\frac{\partial P}{\partial b_j^l} = \frac{\partial P}{\partial z_j^l}.$$

A primeira parte de ambos os cálculos de gradiente é comumente chamada de gradiente local, que pode ser expresso da seguinte maneira:

$$\delta_j^l = \frac{\partial P}{\partial z_j^l}.$$

Os gradientes permitem otimizar os parâmetros da MLP por meio da atualização dos pesos e vieses até que a condição de parada seja atendida, conforme apresentado abaixo:

$$\mathbf{W} = \mathbf{W} - \varepsilon \frac{\partial P}{\partial \mathbf{W}},$$

$$b = b - \varepsilon \frac{\partial P}{\partial b},$$

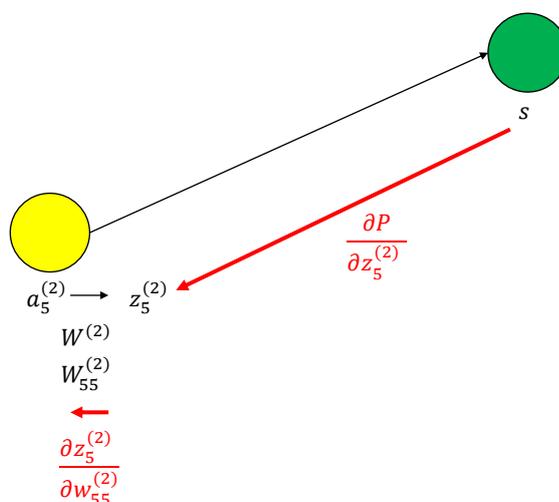
em que os valores iniciais de \mathbf{W} e b são escolhidos de forma aleatória e são representações da matriz de pesos e do viés. As derivadas de P em relação a \mathbf{W} ou b podem ser calculadas utilizando as derivadas parciais de P nos pesos e vieses individuais. O parâmetro ε é a taxa de aprendizado, sendo um fator de ajuste para determinar a influência do gradiente no passo de otimização. Por fim, a condição de parada é satisfeita de acordo com o critério definido em relação à função de perda ou ao número de iterações, de forma equivalente ao detalhado na Seção 2.4.4.2.

Para esclarecer o funcionamento do algoritmo, é apresentado e ilustrado na Figura 26 o processo de retropropagação no qual o gradiente de P é calculado em relação ao peso $w_{55}^{(2)}$. O peso $w_{55}^{(2)}$ se conecta a $a_5^{(2)}$. Dessa forma, para calcular o gradiente é necessário aplicar a regra da cadeia por meio de $z_5^{(2)}$ e s conforme ilustrado abaixo:

$$\frac{\partial P}{\partial w_{55}^{(2)}} = \frac{\partial P}{\partial z_5^{(2)}} \frac{\partial z_5^{(2)}}{\partial w_{55}^{(2)}} a_5^{(2)} = \frac{\partial P}{\partial z_5^{(2)}} f'(z_5^{(2)}) a_5^{(2)}.$$

A seguir, são apresentados os principais otimizadores que utilizam gradiente descendente para MLP:

- **Adagrad:** O Adagrad é um algoritmo de otimização baseado em gradientes passados que adapta a taxa de aprendizado aos parâmetros, realizando atualizações maiores para parâmetros infrequentes e atualizações menores para parâmetros frequentes. Um dos seus principais benefícios é a eliminação da necessidade de ajuste manual da taxa de aprendizado.

Figura 26 – Representação do algoritmo de retropropagação para o cálculo de $w_{55}^{(2)}$.

Fonte: de autoria própria.

- **RMSProp**: do inglês *Root Mean Squared Propagation*, é um algoritmo de otimização desenvolvido para superar a limitação de diminuição radical da taxa de aprendizagem do Adagrad. Isso é feito por meio da implementação de uma taxa de uma aprendizagem adaptativa com o armazenamento da média ponderada exponencial dos quadrados dos gradientes anteriores, posteriormente dividindo a taxa de aprendizagem por essa média para acelerar a convergência (HINTON, 2012).
- **Adam**: o algoritmo de estimativa de momento adaptativo (Adam, do inglês *Adaptive Moment Estimation*) é outro método que também possui a taxa de aprendizagem definida de forma adaptativa. Porém, de forma adicional à estratégia utilizada por RMSProp, Adam também mantém uma média exponencialmente decrescente dos gradientes passados, similar ao conceito de impulso de outros otimizadores. Isso é feito pelo cálculo da média dos gradientes e a variância não centrada dos gradientes.

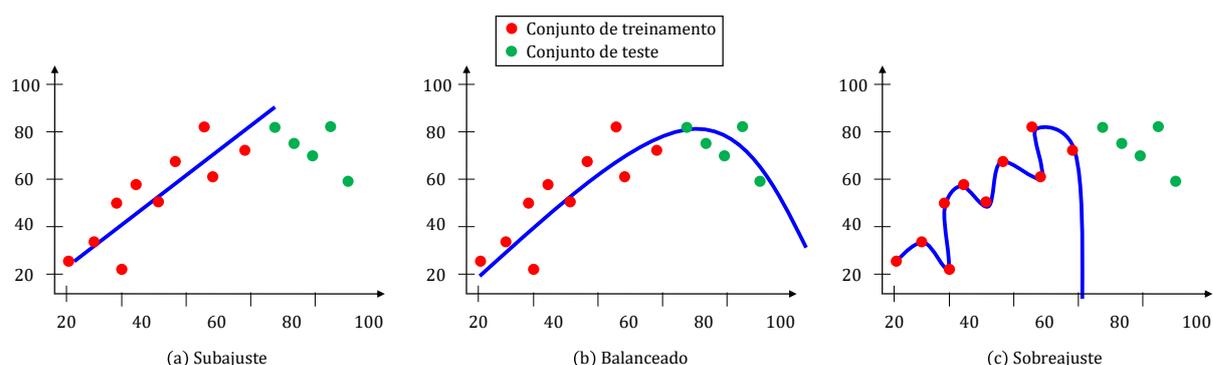
2.4.4 Sobreajuste e subajuste

Durante o processo de treinamento de uma RNA, ocorrem diversas iterações do conjunto de dados de treinamento na tentativa que o modelo consiga aprender melhor a tendência e a variância dos dados. Um dos desafios da etapa de treinamento de uma RNA é saber em quantas épocas o modelo deve ser treinado para obter o resultado otimizado de forma equilibrada, ou seja, para que o modelo não seja subajustado pelo treinamento insuficiente ou sobreajustado pelo treino exagerado (HUANG *et al.*, 2019).

O subajuste ocorre quando o modelo não captura o relacionamento entre as

variáveis de entrada e de saída com precisão, resultando em uma alta taxa de erro não só para o conjunto de treinamento, como, principalmente, para o conjunto de teste. Ocorre quando um modelo é muito simples, o que pode ser o resultado de um modelo que necessita de mais épocas de treinamento, mais recursos de entrada, ou menos regularização. Já o sobreajuste ocorre quando um modelo se ajusta exatamente ao conjunto de treinamento. Quando isso acontece, o algoritmo não consegue apresentar bom desempenho para o conjunto de teste, anulando o propósito de generalização de uma RNA. Se o conjunto de treinamento possui taxa de erro baixa e o conjunto de teste possui uma taxa de erro alta, isso é um sinalizador de sobreajuste (FLACH, 2012). Na Figura 27, é possível observar uma ilustração dos casos de: (a) subajuste, (b) treinamento balanceado e (c) sobreajuste.

Figura 27 – Modelos de RNA com: (a) subajuste, (b) treinamento balanceado e (c) sobreajuste.



Fonte: Adaptado de Mendonça *et al.* (2019).

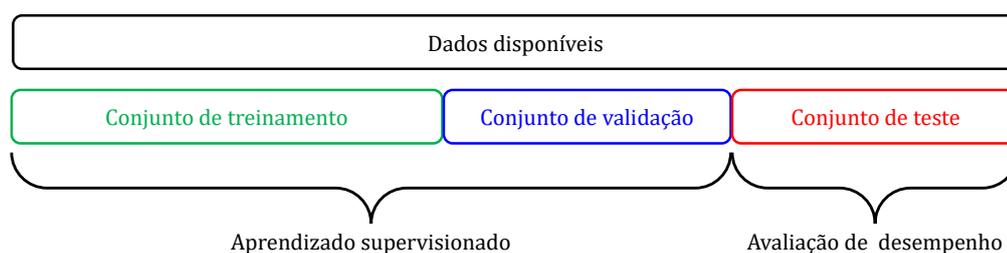
Uma das alternativas para minimizar o efeito de subajuste é aumentar a complexidade ou grau da função que mapeia a entrada com a saída. Em contrapartida, para minimizar os efeitos de sobreajuste, algumas técnicas de aprendizado avançadas são necessárias (HUANG *et al.*, 2019). Dentre as alternativas mais populares para evitar sobreajuste estão a validação cruzada e a parada antecipada, as quais são detalhadas na Seção 2.4.4.1 e na Seção 2.4.4.2, respectivamente.

2.4.4.1 Validação cruzada

Aprender parâmetros de uma RNA e testá-los nos mesmos dados é um erro metodológico, uma vez que provavelmente falharia em prever dados ainda não vistos. Para minimizar o sobreajuste, uma prática comum é, ao realizar o procedimento de aprendizado de máquina supervisionado, reter parte dos dados disponíveis como conjunto de teste. Ao realizar-se o treinamento de diferentes configurações de MLP, ainda existe o risco de sobreajuste com os dados de teste, pois os parâmetros podem ser

ajustados até que a MLP tenha um desempenho ótimo. De modo a resolver esse problema, outra parte dos dados disponíveis pode ser separada e chamada de conjunto de validação. O processo de aprendizado supervisionado é realizado com o conjunto de treinamento e realiza-se a avaliação de desempenho com o conjunto de validação. Caso o resultado seja próspero, uma avaliação final é feita com o conjunto de teste, conforme ilustrado na Figura 28 (HUANG *et al.*, 2019).

Figura 28 – Representação da divisão dos dados disponíveis em conjuntos de treinamento, validação e teste.

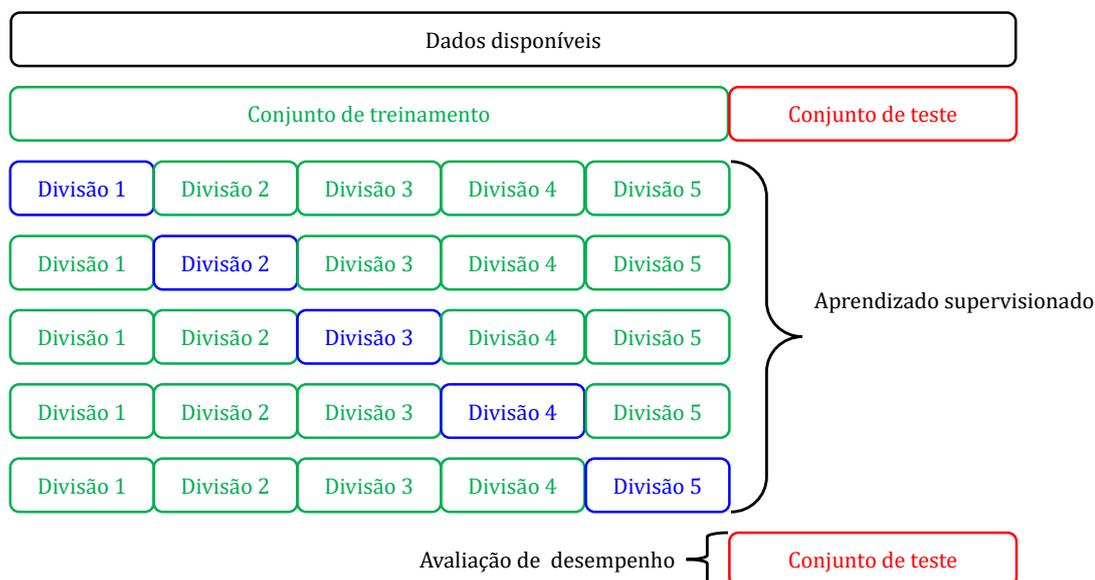


Fonte: Adaptado de Scikit-learn Contributors (2024).

Ao dividir os dados disponíveis em três conjuntos de dados, o número de amostras para o treinamento da RNA é drasticamente diminuído e os resultados podem depender de uma escolha aleatória de um conjunto de dados para treino, validação e teste. Uma solução para esse problema é um procedimento chamado de validação cruzada. Um conjunto de teste ainda deve ser separado para avaliar o desempenho da RNA treinada, porém, o conjunto de validação não é mais necessário quando se utiliza validação cruzada. Na sua implementação mais básica, denominada *k-fold*, em inglês (os termos *K* divisões, *K* dobras ou *K* subconjuntos também são encontrados na literatura, porém é mais comum encontrar a versão original em inglês), o conjunto de treinamento é dividido em um número *K* de conjuntos menores. Outras abordagens não serão descritas neste documento, entretanto, seguem os mesmos princípios de forma generalizada. Para cada conjunto *K*, o conjunto de treinamento é composto por $K - 1$ divisões, a RNA resultante é validada com o conjunto *K* e o desempenho da RNA é avaliado com o conjunto de teste, conforme ilustrado na Figura 29 (BISHOP, 2006).

O desempenho da RNA então é avaliado em relação à média de todas as *K* divisões realizadas. Esse método, apesar de ser computacionalmente custoso, garante que não exista muita perda de dados se comparado ao caso de utilizar um conjunto fixo de validação, a qual é a sua principal vantagem em relação a eventuais problemas de inferência reversa quando o conjunto de dados é muito pequeno (BISHOP, 2006).

Figura 29 – Representação da divisão dos dados disponíveis para validação cruzada k -fold com $K = 5$.



Fonte: Adaptado de Scikit-learn Contributors (2024).

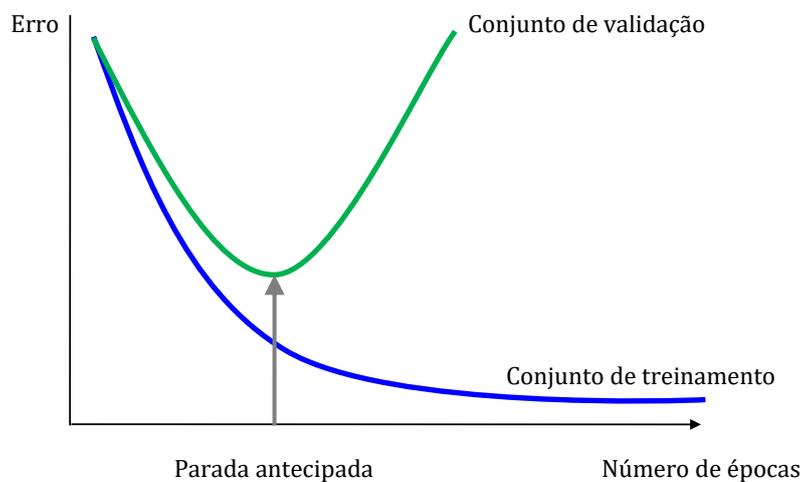
2.4.4.2 Parada antecipada

A parada antecipada é uma estratégia utilizada durante a etapa de treinamento, com a qual o processo de aprendizado é interrompido para evitar que a RNA especifique demais o conjunto de treinamento. O critério de parada se baseia na monitoração da métrica utilizada para cada época de treinamento da RNA para o conjunto de dados de validação. Para o caso da função de perda, a cada época avalia-se a ocorrência da sua diminuição considerando o valor de variação mínima definido para considerar uma melhoria. Uma vez que não ocorre a diminuição para as configurações definidas dentro um número definido de épocas, o processo de treinamento é interrompido (BISHOP, 2006). Na Figura 30 é possível observar uma ilustração da interrupção do processo de aprendizado ao longo do número de épocas em relação ao erro para o conjunto de validação e para o conjunto de treinamento.

2.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo, foram apresentados os conceitos necessários para o desenvolvimento e a análise do método proposto no Capítulo 3. Em inversores de frequência e acionamento de máquinas elétricas, foi dada ênfase ao comportamento do barramento CC devido à influência do seu comportamento em relação ao valor de capacitância do seu banco capacitivo para este tipo de aplicação. Em seguida, foi feita uma descrição da estrutura do capacitor eletrolítico, do modelo equivalente e dos métodos de degra-

Figura 30 – Técnica de parada antecipada para evitar sobreajuste.



Fonte: Adaptado de Dijk (2017).

dação acelerada, uma vez que o método proposto utiliza o valor de capacitância para a estimação da saúde do barramento CC.

Por fim, apresentou-se o funcionamento básico de uma MLP no que se refere à etapa de propagação e retropropagação. Em seguida, foram apresentadas as diferentes funções de ativação, otimizadores e o processo de treinamento, uma vez que a combinação dessas características foi avaliada para a definição da estrutura escolhida no Capítulo 4.

3 DADOS DE TREINAMENTO E DE TESTE

Este capítulo descreve os critérios para a escolha e obtenção dos dados de treinamento e teste da rede neural empregada. Na Seção 3.1, avaliam-se as grandezas utilizadas como dados de entrada e, na Seção 3.2, as características do conjunto formado pelo inversor de frequência e motor utilizados. As estratégias utilizadas para obter os dados de entrada e de saída para a implementação do método são apresentadas na Seção 3.3 e as análises das condições de operação dos dados são feitas na Seção 3.4 para os dados de treinamento e na Seção 3.5 para os dados de teste. Por fim, realiza-se um fechamento do capítulo na Seção 3.6, com destaque e revisão dos itens avaliados.

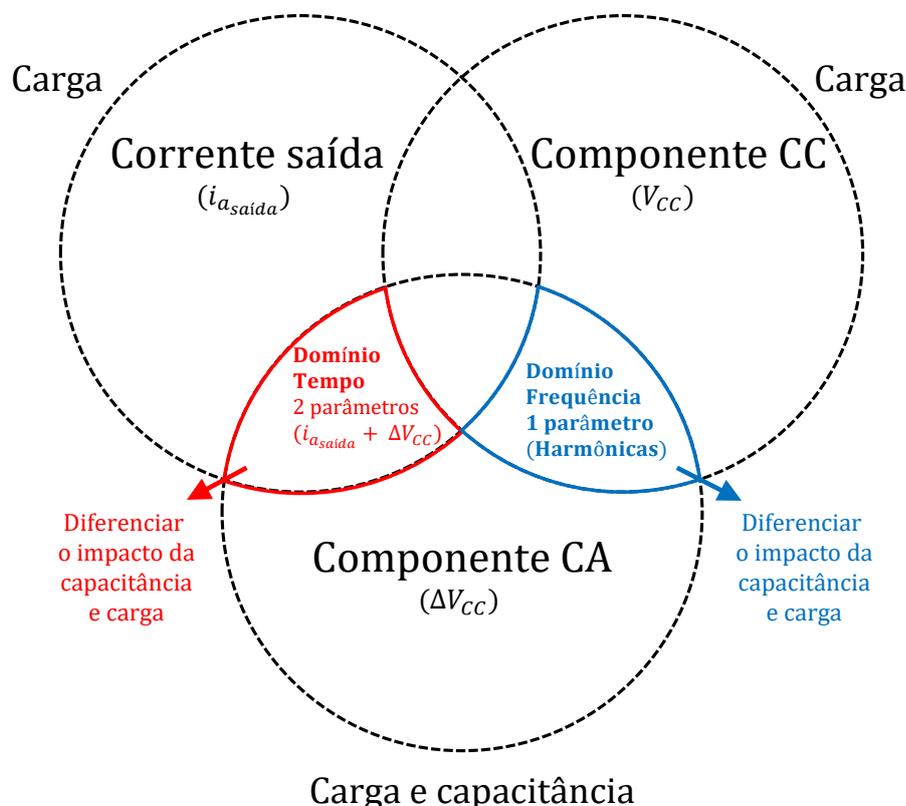
3.1 ANÁLISE DAS GRANDEZAS

Dado o comportamento natural do barramento CC apresentado na Seção 2.2.2 em inversores de frequência trifásicos e o requisito que o método proposto deve ser atrativo para aplicação na indústria, o mesmo utiliza como dados de entrada grandezas usualmente já existentes, sem hardware adicional, sendo elas: tensão do barramento CC, velocidade angular e corrente de saída do inversor. Entretanto, antes da sua escolha, é preciso avaliar a relação dessas grandezas com a capacitância de interesse e com a corrente de saída do inversor, de modo que seja possível separar alterações de capacitância de variações na condição de operação da carga. De modo a simplificar a análise e compreensão, na Figura 31 é apresentado um diagrama adaptado de Soliman *et al.* (2017b).

Posto que a corrente de saída é drenada do barramento CC, no qual está conectada a saída do retificador a diodos, a componente CA do barramento CC é dependente da carga por conta das perdas de condução nos diodos do retificador. Quanto maior a carga, maiores são as perdas e maior é a amplitude da oscilação da tensão do barramento CC, o que pode ser caracterizado por meio da tensão RMS de oscilação, no domínio do tempo. Entretanto, a alteração do valor da capacitância também afeta esse parâmetro, visto que a amplitude da tensão de oscilação gerada pelo retificador a diodos é suavizada de acordo com o aumento do valor da capacitância, uma vez que a sua função é armazenar energia para amenizar as variações de potência na saída do retificador (CHAPMAN, 2013). Assim, de acordo com Soliman *et al.* (2017a), a tensão RMS de oscilação do barramento CC é dependente tanto da capacitância como da corrente de saída do motor, portanto, a utilização combinada da tensão RMS de oscilação do barramento CC e da corrente de saída do motor é importante para diferenciar o impacto da capacitância e da corrente de saída do motor.

Outra alternativa é a utilização das harmônicas da tensão do barramento CC, as quais incluem as componentes CC e CA e podem ser obtidas com uma análise

Figura 31 – Parâmetros dependentes da variação de capacitância e de carga.



Fonte: Adaptado de Soliman *et al.* (2017b)

na frequência. A componente CC é dependente somente da corrente de saída do motor e as harmônicas são afetadas por ambos os efeitos. Dessa forma, a análise anteriormente feita no domínio do tempo pode ser também realizada com base em dados processados no domínio da frequência.

Com o intuito de priorizar o baixo processamento, optou-se por realizar as operações com as grandezas no domínio do tempo, em vez daquelas que requerem ser executadas no domínio da frequência. Isso se deve ao baixo custo dos sistemas embarcados utilizados em inversores de frequência trifásicos industriais se comparado a processadores digitais de sinais, do inglês, *Digital Signal Processor* ou arranjo de porta programável em campo, do inglês, *Field Programmable Gate Array*.

3.2 CONFIGURAÇÃO DO SISTEMA

O método proposto é aplicado para estimar a capacitância do barramento CC em um inversor de frequência trifásico de baixa tensão com retificador a diodos. As características do conjunto inversor de frequência e motor utilizados estão listadas na Tabela 1 e na Tabela 2, respectivamente.

Tabela 1 – Especificações do inversor de frequência utilizado.

Característica	Valor
Fabricante	WEG
Modelo	CFW500
Grau de proteção	IP66
Número de fases de entrada	Três fases (Trifásico)
Corrente nominal de saída	6,5 A
Tensão CA nominal de entrada	380 V a 400 V
Potência nominal	3 kW
Frequência de chaveamento	2,5 kHz a 15 kHz
Filtro supressor de Rádio-Frequência	Sem filtro de Rádio-Frequência interno
Tensão CC teórica barramento	537 V a 622 V
Tensão CC máxima barramento	800 V
Capacitância nominal barramento CC (C_0)	330 μ F
Capacitância FDV barramento CC (C_{FDV})	255 μ F
Impedância de rede mínima	Queda de tensão da rede de 1%

Fonte: WEG (2024a).

Tabela 2 – Especificações do motor utilizado.

Característica	Valor
Fabricante	WEG
Modelo	W22 Super Premium
Corrente nominal	6,72 A
Tensão nominal	380 V
Potência	3 kW
Número de polos	4 polos
Frequência de alimentação elétrica	60 Hz
Velocidade angular nominal	1750 rev min ⁻¹
Escorregamento	2,78%

Fonte: WEG (2024b).

3.3 MEDIÇÃO E USO DAS GRANDEZAS

Em inversores de frequência industriais trifásicos, a tensão do barramento CC e corrente de saída são usualmente medidas para funções de proteção, apresentação de parâmetros para o usuário e controle. Para funções de proteção, as grandezas são utilizadas para detectar sobretensão, subtensão, falta de fase, sobrecorrente e curto-circuito entre fases de saída. Já para parâmetros do usuário, tipicamente são disponibilizadas pelo menos as seguintes grandezas: tensão do barramento CC filtrada, potência de saída, corrente de saída filtrada, nível de subtensão, nível de sobretensão e frenagem reostática. Por fim, para controle, dependendo da estratégia utilizada, escalar ou vetorial, as grandezas são empregadas para regulação do barramento

CC, regulação do fluxo, estimação de variáveis do motor e controle das malhas de posição, velocidade angular e corrente. Para obtenção dos dados de treinamento, na Seção 3.3.1 apenas apresenta-se a estratégia utilizada para obtenção da tensão RMS de oscilação do barramento CC pelo inversor de frequência, uma vez que a corrente de saída RMS já se encontra implementada nas rotinas de inversores de frequência. Por fim, na Seção 3.3.2 as modificações realizadas para alteração da capacitância do barramento CC.

3.3.1 Tensão RMS de oscilação do barramento CC

Apesar de as grandezas escolhidas fazerem parte das principais rotinas e funções de inversores de frequência industriais, para a obtenção da tensão RMS de oscilação do barramento CC é necessário realizar o seu processamento de forma adequada. Conforme apresentado na Seção 2.2.1, a frequência da componente fundamental da tensão do barramento CC é seis vezes a frequência da tensão de alimentação, então é necessário definir a frequência de amostragem e quantos períodos serão utilizados para o cálculo da tensão RMS de oscilação do barramento CC levando isso em consideração. Para se obter um número inteiro de amostras com relação ao número de períodos sem perda do valor de tensão RMS calculado para períodos incompletos do sinal, o mesmo deve levar em consideração a igualdade da Equação (11):

$$\frac{1}{f_{cf}} T = \frac{1}{f_{DAQ}} X_n = \Delta t, \quad (11)$$

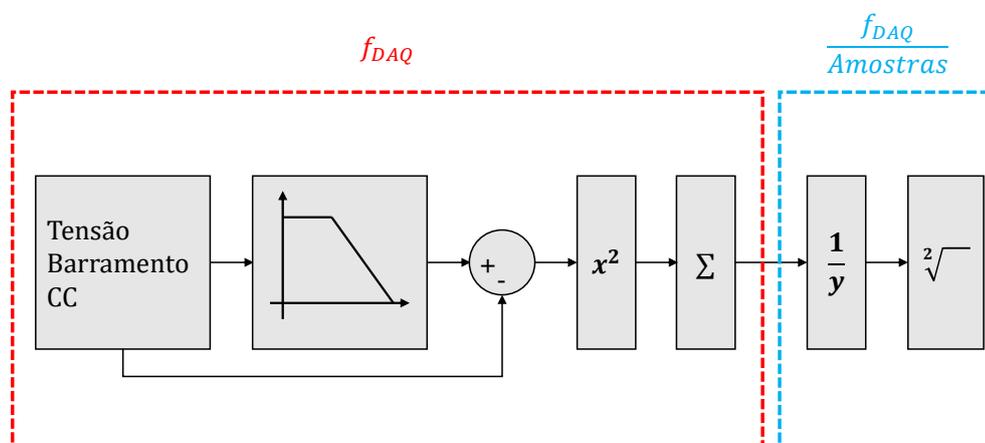
na qual f_{cf} é a frequência da componente fundamental, T é o número de períodos que se deseja adquirir, f_{DAQ} é a frequência do sistema de aquisição de dados, X_n é o número de amostras que se precisa adquirir e Δt é a janela de tempo da aquisição.

Com base na Equação (11), propõe-se a estrutura de blocos apresentada na Figura 32 para cálculo da tensão RMS do barramento CC. Na primeira etapa, faz-se a medição da tensão do barramento CC na frequência de aquisição de dados, obtém-se o valor filtrado e subtrai-se o valor não filtrado, de modo a se obter o valor instantâneo de oscilação da tensão do barramento CC em relação ao valor filtrado, conforme detalhado na Figura 33. Uma vez realizada essa operação, o valor é elevado ao quadrado e se realiza o somatório até o número de amostras definido. Uma vez que o número desejado de amostras é obtido, divide-se o valor do somatório pelo número de amostras e calcula-se a raiz quadrada para se obter o valor eficaz.

3.3.2 Capacitância do barramento CC

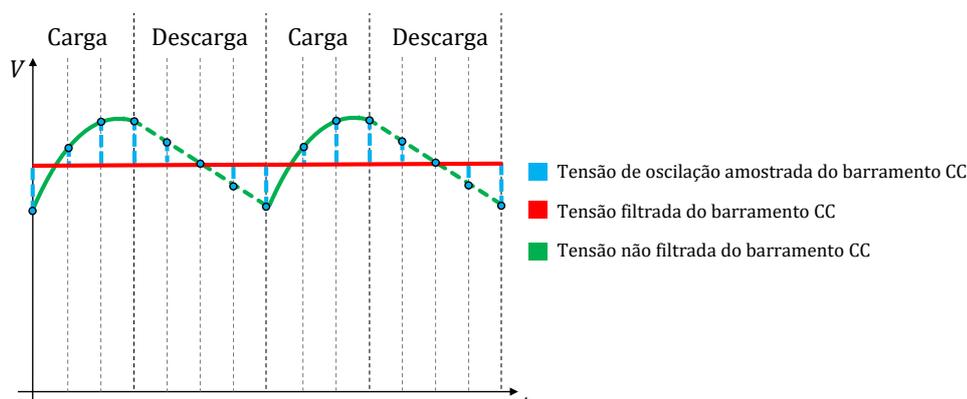
O banco capacitivo original da amostra utilizada é composto por dois pares em paralelo de dois capacitores em série de 330 μF , resultando em uma capacitância total de 330 μF . Para se obter os dados de treinamento no intervalo de monitoração, o

Figura 32 – Estrutura de blocos para obtenção da tensão RMS de oscilação do barramento CC.



Fonte: De autoria própria.

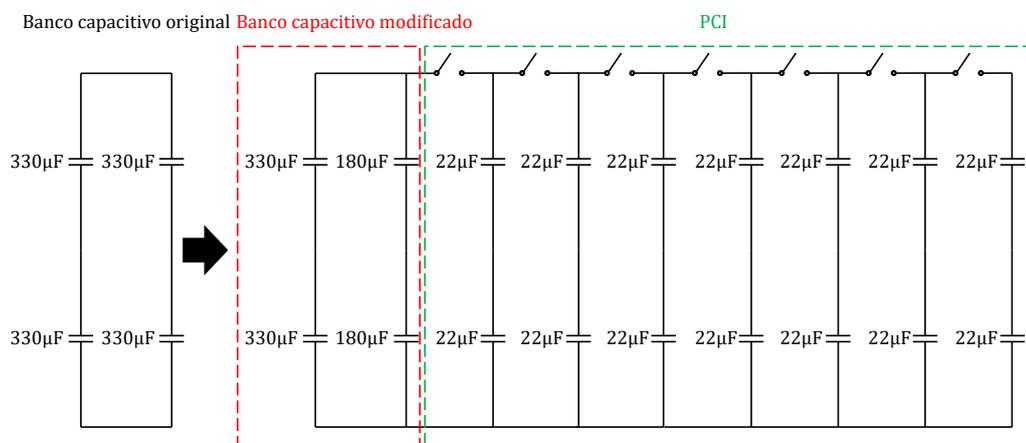
Figura 33 – Ilustração de cálculo do valor instantâneo da tensão de oscilação do barramento CC.



Fonte: de autoria própria.

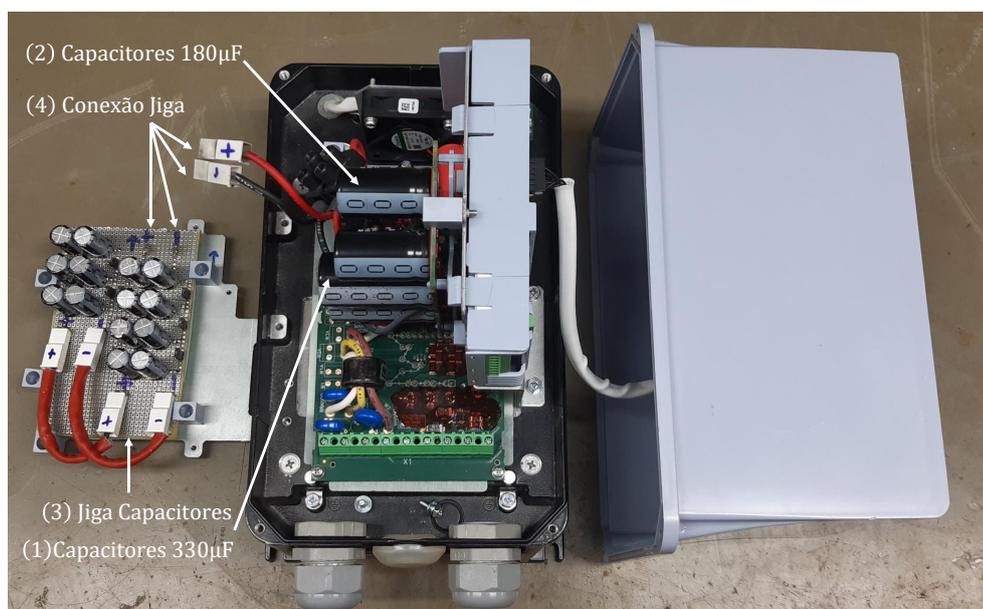
banco capacitivo foi modificado com a substituição de um dos pares de $330 \mu\text{F}$ por um par de $180 \mu\text{F}$. O resultado é um banco capacitivo de $255 \mu\text{F}$, 22,7% abaixo do valor nominal. Para permitir a variação controlada de capacitância de $255 \mu\text{F}$ a $332 \mu\text{F}$, uma Placa de Circuito Impresso (PCI) com sete capacitores de $11 \mu\text{F}$ foi desenvolvida para ser conectada em paralelo com o banco capacitivo modificado. Todos os capacitores utilizados pertencem ao mesmo fabricante e são da mesma série. Na Figura 34, é possível observar uma ilustração das modificações realizadas no banco capacitivo original. Já na Figura 35 é possível observar o banco capacitivo modificado e a jiga desenvolvida na amostra. O banco capacitivo modificado é composto pelos capacitores de $330 \mu\text{F}$ em (1) e $180 \mu\text{F}$ em (2). A jiga de capacitores está indicada em (3) e sua conexão em paralelo com o banco capacitivo modificado está indicada em (4).

Figura 34 – Banco capacitivo original e modificado com PCI.



Fonte: de autoria própria.

Figura 35 – Banco capacitivo modificado com PCI fora da amostra utilizada.



Fonte: de autoria própria.

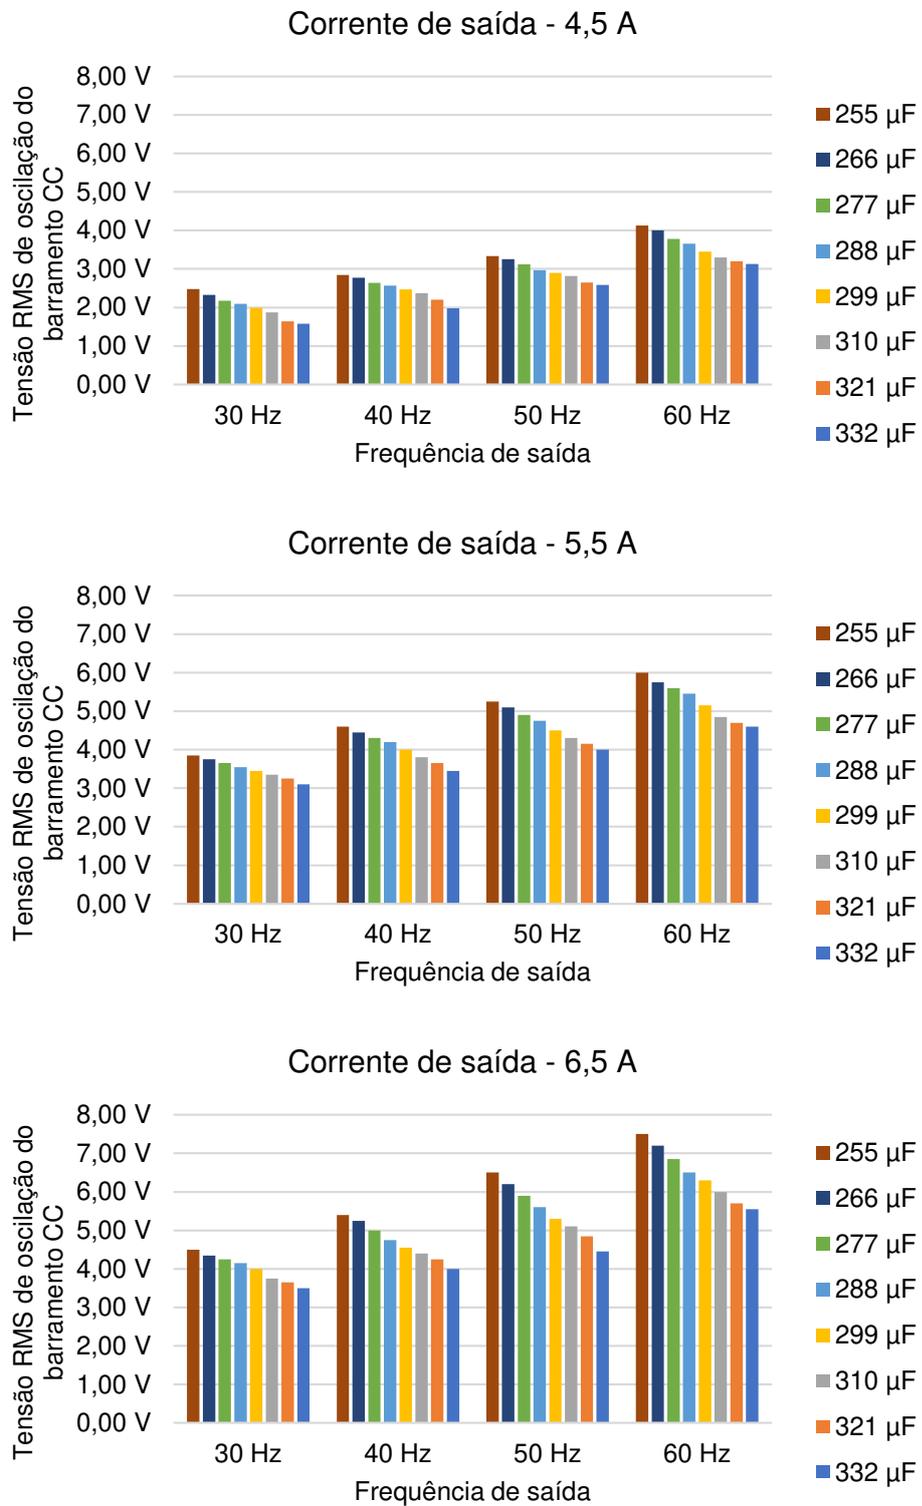
3.4 DADOS DE TREINAMENTO

Os dados de treinamento foram obtidos de acordo com as condições de operação do conjunto inversor de frequência e motor listadas na Tabela 1 e na Tabela 2. Para definir as condições de operação para a obtenção dos dados de treinamento, foi feita uma análise das condições de operação utilizadas por Soliman *et al.* (2017a). Para um inversor de frequência de 4 kW com capacitância nominal do barramento CC de 500 μF , os dados de treinamento foram obtidos nas seguintes condições: uma velocidade angular de saída — 50 Hz (100%), três valores de potência de saída — 2 kW (50%), 3 kW (75%) e 4 kW (100%), e dez valores de capacitância do barramento CC — 500 μF (100%), 511 μF (102,2%), 522 μF (104,4%), 533 μF (106,6%), 555 μF (111,0%), 566 μF (113,2%), 577 μF (115,4%), 588 μF (117,6%) e 599 μF (119,8%). As condições escolhidas estão de acordo com as de operação em aplicações industriais, porém, vale ressaltar que, por se tratar de um inversor de frequência, usualmente há variação da velocidade angular de saída no seu uso. Outra observação relevante é que apesar de o critério de FDV de capacitores eletrolíticos ser a avaliação da diminuição da capacitância, nesse artigo é realizada a adição de capacitância em relação ao seu valor nominal, o que é contraditório ao intervalo de monitoração para degradação de capacitores eletrolíticos. Por fim, não se faz referência em que temperatura ambiente os dados de treinamento e teste foram obtidos. Em Soliman, Wang e Blaabjerg (2016) e Zhao *et al.* (2020), diversos métodos fazem compensação do efeito da temperatura para as variáveis estimadas, uma vez que há diminuição da R_{SE} e aumento da capacitância com o aumento da temperatura.

Para este trabalho, os dados de treinamento foram obtidos por meio do inversor de frequência em uma câmara térmica com temperatura controlada a 25 °C. A variação de carga, que afeta a corrente consumida pelo motor, foi realizada de forma controlada por meio de um dinamômetro com controle de torque. Foram realizadas diversas medições em 96 pontos de operação para se obter os dados de treinamento, definidos pela combinação de: três correntes de saída — 4,5 A (70%), 5,5 A (85%) e 6,5 A (100%); quatro frequências de saída — 30 Hz (50%), 40 Hz (66,6%), 50 Hz (83,3%) e 60 Hz (100%); e oito valores de capacitância — 255 μF (77,3%), 266 μF (80,6%), 277 μF (83,9%), 288 μF (87,3%), 299 μF (90,6%), 310 μF (93,9%), 321 μF (97,3%) e 332 μF (100,6%). O conjunto de dados de treinamento é composto por corrente de saída do motor, frequência de saída do motor, tensão RMS de oscilação do barramento CC e o valor correspondente de capacitância disponível, o qual é a grandeza de estimação, conforme ilustrado na Figura 36.

A fim de avaliar a correlação linear entre as variáveis de entrada e de saída da MLP, foi realizado o mapa de calor de correlação com base no coeficiente de correlação de Pearson. O mesmo indica a correlação linear entre dois conjuntos de dados, sendo o seu valor normalizado e pertencente ao intervalo de -1 a $+1$ (HOTELLING, 1953).

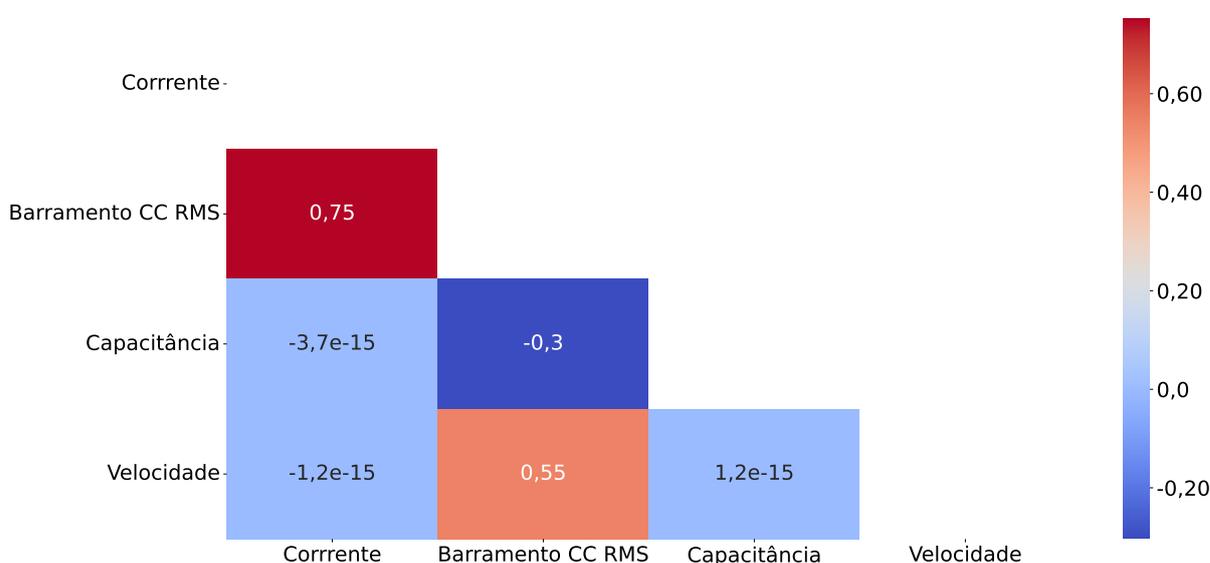
Figura 36 – Conjunto de dados de treinamento.



Fonte: de autoria própria.

Conforme apresentado na Figura 37, é possível inferir que a variação de capacitância do barramento CC não possui correlação linear com a velocidade angular de saída do motor, pelo fato de o par apresentar PCC próximo de zero. O mesmo se aplica para a corrente de saída do motor em relação à velocidade angular de saída do motor e capacitância do barramento CC. Entretanto, se comparada a correlação da tensão RMS de oscilação do barramento CC com a velocidade angular de saída do motor em relação às demais variáveis, torna-se relevante considerar a velocidade angular de saída do motor como dado de entrada da MLP.

Figura 37 – Mapa de calor de correlação linear das variáveis de entrada e de saída.



Fonte: de autoria própria.

3.5 DADOS DE TESTE

As amostras de testes consideradas são o próprio banco capacitivo original e capacitores degradados de forma acelerada por sobretemperatura. Para isso, na Seção 3.5.1 são apresentadas as informações que o fabricante disponibiliza em relação à vida útil e às condições de operação do capacitor utilizado. Na sequência, na Seção 3.5.2 é feita a análise e comparação das técnicas de degradação acelerada utilizadas para capacitores eletrolíticos. Por fim, na Seção 3.5.3 são apresentados os dados de teste obtidos nas mesmas condições de operação definidas para os dados de treinamento.

3.5.1 Características do capacitor original

O modelo do capacitor original utilizado no banco capacitivo da amostra de estudo é o B43504-S9337-M006 do fabricante EPCOS. Suas principais características

se encontram listadas na Tabela 3 e na Tabela 4, conforme a folha de dados do fabricante. As informações de vida útil do componente são apresentadas em função da temperatura de operação e ondulação de corrente para determinar o tempo de operação estimado. Na Figura 38 essa relação para diferentes intervalos de operação pode ser notada. Considerando as informações de operação e vida útil fornecidas pelo fabricante, nas próximas subseções são analisadas as técnicas de degradação de capacitores eletrolíticos e o fator de degradação utilizado com base nos valores nominais do componente.

Tabela 3 – Especificações do capacitor.

Código do fabricante	B43504-S9337-M006
Capacitância nominal	330 μ F
Capacitância FDV (C_{FDV})	255 μ F
Tensão de Operação	200 V a 450 V
Tolerância Capacitância	$\pm 20\%$
Temperatura de operação	-40°C a 105°C
FDV	$< \pm 20\%$ capacitância inicial

Fonte: ALUMINUM... (2013)

Tabela 4 – Informações de vida útil do capacitor.

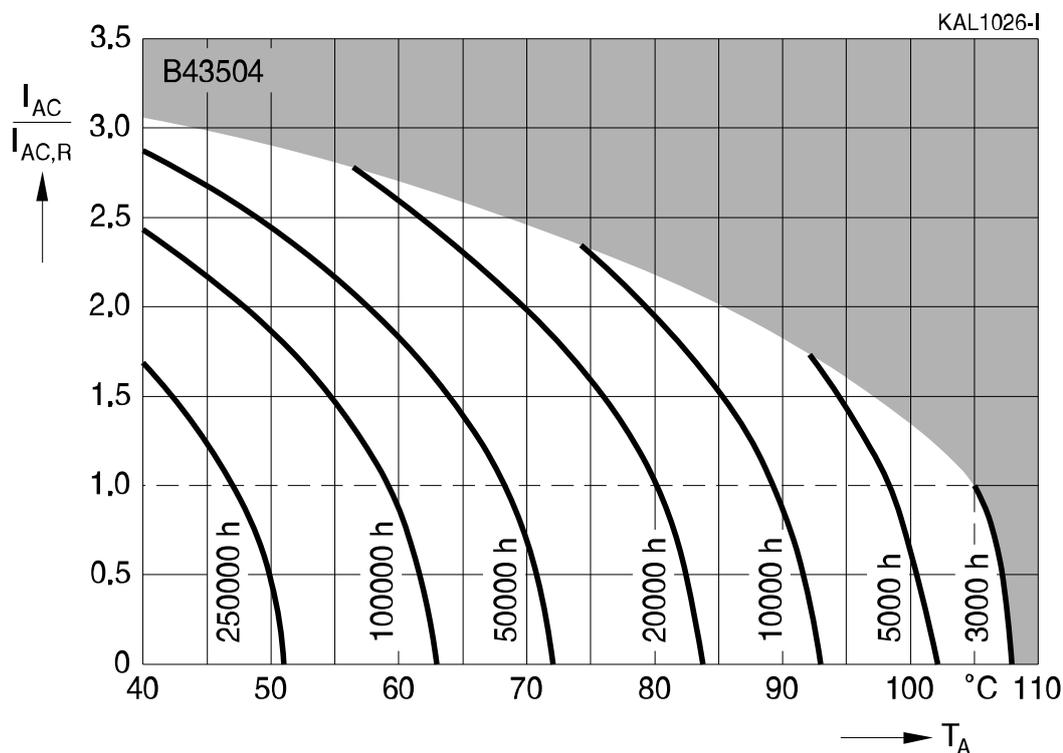
Vida útil	Tempo
105°C; Tensão de Operação; Corrente CA de operação	> 3000 h
85°C; Tensão de Operação; Corrente CA máxima	> 6500 h
40°C; Tensão de Operação; 1,9× Corrente CA de operação	> 20 000 h

Fonte: ALUMINUM... (2013)

3.5.2 Métodos de degradação acelerada

Conforme apresentado na Seção 2.3.5, os modos de degradação de Al-Cap podem ser realizados tanto por estresse elétrico quanto por térmico. Ambos os métodos levam à evaporação do eletrólito e diminuição da capacitância (KULKARNI, C. *et al.*, 2011b). O modo de degradação acelerado por sobretemperatura foi escolhido para as amostras utilizadas para teste do método proposto neste trabalho. Para a aplicação do mesmo, dez amostras foram colocados em uma câmara térmica com temperatura controlada com referência em 130°C , temperatura essa acima da especificada pelo fabricante. A temperatura da câmara térmica foi gradualmente incrementada em passos de 25°C até a temperatura predeterminada de 130°C . As amostras ficaram por pelo menos 15 min em cada incremento de temperatura para equilíbrio térmico. Essa estratégia foi utilizada de modo a diminuir a possibilidade de choques térmicos durante o aquecimento da amostra.

Figura 38 – Vida útil em função da temperatura ambiente e da ondulação de corrente.



Fonte: Adaptado de ALUMINUM... (2013)

De acordo com os dados apresentados na Figura 38, a cada incremento de 10°C de temperatura ambiente (T_A) a vida útil cai em média pela metade para uma dada condição de oscilação de corrente dos capacitores ($\frac{I_{AC}}{I_{AC,R}}$). Portanto, para 130°C , tem-se uma projeção estimada de 750 h para atingir os 20% de diminuição da capacitância inicial do componente. Para monitorar a degradação, a medição da capacitância das amostras foi realizada a cada 100 h. Isso foi feito para verificar o nível de degradação usando a estratégia de redução gradual da temperatura, diminuindo 25°C a cada 15 min, desde a temperatura de degradação acelerada (130°C) até a temperatura ambiente (25°C). Da mesma forma que foi feito para o aquecimento, para a redução de temperatura, foram aplicados decrementos de 25°C até a temperatura ambiente. Os valores de capacitância foram medidos em 120 Hz por meio do instrumento de medição de resistência, capacitância e indutância Quadtech 1730T (QUADTECH, 2024).

O ensaio de degradação foi realizado na câmara térmica Thermotron SE-2000-3-3 (THERMOTRON, 2024). Das dez amostras ensaiadas, cinco foram retiradas aproximadamente na metade do valor de FDV e as cinco demais na capacitância de FDV – $290\ \mu\text{F}$ e $255\ \mu\text{F}$, respectivamente. Essa decisão se deve à importância de se realizar a etapa de validação do método em pelo menos dois valores de capacitância pertencentes ao intervalo de monitoração. É possível observar o valor da capacitância de

cada amostra a cada intervalo de 100 h durante a etapa de degradação acelerada na Figura 39. Pelos resultados apresentados é possível avaliar que o processo de degradação não é linear no tempo para temperatura constante. O valor de capacitância final correspondente a cada amostra é apresentado na Tabela 5.

Posto que a amostra utilizada consiste de um banco de capacitores do barramento CC composto por quatro capacitores dispostos em dois pares em paralelo de dois capacitores em série, foi possível montar dois bancos de capacitores com as dez amostras degradadas, sendo cinco com 200 h de degradação e as outras cinco com 800 h. Para compor os bancos capacitivos, foram escolhidas as associações de amostras com o valor de capacitância mais próxima do desejado. Portanto, foram escolhidas as amostras 1, 2, 4 e 5 para o primeiro banco (resultando em uma capacitância total de 296,47 μF) e as amostras 6, 7, 8 e 9 para o segundo banco (resultando em uma capacitância total de 255,27 μF), conforme apresentado na Figura 40. Os dois bancos capacitivos representam 10,16% e 22,6% de degradação em relação à capacitância nominal de 330 μF .

Tabela 5 – Capacitância das amostras após a degradação acelerada.

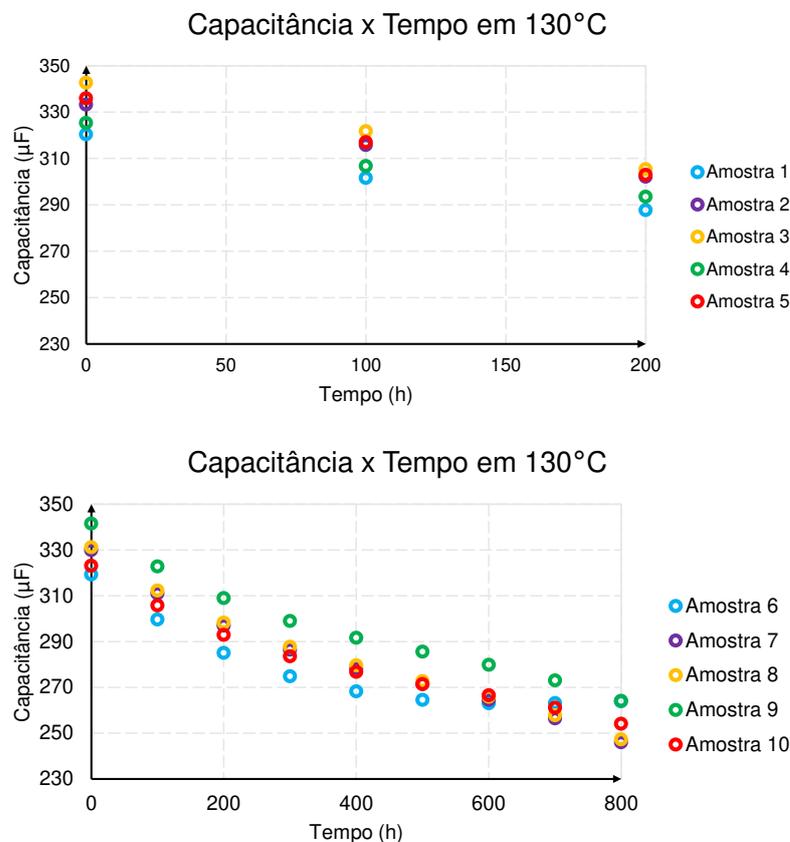
Amostra	Capacitância
1	287,69 μF
2	302,10 μF
3	305,41 μF
4	293,52 μF
5	302,92 μF
6	263,82 μF
7	245,95 μF
8	247,24 μF
9	264,02 μF
10	254,00 μF

Fonte: de autoria própria.

3.5.3 Aquisição dos dados de teste

Para a obtenção dos dados de teste, o banco capacitivo original e os dois degradados por sobretemperatura foram submetidos às mesmas condições de operação definidas para os dados de treinamento, resultando em 36 conjuntos de dados de teste. O conjunto de dados de teste é composto por corrente de saída do motor, frequência de saída do motor, tensão RMS de oscilação do barramento CC e o valor correspondente de capacitância disponível, o qual é a grandeza de estimação, conforme ilustrado na Figura 41.

Figura 39 – Degradação das amostras de capacitores no tempo em câmara térmica.



Fonte: De autoria própria

3.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

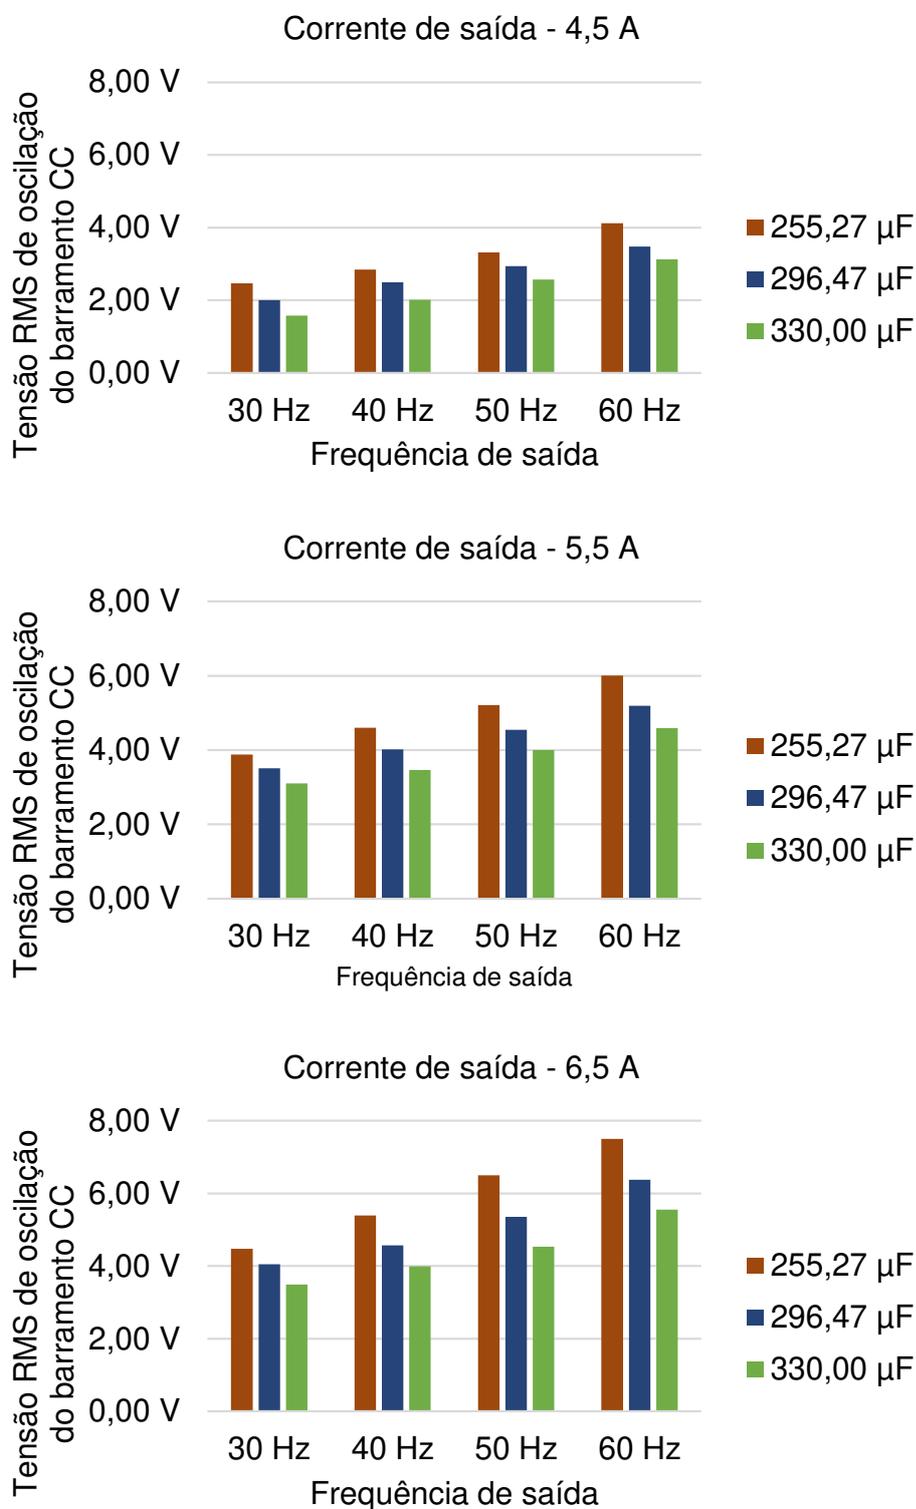
Neste capítulo foram avaliadas e escolhidas as variáveis de entrada do modelo, apresentando as características do objeto de estudo e as estratégias utilizadas para a aquisição dos dados. Feito isso, foram obtidos os dados de treinamento, detalhando as modificações realizadas para a sua obtenção, condições de operação consideradas e análise de correlação linear dos dados obtidos. Já para os dados de teste, apresentou-se o método de degradação de capacitores eletrolíticos utilizado e o conjunto de dados obtidos nas mesmas condições de operação dos dados de treinamento. O próximo capítulo, Capítulo 4, apresenta a análise das diferentes estruturas de MLP e discute o processo de treinamento empregado, a definição da MLP para o método proposto e a análise de desempenho com os dados de teste.

Figura 40 – Banco capacitivo de amostras degradadas de 296,47 μF e 255,27 μF .



Fonte: de autoria própria

Figura 41 – Conjunto de dados de teste.



Fonte: de autoria própria.

4 AVALIAÇÃO DAS REDES E ANÁLISE DE RESULTADOS

Neste capítulo, avalia-se o desempenho das diferentes configurações de MLP para estimação da capacitância do barramento CC. Na Seção 4.1, diferentes estruturas de MLP em relação ao número de camadas escondidas, número de neurônios na camada escondida, algoritmos de otimização e funções de ativação das camadas escondidas são propostas para o problema de predição do valor de capacitância do barramento. Na Seção 4.3, analisa-se o desempenho da MLP escolhida com os dados de teste e, por fim, na Seção 4.4 apresenta-se uma revisão dos principais itens avaliados no capítulo.

4.1 TREINAMENTO DA MLP

Conforme introduzido na Seção 2.4, existem diversas configurações possíveis de MLP. As mesmas podem variar em relação ao número de neurônios na camada escondida, número de camadas escondidas, funções de ativação, otimizadores, entre outros parâmetros de ajuste, para a obtenção de um modelo de MLP. Dessa forma, diversas configurações foram avaliadas por meio do método de ajuste de hiperparâmetros por busca em grade em relação ao número de camadas escondidas (1 e 2), número de neurônios na camada escondida ou nas camadas escondidas (8, 16 e 32), algoritmos de otimização (Adam e RMSprop) e funções de ativação das camadas escondidas (RELU, SELU e ELU). O critério de escolha teve como base o menor MSE obtido em relação a todas as demais combinações conforme os resultados de treinamento apresentados na Tabela 6 para o otimizador Adam e na Tabela 7 para o otimizador RMSprop. O algoritmo de treinamento utilizado minimiza os problemas de sobreajuste por meio da parada prévia com base na variação do erro quadrático médio em 1% das últimas 500 épocas. Os dados de treinamento foram utilizados para treinar a MLP e os de teste para avaliar o seu desempenho. É notória a importância da otimização dos parâmetros avaliados no que se refere ao desempenho de previsão, não só pelas diferentes funções de ativação, número de camadas escondidas e neurônios nas camadas escondidas, mas principalmente pelos otimizadores avaliados. Conforme destacado, apesar de a configuração encontrada com menor erro quadrático ser a configuração de uma camada escondida com 16 neurônios, algoritmo de otimização Adam e função de ativação da camada escondida ELU, na Seção 4.2 é detalhada a técnica de validação cruzada como avaliação da robustez e critério de escolha dos modelos avaliados.

Tabela 6 – Comparativo de desempenho das configurações de MLP com o otimizador Adam.

Função de ativação	Camadas escondidas		R^2	Erro médio absoluto	Referência
	Número	Neurônios por camada			
ELU	1	8	0,74	4,48%	1 / 8 / ELU
ELU	1	16	0,99	0,88%	1 / 16 / ELU
ELU	1	32	0,99	1,01%	1 / 32 / ELU
ELU	2	16	0,97	1,34%	2 / 16 / ELU
RELU	1	8	0,74	4,35%	1 / 8 / RELU
RELU	1	16	0,78	3,95%	1 / 16 / RELU
RELU	1	32	0,78	3,95%	1 / 32 / RELU
RELU	2	16	0,80	4,53%	2 / 16 / RELU
SELU	1	8	0,74	4,39%	1 / 8 / SELU
SELU	1	16	0,98	1,09%	1 / 16 / SELU
SELU	1	32	0,98	1,02%	1 / 32 / SELU
SELU	2	16	0,99	1,03%	2 / 16 / SELU

Fonte: de autoria própria.

Tabela 7 – Comparativo de desempenho das configurações de MLP com o otimizador RMSprop.

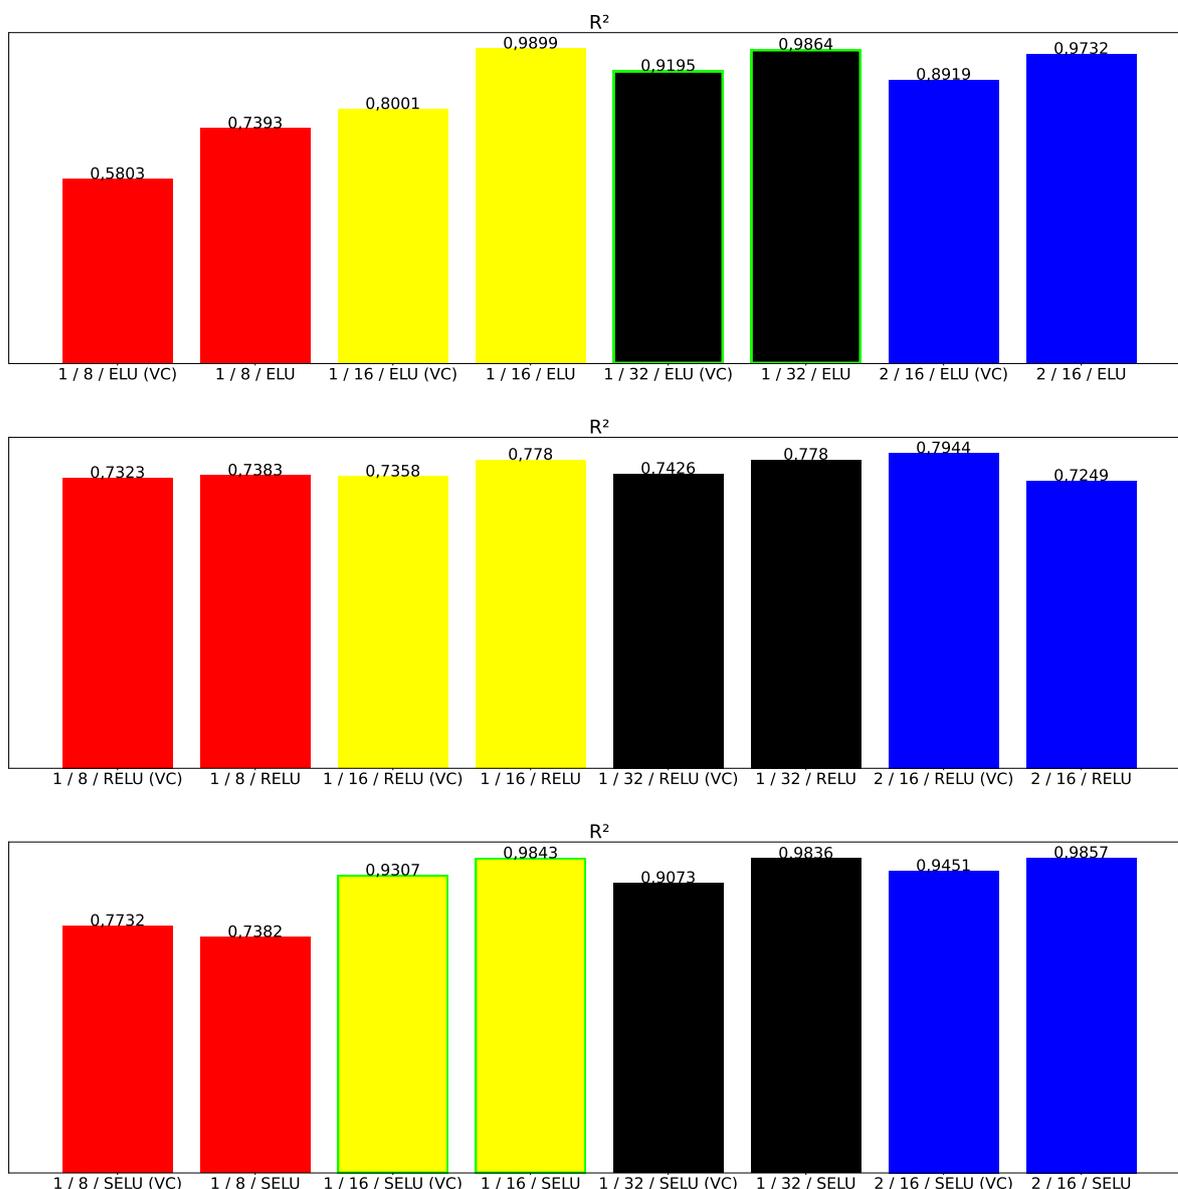
Função de ativação	Camadas escondidas		R^2	Erro médio absoluto	Referência
	Número	Neurônios por camada			
ELU	1	8	0,72	4,63%	1 / 8 / ELU
ELU	1	16	0,77	3,93%	1 / 16 / ELU
ELU	1	32	0,77	3,95%	1 / 32 / ELU
ELU	2	16	0,95	1,96%	2 / 16 / ELU
RELU	1	8	0,39	6,81%	1 / 8 / RELU
RELU	1	16	0,72	4,53%	1 / 16 / RELU
RELU	1	32	0,72	4,53%	1 / 32 / RELU
RELU	2	16	0,78	3,92%	2 / 16 / RELU
SELU	1	8	0,72	4,54%	1 / 8 / SELU
SELU	1	16	0,72	4,52%	1 / 16 / SELU
SELU	1	32	0,97	1,45%	1 / 32 / SELU
SELU	2	16	0,93	2,06%	2 / 16 / SELU

Fonte: de autoria própria.

4.2 VALIDAÇÃO CRUZADA

De modo a minimizar os efeitos de sobreajuste da MLP treinada com os dados de teste, o processo de validação cruzada *k-fold* é empregado para a avaliação das diferentes estruturas propostas. Com um *k* igual à cinco, para cada *fold*, um conjunto de 77 dados é utilizado para treinamento e um conjunto de 19 dados, para validação. Após a etapa de aprendizado supervisionado, cada MLP tem o seu desempenho avaliado

Figura 42 – Coeficiente de determinação com e sem validação cruzada para função de ativação para otimizador Adam.

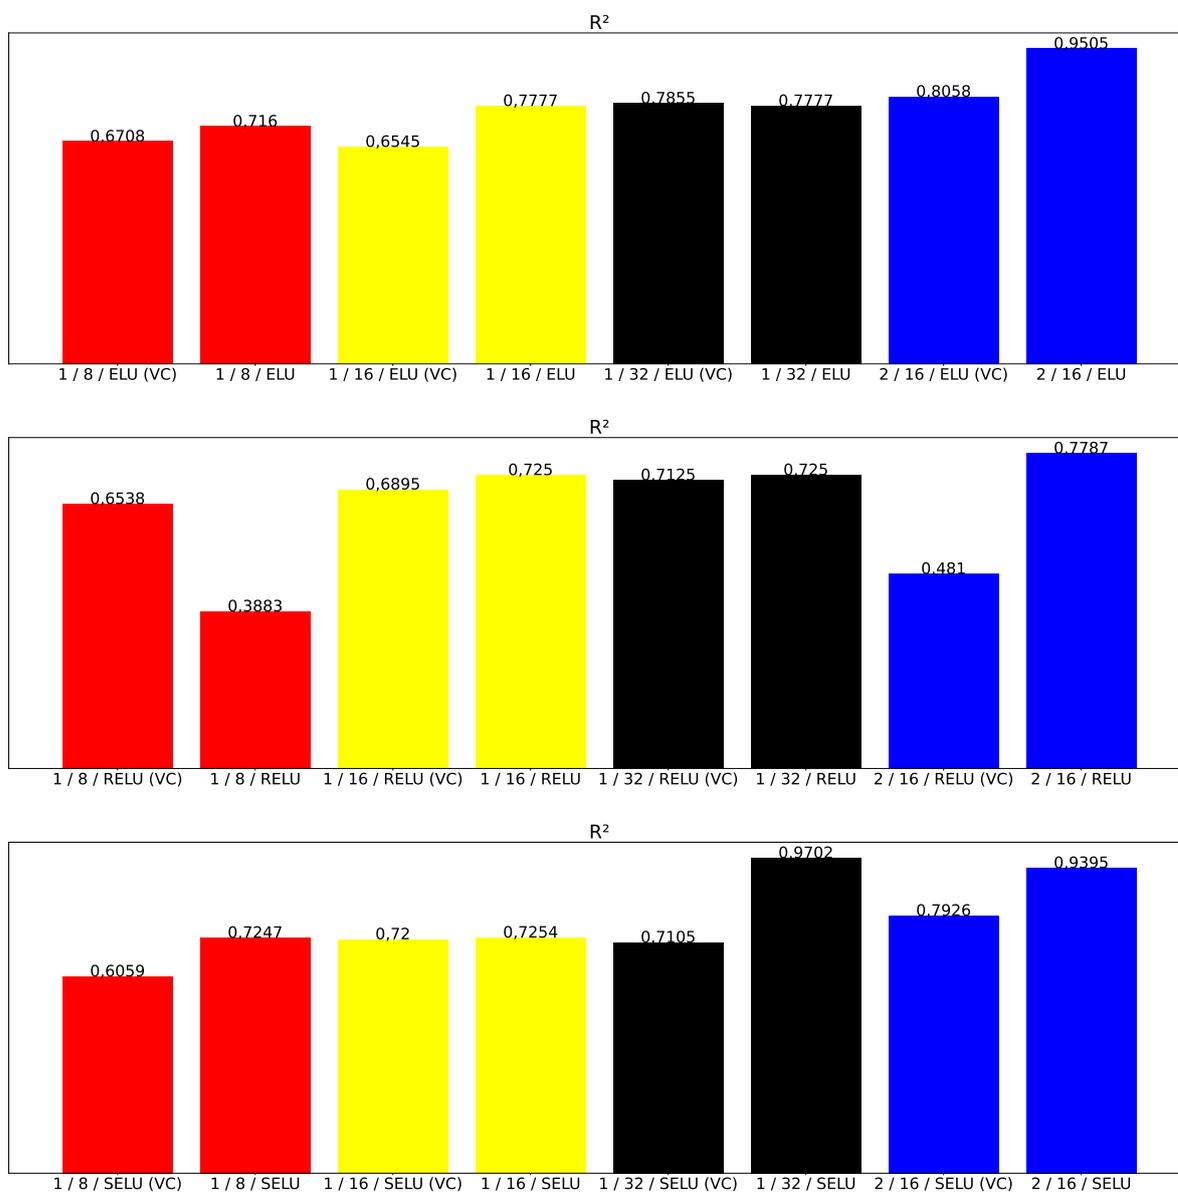


Fonte: de autoria própria.

pele conjunto de teste de 36 dados. Na Figura 42 e Figura 43 é possível observar o R^2 para os treinamentos com e sem validação cruzada de todas as configurações anteriormente avaliadas de função de ativação, número de camadas escondidas, número de neurônios por camada escondida e otimizador.

A partir dos resultados apresentados, para a maioria dos casos, há uma pequena variação do R^2 para cada configuração de MLP treinada com e sem validação cruzada. Portanto, como indicador de robustez, como critério de escolha, é avaliado não só a configuração com maior R^2 , mas também a menor variação para os casos de

Figura 43 – Coeficiente de determinação com e sem validação cruzada para função de ativação para otimizador RMS.



Fonte: de autoria própria.

com e sem validação cruzada. Dessa forma, conforme destacado com contorno verde, apesar de a configuração com maior R^2 ser a configuração de uma camada escondida, 16 neurônios na camada escondida, função de ativação ELU e otimizador Adam; a configuração escolhida para aplicação no método foi a de uma camada escondida, 16 neurônios na camada escondida, função de ativação SELU e otimizador Adam. Os erros de estimação para o conjunto de teste são detalhados na Seção 4.3.

4.3 RESULTADOS EXPERIMENTAIS

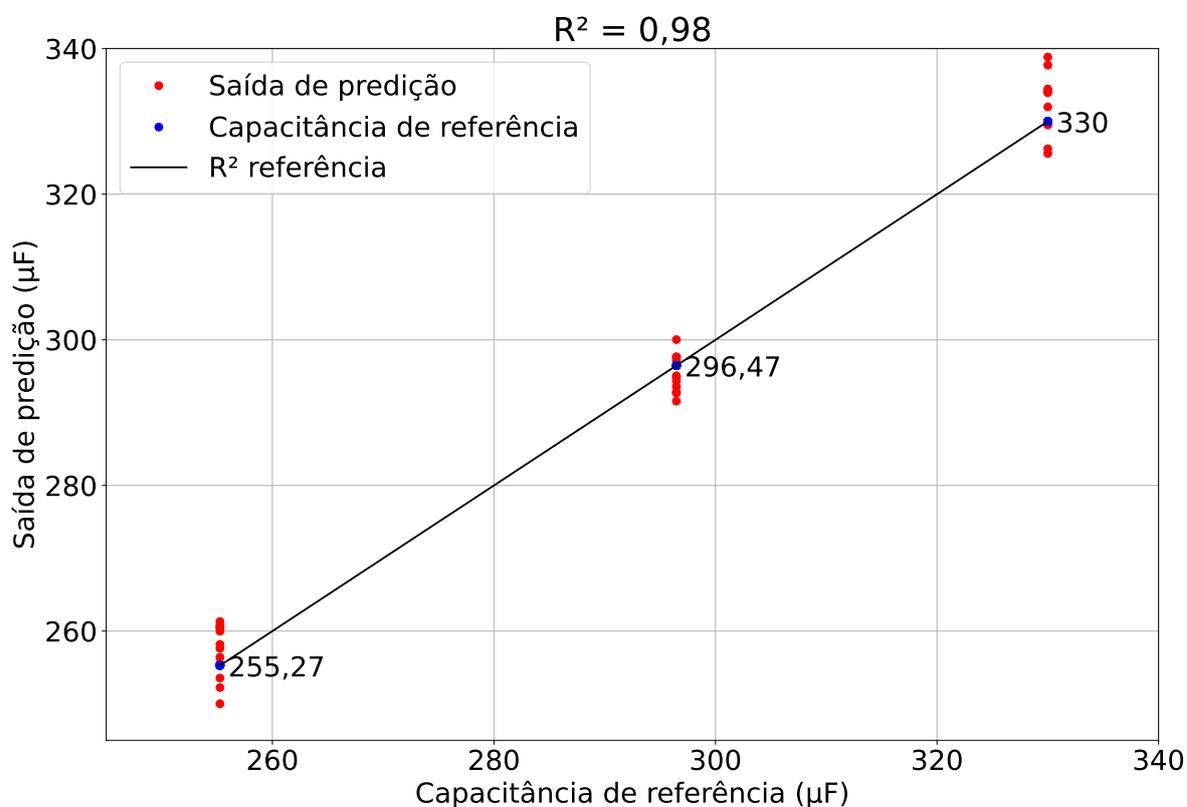
O valor absoluto do erro de predição e o coeficiente de determinação (R^2) são as métricas utilizadas para avaliar o desempenho das predições realizadas pela MLP com os dados de teste. Vale ressaltar que o conjunto de teste é composto pelo banco capacitivo original e os dois bancos de capacitores degradados termicamente, conforme descrito na Seção 3.5. Na Figura 44 é possível observar que todos os 36 dados de teste se ajustam à reta de referência e se obtém $R^2 = 0,98$. Outro ponto relevante é que o erro médio de predição absoluto em relação a todos os dados de teste é menor que 1,09% e o erro máximo absoluto de predição é de 2,67% para o banco capacitivo original. O valor de capacitância de predição e erro de predição para cada dado do conjunto de teste em relação a corrente, frequência e capacitância de referência são apresentados na Tabela 8, na Tabela 9 e na Tabela 10 para os diferentes bancos capacitivos.

Tabela 8 – Erros absolutos de predição para o banco capacitivo de 255,27 μF .

Corrente	Frequência	Capacitância predição	Erro absoluto
4,5 A	30 Hz	255,56 μF	0,11%
4,5 A	40 Hz	260,41 μF	2,02%
4,5 A	50 Hz	260,58 μF	2,08%
4,5 A	60 Hz	250,02 μF	2,05%
5,5 A	30 Hz	253,55 μF	0,67%
5,5 A	40 Hz	261,32 μF	2,37%
5,5 A	50 Hz	257,63 μF	0,92%
5,5 A	60 Hz	258,17 μF	1,14%
6,5 A	30 Hz	256,40 μF	0,44%
6,5 A	40 Hz	252,24 μF	1,18%
6,5 A	50 Hz	259,98 μF	1,84%
6,5 A	60 Hz	260,74 μF	2,14%

Fonte: de autoria própria.

Figura 44 – Coeficiente de determinação e erro de predição para o conjunto de teste da MLP escolhida para a utilização no método.



Fonte: de autoria própria.

4.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foram avaliadas as diferentes estruturas de MLP propostas de modo selecionar a configuração mais apropriada no que se refere a desempenho e robustez de predição. Uma vez escolhida a estrutura de MLP, o seu desempenho foi avaliado para o conjunto de treinamento para o banco capacitivo original e as amostras degradadas por sobretemperatura. O próximo capítulo, Capítulo 5, apresenta as considerações finais do método proposto, revisando os tópicos avaliados no presente trabalho e as propostas de trabalhos futuros.

Tabela 9 – Erros absolutos de predição para o banco capacitivo de 296,47 μF .

Corrente	Frequência	Capacitância predição	Erro absoluto
4,5 A	30 Hz	297,17 μF	0,24%
4,5 A	40 Hz	296,59 μF	0,04%
4,5 A	50 Hz	293,58 μF	0,97%
4,5 A	60 Hz	294,33 μF	0,72%
5,5 A	30 Hz	297,68 μF	0,41%
5,5 A	40 Hz	297,59 μF	0,38%
5,5 A	50 Hz	292,82 μF	1,23%
5,5 A	60 Hz	291,58 μF	1,65%
6,5 A	30 Hz	295,06 μF	0,47%
6,5 A	40 Hz	300,03 μF	1,20%
6,5 A	50 Hz	294,82 μF	0,55%
6,5 A	60 Hz	292,68 μF	1,27%

Fonte: de autoria própria.

Tabela 10 – Erros absolutos de predição para o banco capacitivo de 330,00 μF .

Corrente	Frequência	Capacitância predição	Erro absoluto
4,5 A	30 Hz	325,60 μF	1,33%
4,5 A	40 Hz	331,99 μF	0,60%
4,5 A	50 Hz	338,83 μF	2,67%
4,5 A	60 Hz	333,93 μF	1,19%
5,5 A	30 Hz	329,64 μF	0,10%
5,5 A	40 Hz	329,50 μF	0,15%
5,5 A	50 Hz	337,73 μF	2,34%
5,5 A	60 Hz	326,25 μF	1,13%
6,5 A	30 Hz	329,60 μF	0,12%
6,5 A	40 Hz	334,44 μF	1,34%
6,5 A	50 Hz	334,02 μF	1,21%
6,5 A	60 Hz	334,15 μF	1,26%

Fonte: de autoria própria.

5 CONSIDERAÇÕES FINAIS

Este capítulo sintetiza as principais conclusões e resultados do método proposto. As principais contribuições e sugestões para trabalhos futuros na área de monitoração de vida útil de capacitores eletrolíticos também são apresentadas.

A partir de uma revisão de métodos existentes de monitoramento de vida útil de capacitores do barramento CC de inversores de frequência, foi proposto um método mais adequado às necessidades de aplicação na indústria para monitoração das características elétricas de capacitores eletrolíticos em barramento CC de inversores de frequência com retificadores a diodos. O trabalho parte da hipótese que é possível monitorar a saúde do banco capacitivo pela estimação da sua capacitância.

No Capítulo 1 define-se o método proposto neste trabalho baseado em RNA considerando as três novidades em relação ao proposto por Soliman *et al.* (2017a): (i) inclusão da frequência de saída como entrada da RNA, uma vez que inversores de frequência usualmente não operam com uma frequência fixa de saída; (ii) processos de treinamento e teste com valores de capacitância pertencentes ao intervalo de monitoração; e (iii) validação experimental com o banco capacitivo original e com amostras de capacitores degradadas de forma acelerada por sobretemperatura. No Capítulo 3 são avaliadas as modificações necessárias no objeto de estudo e definidas as condições de operação para obtenção dos dados de teste e de treinamento. Uma vez adquiridos os dados de treinamento, foi possível avaliar e concluir por meio da correlação linear de Pearson que a proposta (i), de inclusão da velocidade angular de saída como entrada da RNA, é coerente. Já em relação aos dados de teste com as amostras degradadas por sobretemperatura, ao avaliar os indicadores de desempenho dos resultados experimentais apresentados no Capítulo 4, foi possível inferir que os dados de treinamento adquiridos a partir da jiga de capacitores são válidos e que a escolha dos valores de capacitância do valor nominal até o FDV é coerente com o objetivo de estimar a saúde dos capacitores do barramento CC. Dessa forma, os pontos (ii) e (iii) foram pertinentes para a contribuição e evolução dos métodos baseados em dados e algoritmos avançados.

Com base na análise acima e nos resultados apresentados, conclui-se que os objetivos definidos foram alcançados. O método proposto é simples e de fácil aplicação inclusive em inversores de frequência que já estão em operação, apenas por meio de alteração de software. Apesar dos resultados expressivos apresentados, com erro médio absoluto de predição menor que 1,09% com o banco capacitivo original e com as amostras degradadas, eles apenas foram avaliados a uma rede de alimentação balanceada com impedância mínima de modo a resultar em uma queda de tensão da rede de 1% e temperatura ambiente controlada em 25 °C. Os resultados apresentam um indicativo de que o método é viável, porém para permitir a aplicação prática ainda é

necessário avaliar o método em diferentes condições. Dessa forma, tem-se como proposta para trabalhos futuros a contínua evolução do método desenvolvido em relação aos seguintes tópicos:

- avaliar outros modelos de inversores de frequência em relação à diferentes tensões de alimentação e potência;
- validação experimental com redes de alimentação desbalanceadas. Considerar a condição de rede desbalanceada é importante para generalizar o método proposto e permitir a sua aplicação em outros contextos, principalmente pela sua consequência ser o surgimento de outras frequências predominantes durante o cálculo de tensão RMS de oscilação do barramento CC;
- obter dados de teste em condições diferentes de operação. No presente trabalho, os dados de teste foram obtidos nas mesmas condições de operação dos dados de treinamento, no que se refere à velocidade angular de saída e corrente de saída. Mesmo que os dados de teste atuais ainda sejam dados não vistos pela RNA, obtidos com um banco capacitivo real degradado, é importante avaliar o poder de predição para velocidades angulares de saída e correntes de saída intermediárias às utilizadas;
- compensação do efeito da temperatura para a estimação da capacitância. Todos os ensaios foram realizados com a temperatura controlada por câmara climática em 25 °C, portanto esse efeito não foi considerado neste estudo. Uma vez que a capacitância aumenta com a temperatura, é importante prever um método de compensação deste efeito para a indicação da degradação. Diversos métodos fazem isto por meio da estimação da temperatura do núcleo dos capacitores pela temperatura ambiente ou resistência estática do motor.

REFERÊNCIAS

- ABO-KHALIL, Ahmed G; LEE, Dong-Choon. DC-link capacitance estimation in AC/DC/AC PWM converters using voltage injection. **IEEE Transactions on Industry Applications**, IEEE, v. 44, n. 5, p. 1631–1637, 2008.
- ALVES, Alan Persico. **Projeto de capacitores eletrolíticos de alumínio para aplicação industriais**. 2019. Monografia (Trabalho de conclusão de curso) – Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- ANDRADE, Mateus Abreu de; FLESCH, Rodolfo César Costa. Capacitance Estimation Algorithm for Condition Monitoring of Electrolytic DC-Link Capacitors Using Artificial Neural Network in Front-End Diode Rectifier Three-Phase Motor Drive Systems. *In: IEEE. 2023 IEEE 8th Southern Power Electronics Conference (SPEC). [S.l.: s.n.], 2023. P. 1–7.*
- ANDRADE, Mateus Abreu de; FLESCH, Rodolfo César Costa; NAKIRIMOTO, Eric Koji. Método de Estimação On-line da Vida Útil de Capacitores Eletrolíticos do Barramento CC em Inversores de Frequência Trifásicos. *In: SBAI. SIMPÓSIO Brasileiro de Automática (2023). [S.l.: s.n.], 2023. P. 1–5.*
- BAKER, Nick; LISERRE, Marco; DUPONT, Laurent; AVENAS, Yvan. Improved reliability of power modules: A review of online junction temperature measurement methods. **IEEE Industrial Electronics Magazine**, IEEE, v. 8, n. 3, p. 17–27, 2014.
- BARBI, Ivo. **Eletrônica de potência**. Florianópolis: Ed. do Autor, 2006.
- BISHOP, Christopher M. **Pattern recognition and machine learning**. Singapura: Springer, 2006.
- CELAYA, Jose; KULKARNI, Chetan; GOEBEL, Kai; BISWAS, Gautam. Towards prognostics of electrolytic capacitors. *In: INFOTECH@ Aerospace 2011. [S.l.: s.n.], 2011. P. 1519.*
- CHAPMAN, Stephen J. **Fundamentos de máquinas elétricas**. 5. ed. Porto Alegre: AMGH Editora, 2013.

CLEVERT, Djork-Arné; UNTERTHINER, Thomas; HOCHREITER, Sepp. Fast and accurate deep network learning by exponential linear units (ELUs). **arXiv preprint arXiv:1511.07289**, 2015.

DIJK, Ziko van. **The mystery of early stopping**. [S.l.: s.n.], 2017. Disponível em: <https://fouryears.eu/2017/12/06/the-mystery-of-early-stopping/>. Acesso em: 25 mar. 2024.

DOU, Zongli; XU, Rong; BERDUQUE, Alfonso. The development of electrolytes in aluminium electrolytic capacitors for automotive and high temperature applications. **Carts Europe**, p. 20–23, 2008.

FALCK, Johannes; FELGEMACHER, Christian; ROJKO, Andreja; LISERRE, Marco; ZACHARIAS, Peter. Reliability of power electronic systems: An industry perspective. **IEEE Industrial Electronics Magazine**, IEEE, v. 12, n. 2, p. 24–35, 2018.

FLACH, Peter. **Machine learning: the art and science of algorithms that make sense of data**. Cambridge, Reino Unido: Cambridge university press, 2012.

FRANCHI, Claiton Moro. **Acionamentos elétricos**. São Paulo: Saraiva Educação SA, 2018.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. Cambridge, Massachusetts, EUA: MIT Press, 2016.

HAN, Jun; MORAGA, Claudio. The influence of the sigmoid function parameters on the speed of backpropagation learning. *In*: SPRINGER. INTERNATIONAL workshop on artificial neural networks. [S.l.: s.n.], 1995. P. 195–201.

HAYKIN, Simon. **Neural networks: a comprehensive foundation**. Hoboken, Nova Jersey, EUA: Prentice Hall PTR, 1998.

HINTON, Geoffrey. **Neural Networks for Machine Learning: Lecture 6a - Overview of Mini-Batch Gradient Descent**. [S.l.], 2012. Acesso: 19 de Março de 2024. Disponível em: <https://www.youtube.com/watch?v=6jfw8MuKwpI>.

HOTELLING, Harold. New light on the correlation coefficient and its transforms. **Journal of the Royal Statistical Society. Series B (Methodological)**, JSTOR, v. 15, n. 2, p. 193–232, 1953.

HUANG, Kaizhu; HUSSAIN, Amir; WANG, Qiu-Feng; ZHANG, Rui. **Deep learning: fundamentals, theory and applications**. Suíça: Springer Nature, 2019. v. 2.

IKONOPISOV, S. Theory of electrical breakdown during formation of barrier anodic films. **Electrochimica Acta**, Elsevier, v. 22, n. 10, p. 1077–1082, 1977.

JO, Taeho. **Deep Learning Foundations**. Suíça: Springer Nature, 2023.

KAISER, Cletus J. **The capacitor handbook**. Berlim, Alemanha: Springer Science & Business Media, 2012.

KAMEL, Tamer; BILETSKIY, Yevgen; CHANG, Liuchen. Capacitor aging detection for the DC filters in the power electronic converters using ANFIS algorithm. *In*: IEEE. 2015 IEEE 28th Canadian Conference on Electrical and Computer Engineering (CCECE). [S.l.: s.n.], 2015. P. 663–668.

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**, IEEE, v. 1, n. 2, p. 47–58, 2013.

KLAMBAUER, Günter; UNTERTHINER, Thomas; MAYR, Andreas; HOCHREITER, Sepp. Self-normalizing neural networks. **Advances in Neural Information Processing Systems**, v. 30, 2017.

KULKARNI, Chetan; BISWAS, Gautam; CELAYA, Jose; GOEBEL, Kai; SGT, NASA. Prognostic techniques for capacitor degradation and health monitoring. *In*: THE Maintenance & Reliability Conference, MARCON. [S.l.: s.n.], 2011.

KULKARNI, Chetan; BISWAS, Gautam; SAHA, Sankalita; GOEBEL, Kai *et al.* A model-based prognostics methodology for electrolytic capacitors based on electrical overstress accelerated aging. *In*: 1. ANNUAL Conference of the PHM Society. [S.l.: s.n.], 2011. v. 3.

KULKARNI, Chetan S; CELAYA, José R; GOEBEL, Kai; BISWAS, Gautam. Physics based electrolytic capacitor degradation models for prognostic studies under thermal overstress. *In*: 1. PHM Society European Conference. [S.l.: s.n.], 2012. v. 1.

- LAHYANI, Amine; VENET, Pascal; GRELLET, Guy; VIVERGE, P-J. Failure prediction of electrolytic capacitors during operation of a switchmode power supply. **IEEE Transactions on Power Electronics**, IEEE, v. 13, n. 6, p. 1199–1207, 1998.
- LEE, Kwang-Woon; KIM, Myungchul; YOON, Jangho; LEE, Sang Bin; YOO, Ji-Yoon. Condition monitoring of DC-link electrolytic capacitors in adjustable-speed drives. **IEEE Transactions on Industry Applications**, IEEE, v. 44, n. 5, p. 1606–1613, 2008.
- LEE, Sang Bin *et al.* A new strategy for condition monitoring of adjustable speed induction machine drive systems. **IEEE Transactions on Power Electronics**, IEEE, v. 26, n. 2, p. 389–398, 2010.
- LOBOSCO, Orlando Silvio; DIAS, Jose Luiz Pereira da Costa. **Seleção e aplicação de motores elétricos**. São Paulo: Mcgraw-Hill/Siemens, 1988.
- LU, Z; TANG, WH; JI, TY; WU, QH. A morphological scheme for inrush identification in transformer protection. **IEEE Transactions on Power Delivery**, IEEE, v. 24, n. 2, p. 560–568, 2009.
- MAMEDE FILHO, João. **Instalações elétricas industriais**. São Paulo: GEN – Grupo Editorial Nacional, 2007.
- MENDONÇA, Guilherme Góes *et al.* **Redes neurais artificiais na predição do preço de ações**. 2019.
- MENG, Tianze; ZHANG, Pinjia. A Novel Non-invasive DC-link Capacitance Estimation Method for Motor Drive System. *In: IEEE. 2020 IEEE 9th International Power Electronics and Motion Control Conference (IPEMC2020-ECCE Asia)*. [S.l.: s.n.], 2020. P. 927–934.
- NWANKPA, Chigozie; IJOMAH, Winifred; GACHAGAN, Anthony; MARSHALL, Stephen. Activation functions: Comparison of trends in practice and research for deep learning. **arXiv preprint arXiv:1811.03378**, 2018.
- PETRUZELLA, Frank. **Motores Elétricos e Acionamentos: Série Tekne**. Porto Alegre, Rio Grande do Sul: Bookman Editora, 2013.

PRYMAK, John; RANDALL, Mike; BLAIS, Peter; LONG, Bill. Why that 47 uF capacitor drops to 37 uF, 30 uF, or lower. *In*: CARTS USA. 28TH Symposium for Passive Electronics. [S.l.: s.n.], 2008. P. 193–208.

PU, Xingsi; NGUYEN, Thanh-Hai; LEE, Dong-Choon; LEE, Suk-Gyu. Capacitance estimation of DC-link capacitors for single-phase PWM converters. *In*: IEEE. 2009 IEEE 6th International Power Electronics and Motion Control Conference. [S.l.: s.n.], 2009. P. 1656–1661.

QUADTECH. **Quadtech 1730T - LCR Meter**. [S.l.: s.n.], 2024. Disponível em: <http://www.quadtech.com/1730t.php>. Acesso em: 25 mar. 2024.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, American Psychological Association, v. 65, n. 6, p. 386, 1958.

RUMELHART, David; HINTON, Geoffrey; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **Nature**, Nature Publishing Group UK London, v. 323, n. 6088, p. 533–536, 1986.

SCIKIT-LEARN CONTRIBUTORS. **Cross-validation: evaluating estimator performance**. [S.l.: s.n.], 2024. Disponível em: https://scikit-learn.org/stable/modules/cross_validation.html. Acesso em: 25 mar. 2024.

SOLIMAN, Hammam; ABDELSALAM, Ibrahim; WANG, Huai; BLAABJERG, Frede. Artificial neural network based DC-link capacitance estimation in a diode-bridge front-end inverter system. *In*: IEEE. 2017 IEEE 3rd International Future Energy Electronics Conference and ECCE Asia (IFEEC 2017-ECCE Asia). [S.l.: s.n.], 2017. P. 196–201.

SOLIMAN, Hammam; DAVARI, Pooya; WANG, Huai; BLAABJERG, Frede. Capacitance estimation algorithm based on DC-link voltage harmonics using artificial neural network in three-phase motor drive systems. *In*: IEEE. 2017 IEEE Energy Conversion Congress and Exposition (ECCE). [S.l.: s.n.], 2017. P. 5795–5802.

SOLIMAN, Hammam; WANG, Huai; BLAABJERG, Frede. A review of the condition monitoring of capacitors in power electronic converters. **IEEE Transactions on Industry Applications**, IEEE, v. 52, n. 6, p. 4976–4989, 2016.

SUNDARARAJAN, Prasanth; SATHIK, Mohamed Halick Mohamed; SASONGKO, Firman; TAN, Chuan Seng; POU, Josep; BLAABJERG, Frede; GUPTA, Amit Kumar. Condition monitoring of DC-link capacitors using Goertzel algorithm for failure precursor parameter and temperature estimation. **IEEE Transactions on Power Electronics**, IEEE, v. 35, n. 6, p. 6386–6396, 2019.

TDK ELECTRONICS AG. **Aluminum electrolytic capacitors, Snap-in capacitors**. [S.l.], dez. 2013. Acesso: 25 mar 2024. Disponível em: <https://4donline.ihs.com/images/VipMasterIC/IC/EPCO/EPCO-S-A0000009109/EPCO-S-A0000009109-1.pdf?hkey=CECEF36DEECDDED6468708AAF2E19C0C6>.

THERMOTRON. **Thermotron SE-2000-3-3 Product Description**. [S.l.: s.n.], 2024. Disponível em: <https://thermotron.com/equipment/se-series-detail/se-2000-3-3-environmental-chamber/>. Acesso em: 25 mar. 2024.

TORKI, Jami; JOUBERT, Charles; SARI, Ali. Electrolytic capacitor: Properties and operation. **Journal of Energy Storage**, Elsevier, v. 58, p. 106330, 2023.

WANG, Huai; BLAABJERG, Frede. Reliability of capacitors for DC-link applications in power electronic converters—An overview. **IEEE Transactions on Industry Applications**, IEEE, v. 50, n. 5, p. 3569–3578, 2014.

WANG, Huai; LISERRE, Marco; BLAABJERG, Frede. Toward reliable power electronics: Challenges, design tools, and opportunities. **IEEE Industrial Electronics Magazine**, IEEE, v. 7, n. 2, p. 17–26, 2013.

WANG, Huai; LISERRE, Marco; BLAABJERG, Frede; PLACE RIMMEN, Peter de; JACOBSEN, John B; KVISGAARD, Thorkild; LANDKILDEHUS, Jørn. Transitioning to physics-of-failure as a reliability driver in power electronics. **IEEE Journal of Emerging and Selected Topics in Power Electronics**, IEEE, v. 2, n. 1, p. 97–114, 2013.

WEG. **CFW500 G2 IP66 14976814**. [S.l.: s.n.], 2024. Disponível em: <https://www.weg.net/catalog/weg/BR/en/Industrial-Automation/Drives/Inverters/OEM-and-General-Purpose-Drives/Variable-Speed-Drive-CFW500-Series/DRIVE-CFW500A06P5T4DB66G2/p/14976814>. Acesso em: 25 mar. 2024.

WEG. **W22 Super Premium 15249711**. [S.l.: s.n.], 2024. Disponível em: <https://www.weg.net/catalog/weg/BR/en/Electric-Motors/Three-Phase-Low->

Voltage/General-Purpose/W22/W22/W22-Super-Premium-4-cv-4P-L100L-3Ph-220-380-V-60-Hz-IC411---TFVE---B3D/p/15249711. Acesso em: 25 mar. 2024.

YANG, Shaoyong; BRYANT, Angus; MAWBY, Philip; XIANG, Dawei; RAN, Li; TAVNER, Peter. An industry-based survey of reliability in power electronic converters. **IEEE Transactions on Industry Applications**, IEEE, v. 47, n. 3, p. 1441–1451, 2011.

ZEILER, Matthew D *et al.* On rectified linear units for speech processing. *In*: IEEE. 2013 IEEE International Conference on Acoustics, Speech and Signal Processing. [S.l.: s.n.], 2013. P. 3517–3521.

ZHAO, Zhaoyang; DAVARI, Pooya; LU, Weiguo; WANG, Huai; BLAABJERG, Frede. An overview of condition monitoring techniques for capacitors in DC-link applications. **IEEE Transactions on Power Electronics**, IEEE, v. 36, n. 4, p. 3692–3716, 2020.