



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ANTÔNIO MATHEUS ARAÚJO VILLARIM

**PREVISÃO DA VIDA ÚTIL REMANESCENTE DE SUPERCAPACITORES POR MEIO
DE REDES NEURAIS ARTIFICIAIS**

Recife
2023

ANTÔNIO MATHEUS ARAÚJO VILLARIM

**PREVISÃO DA VIDA ÚTIL REMANESCENTE DE SUPERCAPACITORES POR
MEIO DE REDES NEURAIAS ARTIFICIAIS**

Trabalho de Conclusão de Curso
apresentado ao Curso de Graduação em
Engenharia Elétrica da Universidade
Federal de Pernambuco, como requisito
parcial para obtenção do grau de Bacharel
em Engenharia Elétrica.

Orientador: Prof. Dr. Marcelo Cabral Cavalcanti
Coorientador: Prof. Dr. João Mateus Marques Santana

Recife
2023

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Villarim, Antônio Matheus Araújo.

Previsão da vida útil remanescente de supercapacitores por meio de redes neurais artificiais / Antônio Matheus Araújo Villarim. - Recife, 2023.

76 : il., tab.

Orientador(a): Marcelo Cabral Cavalcanti

Coorientador(a): João Mateus Marques Santana

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Engenharia Elétrica - Bacharelado, 2023.

1. supercapacitor. 2. vida útil remanescente. 3. prognóstico e gestão da saúde. 4. rede neural artificial. 5. aprendizado profundo. I. Cavalcanti, Marcelo Cabral. (Orientação). II. Santana, João Mateus Marques. (Coorientação). IV. Título.

620 CDD (22.ed.)

ANTÔNIO MATHEUS ARAÚJO VILLARIM

**PREVISÃO DA VIDA ÚTIL REMANESCENTE DE SUPERCAPACITORES POR
MEIO DE REDES NEURAIS ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Aprovado em: 20/09/2023.

BANCA EXAMINADORA

Prof. Dr. Marcelo Cabral Cavalcanti (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Jeydson Lopes da Silva (Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. José Filho da Costa Castro (Examinador Interno)
Universidade Federal de Pernambuco

Dedico este trabalho à minha mãe Ermelinda, ao meu pai Tagore e ao meu irmão Manoel, com afeto.

AGRADECIMENTOS

Agradeço ao Curso de Engenharia Elétrica da Universidade Federal de Pernambuco, coordenadores, professores e funcionários;

Ao CEERMA, pela oportunidade de participar na pesquisa que inspirou este trabalho;

Ao Programa de Formação de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis – PRH-ANP-FINEP, pelo apoio financeiro suportado com recursos provenientes do investimento de empresas petrolíferas qualificadas na Cláusula de PD&I da Resolução ANP nº 50/2015;

Ao Prof. Dr. Marcelo Cavalcanti, que aceitou orientar este trabalho, pela sua atenção e disponibilidade, bem como ao coorientador Prof. Dr. João Mateus Santana, pelo suporte e acompanhamento desde o início desta pesquisa;

Aos meus pais e irmão pelo apoio e incentivo de sempre;

Aos colegas do meu curso, em particular a Abinadi Rufino;

E a todos aqueles que de alguma maneira contribuíram para a realização deste trabalho.

A vida só pode ser comprendida olhando-se para trás, mas só pode ser vivida olhando-se para a frente. (KIERKEGAARD, Søren).

RESUMO

O supercapacitor, também conhecido como ultracapacitor e capacitor eletroquímico, é o termo utilizado para descrever uma família dispositivos de armazenamento de energia que têm apresentado notáveis avanços tecnológicos nos últimos anos e um crescente número de aplicações, especialmente em cenários que demandam elevada densidade de potência, como, por exemplo, sistemas de controle do ângulo de passo das pás de turbinas eólicas, sistemas de frenagem regenerativa e fontes de alimentação ininterruptas. Neste contexto, estudos relacionados à sua confiabilidade são essenciais para aferir a viabilidade de implementação desta tecnologia e atuar no suporte ao planejamento da manutenção dos sistemas em que serão utilizados. Este trabalho tem como objetivo principal o desenvolvimento de modelos baseados em redes neurais artificiais capazes de efetuar a previsão da vida útil remanescente deste dispositivo, incluindo a quantificação das incertezas associadas, a partir de uma curta janela de dados elétricos coletada durante ciclos de carregamento e descarregamento. A análise foi conduzida em uma base de dados aberta e teve como ênfase a investigação das arquiteturas *feedforward*, LSTM e convolucional junto ao algoritmo *dropout* Monte Carlo. Destacando o crescente interesse da indústria e academia por análises baseadas em dados por meio de modelos de aprendizado de máquina, busca-se com este trabalho contribuir para esta área em expansão.

Palavras-chave: supercapacitor, vida útil remanescente, prognóstico e gestão da saúde, rede neural artificial, aprendizado profundo.

ABSTRACT

The supercapacitor, also known as ultracapacitor and electrochemical capacitor, is the term used to describe a family of energy storage devices that have shown remarkable technological advances in recent years and a growing number of applications, especially in scenarios that demand high power density, such as wind turbine blade pitch control systems, regenerative braking systems and uninterruptible power supplies. In this context, reliability studies are essential to assess the feasibility of implementing this technology and to support the maintenance planning of the systems in which it will be used. The main objective of this work is to develop models based on artificial neural networks capable of predicting the remaining useful life of this device, including the quantification of the associated uncertainties, based on a short window of electrical data collected during charging and discharging cycles. The analysis was conducted on an open database and focused on the investigation of feedforward, LSTM and convolutional architectures together with the Monte Carlo dropout algorithm. Highlighting the growing interest of industry and academia in data-based analyses using machine learning models, this work aims to contribute to this growing field.

Keywords: supercapacitor, remaining useful life, prognostics and health management, artificial neural network, deep learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Funções de ativação típicas	28
Figura 2 – Exemplo de rede neural <i>feedforward</i>	30
Figura 3 – Representação do <i>dropout</i> aplicado em uma rede neural <i>feedforward</i> ...	33
Figura 4 – Representação gráfica de uma rede neural recorrente	35
Figura 5 – Exemplo de aplicação de max-pooling e average pooling	37
Figura 6 – Diagrama de Ragone	39
Figura 7 – Supercapacitores Eaton modelo HV	44
Figura 8 – Visualização das curvas de capacidade de carga e descarga em função do tempo para um supercapacitor do grupo 2.....	47
Figura 9 – Variação das curvas de tensão para as etapas de carga e descarga ao longo da vida útil de um supercapacitor da base de dados.....	48
Figura 10 – Variação das curvas de capacidade para as etapas de carga e descarga ao longo da vida útil de um supercapacitor da base de dados.....	49
Figura 11 – Evolução das capacitâncias ao longo do tempo.....	50
Figura 12 – Variação das curvas de capacidade para as etapas de carga e descarga ao longo da vida útil de um supercapacitor da base de dados referidas ao eixo da tensão.....	52
Figura 13 – Exemplo para a curva da capacitância após a aplicação do filtro de Savitzky-Golay	53
Figura 14 – Distribuição das vidas úteis para a base de dados e conjuntos de treino, teste e validação.....	55
Figura 15 – Exemplo de entrada para a rede LSTM.....	58
Figura 16 – Exemplo de entrada para a rede convolucional.....	59
Figura 17 – Evolução das perdas da rede <i>feedforward</i> ao longo do treinamento	61
Figura 18 – Resultados incluindo intervalo de confiança de 95% e resíduos obtidos a partir da rede <i>feedforward</i> para os supercapacitores do conjunto de teste	62
Figura 19 – Evolução das perdas da rede LSTM ao longo do treinamento	64
Figura 20 – Resultados incluindo intervalo de confiança de 95% e resíduos obtidos a partir da rede LSTM para os supercapacitores do conjunto de teste.....	65
Figura 21 – Evolução das perdas da rede convolucional ao longo do treinamento...	66
Figura 22 – Resultados incluindo intervalo de confiança de 95% e resíduos obtidos a partir da rede convolucional para os supercapacitores do conjunto de teste	67
Figura 23 – Perfil dos intervalos de confiança de 95% para um supercapacitor do conjunto de teste	69

Figura 24 – Histograma obtido a partir da aplicação do dropout Monte Carlo com 250 previsões para a mesma entrada 71

LISTA DE TABELAS

Tabela 1 – Exemplos de cargas durante o ciclo de vida de um equipamento.	20
Tabela 2 – Descrição da base de dados.....	45
Tabela 3 – Descrição da arquitetura para a rede <i>feedforward</i>	56
Tabela 4 – Descrição da arquitetura para a rede LSTM.....	57
Tabela 5 – Descrição da arquitetura para a rede convolucional.....	58
Tabela 6 – Métricas de desempenho para obtidas para os três modelos desenvolvidos.....	67

LISTA DE ABREVIATURAS E SIGLAS

ANN	<i>Artificial Neural Network</i> (Rede Neural Artificial)
CNN	<i>Convolutional Neural Network</i> (Rede Neural Convolucional)
DL	<i>Deep Learning</i> (Aprendizado Profundo)
LSTM	<i>Long Short-Term Memory</i>
MAE	<i>Mean Absolute Error</i> (Erro Médio Absoluto)
MCDO	<i>Monte Carlo Dropout</i> (Dropout Monte Carlo)
MLP	<i>Multilayer Perceptron</i> (Perceptron Multicamada)
MSE	<i>Mean Squared Error</i> (Erro Médio Quadrático)
PHM	Prognostics and Health Management (Prognóstico e Gestão da Saúde)
PoF	<i>Physics of Failure</i> (Física de Falha)
ReLU	<i>Rectified Linear Unit</i> (Unidade Linear Retificada)
RMSE	<i>Root Mean Squared Error</i> (Raiz do Erro Médio Quadrático)
RNN	<i>Recurrent Neural Network</i> (Rede Neural Recorrente)
RUL	<i>Remaining Useful Life</i> (Vida Útil Remanescente)
SGD	<i>Stochastic Gradient Descent</i> (Gradiente Descendente Estocástico)
sMAPE	<i>Symmetrical Mean Absolute Percentage Error</i> (Erro Percentual Médio Absoluto Simétrico)
SoC	<i>State of Charge</i> (Estado de Carga)
SoH	<i>State of Health</i> (Estado de Saúde)

LISTA DE SÍMBOLOS

t	Instante no tempo
γ	Limite de falha
$\inf()$	Limite inferior
x	Valor de entrada
b	Viés
w_i	Peso
$g()$	Função de ativação
$\max(a, b)$	Valor máximo entre a e b
α	Inclinação de uma reta
θ	Parâmetro de uma rede neural
$R(\theta)$	Função custo
ρ	Taxa de aprendizagem
Q	Capacidade
V	Tensão elétrica
i	Corrente elétrica
y_i	Saída esperada para um modelo
\hat{y}_i	Saída prevista por um modelo

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVOS	15
1.1.1	Geral	15
1.1.2	Específicos	15
1.2	ORGANIZAÇÃO DO TRABALHO	15
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	ENGENHARIA DE CONFIABILIDADE	17
2.1.1	Falha	18
2.1.2	Prognóstico e Gestão da Saúde	19
2.1.3	Vida Útil Remanescente	21
2.1.4	Manutenção	23
2.2	REDES NEURAIS ARTIFICIAIS	24
2.2.1	Visão Histórica	25
2.2.2	O Modelo do Neurônio	27
2.2.3	Redes Neurais <i>Feedforward</i>	30
2.2.4	Redes Neurais Recorrentes	34
2.2.5	Redes Neurais Convolucionais	35
2.2.6	Técnicas para Quantificação da Incerteza	36
2.3	SUPERCAPACITORES	37
2.3.1	Caracterização da Tecnologia	37
2.3.2	Aplicações	40
2.3.3	Modelos para a previsão da vida útil remanescente de supercapacitores	41
3	DESENVOLVIMENTO DO TRABALHO	42
3.1	ANÁLISE EXPLORATÓRIA DA BASE DE DADOS	42
3.2	PRÉ-PROCESSAMENTO DOS DADOS	49
3.3	IMPLEMENTAÇÃO DOS MODELOS	54
3.4	RESULTADOS E DISCUSSÕES	58
3.4.1	Rede <i>Feedforward</i>	59
3.4.2	Rede LSTM	61
3.4.3	Rede Convolucional	63
3.4.4	Discussão Geral	65
4	CONCLUSÕES E PROPOSTAS DE CONTINUIDADE	68
	REFERÊNCIAS	70

1 INTRODUÇÃO

De acordo com Burke e Zhao (2021), os supercapacitores são dispositivos de armazenamento de energia que, devido às suas favoráveis características de alta densidade de potência, elevada vida útil e resiliência a uma ampla faixa de temperaturas, apresentam um crescente número de aplicações, que percorre desde dispositivos eletrônicos até campos como o transporte, a geração renovável e fontes de alimentação ininterruptas. Além disso, Simon e Gogotsi (2020) apontam que relevantes avanços tecnológicos nos seus materiais, resultando em densidades de energia mais elevadas, potencializam a sua introdução numa gama mais variada de aplicações, possibilitando implementações que visam o suporte ou substituição de sistemas de armazenamento de energia atualmente baseados em baterias eletroquímicas.

Considerando este cenário, ressalta-se que o desenvolvimento de estudos associados à confiabilidade destes dispositivos é um tema de grande relevância para viabilizar uma introdução robusta desta tecnologia em maior escala e em outras áreas de aplicação. Dentro do contexto da engenharia de confiabilidade, Zio (2016) comenta que a área de prognóstico e gestão da saúde (PHM – do inglês *Prognostics and Health Management*), que possui como um de seus objetivos a previsão da métrica de vida útil remanescente para componentes de engenharia, apresenta grande relevância nos últimos anos devido ao aumento da capacidade de monitoramento e avanços técnicos em análises de dados. Adicionalmente, Si *et al.* (2011) observam que a obtenção da métrica de vida útil remanescente é fundamental para a aplicação da manutenção baseada em condição.

Com relação às estratégias aplicadas para a previsão da vida útil remanescente, Fink *et al.* (2020) observam que a utilização de redes neurais artificiais, dentro do contexto do aprendizado profundo (DL – do inglês *deep learning*), apresentam o potencial de solucionar algumas dificuldades encontradas por métodos clássicos como a capacidade de processar um grande volume de dados de monitoramento, extrair características úteis automaticamente e aprender relações temporais de sinais. Entretanto, os autores também ressaltam o fato de que a consideração das incertezas associadas aos modelos e dados aplicados nestas análises é essencial para garantir tomadas de decisão coerentes. Deste modo, destaca-se a relevância da investigação

de métodos para a quantificação das incertezas associadas às previsões destes modelos.

Partindo do contexto apresentado nesta introdução, propõe-se com este trabalho a realização de uma análise comparativa entre modelos baseados em redes neurais artificiais aplicados à previsão da vida útil remanescente de supercapacitores a partir de uma janela de dados elétricos recentes. Especificamente, as arquiteturas *feedforward*, convolucional e recorrente foram exploradas neste trabalho junto ao método *dropout* Monte Carlo para a quantificação das incertezas associadas às previsões. Os dados utilizados são provenientes da base de dados aberta disponibilizada pelo artigo publicado por Ren *et al.* (2020), que contém dados de natureza elétrica para 113 supercapacitores submetidos a 10.000 ciclos de carga e descarga.

1.1 Objetivos

1.1.1 Geral

Este trabalho tem como objetivo geral o desenvolvimento de modelos baseados em redes neurais artificiais capazes de retornar previsões da vida útil remanescente de um supercapacitor a partir de uma janela breve de dados elétricos.

1.1.2 Específicos

Com base no objetivo geral, os seguintes objetivos específicos foram determinados:

- a) Apresentar dos principais aspectos teóricos relevantes para o desenvolvimento deste trabalho;
- b) Analisar uma base de dados contendo informações sobre ciclos de carga e descarga de múltiplos supercapacitores com o propósito de investigar as possíveis representações de seu envelhecimento em função do tempo;

- c) Determinar uma estratégia de pré-processamento para adequar os dados brutos aos modelos desenvolvidos;
- d) Treinar modelos com arquiteturas distintas e analisar os resultados de forma comparativa por meio de visualizações gráficas e métricas de desempenho.

1.2 Organização do Trabalho

Este trabalho foi dividido em quatro capítulos. O primeiro, que consiste nesta introdução, buscou apresentar um panorama global do trabalho, incluindo a sua contextualização e a justificativa do tema proposto, além de também apresentar os objetivos gerais e específicos que foram abordados.

O segundo capítulo teve como objetivo a descrição dos principais aspectos teóricos que foram utilizados no seu desenvolvimento: a engenharia de confiabilidade, como fundamento para a compreensão da métrica da vida útil remanescente e a aplicabilidade deste parâmetro; as redes neurais artificiais, como modelo matemático utilizado ao problema apresentado; e os supercapacitores, com o intuito de evidenciar as características gerais desta tecnologia e suas potenciais áreas de aplicação.

O terceiro capítulo tratou sobre o desenvolvimento dos modelos baseados em redes neurais artificiais. Para isso, inicialmente é desenvolvida uma análise dos dados seguida por uma etapa de pré-processamento que visa a sua adequação aos modelos propostos. Em seguida, são apresentados detalhes sobre os modelos selecionados e, após o treinamento, seus resultados são exibidos, interpretados e discutidos.

Por fim, o quarto capítulo conclui o trabalho, fornecendo uma análise e interpretação abrangentes sobre o seu desenvolvimento e resultados obtidos.

2 FUNDAMENTAÇÃO TEÓRICA

Com o propósito de contextualizar o objetivo geral do trabalho e apresentar as suas principais referências, este capítulo explorará três temas que juntos configuram esta proposta: a engenharia de confiabilidade, as redes neurais artificiais e os supercapacitores. Em primeiro lugar, são apresentados alguns tópicos relacionados à engenharia de confiabilidade com o intuito de apresentar a relevância desta área com especial destaque para a obtenção e aplicações envolvendo a métrica de vida útil remanescente. Em seguida, é realizada uma introdução sobre modelos baseados em redes neurais artificiais que visa expor o princípio de funcionamento e detalhes técnicos das arquiteturas desenvolvidas neste trabalho. Por fim, a última seção ressalta o funcionamento e potencial que os supercapacitores exibem como tecnologia de armazenamento de energia e apresenta uma revisão de alguns dos principais trabalhos encontrados na literatura que, assim como este, realizam a previsão da vida útil remanescente de supercapacitores por meio de modelos baseados em dados.

2.1 Engenharia de Confiabilidade

Zio (2016) destaca que, com os avanços tecnológicos recentes e a maior integração entre sistemas digitais e físicos, estudos relacionados à confiabilidade de componentes e sistemas continuam tendo um papel fundamental na indústria. Além disso, o progresso no conhecimento, métodos, técnicas, o aumento da capacidade de compartilhamento de informações e a maior disponibilidade de dados configuram um cenário de novas oportunidades para a engenharia de confiabilidade.

Esta seção inicia com a descrição do conceito de falha, fundamental para a compreensão das análises de confiabilidade. Em seguida, é realizada uma apresentação geral sobre as principais metodologias empregadas na área de prognóstico e gestão da saúde, com ênfase em equipamentos eletrônicos. A métrica da vida útil remanescente, um dos pontos de discussão do trabalho, é explorada com maior nível de detalhes na sequência. Por fim, é exibido um breve resumo sobre as principais estratégias de manutenção aplicadas atualmente.

2.1.1 Falha

Birolini (2017) define a falha como o momento em que um dispositivo para de executar sua função requerida. Adicionalmente, ele detalha que sua classificação é normalmente realizada de acordo com os parâmetros de frequência, o número de ocorrências por unidade de tempo; modo, o sintoma pelo qual a falha é observada; causa, que pode ser intrínseca ou extrínseca; efeito, que é a consequência da falha, geralmente categorizada de acordo com seu nível de gravidade; e mecanismo, o processo que leva a falha, como por exemplo, processos físicos ou químicos.

Modarres, Kaminskiy e Krivtsov (2017) apresentam uma definição complementar, descrevendo a falha a partir de um modelo genérico baseado nos conceitos de desafio, capacidade e condições adversas. Os desafios abrangem as condições operacionais e características de envelhecimento presentes no sistema em análise. A capacidade, por sua vez, consiste no potencial intrínseco do sistema de resistir a estes desafios. Tanto os desafios como a capacidade são variáveis que podem ser afetadas por condições adversas, que têm o potencial de induzir ou aumentar a intensidade dos desafios e reduzir a capacidade de um sistema. A falha, neste contexto, pode ser definida como o momento em que os desafios de um sistema superam sua capacidade.

A partir das duas definições apresentadas, nota-se que o conceito de falha pode apresentar diferentes interpretações em contextos distintos. Em dispositivos de armazenamento de energia, uma possível estratégia para conceitualização da falha pode ser desenvolvida a partir do modelo tolerância-requerimento proposto por Dasgupta e Pecht (1991). Nele, define-se que o sistema opera de forma satisfatória apenas quando sua tolerância está dentro de um requerimento estabelecido. Consequentemente, a falha é alcançada quando a performance, ou tolerância, do sistema ultrapassa seu requerimento, ainda que apresente um perfil de funcionamento semelhante ao nominal. Grandezas relacionadas à carga, como capacidade e capacitância, são parâmetros comuns para o estabelecimento de requerimentos em dispositivos de armazenamento de energia.

2.1.2 Prognóstico e Gestão da Saúde

De acordo com Zio (2016), prognóstico e gestão da saúde consiste no campo de estudos e aplicações dedicado à detecção da degradação de componentes de engenharia, diagnóstico de tipos de falhas, predição de tempos de falha e gestão proativa destas falhas. A área exhibe uma crescente atenção tanto na academia como na indústria devido ao aumento da capacidade de monitoramento e avanços em técnicas de análise de dados e processamento de sinais que potencializam a realização de procedimentos como diagnósticos e previsões de ocorrência de falhas.

Kapur e Pecht (2014) apontam que a aplicação de técnicas de PHM em dispositivos eletrônicos cumprem objetivos importantes, dentre eles: o fornecimento de alertas antecipados sobre falhas; a minimização de manutenções não-programadas, a extensão dos ciclos de manutenção; a preservação da eficácia por meio de ações de reparo oportunas; a redução dos custos associados aos equipamentos através da diminuição de gastos relacionados à inspeção, tempo de inatividade e inventário; a melhoria da qualificação e assistência no projeto; e o apoio logístico de sistemas em campo e futuros. Eles destacam que três das principais estratégias para realização de prognósticos nesta área são: o uso de dispositivos canários, o monitoramento e modelagem de precursores de falha e o monitoramento de condições ambientais e de uso para modelagem baseada em física de falha. Estas estratégias serão descritas com mais detalhes nos próximos parágrafos.

O prognóstico por meio de dispositivos canários, conforme Mathew, Osterman e Pecht (2015), consiste na utilização de dispositivos auxiliares mais sensíveis a condições operacionais de interesse junto ao sistema principal com o propósito de que este atinja uma falha antes do sistema principal, assim servindo como um alerta antecipado para a degradação do sistema principal. O termo "dispositivo canário" tem origem histórica nas minas de carvão, onde mineradores levavam consigo pássaros canários e monitoravam sua saúde. O adoecimento do animal, que é mais sensível aos gases tóxicos das minas do que os seres humanos, servia como um alerta para a evacuação dos mineradores (MATHEW; OSTERMAN; PECHT, 2015). Neste contexto, é possível ressaltar que dispositivos como os fusíveis em sistemas elétricos cumprem um papel similar aos dispositivos canários, ao indicar condições críticas de corrente em um sistema antes da ocorrência de uma falha no mesmo.

Os precursores de falha, segundo Kapur e Pecht (2014), são eventos ou tendências que implicam em falhas iminentes. A realização de um prognóstico a partir destes precursores envolve uma análise inicial, com o intuito de identificar as variáveis de interesse do sistema, seguida do desenvolvimento de um algoritmo capaz de correlacioná-las com a falha. É importante ressaltar que os autores alertam que esta abordagem pode produzir resultados incompatíveis caso exista uma diferença considerável entre as condições operacionais utilizadas para a construção do algoritmo e o sistema operacional em campo. Tratando especificamente de supercapacitores, a tendência de aumento da resistência interna e de decréscimo da capacitância podem ser considerados os seus principais precursores de falha. Estas variáveis serão apresentadas com mais detalhes na seção 2.3.1.

Utilizando o modelo de consumo de vida proposto por Ramakrishnan e Pecht (2003), é possível descrever a terceira estratégia de prognóstico mencionada. Ela possui três etapas principais: o monitoramento de parâmetros críticos do ambiente, a simplificação dos dados monitorados e a análise por física de falha. O monitoramento de parâmetros críticos envolve a medição periódica das cargas que impactam na confiabilidade do equipamento. Alguns exemplos típicos destas cargas estão apresentados na Tabela 1. O processo de simplificação dos dados trata da conversão dos dados monitorados para uma entrada adequada para os modelos de confiabilidade a serem utilizados. Por fim, a análise por física de falha (PoF – do inglês *Physics of Failure*) envolve, neste caso, o dimensionamento do dano cumulativo, considerando uma modelagem baseada nas propriedades físicas do sistema e os múltiplos mecanismos de falha induzidos pelas cargas monitoradas.

Tabela 1 - Exemplos de cargas durante o ciclo de vida de um equipamento.

Carga	Condições da carga
Térmica	Temperatura de estado estacionário, faixas de temperatura, ciclos de temperatura, gradientes de temperatura, taxas de rampa, dissipação de calor
Mecânica	Magnitude de pressão, gradiente de pressão, vibração, carga de choque, nível acústico, tensão, estresse
Química	Ambiente agressivo versus inerte, nível de umidade, contaminação, ozônio, poluição, derramamento de combustível
Física	Radiação, interferência eletromagnética, altitude

Carga	Condições da carga
Elétrica	Corrente, tensão, potência, resistência

Fonte: adaptado de Kapur, Pecht (2014).

Um dos principais parâmetros determinados através do prognóstico de um dispositivo ou sistema é a sua vida útil remanescente. Considerando que um dos objetivos deste trabalho consiste no desenvolvimento de um modelo capaz realizar uma previsão desta grandeza, convém apresentar uma discussão mais detalhada sobre este conceito na seção a seguir.

2.1.3 Vida Útil Remanescente

Segundo Si *et al.* (2011), a vida útil remanescente (RUL – do inglês *Remaining Useful Life*) pode ser definida como a distância entre o tempo atual e o tempo em que o dispositivo ou sistema em análise atinge o fim de sua vida útil. Lei *et al.* (2018) complementam esta definição, descrevendo a RUL como o tempo restante até os estados de saúde de um equipamento cruzarem um limite de falha estabelecido. Com base nestas definições, a expressão a seguir, apresentada por Lei *et al.* (2018), pode ser utilizada para representar esta métrica:

$$RUL(t_i) = \inf(t: x(t + t_i) \leq \gamma), \quad (1)$$

onde:

t_i representa o instante em que a análise é realizada;

$x(t + t_i)$ representa o estado de saúde do sistema em $t + t_i$;

γ representa o limite de falha;

e $\inf()$ representa o limite inferior de uma variável.

Em outras palavras, a RUL avaliada em um k-ésimo instante é o menor valor de tempo a partir do instante da análise que resulta em um estado de saúde inferior ao limite de falha. Lei *et al.* (2018) destacam o fato de que o limite de falha deve ser modelado a partir de uma distribuição de probabilidade com o propósito de considerar as incertezas e variabilidades do sistema. Utilizando esta configuração, a RUL é uma

variável aleatória que pode ser representada por meio de uma função densidade de probabilidade e conter intervalos de confiança. Por outro lado, os autores também ressaltam a existência de muitas publicações que consideram o limite de falha como um valor constante, pois isto facilita sua aquisição em casos práticos e simplifica o processo de predição. Neste caso, a RUL se torna um valor pontual.

No trabalho desenvolvido por Lei *et al.* (2018) são apresentadas as principais estratégias para realização da predição da RUL de máquinas. Esta divisão não é exclusiva a esta classe de equipamentos e pode ser generalizada para dispositivos como supercapacitores. Nela, destacam-se estratégias baseadas em modelos físicos, estatísticos e de inteligência artificial, além dos denominados "modelos híbridos" que aplicam a combinação destas e outras estratégias. Em grande parte, elas efetuam o prognóstico com base em precursores de falha e modelos de física de falha, abordados na seção anterior. Os próximos parágrafos desta seção serão dedicados ao detalhamento das categorias mencionadas.

De acordo com Sikorska, Hodkiewicz e Ma (2011), a modelagem por meio de modelos físicos (também chamados de modelos de física de falha) consiste na caracterização do comportamento dos modos de falha de um sistema com base em leis físicas, partindo da suposição que é possível obter uma descrição precisa do sistema de forma analítica. Conseqüentemente, esta estratégia exige um conhecimento aprofundado sobre o funcionamento deste sistema. Tratando de dispositivos de armazenamento de energia, como baterias e supercapacitores, os circuitos equivalentes e modelos eletroquímicos estão entre as principais estratégias utilizadas para sua modelagem. Estas estratégias serão exploradas na seção 2.3.2.

Si *et al.* (2011) realizaram uma extensa revisão de modelos encontrados na literatura que utilizam métodos estatísticos para obtenção da RUL. De acordo com os autores, esta classe de métodos realiza o ajuste de seus modelos com base em dados disponíveis dentro de um modelo probabilístico, que não depende de princípios físicos. Regressão, o processo de Wiener, cadeias de Markov e o filtro de Kalman são alguns exemplos de técnicas empregadas para o desenvolvimento destas modelagens.

Os métodos baseados em inteligência artificial, especificamente dentro do contexto do aprendizado de máquina, independem do conhecimento sobre a física de

falha do sistema, da mesma forma que os métodos estatísticos, e são ajustados a partir de dados característicos e operacionais disponíveis. Fink *et al.* (2020) ressaltam que este grupo de modelos, com especial ênfase em modelos de aprendizado profundo, são uma interessante proposição para o desenvolvimento de modelos de prognóstico, pois apresentam as seguintes capacidades: processamento automático de grandes quantidades de dados de monitoramento, extração de características úteis a partir de fontes heterogêneas e de dimensão elevada, aprendizado de relações temporais e funcionais de séries temporais e capacidade de generalizar o conhecimento entre diferentes condições operacionais em múltiplas unidades.

Com relação às aplicações da vida útil remanescente, ressalta-se que ela é utilizada como um dos principais critérios no processo de manutenção preditiva. A próxima seção apresenta as principais estratégias de manutenção atualmente desenvolvidas e realiza uma breve comparação entre elas com o propósito de apresentar os pontos positivos da manutenção preditiva, reforçando a importância do desenvolvimento de modelos de prognóstico.

2.1.4 Manutenção

Birolini (2017) define manutenção como o conjunto de ações realizadas em um equipamento para mantê-lo ou restaurá-lo para um estado operacional especificado. Modarres, Kaminskiy e Krivtsov (2017) complementam esta definição ao ressaltar o fato de que a manutenção é um conceito mais amplo que reparo, englobando todos os tipos de processo de renovação e com a possibilidade de ser realizada em um dispositivo que ainda não atingiu uma falha. Deste modo, é um procedimento que serve para prevenir, proteger ou mitigar o processo de degradação que irá induzir uma falha. De modo geral, Merkt (2019), com base na norma europeia DIN EN 13306, estabelece que as atuais estratégias de manutenção podem ser classificadas como corretivas, preventivas, baseadas em condição e preditivas.

Com base em Merkt (2019, apud DIN EN 13306), serão apresentadas as definições para cada uma das estratégias de manutenção mencionadas. A manutenção corretiva consiste no processo de manutenção realizado após a detecção de uma falha, com o objetivo de fazer com que o sistema consiga retornar a um estado

operacional funcional. A manutenção preventiva, por outro lado, utiliza análises prévias para determinar a frequência com que deve ser realizada a manutenção, com o objetivo de reduzir a probabilidade de falha ou a degradação do sistema. A manutenção baseada em condição é um subconjunto da manutenção preventiva, combinando técnicas de monitoramento, inspeção e/ou teste junto a uma análise e ações de manutenção subsequentes. Por fim, a manutenção preditiva pode ser categorizada como a realização da manutenção baseada em condição a partir de uma previsão em análises repetidas ou características conhecidas e avaliação dos parâmetros significativos de degradação do sistema.

Merkt (2019) observa que a manutenção corretiva, apesar de aproveitar por completo a vida útil do dispositivo, é imprevisível com relação ao momento de ocorrência da falha, frequentemente resultando em danos que podem ter um impacto mais negativo do que o aproveitamento total do dispositivo. Conseqüentemente, a manutenção preventiva, quando bem calibrada, tende a ser uma escolha mais favorável quando comparada à corretiva, uma vez que evita a ocorrência da falha. Comparando a manutenção preventiva à manutenção preditiva, Hashemian (2011) destaca o fato de que a aplicação de técnicas como a predição da vida útil remanescente na manutenção preditiva tem o potencial de evitar a substituição desnecessária de equipamentos, economizar recursos e ampliar a segurança, disponibilidade e eficiência do sistema em que está inserido.

2.2 Redes Neurais Artificiais

LeCun, Bengio e Hinton (2015) descrevem as redes neurais artificiais, especificamente dentro do contexto do aprendizado profundo, como modelos computacionais compostos por múltiplas camadas de processamento capazes de aprender representações para dados de entrada com múltiplos níveis de abstração. Esta seção, que foi dividida em seis partes, desenvolve uma breve introdução sobre estes modelos. Ela inicia com uma apresentação histórica sobre a evolução desta família de modelos seguida de uma descrição do modelo do neurônio. Com base nestes pontos, são então apresentadas as três arquiteturas exploradas neste trabalho: as redes *feedforward* junto a outros conceitos básicos gerais associados a esta família de algoritmos, as redes recorrentes e as redes convolucionais. Por fim, são

apresentadas técnicas para a representação de incertezas nestes modelos, com ênfase para o Dropout Monte Carlo, que foi a estratégia selecionada para utilização no desenvolvimento deste trabalho.

2.2.1 Visão Histórica

De acordo com Goodfellow, Bengio e Courville (2016), o desenvolvimento das redes neurais artificiais pode ser dividido, numa perspectiva histórica, em três grandes ondas: a cibernética, que ocorreu entre as décadas de 1940 e 1960; o conexionismo, entre os anos 1980 e 1990; e o aprendizado profundo, que teve início em 2006 e segue na atualidade. Neste contexto, os autores ressaltam que os diferentes nomes atribuídos a este campo de pesquisa são um reflexo das distintas perspectivas que diferentes pesquisadores da área apresentaram ao longo dos anos. Uma breve apresentação de cada uma destas ondas será realizada nos parágrafos seguintes, tendo como principal referência a análise histórica apresentada por Goodfellow, Bengio e Courville no livro *Deep Learning*.

Wiener (1948) define que um dos principais objetivos da cibernética é o estudo de processos comuns entre as máquinas matemáticas e os sistemas nervosos. É possível observar, neste contexto, que os primeiros avanços na área foram motivados pelos estudos da neurociência. O neurônio de McCulloch-Pitts (MCCULLOCH; PITTS, 1943), por exemplo, foi um dos primeiros modelos matemáticos desenvolvidos com o objetivo de descrever o funcionamento do cérebro. A partir da aplicação de sistemas lineares, o modelo era capaz de retornar uma saída binária. Entretanto, ele apresentava muitas limitações, destacando-se a necessidade de ajuste manual dos seus pesos para garantir um funcionamento adequado. Na década seguinte, continuando a linha de pesquisa de McCulloch e Pitts dentre outros autores, Rosenblatt (1958) propôs o modelo do *perceptron*, que representou um importante avanço na área por meio da introdução de uma estratégia para ajuste de seus pesos a partir exemplos. Nesta mesma época, Widrow e Hoff (1960) apresentaram o ADALINE (*adaptive linear element*), modelo que, assim como o perceptron de Rosenblatt, utilizava uma estratégia iterativa para o ajuste de seus pesos. O algoritmo introduzido pelos autores pode ser interpretado como um caso particular do método do gradiente descendente estocástico (SGD – do inglês *stochastic gradient descent*),

um dos principais métodos utilizados para o treinamento de redes neurais atualmente. Além disso, o ADALINE diferia do *perceptron* em termos de sua saída: enquanto o *perceptron* apresentava uma saída categórica, o ADALINE tinha uma saída pertencente ao domínio dos números reais.

Seguindo a linha histórica, o conexionismo, de acordo com Fodor e Pylyshyn (1988), fez parte dos estudos das ciências cognitivas, envolveu áreas como a psicologia e a ciência da computação e buscou o desenvolvimento de modelos baseados em redes contendo um grande número de unidades de processamento simples, porém altamente interconectadas. Estes modelos seguiam o princípio de que esta estratégia de conexão era capaz de produzir um comportamento inteligente. Durante este período, ocorreram múltiplos avanços relevantes para a área de redes neurais artificiais. Um deles foi o desenvolvimento do algoritmo de retropropagação (*backpropagation*) proposto por Rumelhart, Hinton e Williams (1986), que se tornou a principal e estratégia para o treinamento de redes neurais artificiais na atualidade. Ressaltam-se também pesquisas na área de modelagem de sequências, que resultaram, por exemplo, no desenvolvimento da rede LSTM (*long short-term memory*) por Hochreiter e Schmidhuber (1997), que demonstrou grande relevância nos últimos anos em aplicações como processamento de linguagem natural e análises de séries temporais.

Apesar da forte motivação biológica, especialmente durante as fases mais antigas de desenvolvimento da área, cuja influência perdura, por exemplo, no termo *rede neural artificial*, Goodfellow, Bengio e Courville (2016) destacam o fato de que o campo da neurociência atualmente não é mais uma referência predominante para a área, ainda que continue sendo uma fonte de inspiração importante. O principal motivo para isto é que ainda não há compreensão suficiente sobre o funcionamento do cérebro para utilizá-lo de modo restrito como referência fundamental para o desenvolvimento de modelos. Ao longo das últimas décadas, os autores observam que as pesquisas utilizaram esta inspiração especialmente para o desenvolvimento das arquiteturas de múltiplas redes neurais artificiais. Adicionalmente, eles também pontuam que pesquisas atuais estão mais alinhadas com o princípio de múltiplos níveis de composição, que também pode ser aplicado em outros modelos de aprendizado de máquina que não possuem inspiração em sistemas nervosos.

A onda do aprendizado profundo teve início com o trabalho proposto por Hinton, Osindero e Teh (2006), no qual foi introduzido um algoritmo veloz para o treinamento de redes neurais artificiais, que possibilitou que os pesquisadores da época se dedicassem ao estudo dos impactos da profundidade nas redes. Numa perspectiva mais atual, LeCun, Bengio e Hinton (2015) descrevem que a teoria do aprendizado profundo permite com que modelos computacionais contendo múltiplas camadas de processamento sejam capazes de aprender representações com múltiplas camadas de abstração. Nos últimos anos, observa-se que os modelos tendem a aumentar em tamanho ao mesmo tempo que a quantidade de dados disponíveis para treinamento em muitos cenários acompanha esta tendência. Junto ao avanço de tecnologias que trazem consigo um maior poder computacional, modelos de aprendizado profundo continuam se tornando cada vez mais robustos ao longo dos anos e revolucionando o estado da arte em múltiplas áreas num ritmo acelerado.

Como ponto de partida para compreensão destes modelos, a seção seguinte trata do modelo do neurônio, que pode ser tratado como a principal unidade de processamento básica das redes neurais artificiais. Esta explicação será útil para o desenvolvimento de modelos e arquiteturas mais complexas que serão apresentados na sequência.

2.2.2 O Modelo do Neurônio

Assim, como apresentado por Haykin (2009), é possível descrever o modelo do neurônio a partir de três elementos principais: as suas entradas, a operação de soma e a função de ativação. Com relação às entradas, observa-se, de forma geral, que pertencem ao domínio dos números reais e que são multiplicadas por pesos de mesma natureza matemática como primeira etapa do modelo. Em seguida, realiza-se a soma destes valores junto a um peso adicional independente que recebe o nome de viés. Esta etapa pode ser interpretada como uma combinação linear das entradas do modelo acrescida de uma translação provocada pelo viés. A fim de introduzir uma relação não-linear entre as entradas e a saída, a última operação consiste na aplicação de uma função de natureza não-linear. Este processo pode ser descrito por meio da seguinte equação:

$$y = g\left(\sum_{i=0}^k w_i \cdot x_i + b\right), \quad (2)$$

onde:

x_i representa a i -ésima entrada do modelo;

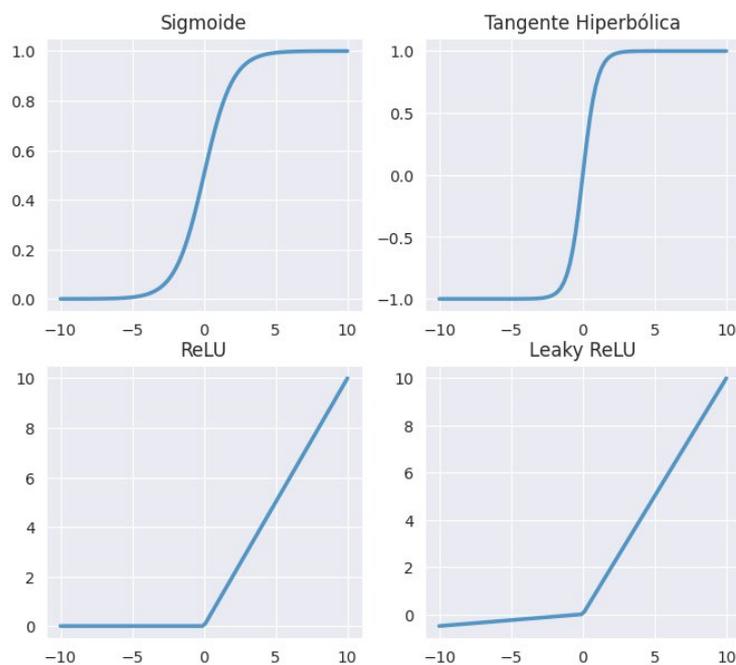
w_i representa o peso atribuído à i -ésima entrada;

b representa o viés;

e $g()$ representa a função de ativação selecionada para a operação do neurônio.

Acerca das funções de ativação, é importante destacar o fato de que existe um grande número delas e que cada uma possui vantagens, desvantagens e cenários aplicáveis específicos que variam de acordo com o objetivo e arquitetura do neurônio ou rede a ser utilizado. É possível destacar as funções sigmoide, tangente hiperbólica, ReLU e *leaky* ReLU como algumas das principais atualmente aplicadas em modelos baseados em redes neurais artificiais. A Figura 1 apresenta representação gráfica para estas funções.

Figura 1 - Funções de ativação típicas



Fonte: Elaborado pelo autor

A função sigmoide é definida da seguinte forma:

$$y = \frac{1}{1+e^{-x}}. \quad (3)$$

A tangente hiperbólica pode ser descrita diretamente a partir da expressão:

$$y = \tanh(x). \quad (4)$$

Já a unidade linear retificada (ReLU – do inglês *rectified linear unit*), apresenta a seguinte definição:

$$y = \max(0,x), \quad (6)$$

onde:

$\max(a,b)$ representa o valor máximo entre as variáveis a e b.

A *leaky ReLU*, que é uma variação da ReLU, possui uma pequena inclinação na saída para valores menores que zero, como pode ser evidenciado por meio da seguinte equação:

$$y = \max(\alpha \cdot x, x), \quad (7)$$

onde:

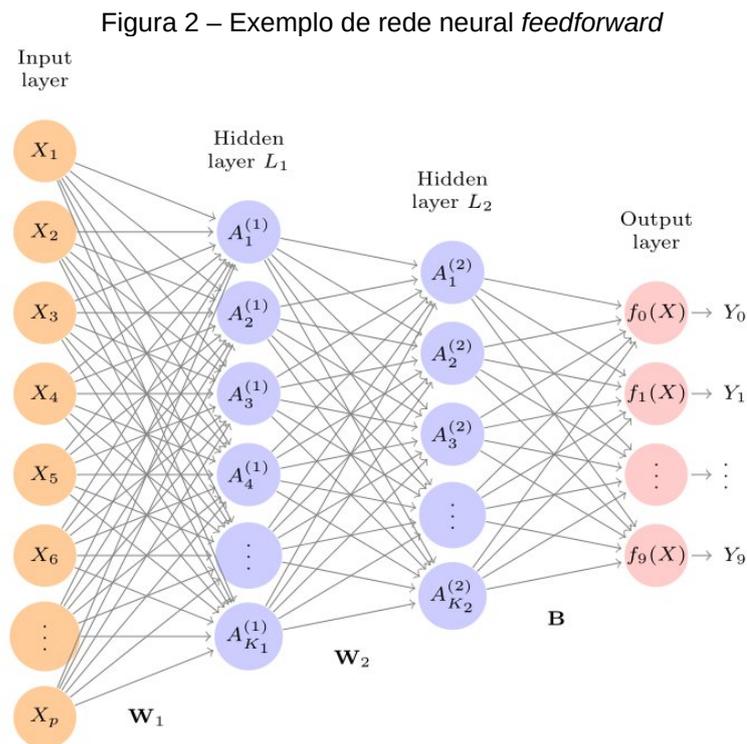
α representa a inclinação da reta para $x < 0$.

Por fim, destaca-se que, dependendo da tarefa a ser realizada pelo neurônio ou rede neural artificial, é possível que a etapa da função de ativação não seja realizada, procedimento que também pode ser interpretado como a aplicação de uma função ativação do tipo identidade. Como consequência, a sua saída pode apresentar valores que percorrem todo o domínio dos números reais. Esta estratégia é frequentemente empregada em modelos desenvolvidos com o propósito de executar tarefas de regressão.

A partir do modelo do neurônio apresentado, é possível desenvolver modelos derivados com arquiteturas mais complexas, por exemplo, através da conexão das saídas de alguns neurônios com as entradas de outros. Uma das arquiteturas mais populares que derivam desta estratégia de conexão são as redes neurais *feedforward* que serão exploradas na seção a seguir.

2.2.3 Redes Neurais Feedforward

Segundo Goodfellow, Bengio e Courville (2016), as redes neurais *feedforward* profundas, também conhecidas como redes *feedforward* e perceptron multicamadas (MLP – do inglês *multilayer perceptron*), são caracterizadas pelo sentido no qual as informações do modelo viajam da entrada para a saída sem nenhum mecanismo de realimentação. Nesta arquitetura, neurônios são agrupados em camadas nas quais todas as suas saídas são conectadas com as entradas da camada seguinte conforme a representação da Figura 2. Seguindo este modelo, é comum nomear as variáveis de entrada como a camada de entrada, as camadas intermediárias como camadas ocultas e a última camada que produz os resultados do modelo como camada de saída.



Fonte: James et al. (2023)

A operação matemática que consiste na introdução de valores de entrada a fim de se obter saídas deste modelo recebe o nome de propagação para frente, ou *forward propagation*. Este processo segue a mesma lógica da obtenção de um valor de saída a partir de um único neurônio que foi apresentada na equação (2), porém

com duas diferenças notáveis. A primeira é que, considerando o caso de um único neurônio, os pesos adquirem o formato vetorial com dimensão igual à quantidade de entradas do modelo. Na rede neural, os pesos assumem um formato matricial, que pode ser interpretado como a junção de múltiplos vetores peso com dimensão igual à saída da camada anterior para cada um dos neurônios da camada atual. Além disso, nota-se também que esta operação é realizada um número de vezes igual à quantidade de camadas que contêm neurônios. De acordo com a modelagem apresentada pela Figura 2, este valor seria igual ao número de camadas ocultas acrescido da camada de saída, uma vez que a camada de entrada envolve apenas as variáveis de entrada do modelo. Deste modo, a propagação para frente através de uma camada pode ser representada a partir da seguinte equação, considerando que todos os neurônios possuem a mesma função de ativação:

$$A_i^{(n)} = g\left(\sum_{j=0}^k w_{ij} \cdot A_j^{(n-1)} + B_i^{(n)}\right), \quad (8)$$

onde:

$A_i^{(n)}$ representa saída do i -ésimo neurônio da camada n ;

$A_i^{(n-1)}$ representa a saída do i -ésimo neurônio da camada anterior à camada n ;

$w_{ij}^{(n)}$ representa o peso atribuído à j -ésima entrada pelo i -ésimo neurônio da camada n ;

$B_i^{(n)}$ representa o viés do i -ésimo neurônio da camada n ;

e $g(\cdot)^{(n)}$, representa a função de ativação selecionada para a operação dos neurônios da camada n .

Observa-se, a partir desta expressão, que estes modelos tendem a exibir um elevado número de parâmetros (pesos e vieses) a depender do número de neurônios por camada e da quantidade de camadas que possuem. Consequentemente, nota-se que a tentativa de um ajuste manual destes parâmetros é uma tarefa árdua e pouco prática. Deste modo, como ressaltado na seção 2.2.1, nota-se que o desenvolvimento de algoritmos para o ajuste automático destes pesos foi uma das inovações mais importantes para viabilizar a sua aplicabilidade. Conforme James *et al.* (2023), este ajuste de pesos pode ser realizado por meio da otimização de uma função custo, que realiza a comparação entre as saídas do modelo após uma propagação para frente

com as saídas esperadas. Conhecendo o gradiente desta função custo, que pode ser determinado a partir da aplicação do algoritmo de retropropagação ou *backpropagation*, é possível determinar ajustes que direcionem o modelo a um custo mínimo local ou global através da aplicação de um algoritmo de otimização, aumentando assim o seu desempenho. Segundo James *et al.* (2023), o cálculo dos gradientes para os parâmetros do modelo pode ser definido a partir da seguinte equação:

$$\nabla R(\theta^{(m)}) = \frac{\partial R(\theta)}{\partial \theta} \Big|_{\theta=\theta^{(m)}}, \quad (9)$$

onde:

$\theta^{(m)}$ representa o ajuste durante a iteração de número m para o parâmetro θ ;

$R(\theta)$ representa a função custo.

Um algoritmo de otimização normalmente utilizado para minimizar a função custo de modelos baseados em redes neurais na atualidade é o Adam, proposto por Kingma e Ba (2014). Este foi o selecionado para o treinamento dos modelos desenvolvidos neste trabalho. James *et al.* (2023) ressaltam que a aplicação do método do gradiente é uma outra possível estratégia a ser aplicada e é capaz de fornecer uma ideia geral sobre o princípio de funcionamento destes algoritmos. Este método pode ser descrito a partir da seguinte operação:

$$\theta^{(m+1)} \leftarrow \theta^{(m)} - \rho \nabla R(\theta^{(m)}), \quad (10)$$

onde:

$\theta^{(m+1)}$ representa o ajuste atualizado para o parâmetro θ ;

ρ representa a taxa de aprendizado, hiperparâmetro que ajusta a magnitude dos gradientes e, por consequência, é utilizado para regular a velocidade com a qual os ajustes de pesos do modelo são realizados a cada iteração do algoritmo.

Levando em consideração que, dentro do contexto do aprendizado supervisionado, este processo de ajuste de pesos envolve a apresentação de um conjunto de dados a serem utilizados como exemplo para o modelo, ressalta-se que uma das dificuldades apresentadas no processo de treinamento é a garantia de que este tem a capacidade de generalizar suas saídas para outras entradas de natureza similar que não fazem parte do conjunto de dados utilizados para o seu treinamento.

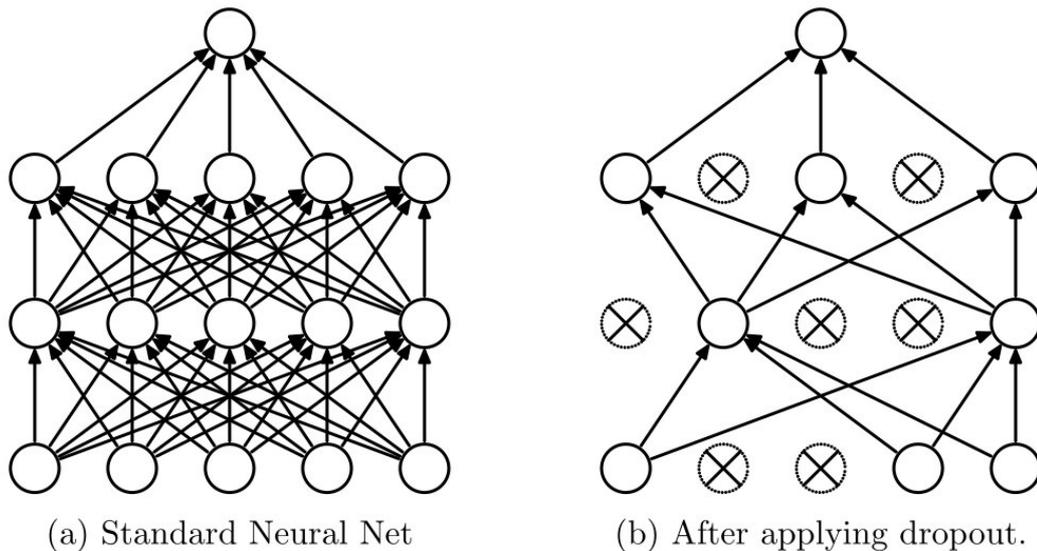
O problema conhecido como sobreajuste ou *overfitting* é um fenômeno comumente evidenciado durante o desenvolvimento de redes neurais que tem como principal efeito a redução da capacidade de generalização do modelo. Ele ocorre quando há um ajuste extremo dos pesos para os dados de treinamento, caracterizando, conseqüentemente, uma notável disparidade entre o desempenho do modelo para os dados treinados e dados externos de teste. Uma estratégia para contornar este problema consiste na aplicação de técnicas de regularização, que, segundo Goodfellow, Bengio e Courville (2016), podem ser definidas como qualquer tipo de modificação realizada no algoritmo de treinamento com o propósito de reduzir apenas o erro de generalização, não incluindo o erro advindo dos dados de treinamento.

Uma das principais técnicas de regularização de redes neurais que será utilizada neste trabalho é o *dropout* devido à sua integração com o *dropout* Monte Carlo, método selecionado para a quantificação das incertezas dos modelos desenvolvidos, que será apresentado na seção 2.2.6. Inicialmente proposta por Srivastava *et al.* (2014), esta técnica consiste essencialmente no processo de desligamento de uma seleção aleatória de neurônios junto às suas respectivas conexões durante o treinamento do modelo, conforme ilustra a Figura 3. Em termos matemáticos, este processo consiste em zerar todos os pesos associados aos neurônios desligados. Segundo os autores, ao utilizar a rede completa durante a etapa de avaliação dos resultados, com o *dropout* já desativado, é possível aproximar a média de múltiplas redes neurais distintas, estratégia que tende a apresentar resultados melhores do que modelos isolados.

A partir dos tópicos discutidos nos parágrafos anteriores, é possível perceber que os pesos e vieses das redes neurais artificiais são ajustados durante o processo de treinamento. Devido a este fato, estas variáveis são denominadas os parâmetros do modelo. Entretanto, existem outras configurações ligadas à arquitetura das redes, como, por exemplo, o número de neurônios por camadas e o número de camadas, que têm o potencial de afetar propriedades importantes como o seu custo computacional e desempenho. Estas outras variáveis recebem o nome de hiperparâmetros. De acordo com Goodfellow, Bengio e Courville (2016), existem duas estratégias gerais para sua seleção: o ajuste manual e a seleção automática. Com relação ao ajuste manual, os autores ressaltam o fato de que neste processo é exigido um bom conhecimento entre a relação de fatores como erro de generalização, erro no

conjunto de testes e custo computacional para a seleção de hiperparâmetros adequados. Já na seleção automática, este processo de busca é substituído por um algoritmo de otimização. Alguns exemplos normalmente aplicados são a busca em rede, a busca aleatória e a busca por meio de modelos.

Figura 3 – Representação do *dropout* aplicado em uma rede neural *feedforward*



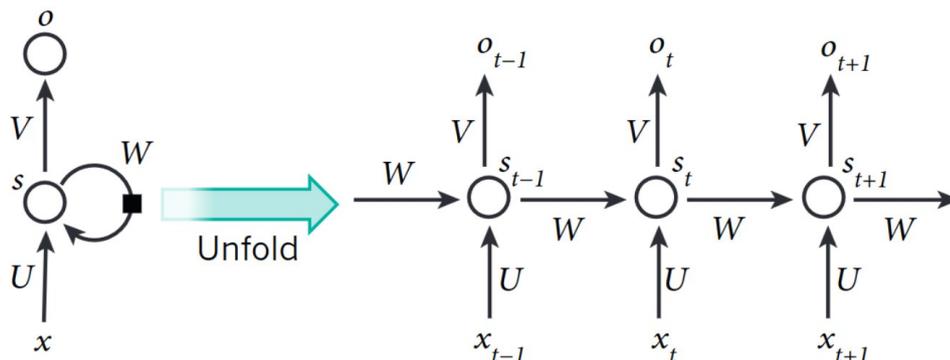
Fonte: Srivastava *et al.* (2014)

Após esta breve apresentação sobre aspectos gerais relacionados ao modelo das redes neurais *feedforward*, é importante ressaltar que existem múltiplas variantes à este modelo que são utilizadas em uma vasta gama de aplicações devido a vantagens que apresentam quando comparadas a este modelo base. Duas que exibem grande destaque nos últimos anos e serão exploradas neste trabalho são as redes neurais recorrentes e as redes neurais convolucionais. Deste modo, as próximas seções terão como objetivo introduzir aspectos gerais de ambas. Em seguida, a seção é concluída através de uma breve descrição sobre técnicas para a quantificação de incertezas nestes modelos, que permitem a descrição de suas saídas por meio de parâmetros estatísticos ao invés dos valores pontuais intrínsecos aos modelos.

2.2.4 Redes Neurais Recorrentes

De acordo com Goodfellow, Bengio e Courville (2016), a rede neural recorrente (RNN – do inglês *recurrent neural network*) é o termo utilizado para categorizar um grupo de arquiteturas de redes neurais artificiais especializadas no processamento de dados sequenciais. Fundamentalmente, conforme indicado pelo seu nome, estas redes são caracterizadas por apresentarem um mecanismo de recorrência que, por exemplo, pode ser identificado pela realimentação das saídas de uma camada nela mesma, conforme indica a Figura 4. Acerca deste tema, LeCun, Bengio e Hinton (2015) adicionam o fato de que estas redes processam um elemento por vez e mantêm em suas unidades ocultas um vetor de estados que preserva informações sobre todos os elementos da sequência processada.

Figura 4 - Representação gráfica de uma rede neural recorrente



Fonte: LeCun, Bengio e Hinton (2015).

Uma relevante arquitetura de rede neural recorrente é a rede LSTM (do inglês *long short-term memory*), proposta por Hochreiter e Schmidhuber (1997). James *et al.* (2023) comentam que ela é caracterizada por apresentar dois caminhos distintos para a ativação de camadas ocultas, permitindo com que receba como entrada dados próximos e distantes em relação à sua posição na sequência. Os autores ainda adicionam o fato de que este mecanismo evita com que a influência de dados iniciais seja efetivamente perdida até atingir a etapa de propagação.

2.2.5 Redes Neurais Convolucionais

Assim como as redes neurais recorrentes possuem um campo de aplicação específico para séries sequenciais, constata-se que as redes neurais convolucionais (CNN – do inglês *convolutional neural networks*) são especializadas, conforme destacam LeCun, Bengio e Hinton (2015), no processamento de dados compostos por múltiplos vetores ou matrizes. Os autores comentam que estes dados frequentemente assumem formatos como três matrizes contendo dados sobre as intensidades dos pixels de uma imagem, vetores descrevendo sinais e sequências e sistemas tridimensionais para entradas como vídeos e imagens volumétricas.

Goodfellow, Bengio e Courville (2016) pontuam que estas redes são identificadas pela presença da operação de convolução em substituição a uma multiplicação matricial em pelo menos uma de suas camadas. Adicionalmente, eles também destacam o fato de que estas operações são frequentemente acompanhadas por operações de *pooling*. No contexto das redes neurais convolucionais, James *et al.* definem a operação de convolução como o processo sequenciado de multiplicação de elementos de uma matriz por um filtro de dimensão menor ou igual a entrada, seguido pela soma destes resultados. Este filtro possui tamanho e passo de deslocamento ao longo da entrada que podem ser definidos e otimizados de acordo com o problema em análise. Para exemplificar este processo seguindo o exemplo apresentado pelos autores, é necessário definir uma matriz de entrada e um filtro de convolução:

$$\text{Matriz de entrada} = \begin{matrix} a & b & c \\ d & e & f \\ g & h & i \end{matrix}, \quad (11.1)$$

$$\text{Filtro de convolução} = \begin{matrix} \alpha & \beta \\ \gamma & \delta \end{matrix}. \quad (11.2)$$

Considerando que o filtro se desloca com um passo unitário e que a matriz de entrada não recebe um preenchimento, processo no qual valores são adicionados ao seu redor, a matriz após o processo de convolução deve apresentar a seguinte forma:

$$\text{Matriz após convolução} = \begin{matrix} a\alpha + b\beta + c\gamma + d\delta & b\alpha + c\beta + e\gamma + f\delta \\ d\alpha + e\beta + g\gamma + h\delta & e\alpha + f\beta + h\gamma + i\delta \end{matrix}. \quad (11.3)$$

Com relação às operações de *pooling*, duas foram utilizadas neste trabalho: a *max pooling* e a *average pooling*. Estas duas assemelham-se à convolução no sentido que também consistem numa janela que percorre uma matriz de entrada. Entretanto, diferem em termos da operação realizada. Enquanto o *max pooling* retorna apenas o valor máximo identificado em cada uma de suas comparações ao longo da entrada, a operação de *average pooling* retorna a média destes valores. A Figura 5, apresentada abaixo, ilustra este processo para um filtro de dimensão 2x2 e passo igual a 2.

Figura 5 - Exemplo de aplicação de max-pooling e average pooling



Fonte: Elaborado pelo autor.

2.2.6 Técnicas para Quantificação da Incerteza

Segundo Nemani *et al.* (2023), a quantificação de incertezas em modelos de aprendizado de máquina age como uma camada garantia da segurança que possibilita melhores tomadas de decisão e gestão de risco, além de exibir o potencial de viabilizar a aplicação destes modelos até mesmo em setores caracterizados pelo intrínseco risco elevado, como saúde, indústrias e aviação. Os autores indicam que algumas das estratégias de estado da arte para esta tarefa são a regressão do processo gaussiano, redes neurais bayesianas, conjuntos de redes neurais e processos gaussianos com normalização espectral.

Adicionalmente, os autores também adicionam que o *Dropout Monte Carlo* (MCDO) é um método que, apesar de apresentar limitações, é computacionalmente eficiente e facilmente integrável em arquiteturas baseadas em redes neurais. Proposto

por Gal e Ghahramani (2016), ele consiste na estratégia de manter o *dropout* do modelo ligado durante a etapa de testes junto à coleta de múltiplas previsões para uma mesma entrada. A cada propagação para frente e subsequente coleta das previsões, o *dropout* altera o perfil da rede, que, por consequência, resulta em saídas distintas. A partir de um conjunto de múltiplas previsões de uma saída tendo em base a mesma entrada, é possível obter uma estimativa para a incerteza do modelo com relação à entrada específica. Devido a sua simplicidade de implementação, este foi o método selecionado para executar o papel de quantificação das incertezas dos modelos desenvolvidos neste trabalho.

2.3 Supercapacitores

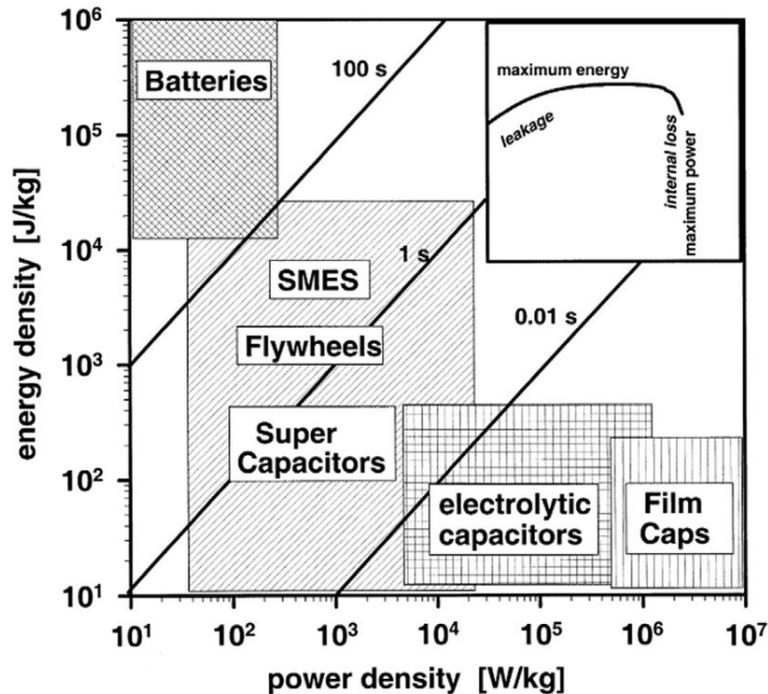
Esta seção tem como objetivo introduzir aspectos gerais sobre os supercapacitores como dispositivos de armazenamento de energia. Em primeiro lugar, são apresentadas características gerais sobre a tecnologia. Em seguida, é realizado um breve comentário sobre atuais e potenciais aplicações deste dispositivo em múltiplas áreas. Por fim, são apresentados os modelos nos quais a parte técnica deste trabalho foi inspirada.

2.3.1 Caracterização da Tecnologia

A Figura 6 apresenta um diagrama de Ragone, gráfico que relaciona a energia específica com a potência específica de várias tecnologias de armazenamento de energia. Uma análise desta figura complementa algumas das observações propostas por González *et al.* (2016) sobre os supercapacitores. Em primeiro lugar, quando comparados às baterias, estes dispositivos tendem a apresentar potências volumétricas de centenas a milhares de vezes maiores; porém apenas conseguem armazenar uma carga de 3 a 30 vezes mais baixa. Por outro lado, quando comparados aos capacitores eletrolíticos, apresentam menor potência específica e maior energia específica. Deste modo, constata-se que os supercapacitores ocupam um espaço estratégico entre estas outras duas tecnologias de armazenamento de energia. Os

autores ainda observam que os dois principais mecanismos que regem seu funcionamento são a capacitância de dupla camada e a pseudocapacitância.

Figura 6 - Diagrama de Ragone



Fonte: González *et al.* (2016)

Numa visão de confiabilidade, Laadjal e Marques Cardoso (2021) comentam que alguns dos principais modos de falhas em supercapacitores são a evaporação do eletrólito, a abertura da célula, a queda na capacitância, o aumento da resistência interna, o vazamento de eletrólito, o abaulamento e o circuito aberto. Dentro deste contexto, tanto a capacitância como a resistência interna são parâmetros característicos para a determinação do estado de saúde (SOH – do inglês *state of health*), métrica que relaciona o estado atual do dispositivo com seu critério de fim de vida útil. De acordo com os autores, a IEC-62391 define uma capacitância igual a 80% de seu valor nominal e uma resistência interna igual a 200% de seu valor nominal como critérios de fim de vida útil para estes dispositivos. Com relação à resistência interna, por exemplo, seu estado de saúde poderia ser calculado da seguinte forma:

$$SOH(\%) = \frac{2ESR - \widehat{ESR}}{ESR}, \quad (13)$$

onde:

ESR representa a resistência série equivalente nominal (do inglês *equivalent series resistance*);

\widehat{ESR} representa a resistência série equivalente atual, estimada.

Tratando agora sobre o cálculo da capacitância, Burke e Zhao (2021) definem que esta grandeza pode ser determinada a partir da seguinte expressão para um supercapacitor:

$$C(V) = \frac{dQ}{dV}, \quad (12.1)$$

onde:

Q representa a sua carga;

V representa a sua tensão.

Considerando um conjunto de leituras discreto, a equação 3.1 pode ser aproximada da seguinte forma:

$$C(V) = \frac{I\Delta t}{\Delta V} \quad (12.2)$$

onde:

I representa a sua corrente;

Δt representa o intervalo de tempo entre as leituras.

Com o propósito de simplificar sua representação e auxiliar análises, algo típico para qualquer sistema de engenharia, Zhang *et al.* (2018) apresentaram um levantamento dos principais tipos de modelagem encontrados na literatura para os supercapacitores. De modo geral, os autores indicam a existência de quatro tipos principais de modelos: os eletroquímicos, os baseados em circuitos equivalentes, os de ordem fracionária e os baseados em inteligência artificial. Como todas estas

estratégias são, em essência, apenas uma abstração matemática do dispositivo real, os autores ressaltam o fato de que é natural constatar a presença de erros, assim como vantagens e desvantagens entre os modelos.

2.3.2 Aplicações

De acordo com Simon e Gogotsi (2020), as notáveis características de densidade de potência e energia dos supercapacitores junto a outras propriedades favoráveis como uma taxa de carregamento veloz, boa faixa operacional de temperaturas e elevada vida útil, que pode exceder um milhão de ciclos, torna estes dispositivos interessantes para aplicações que utilizam desde pequenas unidades em sistemas de eletrônica de potência até unidades maiores e módulos que, conforme descrevem Zhao e Burke (2020), encontram aplicações inovadoras em campos como o transporte, aplicações industriais, geração renovável junto a *smart grids* e fontes de alimentação ininterruptas.

Com relação ao campo dos transportes, Zhao e Burke (2020) comentam que veículos como carros, caminhões, ônibus e bondes elétricos utilizam supercapacitores com o propósito de exercer funções como a frenagem regenerativa, a propulsão assistida de potência e a partida do motor em tempo frio. Sobre aplicações industriais, os autores observam que estes dispositivos são especialmente encontrados em sistemas nos quais a sua eficiência energética é elevada por meio da recuperação regenerativa de energia durante ciclos com demanda dinâmica de potência. Em termos de aplicações renováveis, eles comentam que os supercapacitores podem ser utilizados em sistemas de geração fotovoltaica para regulação de frequência e que já são aplicados em larga escala nos sistemas de ajuste do ângulo de passo das pás de turbinas eólicas. Por fim, eles concluem esta apresentação comentando que os supercapacitores ainda têm o potencial de serem utilizados como sistemas de *backup* isolados ou híbridos juntos às baterias.

2.3.3 Modelos para a previsão da vida útil remanescente de supercapacitores

Tratando sobre modelos baseados em dados para a previsão da vida útil remanescente de supercapacitores, decidiu-se nesta seção ressaltar os artigos propostos por Ren *et al.* (2020) e Wang *et al.* (2022), que foram as principais referências que viabilizaram o desenvolvimento deste trabalho.

Iniciando a discussão com o trabalho proposto por Ren *et al.* (2020), destaca-se o fato de que os autores mantêm aberta e acessível a base de dados que desenvolveram para as suas análises. Esta base é a que foi utilizada neste trabalho e é interpretada com detalhes na seção 3.1. Com relação ao trabalho proposto pelos autores em seu artigo, nota-se que suas propostas foram em maioria baseadas em métodos clássicos de aprendizado de máquina, como a regressão linear e a análise de componentes principais e tiveram como objetivo principal a realização da previsão da vida útil remanescente durante os ciclos iniciais de vida. Utilizando uma rede neural *feedforward* e os primeiros 657 ciclos dos supercapacitores de teste, os autores conseguiram alcançar uma raiz do erro médio quadrático igual a 599 ciclos.

Também a partir dos dados disponibilizados por Ren *et al.* (2020), Wang *et al.* (2022) apresentaram o seu modelo. Este exhibe uma proposta distinta: a realização de previsões precisas e velozes a partir de uma quantidade limitada de dados históricos, apenas incluindo os cinco últimos ciclos de carregamento e descarregamento do dispositivo. Os autores propuseram uma rede neural convolucional para trabalhar com séries de capacidades de carga e descarga, conseguindo alcançar um valor para a raiz do erro médio quadrático igual a 501 ciclos. Ressalta-se que esta abordagem inspirou a proposta deste trabalho e que o pré-processamento dos dados proposto pelos autores foi replicado de forma similar na seção 3.2.

3 DESENVOLVIMENTO DO TRABALHO

Este capítulo busca descrever as análises e etapas realizadas neste trabalho com o objetivo de desenvolver modelos baseados em redes neurais artificiais para a previsão da vida útil remanescente de supercapacitores. As suas seções estão organizadas de acordo com a ordem na qual o trabalho foi realizado. Primeiro, apresenta-se uma análise exploratória da base de dados utilizada para o desenvolvimento dos modelos, na qual são observadas características gerais dos dados, com destaque para a obtenção das curvas de capacitância, e discute-se sobre a seleção dos dados de entrada. Logo após, a metodologia utilizada para a conversão dos dados brutos em dados processados que podem ser utilizados pelos modelos é apresentada. A seção seguinte a esta descreve as três arquiteturas finais que foram desenvolvidas e nas quais os resultados foram obtidos: uma rede *feedforward*, uma rede LSTM e uma rede convolucional. Cada uma delas é discutida em termos de sua relevância para a tarefa estabelecida. Por último, os resultados do modelo são comentados e exibidos por meio de curvas de treinamento, métricas de desempenho e visualizações gráficas.

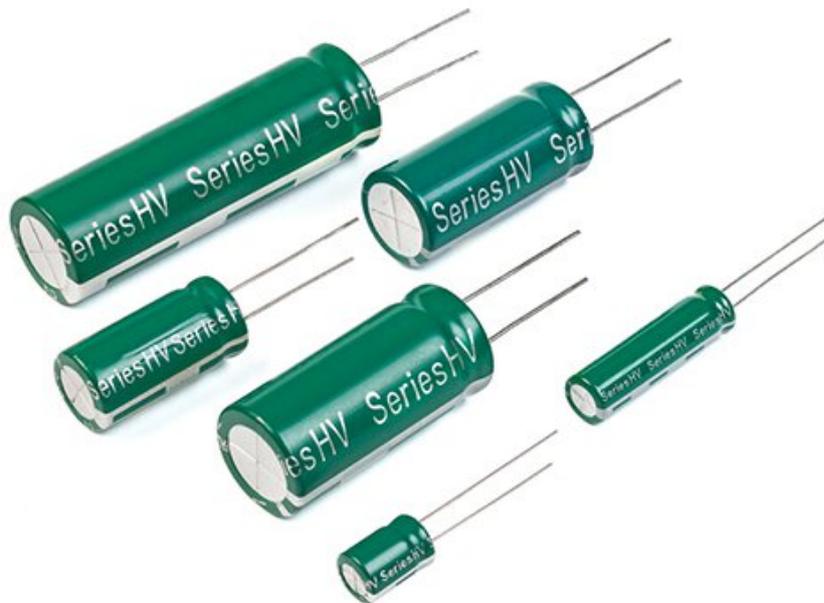
3.1 Análise Exploratória da Base de Dados

Conforme mencionado na seção 2.3.3, que tratou sobre as referências de estado da arte para este trabalho em termos de modelos de previsão da vida útil remanescente, a base de dados utilizada para seu desenvolvimento foi inicialmente apresentada e analisada por Ren *et al.* (2020) e pode ser obtida a partir da página da publicação. Esta contém dados para 113 supercapacitores Eaton modelo HV 1 F 2,7 V, representados na Figura 7, que foram submetidos a 10.000 ciclos em uma temperatura controlada de 28° C sob estratégias de carregamento e descarregamento distintas. Especificamente, todos os supercapacitores da base foram descarregados com uma corrente constante de 20 mA entre as tensões de 2,7 V e 1 V e foram carregados a partir de duas estratégias distintas: 88 unidades foram submetidas a um carregamento com corrente constante de 20 mA e outros 25 a um carregamento por corrente constante de 15 mA entre 1 V e 1,85 V, 10 mA entre 1,85 V e 2,36 V e 5 mA entre 2,36 V e 2,7 V. A Tabela 2 apresenta de forma detalhada estas características

além de incluir a taxa de amostragem utilizada e a divisão em grupos presente na base.

Com relação à natureza dos dados, constata-se a presença das características de tempo, corrente, tensão, capacidade, energia (presente nos grupos 2, 3 e 4) e informações auxiliares relacionadas à identificação do estado do supercapacitor, como o índice atual para seu ciclo e a identificação sobre o estado de carregamento, ou seja, se está carregando ou descarregando. Entretanto, é importante ressaltar o fato de que a partir da interpretação e manipulação numérica das colunas de tempo, corrente e tensão, é possível determinar todas as outras características presentes na base, assim como outras adicionais a exemplo da capacitância, que será explorada no final desta seção.

Figura 7 - Supercapacitores Eaton modelo HV



Fonte: Eaton (2017)

Tabela 2 - Descrição da base de dados

Grupo	Quantidade de supercapacitores	Estratégia de carregamento	Estratégia de descarregamento	Taxa de amostragem (Hz)
1	28	Corrente constante de 20 mA entre 1 V e 2,7 V	Corrente constante de 20 mA entre 2,7 V e 1 V	0,1
2	25	Corrente constante de 15 mA entre 1 V e 1,85 V, 10 mA entre 1,85 V e 2,36 V e 5 mA entre 2,36 V e 2,7 V	Corrente constante de 20 mA entre 2,7 V e 1 V	0,1
3	30	Corrente constante de 20 mA entre 1 V e 2,7 V	Corrente constante de 20 mA entre 2,7 V e 1 V	1
4	30	Corrente constante de 20 mA entre 1 V e 2,7 V	Corrente constante de 20 mA entre 2,7 V e 1 V	1

Fonte: adaptado de Wang, Xiong, Tian *et al.*(2022).

Buscando possuir um referencial teórico aplicado para o desenvolvimento dos modelos, a degradação da capacitância foi selecionada como o parâmetro de monitoramento para o fim da vida útil dos supercapacitores, conforme também desenvolvido nos trabalhos de Ren *et al.* (2020), Wang *et al.* (2022). Deste modo, esta seção irá analisar com mais detalhes parâmetros relacionados à esta variável. Especificamente, uma segunda análise das equações 3.1 e 3.2, indicam que estes parâmetros seriam a carga e a tensão do supercapacitor.

A capacidade, que é uma medida da carga elétrica do dispositivo, pode ser calculada a partir da seguinte expressão:

$$Q(t) = \int_0^t i dt, \quad (14.1)$$

onde:

$Q(t)$ representa a capacidade no instante t em coulombs;

$i(t)$ representa a função da corrente no tempo em ampères.

Considerando a natureza discreta dos dados da base, esta integração pode ser realizada, por exemplo, através da aplicação do método do trapézio:

$$Q^{(t)} = Q^{(t-1)} + \frac{i^{(t)} + i^{(t-1)}}{2} \Delta t, \quad (14.2)$$

onde:

$Q^{(t)}$ e $Q^{(t-1)}$ representam a capacidade atual e a capacidade da amostra imediatamente anterior, respectivamente;

$i^{(t)}$ e $i^{(t-1)}$ representam a corrente atual e a corrente da amostra imediatamente anterior, respectivamente;

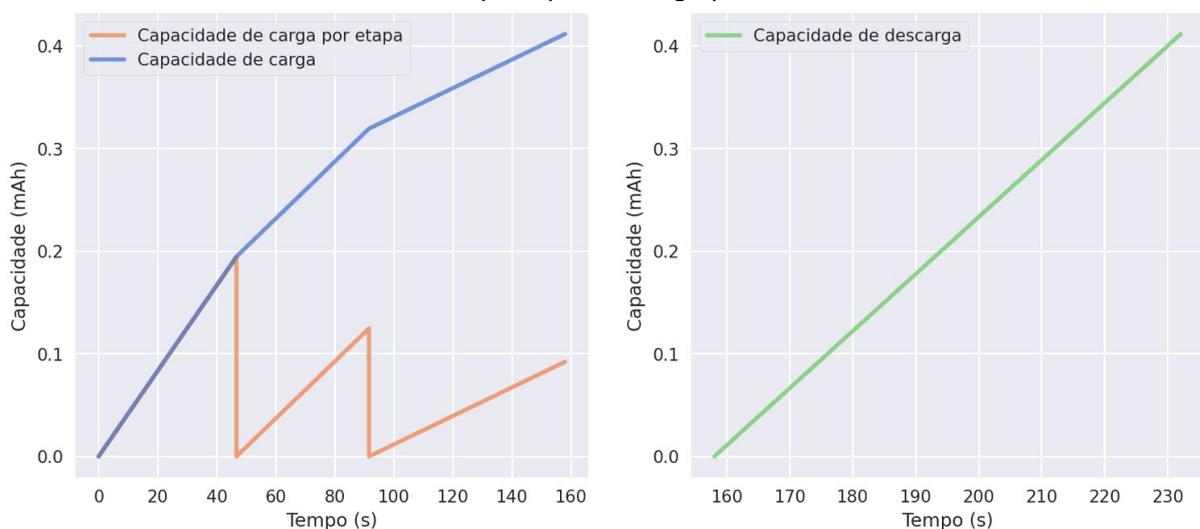
Δt representa o intervalo de tempo entre as duas amostras, equivalendo ao inverso da taxa de amostragem.

Alguns comentários podem ser traçados sobre esta variável e as abordagens apresentadas. Primeiro, observa-se que os valores de capacidade em coulomb podem ser convertidos para a convencional unidade ampère-hora através de uma simples multiplicação pelo fator 1/3600, uma vez que um coulomb é equivalente a um ampère-segundo e a única conversão necessária a ser realizada é a de segundos para horas. Além disso, nota-se que devido a presença de perdas para cada etapa de carregamento e descarregamento, convém avaliar a capacidade do dispositivo de forma desacoplada, em termos da capacidade de carga e da capacidade de descarga para cada um de seus ciclos. Neste caso, a capacidade de carga é interpretada como um valor que cresce junto com a tensão do supercapacitor, representando a carga consumida pelo dispositivo, enquanto que a capacidade de descarga representa um comportamento crescente junto a redução de sua tensão, indicando a carga entregue ao sistema durante esta etapa.

No caso do cálculo discreto apresentado na equação 6.2, é importante ressaltar que o método deve ser aplicado apenas durante intervalos nos quais a corrente apresenta um comportamento contínuo a fim de evitar erros substanciais na integração. Deste modo, as capacidades de carga dos supercapacitores do grupo 2, que possuem estratégia de carregamento por degraus de corrente, foram avaliadas inicialmente para cada um dos degraus e então agrupadas de forma cumulativa, onde a capacidade final de cada degrau era somada aos valores de capacidade dos degraus seguintes. A Figura 8 traz uma representação gráfica para este processo

além de ilustrar o perfil das curvas de capacidade de carga e descarga para um supercapacitor do grupo 2. Nota-se que, neste gráfico, tanto as curvas de capacidade de carga como a curva de capacidade de descarga apresentam um perfil ascendente devido ao fato da tensão da tensão crescer em função do tempo durante a etapa de carregamento e decrescer durante a etapa de descarregamento, consequência direta do sentido da corrente imposta no dispositivo nestes dois momentos distintos.

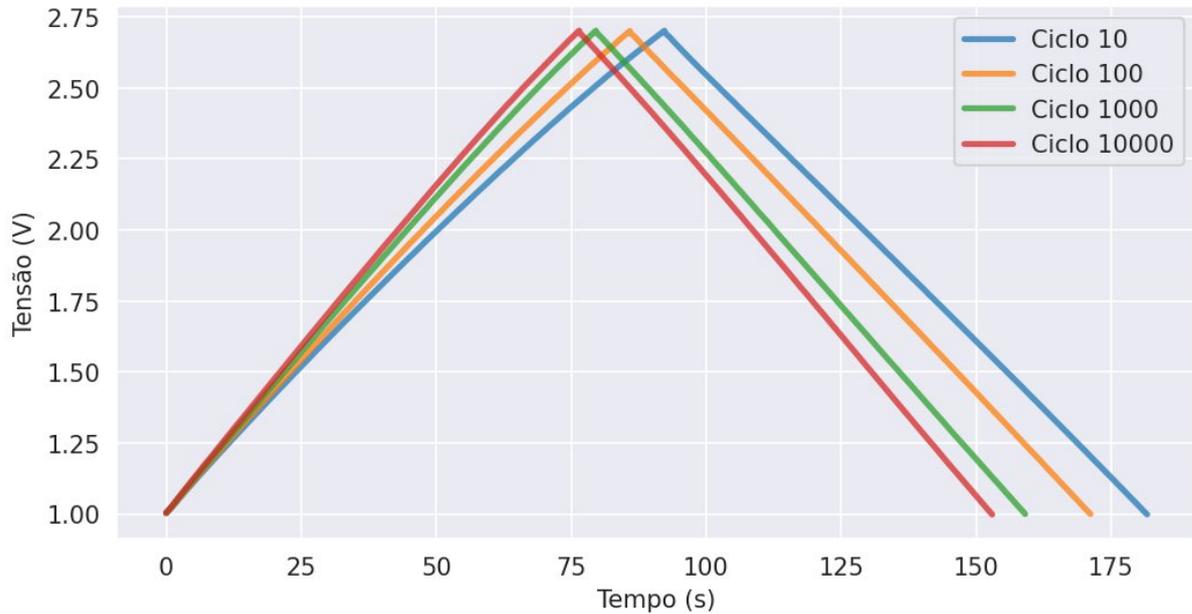
Figura 8 – Visualização das curvas de capacidade de carga e descarga em função do tempo para um supercapacitor do grupo 2



Fonte: Elaborado pelo autor

Deslocando agora a análise para a tensão, dois pontos principais podem ser destacados. O primeiro é que, como todos os supercapacitores desta base de dados foram submetidos a estratégias de carregamento e descarregamento baseados na aplicação de correntes constantes e estes dispositivos caracteristicamente possuem uma baixa resistência interna, torna-se natural a observação de que, assim como as capacidades, suas curvas de tensão se comportarão aproximadamente como retas em função do tempo. Além disso, devido aos limites de tensão entre 1 V e 2,7 V estabelecidos pela estratégia operacional dos dispositivos, constata-se que o seu envelhecimento é evidenciado pela redução do tempo total para a conclusão dos ciclos, conforme ilustra a Figura 9. A capacidade, por outro lado, apresenta também uma atenuação adicional em termos de magnitude, que pode ser percebida na Figura 10, devido ao seu perfil cumulativo causado pela integração da corrente em função do tempo.

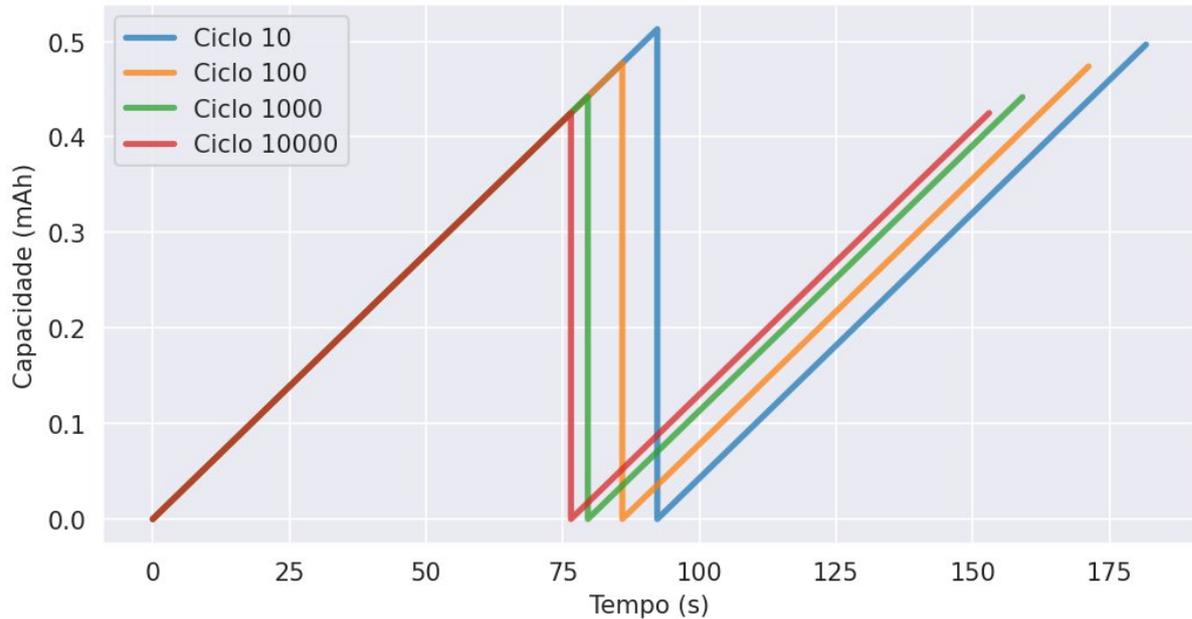
Figura 9 - Variação das curvas de tensão para as etapas de carga e descarga ao longo da vida útil de um supercapacitor da base de dados



Fonte: Elaborado pelo autor.

Considerando que a capacitância é progressivamente degradada ao longo das etapas de carregamento e descarregamento, é possível perceber que o comportamento das duas últimas curvas apresentadas é esperado. Na medida em que este parâmetro diminui, pode-se interpretar, a partir da equação 12.2 para a capacitância, que o dispositivo perde potencial de armazenamento de carga por nível de tensão. Uma vez que as suas correntes operacionais são sempre contínuas, a taxa da carga movimentada pelo dispositivo em função do tempo é fixa. Conseqüentemente, conclui-se que, nestas condições, os supercapacitores deverão apresentar um tempo de carregamento e descarregamento que varia de modo proporcional à sua capacitância. Utilizando a equação 12.2 para realizar uma avaliação das capacitâncias a partir dos instantes iniciais e finais das etapas de descarregamento para cada ciclo monitorado, as curvas que descrevem a evolução desta variável para todos os supercapacitores da base de dados foram obtidas e podem ser consultadas na Figura 11.

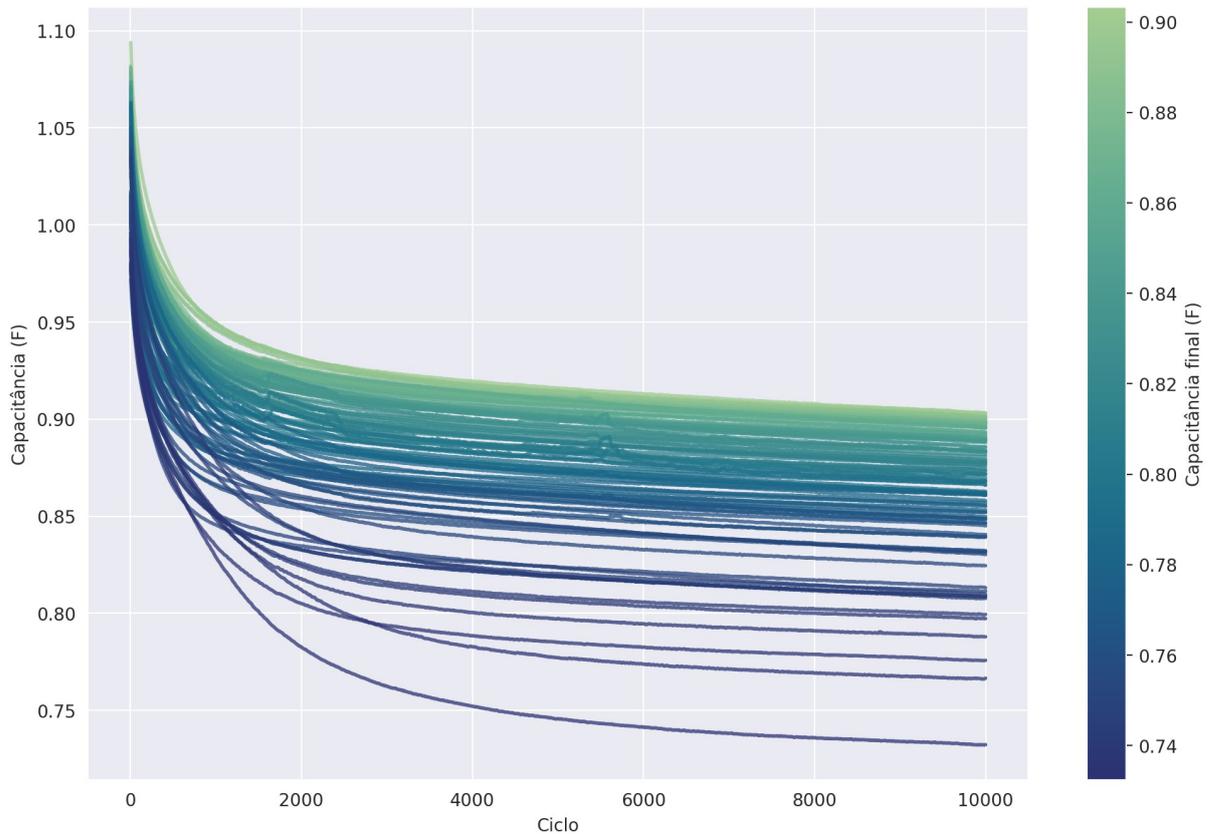
Figura 10 - Variação das curvas de capacidade para as etapas de carga e descarga ao longo da vida útil de um supercapacitor da base de dados



Fonte: Elaborado pelo autor.

Observa-se que estas curvas apresentam um comportamento claramente não-linear, caracterizado por uma degradação da capacitância mais aguda durante os ciclos iniciais que tende a desacelerar ao longo das sequências de carregamentos e descarregamentos. Este fenômeno também pode ser indiretamente percebido por meio da análise dos tempos dos ciclos nas Figuras 9 e 10. Além disso, também nota-se uma considerável variabilidade em termos da capacitância final atingida no ciclo de número 10.000. Tendo como ponto de partida os desafios exibidos por estes dados e buscando a obtenção de previsões competentes e flexíveis para múltiplas arquiteturas de redes neurais a partir de uma janela de dados limitada, optou-se por utilizar a estratégia de pré-processamento proposta por Wang *et al.* (2022), que será descrita e justificada com detalhes na seção seguinte.

Figura 11 – Evolução das capacitâncias ao longo do tempo



Fonte: Elaborado pelo autor

3.2 Pré-Processamento dos Dados

Conforme mencionado na seção 2.3, múltiplas abordagens distintas foram propostas na literatura para a modelagem da vida útil remanescente de supercapacitores, cada uma com suas vantagens e desvantagens. Neste trabalho, buscou-se desenvolver uma modelagem flexível, que permitisse a avaliação da RUL em dispositivos sem um histórico de dados nem em um momento de vida útil específico, dependendo apenas de uma coleta de dados realizada no momento do prognóstico. Uma consulta à literatura demonstrou que Wang *et al.* (2022) desenvolveram exatamente esta proposta para a base de dados em análise. Deste modo, havendo a comprovação de resultados positivos a partir do pré-processamento proposto pelos autores, optou-se por utilizá-la neste trabalho.

Sabendo que os dados foram coletados com uma taxa de amostragem constante, fica evidente que a quantidade de pontos de informação para cada ciclo apresenta um valor decrescente ao longo da sua vida útil. Além disso, dados dos

grupos 1 e 2 possuem uma taxa de amostragem distinta daquela dos grupos 3 e 4. Apesar de haver modelos baseados em redes neurais recorrentes capazes de lidar com sequências de tamanhos distintos, arquiteturas como, por exemplo, a convolucional e a *feedforward* assumem entradas de tamanho fixo. Assim, é possível argumentar que a utilização de dados de tamanhos variáveis referentes a cada ciclo acaba tornando o desenvolvimento dos modelos uma tarefa potencialmente mais complexa ao mesmo tempo que não garante necessariamente melhores resultados e limita as possibilidades em termos de arquiteturas a serem exploradas.

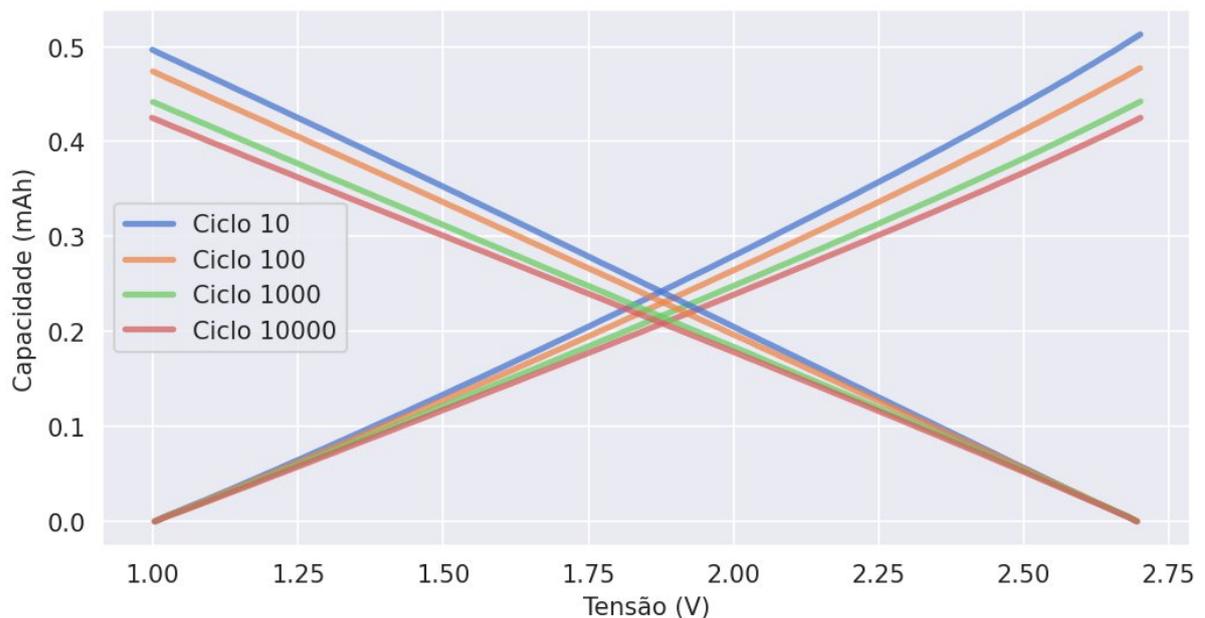
Considerando também a existência da relação apresentada entre a degradação das capacidades de carga e descarga com a degradação da capacitância ao longo dos ciclos, torna-se natural compreender o motivo pelo qual os autores a utilizaram como entrada para o modelo. Tendo conhecimento sobre a variável de interesse a ser aplicada e a dificuldade encontrada com relação ao comprimento destas séries ao longo dos ciclos, os autores propuseram uma estratégia baseada em uma interpolação dos dados que solucionou este impasse, que será descrita no parágrafo a seguir.

Uma vez que os limites de tensão máxima e mínima são fixos para todas as etapas de carregamento e descarregamento em 2,7 V e 1 V, respectivamente, os dados de capacidade podem ser visualizados com extremos fixos num gráfico do tipo capacidade versus tensão, ao contrário do gráfico capacidade versus tempo previamente analisado. A Figura 12 ilustra este argumento, apresentando uma visualização análoga à Figura 10, porém agora referindo as capacidades ao eixo das tensões. A partir deste gráfico, basta selecionar a quantidade de pontos desejada para cada etapa de carregamento e descarregamento e obtê-las por meio de uma simples interpolação. Neste trabalho, considerando o perfil predominantemente linear destas curvas, optou-se por utilizar um total de 16 pontos para cada curva de carga e descarga em contraste aos 34 pontos por curva aplicados por Wang *et al* (2022), visando a redução do tamanho da base de dados processados.

Após a explicação das etapas fundamentais associadas ao pré-processamento das entradas, um processo semelhante será realizado agora para as saídas. Com relação à extensão dos dados em termos do número de ciclos, uma segunda consulta às curvas das capacitâncias na Figura 11 evidencia que esta quantidade de dados é insuficiente para atingir o critério usual de 80% da capacitância nominal para a grande

maioria dos supercapacitores da base. Caso este critério fosse selecionado, um número mínimo de dados poderia ser utilizado em seu desenvolvimento, uma vez que a maioria dos supercapacitores estariam dentro de sua vida útil no último ciclo da base, o de índice 10.000, impossibilitando a determinação do ciclo em que atingiu o critério de vida útil. Conseqüentemente, foi necessário definir um critério mais rigoroso, porém incomum, com o propósito de maximizar os dados úteis para o modelo além de obter uma distribuição mais ampla para as vidas úteis que possibilitou a verificação do funcionamento dos modelos em situações variadas.

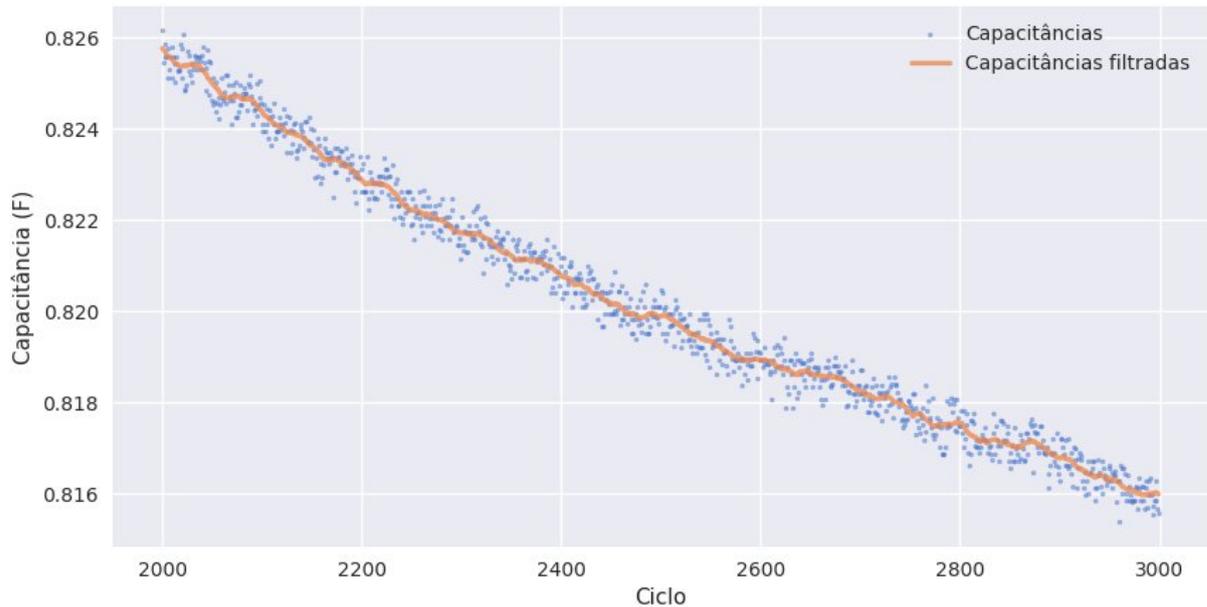
Figura 12 – Variação das curvas de capacidade para as etapas de carga e descarga ao longo da vida útil de um supercapacitor da base de dados referidas ao eixo da tensão



Fonte: Elaborado pelo autor.

Antes de concluir a explicação sobre como as saídas do modelo foram obtidas, é importante ressaltar o fato de que, especificamente no pré-processamento desenvolvido neste trabalho, as curvas de capacitância foram suavizadas por meio do emprego do filtro de Savitzky-Golay (SAVITZKY; GOLAY, 1964), que consiste na aplicação de uma regressão polinomial em torno de uma janela para cada ponto de uma série. As capacitâncias nesta análise foram processadas com uma janela de 25 ciclos e uma regressão de grau 1. A Figura 13 apresenta um exemplo deste processo obtido para um segmento da capacitância após a aplicação deste filtro.

Figura 13 - Exemplo para a curva da capacitância após a aplicação do filtro de Savitzky-Golay



Fonte: Elaborado pelo autor.

Retornando para a determinação das saídas do modelo, ressalta-se o fato de que a estratégia selecionada para selecionar o critério de fim da vida útil dos supercapacitores foi inspirado na proposta apresentada por Ren *et al.* (2020), que visou maximizar a quantidade de dados úteis para treinamento e avaliação além de sua distribuição. A partir das curvas de capacitância filtradas, foi identificado o supercapacitor que apresentava maior vida útil no final dos 10.000 ciclos e o valor final de sua capacitância foi utilizada como o critério de fim da vida útil do modelo. Especificamente, este valor para a análise aqui desenvolvida foi considerado como igual a 0.9033 F, que é equivalente ao supercapacitor atingir 90,33% da sua capacitância nominal.

A partir da delimitação desta fronteira, o ciclo do fim da vida útil para todos os supercapacitores da base foi determinado como aquele no qual a curva de capacitância cruza com a fronteira estabelecida pela primeira vez. Para cada capacitor, os pontos referentes aos ciclos seguintes foram descartados, considerando o fato de que já haviam atingido o final de sua vida útil e que isso poderia ser verificado, em um cenário prático, diretamente por meio da medição de sua capacitância, uma vez que foi constatado na Figura 9 que as capacitâncias basicamente apresentam um comportamento apenas decrescente ao longo de seus ciclos. Utilizando então apenas os dados úteis ao modelo, foram obtidas as suas variáveis de saída, que são as vidas

úteis remanescentes, e consistem na distância entre o início de sua vida útil, o ciclo 0, e o ciclo final calculado. Este processo foi representado matematicamente pela equação 1, apresentada na seção 2.1.3.

Seguindo a proposta de pré-processamento sugerida por Wang *et al.* (2022), as amostras para treinamento e previsão foram compostas a partir de uma janela de cinco ciclos consecutivos. Esta proposta é interessante numa perspectiva prática, pois conforme comentam os autores, dados para uma janela deste tamanho podem ser obtidos dentro de um intervalo de 15 min. No caso deste trabalho, foram coletadas janelas de 5 ciclos com um passo de janela deslizante igual a 1. Isto significa, por exemplo, que a primeira janela de dados para um supercapacitor inicia no ciclo 0 e acaba no ciclo 4. A próxima janela, por sua vez, inicia no ciclo 1 e acaba no ciclo 5. As janelas restantes são obtidas seguindo o mesmo raciocínio. A vida útil remanescente associadas a cada uma das amostras é, naturalmente, a associada ao último ciclo da janela. Seguindo este processo para toda sua vida útil e para todos os supercapacitores, são obtidas as amostras da base de dados.

Com o propósito de utilizar os dados da base para desenvolver e avaliar os modelos propostos, os supercapacitores foram separados seguindo uma convencional divisão em grupos de treino, validação e teste. Cada um destes cumpre um papel específico durante a elaboração dos modelos. O conjunto de treino fornece os dados que serão utilizados como referência para o ajuste de seus parâmetros. O conjunto de validação serve para avaliar o desempenho do modelo enquanto aspectos como hiperparâmetros e arquiteturas são ajustadas. Por fim, o conjunto de teste serve para analisar as saídas do modelo a partir de dados independentes que não participaram do seu desenvolvimento. Um total de 12 supercapacitores de treino e 12 supercapacitores de validação foram selecionados manualmente para compor estes conjuntos, onde buscou-se uma representação equilibrada e próxima da base de dados completa, conforme indica a Figura 14. Ao comentar sobre a divisão por supercapacitores neste parágrafo, subentende-se que a divisão de fato ocorre para as amostras associadas aos mesmos.

Finalmente, o último tratamento executado nos dados antes de serem treinados foi a normalização MinMax das janelas de capacidade. Este algoritmo foi aplicado ao conjunto de treino e os seus valores máximo e mínimo foram então utilizados para a aplicação do algoritmo nos conjuntos de validação e teste. Este processo, que tem

como característica principal a conformação dos dados entre uma escala de zero a um, pode ser descrito pela seguinte equação:

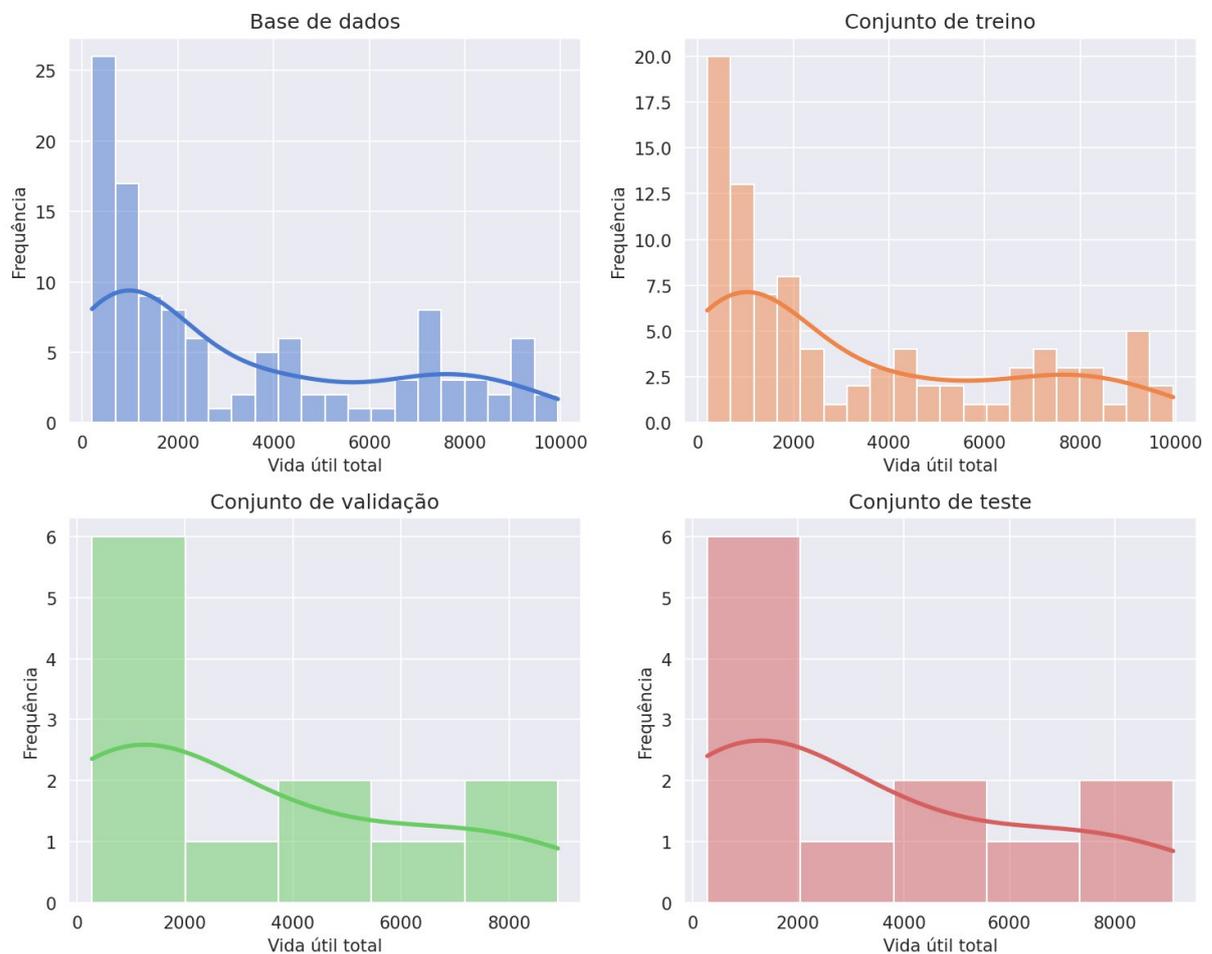
$$x' = \frac{x - \min(X)}{\max(X) - \min(X)}, \quad (15)$$

onde:

$\min(X)$ representa o valor mínimo observado em X;

$\max(X)$ representa o valor máximo observado em X.

Figura 14 – Distribuição das vidas úteis para a base de dados e conjuntos de treino, teste e validação



Fonte: Elaborado pelo autor.

3.3 Implementação dos Modelos

Com o propósito de investigar o impacto da seleção de arquiteturas e formatações para os dados de entrada, foram propostos três modelos básicos: uma

rede *feedforward*, uma rede LSTM e uma rede convolucional. Buscando levantar quantificações sobre as incertezas associadas às suas previsões por meio da técnica do *dropout* Monte Carlo, todos os modelos apresentaram um conjunto de camadas *feedforward* intercaladas com camadas de *dropout*. Estes foram construídos, treinados e avaliados por meio da linguagem de programação Python junto à biblioteca PyTorch. Adicionalmente, pontua-se que, devido ao custo computacional considerável para treinar estes modelos no *hardware* do autor (GPU NVIDIA GTX 1650 4GB, CPU Intel Core i5 e 16GB de RAM), os hiperparâmetros propostos para os três foram selecionados a partir de um ajuste manual.

Tratando especificamente da rede *feedforward*, comenta-se sobre esta que sua arquitetura é a mesma arquitetura de saída para os modelos LSTM e convolucional desenvolvidos neste trabalho. Além disso, seus dados de entrada também foram simplificados para conter apenas os valores finais das capacidades de carga e descarga para cada um dos ciclos de sua janela, resultando numa entrada vetorial para o modelo com comprimento igual a 10. Deste modo, destaca-se que este modelo foi proposto com o intuito de servir como uma referência de desempenho para os outros modelos mais complexos, além de evidentemente investigar uma estratégia substancialmente mais leve em termos computacionais. A Tabela 3 descreve a topologia desta rede. Os dados da camada "Linear" descrevem a dimensão de entrada, dimensão de saída e função de ativação aplicada na camada, respectivamente. Já o único dado referente à camada *dropout* define a sua probabilidade de ativação.

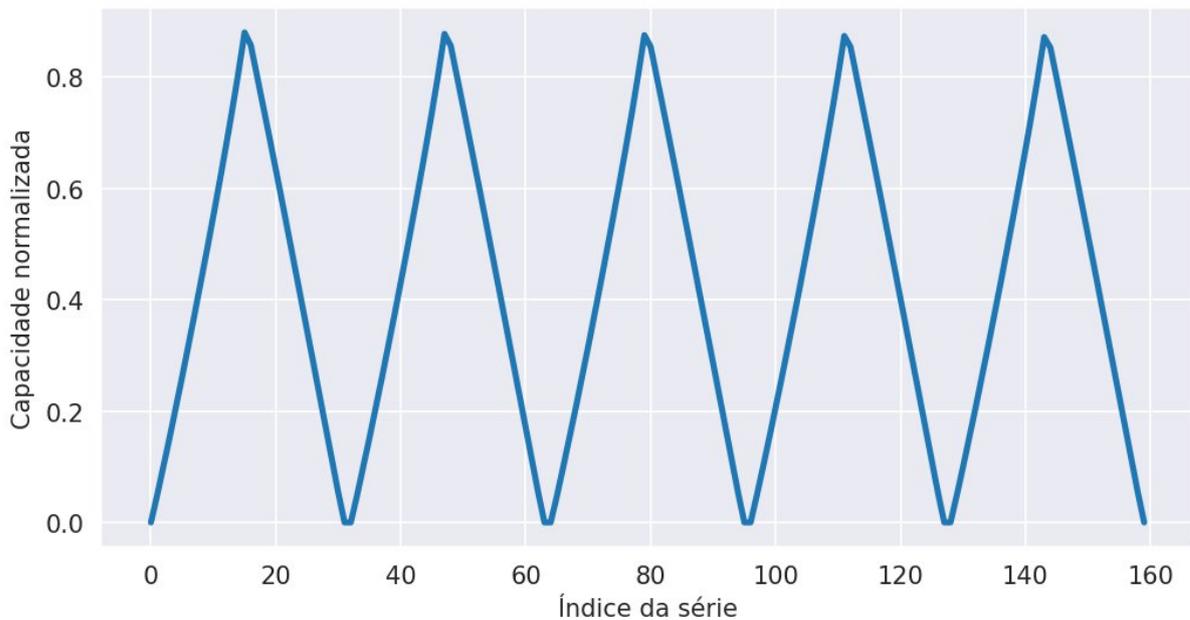
Tabela 3 - Descrição da arquitetura para a rede *feedforward*

Camada	Quantidade de parâmetros
Linear (10, 64, ReLu)	704
Dropout (0.1)	-
Linear (64, 64, ReLu)	4.160
Dropout (0.1)	-
Linear (64, 32, ReLu)	2.080
Dropout (0.1)	-
Linear (32, 1, ReLu)	33

Fonte: Elaborado pelo autor

Com relação à rede LSTM, ressalta-se o fato de que esta topologia foi uma das selecionadas para investigação devido à sua excelente capacidade de lidar com dados de natureza sequencial. Deste modo, as entradas utilizadas para este modelo essencialmente utilizaram as janelas obtidas diretamente a partir do pré-processamento dos dados, que consistiram numa representação unidimensional contendo sequências ascendentes para a capacidade de carga intercaladas com sequências descendentes para a capacidade de descarga de cada ciclo, conforme pode ser visto na Figura 15. A arquitetura desta rede está descrita na Tabela 4. Note-se que o dado associado à camada LSTM refere-se ao seu número de unidades ocultas.

Figura 15 – Exemplo de entrada para a rede LSTM



Fonte: Elaborado pelo autor

Tabela 4 - Descrição da arquitetura para a rede LSTM

Camada	Quantidade de parâmetros
LSTM (64)	57.856
Dropout (0.1)	-
Linear (64, 64, ReLu)	4.160
Dropout (0.1)	-
Linear (64, 64, ReLu)	4.160
Dropout (0.1)	-

Camada	Quantidade de parâmetros
Linear (64, 32, ReLu)	2.080
Dropout (0.1)	-
Linear (32, 1, ReLu)	33

Fonte: Elaborado pelo autor

A rede convolucional, por sua vez, está descrita na Tabela 5. Aqui pontua-se que os dados da camada Conv2d representam a dimensão de entrada, a dimensão de saída e o formato do filtro aplicado, respectivamente. Já a camada MaxPool2d, contém dados para o tamanho de seu filtro e de seu passo, respectivamente. Uma vez que esta topologia de rede é especializada em analisar dados matriciais, cada uma das sequências de capacidade de carregamento e descarregamento foram empilhadas para formar uma matriz de formato 10x16, conforme ilustrado pela Figura 16.

Tabela 5 - Descrição da arquitetura para a rede convolucional

Camada	Quantidade de parâmetros
Conv2d (1, 16, 3x3)	160
MaxPool2d (2x2, 2)	-
Conv2d (16, 32, 3x3)	4.640
MaxPool2d (3x3, 2)	-
Conv2d (32, 64, 3x3)	18.496
GlobalAvgPool	-
Linear (64, 64, ReLu)	4.160
Dropout (0.1)	-
Linear (64, 64, ReLu)	4.160
Dropout (0.1)	-
Linear (64, 32, ReLu)	2.080
Dropout (0.1)	-
Linear (32, 1, ReLu)	33

Fonte: Elaborado pelo autor

A função custo aplicada para o treinamento dos três modelos propostos foi o erro médio quadrático (MSE – do inglês *mean squared error*). Sua principal característica é uma penalização que cresce em severidade na medida em que as

distâncias entre os dados esperados e os dados previstos aumentam, conforme evidenciado por sua fórmula:

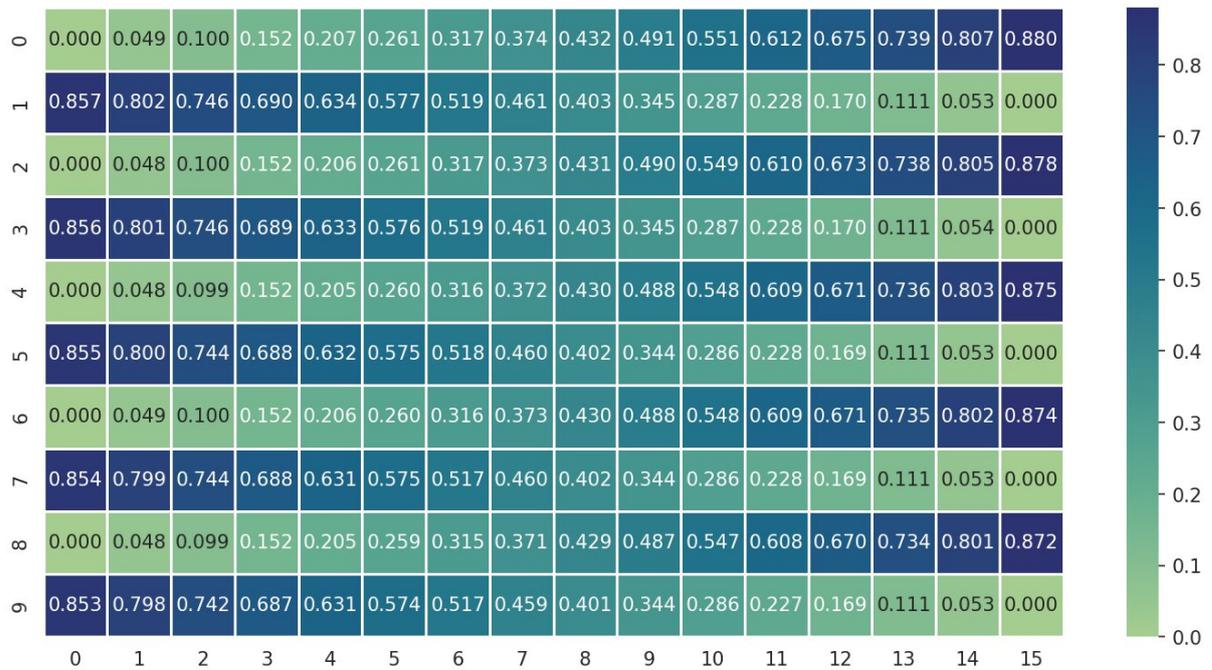
$$MSE = \frac{1}{n} \sum_{i=0}^n (y_i - \hat{y}_i)^2, \quad (16)$$

onde:

y_i representa a i -ésima saída esperada para o modelo;

\hat{y}_i representa a i -ésima saída prevista pelo modelo.

Figura 16 – Exemplo de entrada para a rede convolucional



Fonte: Elaborado pelo autor

3.4 Resultados e discussões

Devido à quantidade de modelos desenvolvidos e a necessidade de discutir individualmente e comparativamente seus desempenhos, esta seção terá início com a apresentação e análise das características particulares observadas em cada um deles que então será concluída com uma análise comparativa. Como observação geral sobre os resultados apresentados, destaca-se que os três modelos utilizaram o algoritmo Adam para sua otimização com taxa de aprendizado igual a $5 \cdot 10^{-4}$. As

perdas de treinamento e validação foram monitoradas ao longo das épocas de treinamento e os pesos e vieses associados às redes foram gravados para as épocas em que foi observado um novo mínimo na função custo para o conjunto de validação. Esta estratégia foi utilizada para seleção das redes de melhor desempenho no caso das arquiteturas LSTM e convolucional.

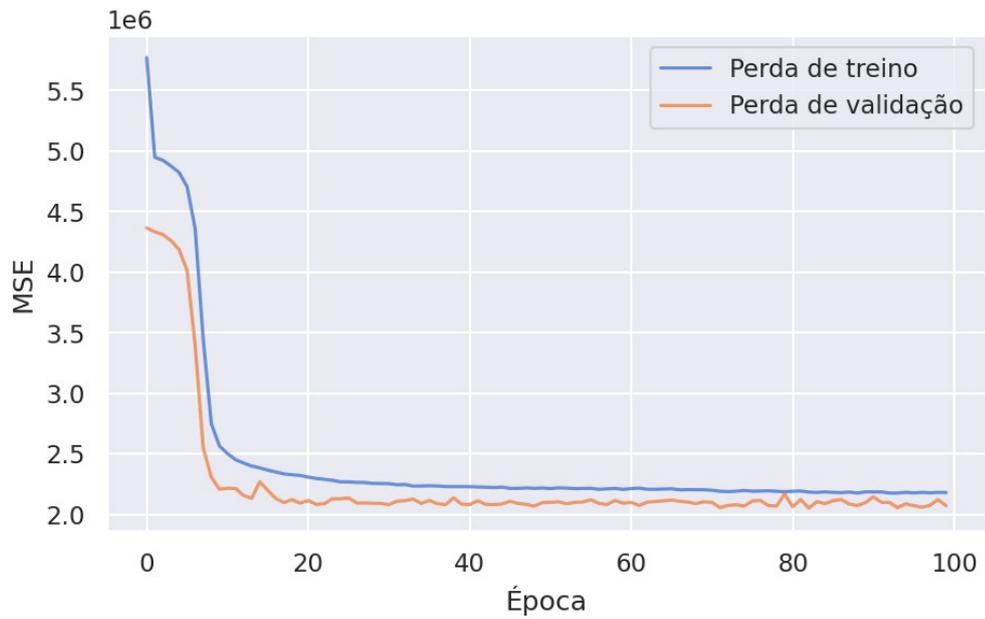
Adicionalmente, também observa-se que, para cada uma das três arquiteturas investigadas, os resultados integrais das previsões de todas as janelas coletadas para os 12 supercapacitores do conjunto de teste estão apresentadas por meio de gráficos que relacionam a vida útil remanescente esperada, calculada a partir da diferença entre o ciclo atual da amostra e o ciclo no qual o seu supercapacitor associado atingiu o critério de fim de vida útil, com a vida útil remanescente prevista pelos modelos, obtida a partir da média de 250 previsões repetidas para cada amostra utilizando o *dropout* Monte Carlo, que também contemplou uma banda representando um intervalo de confiança de 95% para cada uma destas previsões. A vida útil remanescente esperada está ilustrada nestes gráficos por uma reta azul, enquanto que a vida útil remanescente prevista para cada janela é indicada por pontos laranjas associados a uma banda vertical que indica o intervalo de confiança. Dentro de cada um destes gráficos, ainda é possível visualizar um subgráfico que contém dados dos resíduos associados a cada uma das previsões médias.

3.4.1 Rede Feedforward

A Figura 17 apresenta o comportamento das perdas de treino e validação da rede *feedforward* ao longo de seu treinamento. Observa-se que os principais avanços em termos de redução das perdas ocorreram, aproximadamente, durante as dez primeiras épocas. Após esta etapa, as perdas dos dois conjuntos praticamente se aproximam de valores constantes e próximos entre si, indicando que o modelo atingiu um nível de ajuste com boa capacidade de generalização quando comparado à base de dados de validação. A Figura 18, por sua vez, apresenta os resultados deste modelo a partir da aplicação do *dropout* Monte Carlo com um total de 250 previsões repetidas por entrada para a base de dados de teste em um formato gráfico, conforme explicado na seção anterior. Uma análise visual destes resultados permite concluir que o modelo apresentou bom desempenho em alguns supercapacitores do conjunto

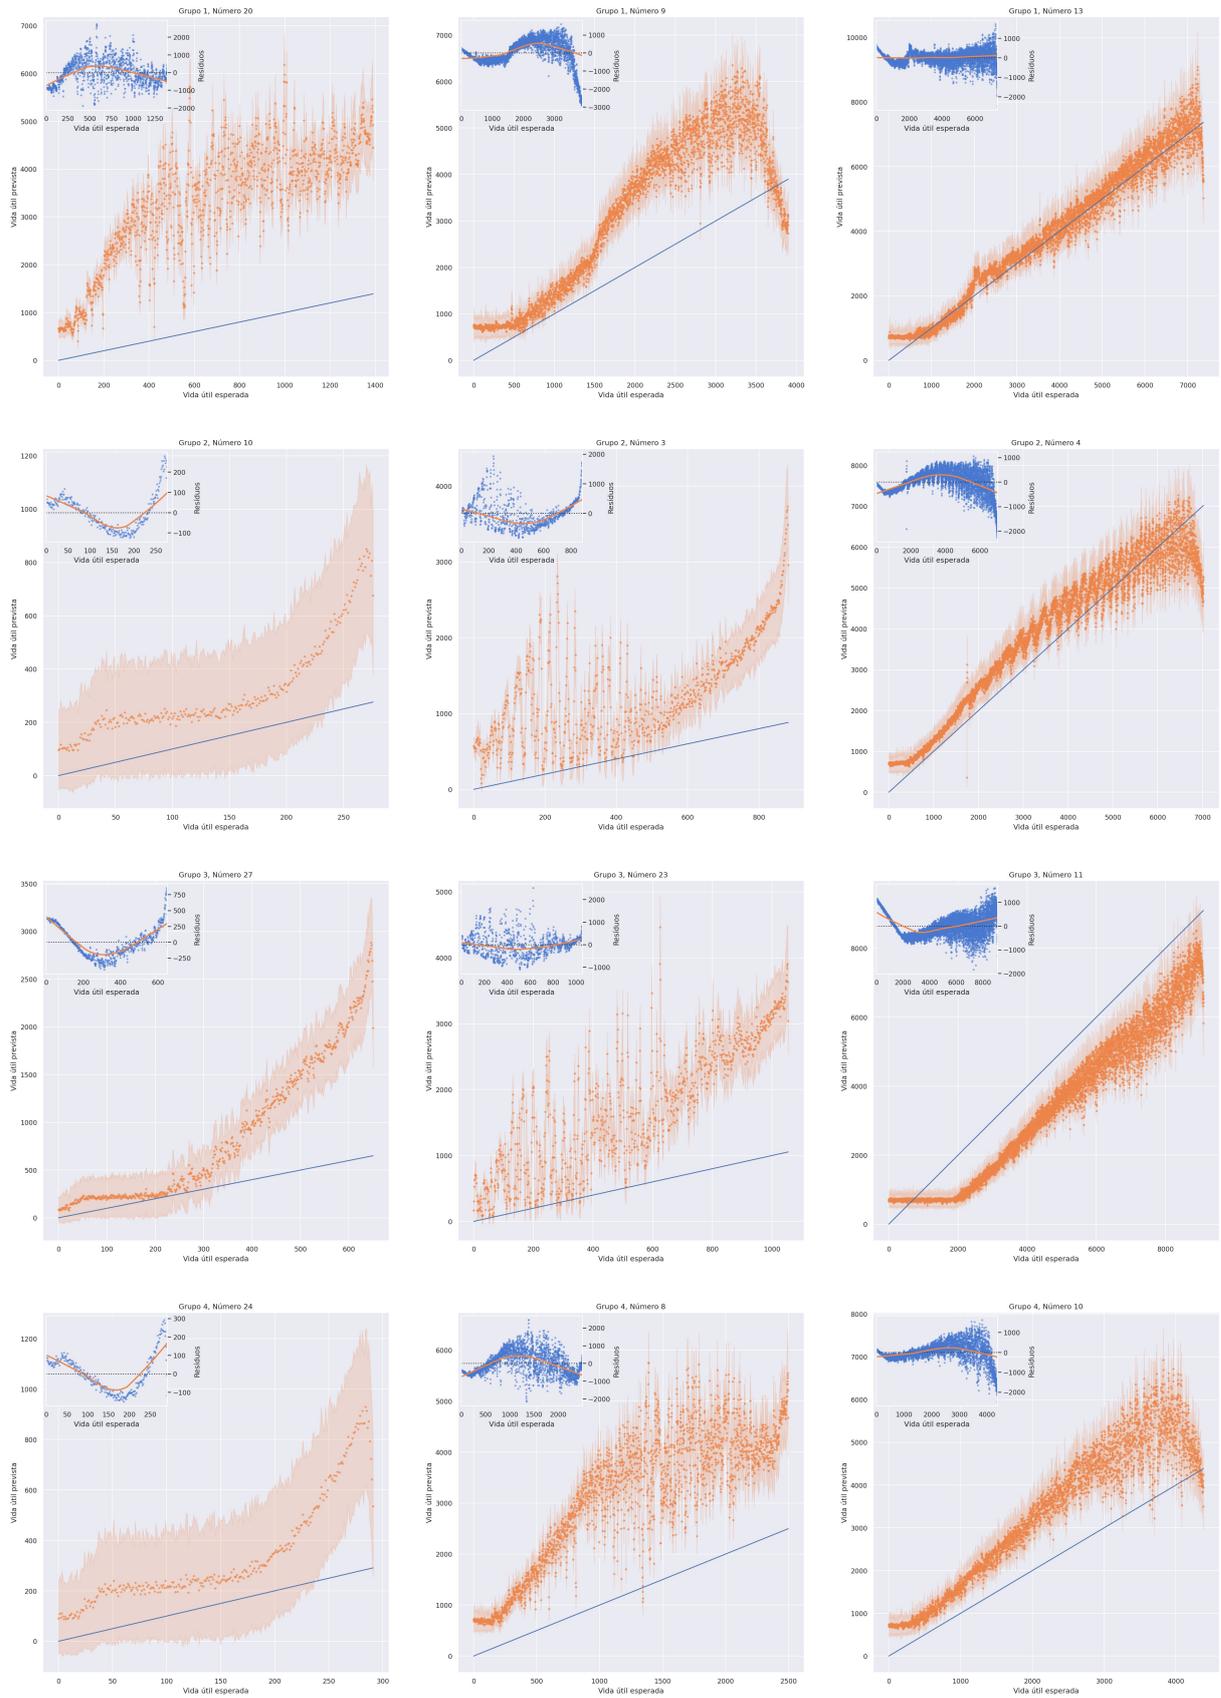
de teste, como o número 13 do grupo 1 e um perfil mais ruidoso e deslocado do valor esperado, como é o caso do número 4 do grupo 10. Constata-se também, de modo geral, previsões mais ruidosas e com maior erro durante os ciclos iniciais dos dispositivos.

Figura 17 - Evolução das perdas da rede *feedforward* ao longo do treinamento



Fonte: Elaborado pelo autor.

Figura 18 - Resultados incluindo intervalo de confiança de 95% e resíduos obtidos a partir da rede *feedforward* para os supercapacitores do conjunto de teste

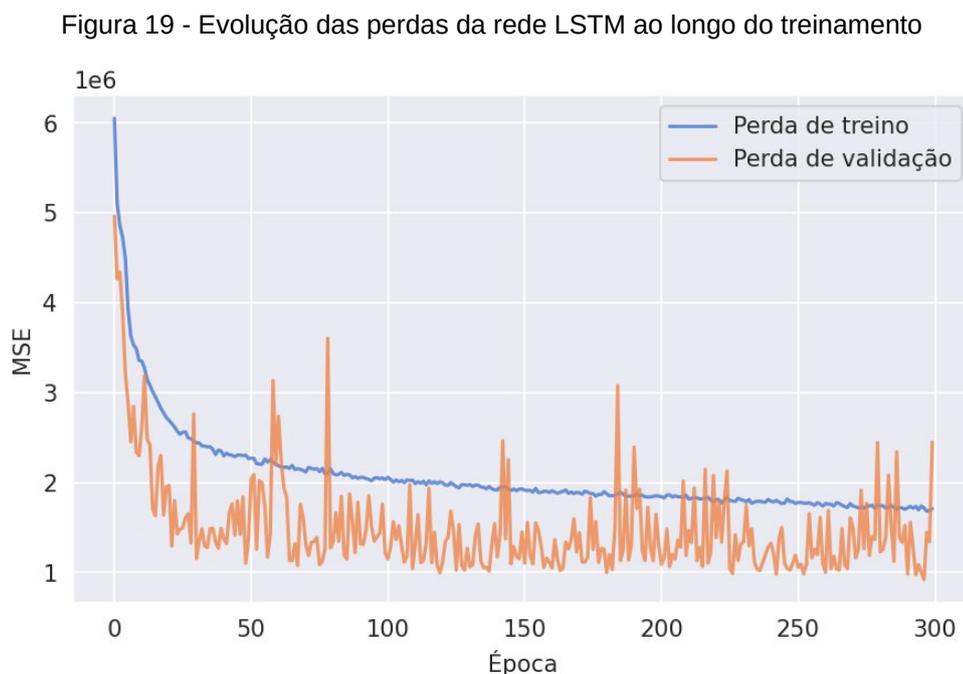


Fonte: Elaborado pelo autor.

3.4.2 Rede LSTM

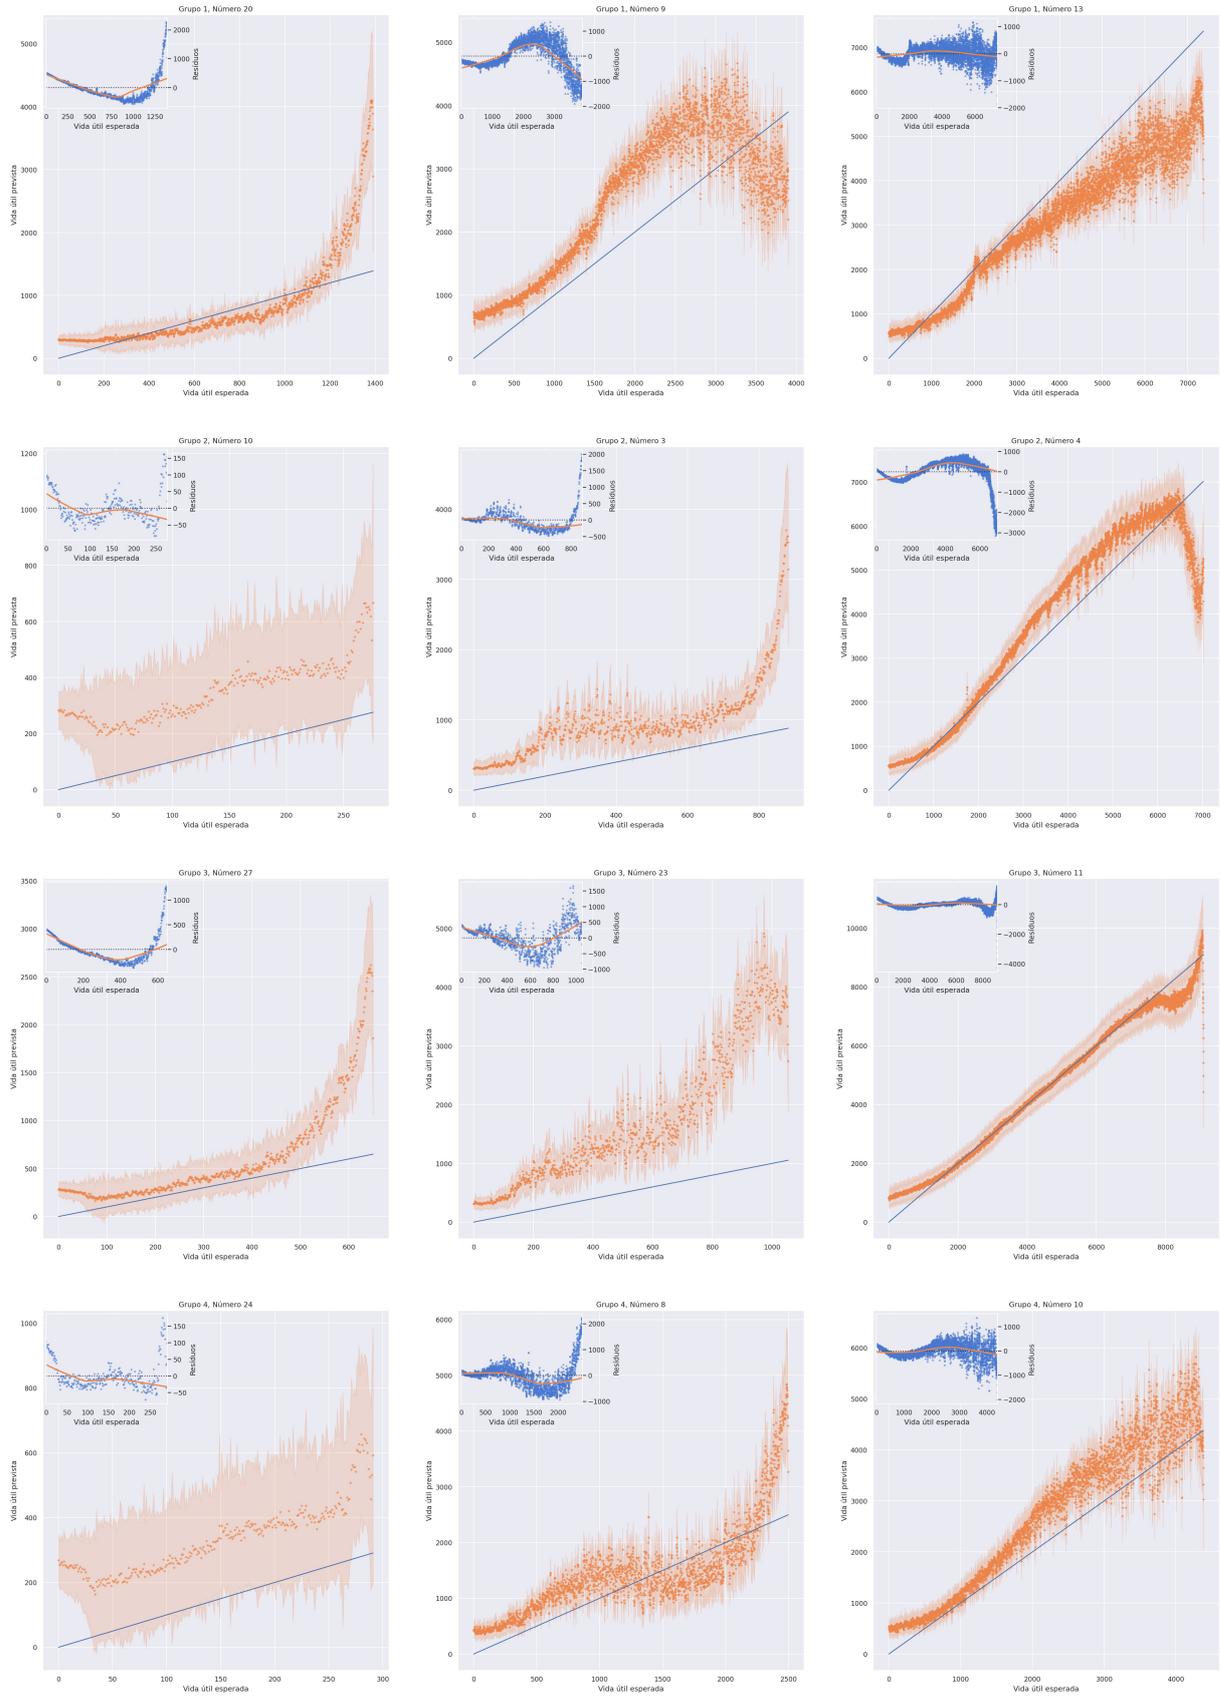
A Figura 19 apresenta a evolução das perdas para a rede LSTM ao longo de um total de 300 épocas. Estas curvas exibem duas características notáveis. Em primeiro lugar, é possível observar que as perdas de treino continuam demonstrando o potencial de maior ajuste ao conjunto de dados de treinamento, como pode ser evidenciado pelo seu perfil decrescente na época de número 300. Entretanto, também é percebido que a perda de validação é bastante ruidosa ao longo de todo o processo e, na maioria das vezes, menor que a perda de treino.

Com relação aos fenômenos observados durante o treinamento, pode-se supor que uma possível causa para este fenômeno seja a quantidade limitada de supercapacitores no conjunto de validação frente à sua distribuição de vidas úteis desequilibrada. Uma análise da Figura 20, que apresenta os resultados obtidos da rede para a época de treinamento de número 296, demonstra um excelente ajuste geral para a maioria das curvas propostas com baixa oscilação entre previsões de entradas consecutivas. Entretanto, também observa-se, em alguns momentos, desvios notáveis para os primeiros ciclos de vida útil de alguns supercapacitores.



Fonte: Elaborado pelo autor.

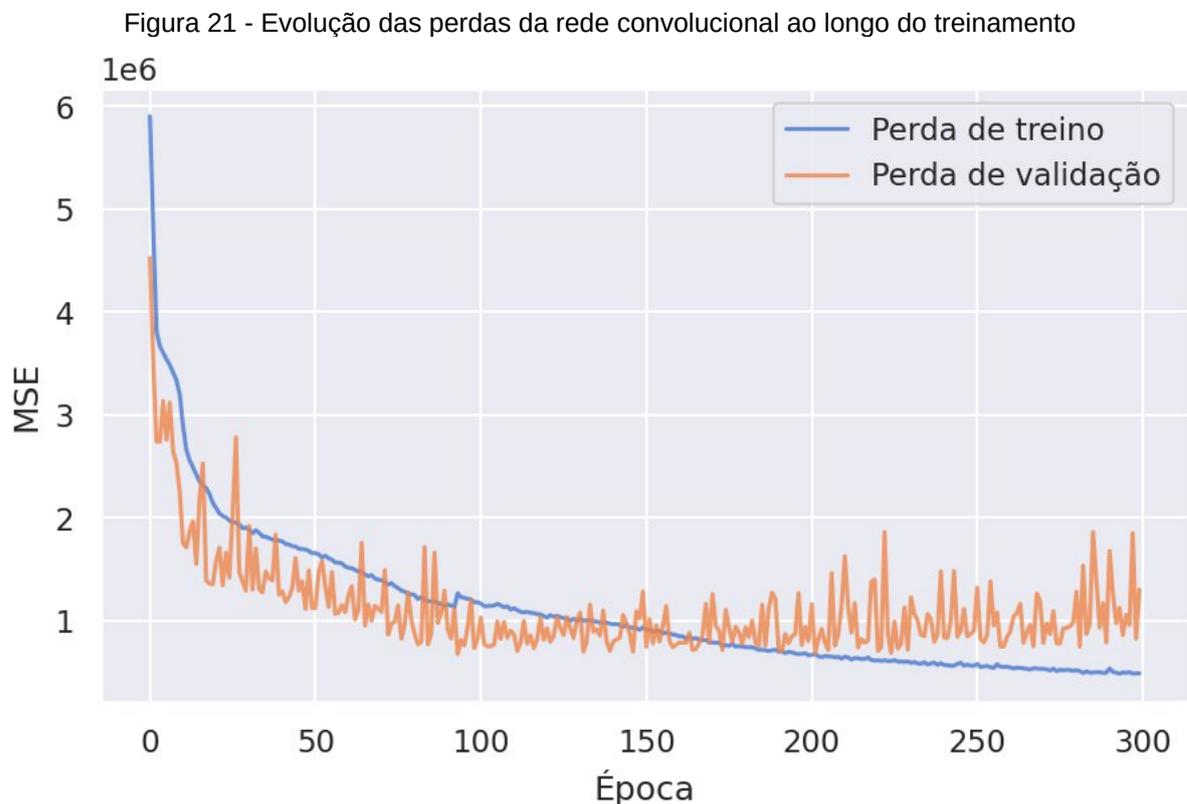
Figura 20 – Resultados incluindo intervalo de confiança de 95% e resíduos obtidos a partir da rede LSTM para os supercapacitores do conjunto de teste



Fonte: Elaborado pelo autor.

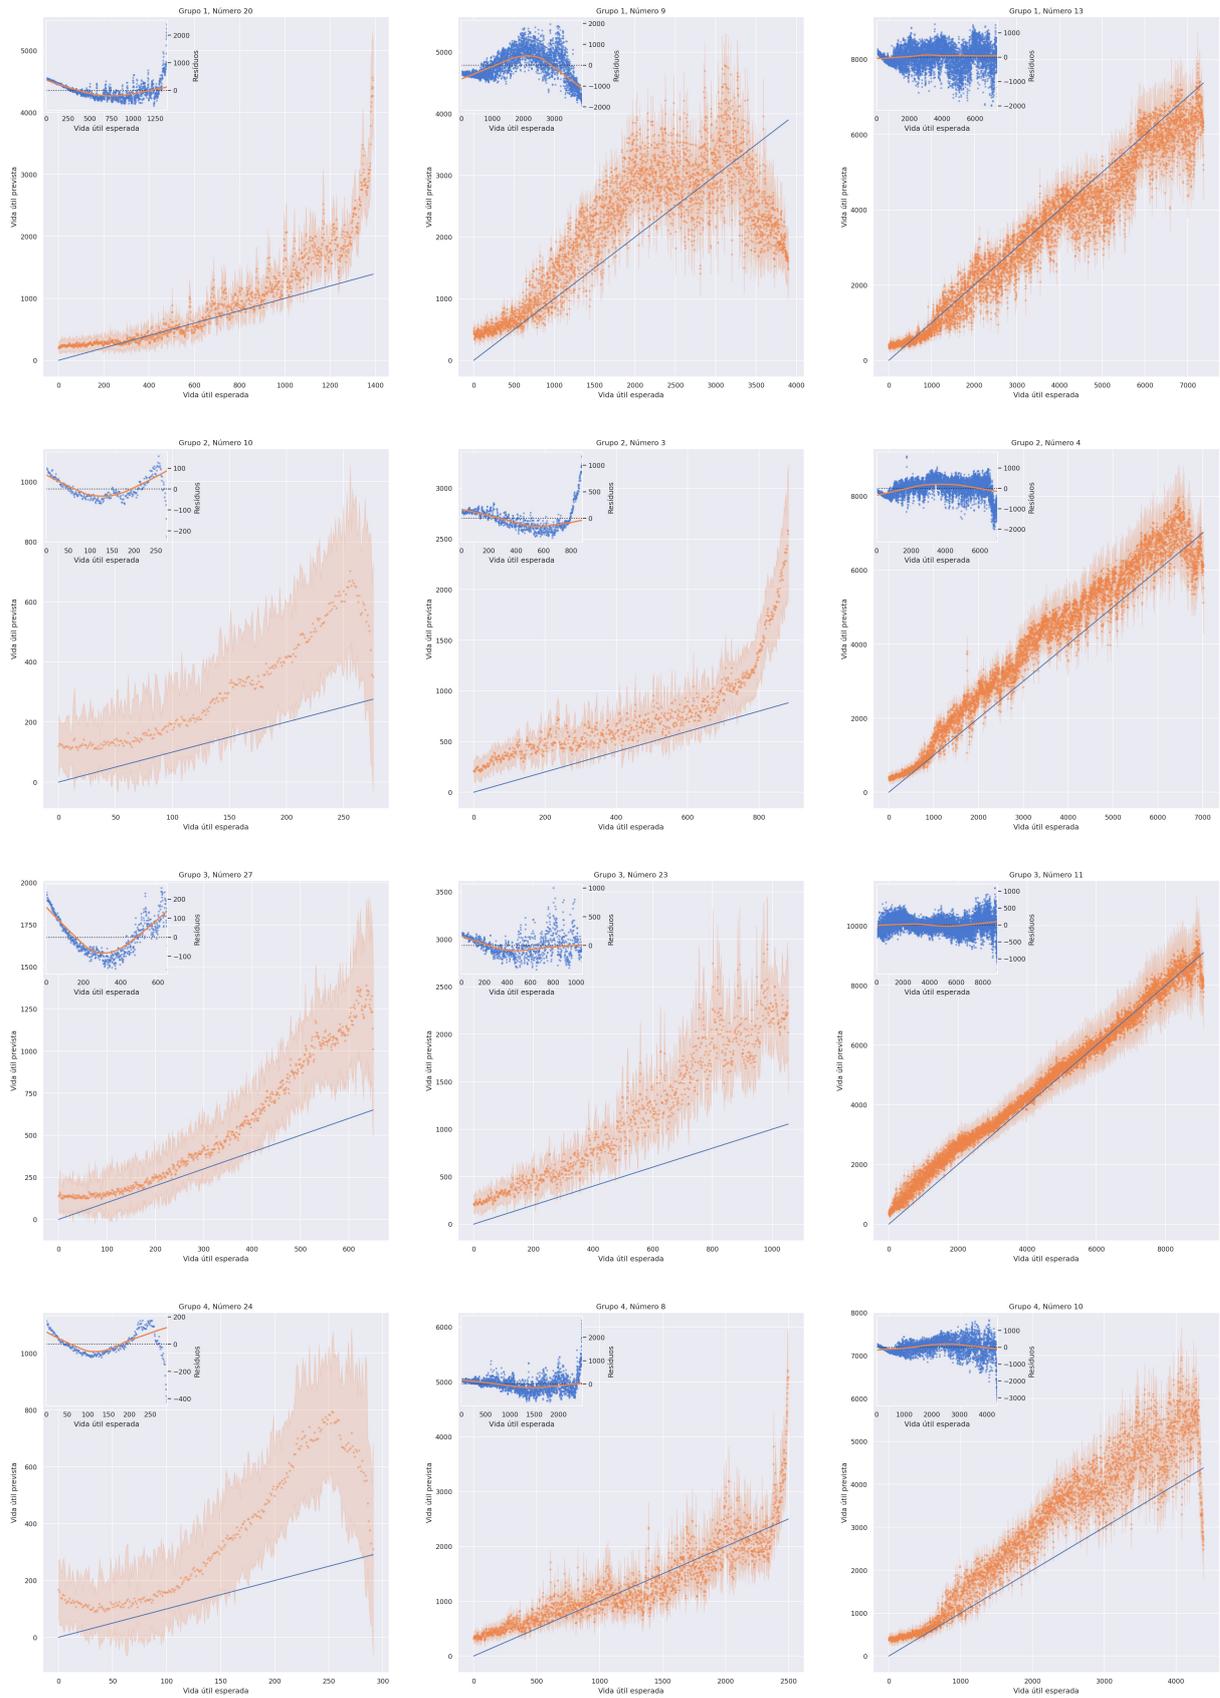
3.4.3 Rede Convolutacional

A Figura 21 apresenta, por sua vez, os resultados para as perdas de treino e validação obtidas para para a rede convolutacional que foi treinada por um total de 300 épocas. Esta curva de validação também apresenta uma oscilação perceptível, porém menos intensa do que a observada na rede LSTM. Também percebe-se que esta segue a curva de perdas de treino de forma mais próxima durante as primeiras 150 épocas. As etapas seguintes do treinamento evidenciam uma divergência entre as duas perdas, indicando um sobreajuste dos parâmetros do modelo. Deste modo, foram selecionados os pesos referentes à época de número 93 para a construção dos gráficos da Figura 22. Esta rede apresenta resultados bem ajustados para a maioria dos supercapacitores de teste. Todavia, constata-se em alguns casos a presença de uma dispersão notável entre previsões próximas como no supercapacitor 13 do grupo 1. Destaca-se a observação de que nestes momentos os intervalos de confiança tendem a se tornar maiores, evidenciando a maior incerteza do modelo a avaliação destas entradas.



Fonte: Elaborado pelo autor.

Figura 22 - Resultados incluindo intervalo de confiança de 95% e resíduos obtidos a partir da rede convolucional para os supercapacitores do conjunto de teste



Fonte: Elaborado pelo autor.

3.4.4 Discussão Geral

Com o intuito de avaliar e comparar os modelos de forma quantitativa, foram selecionadas as métricas raízes do erro médio quadrático (RMSE – do inglês *root mean square root error*), erro médio absoluto (MAE – do inglês *mean absolute error*) e erro Percentual Médio Absoluto Simétrico (sMAPE – do inglês *symmetrical mean absolute percentage error*). Nota-se que estas métricas foram computadas a partir da consideração de que o valor previsto pelo modelo equivale a uma média de 250 amostras para cada entrada analisada.

$$RMSE = \sqrt{MSE}, \quad (17)$$

$$MAE = \frac{1}{n} \sum_{i=0}^n |y_i - \hat{y}_i|, \quad (18)$$

$$sMAPE = \frac{100}{n} \sum_{i=0}^n \frac{|y_i - \hat{y}_i|}{|y_i| + |\hat{y}_i|}. \quad (19)$$

Tabela 6 - Métricas de desempenho para obtidas para os três modelos desenvolvidos

Modelo	MAE	RMSE	sMAPE
Rede <i>Feedforward</i>	963,47	1233,00	23,17
Rede LSTM	497,15	703,83	14,83
Rede Convolutacional	471,40	622,63	13,75

Fonte: Elaborado pelo autor

De modo geral, constata-se que os três modelos trouxeram consigo resultados favoráveis para o conjunto de teste, especialmente quando comparados com as modelagens propostas por Ren *et al.* (2020) e Wang *et al.* (2022), que apresentaram RMSEs iguais a 599 e 501, respectivamente. Nota-se que, apesar de utilizar arquitetura e entrada de natureza mais simples, a rede *feedforward* exibiu um treinamento estável e resultados que evidenciam uma coerência com a vida útil remanescente esperada para boa parte dos exemplos analisados. Entretanto, nota-

se que a inclusão dos dados intermediários referentes às capacidades de carga e descarga junto ao uso de topologias mais sofisticadas renderam resultados substancialmente melhores para as redes LSTM e convolucional, que demonstram resultados próximos entre si em termos das métricas de desempenho apresentadas.

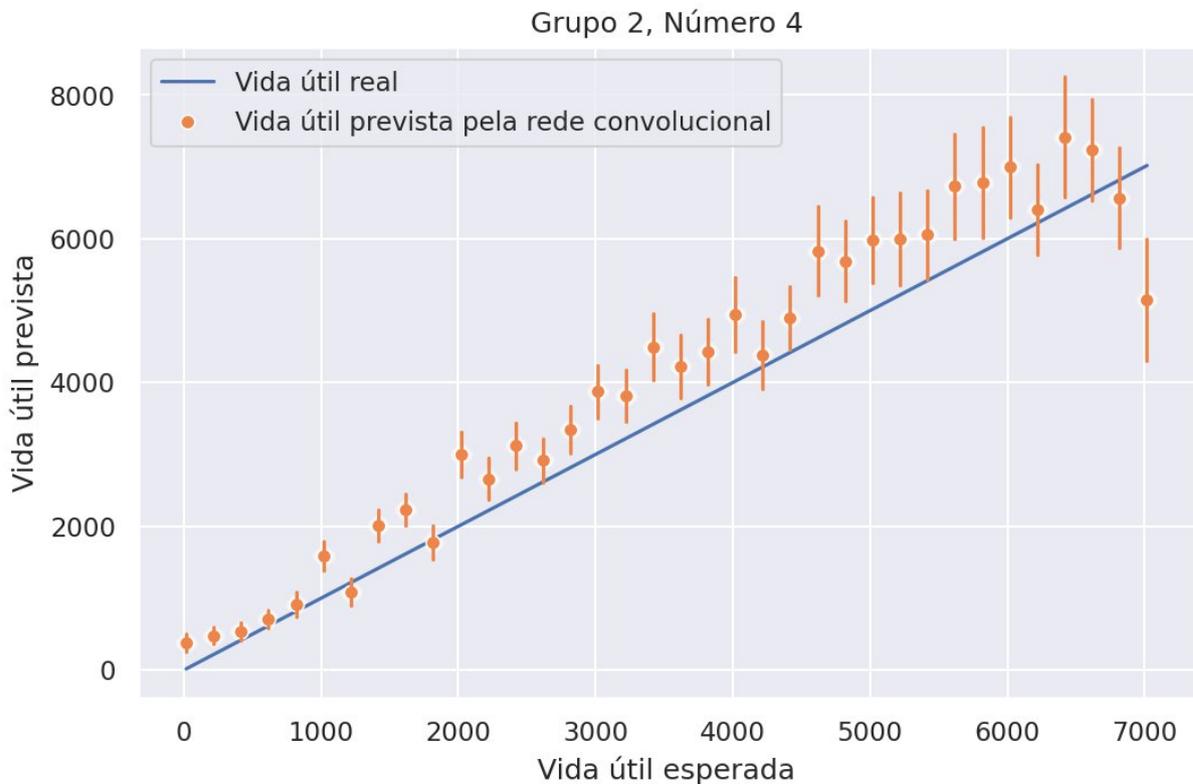
A análise dos gráficos indica que a estratégia proposta de utilização de janelas referentes aos cinco últimos ciclos do dispositivo como entrada foi eficiente para a estimação da RUL ao longo de toda sua vida útil. Para a maioria das amostras analisadas nos três modelos, as previsões médias delimitaram-se em valores próximos das métricas de desempenho obtidas com a exceção, para algumas combinações específicas de modelos e supercapacitores, de ciclos contidos na região de início de vida útil.

Neste caso, destaca-se o fato que a quantificação de incertezas torna-se uma ferramenta útil para averiguar a qualidade das previsões obtidas pelos modelos. Deste modo, convém apresentar a Figura 23, uma visualização mais detalhada para os intervalos de confiança obtidos a partir das distribuições extraídas por meio do *dropout* Monte Carlo para 250 previsões repetidas em um supercapacitor de teste. Observa-se que para o caso ilustrado, o intervalo de confiança aumenta na medida em que a vida útil prevista das amostras também aumenta. Assim, é possível concluir que nestas avaliações o modelo apresenta maior certeza sobre suas previsões na medida em que o dispositivo aproxima-se do final de sua vida útil, uma observação plausível, uma vez que as possibilidades de trajetórias distintas e variabilidade diminuem neste cenário. Os intervalos de confiança podem ser utilizados como parâmetro para determinar a confiabilidade das previsões apresentadas e tomar decisões com base no risco associado.

Apesar deste aspecto não haver sido explorado explicitamente neste trabalho, convém apresentar a Figura 24 como um potencial ponto de estudo para trabalhos futuros. Além das médias obtidas para as previsões repetidas por meio do *dropout* Monte Carlo, é possível obter uma perspectiva mais rica sobre as previsões a partir da análise do seu histograma associado. Observa-se que este pode ser utilizado, por exemplo, como referência para o ajuste de uma distribuição de probabilidade associada à previsão, viabilizando análises de natureza estatística.

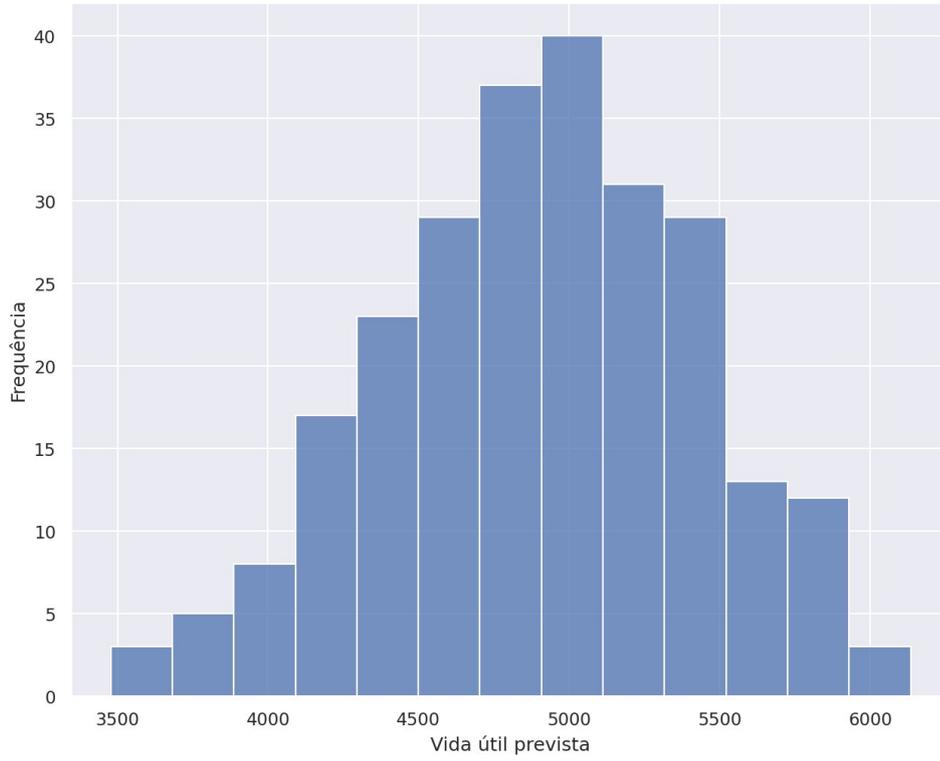
Por fim, é ainda importante observar que a presença de ruídos nas curvas de perda de validação da rede convolucional e, especialmente, da rede LSTM podem ser um indicativo de sobreajuste ou de dados pouco representativos do conjunto de validação, potencialmente uma consequência do caráter desbalanceado da base de dados analisada. Uma investigação mais aprofundada sobre estes resultados é fundamental para aferir a robustez destes modelos em dados distintos do conjunto de supercapacitores estudados.

Figura 23 - Perfil dos intervalos de confiança de 95% para um supercapacitor do conjunto de teste



Fonte: Elaborado pelo autor.

Figura 24 - Histograma obtido a partir da aplicação do dropout Monte Carlo com 250 previsões para a mesma entrada



Fonte: Elaborado pelo autor.

4 CONCLUSÕES E PROPOSTAS DE CONTINUIDADE

Em uma perspectiva geral, é possível constatar que os três modelos desenvolvidos alcançaram, com diferentes limitações e graus de sucesso, a tarefa proposta de previsão da vida útil remanescente de supercapacitores a partir de uma curta janela de dados elétricos. Os resultados obtidos neste trabalho estão próximos dos apresentados por Ren *et al.* (2020) e Wang *et al.* (2022), que serviram como principais referências para seu desenvolvimento. Destaca-se também o fato que a proposta de integrar um método para a quantificação das incertezas rendeu resultados que enriqueceram a interpretação das suas previsões, ressaltando a importância da integração deste tipo de estratégia para sistemas no qual a gestão do risco é fundamental.

Entretanto, em conformidade com outros problemas baseados na elaboração de modelos a partir de dados experimentais, constata-se que ainda há uma vasta área a ser explorada neste tema em termos de diferentes estratégias de pré-processamento dos dados, arquiteturas para as redes e otimização de seus hiperparâmetros. Deste modo, investigações adicionais e diferentes da proposta neste trabalho têm o potencial de atingir resultados mais robustos do que os aqui apresentados.

Complementarmente, é fundamental ressaltar as limitações desta modelagem, uma vez que esta também tem impacto direto sobre a capacidade de generalização dos modelos desenvolvidos. Pontos como a temperatura controlada durante a coleta dos dados, modelo e especificações dos supercapacitores utilizados, critério de fim de vida útil, e as estratégias de carregamento e descarregamento empregadas são, a princípio, fatores que devem ser compatíveis com um possível sistema em que deseja-se utilizar este modelo para que haja uma expectativa de generalização destes resultados em campo. Deste modo, é importante evidenciar a relevância da elaboração de bases de dados mais robustas ou específicas ao sistema que serão aplicadas, visando garantir desempenhos semelhantes aos apresentados em um conjunto de teste.

O repositório contendo o código desenvolvido neste trabalho está disponível no seguinte link: <https://github.com/antonio-mav/supercap-rul-tcc>.

Com base nos principais pontos abordados nesta seção, destacam-se as seguintes propostas de continuidade para esta linha de pesquisa:

- Levantamento experimental de dados com o intuito de promover uma segunda fonte de testes e, possivelmente, dados para condições operacionais distintas das apresentadas na base de dados analisada;
- Desenvolvimento de uma análise análoga para composições mais complexas, como sistemas de supercapacitores e sistemas híbridos envolvendo baterias e supercapacitores;
- Investigação de técnicas de pré-processamento, ampliação artificial dos dados, validação cruzada, arquiteturas alternativas e estratégias automáticas para otimização de hiperparâmetros com o objetivo de atingir desempenhos melhores e mais confiáveis;
- Elaboração de um estudo aprofundado sobre estratégias e aplicações para a quantificação das incertezas do modelo.

REFERÊNCIAS

- ALESSANDRO BIROLINI. **Reliability Engineering: Theory and Practice**. [S.l.]: Springer Berlin, Heidelberg, 2017.
- BURKE, Andrew F.; ZHAO, Jingyuan. Past, present and future of electrochemical capacitors: Technologies, performance and applications. **Journal of Energy Storage**, v. 35, p. 102310, 2021.
- DASGUPTA, A.; PECHT, M. Material failure mechanisms and damage models. **IEEE transactions on reliability**, v. 40, n. 5, p. 531–536, 1991.
- EATON. **Technical Data 4376**: HV Supercapacitors: Cylindrical cells. Cleveland. Eaton Electronics Division, 2020. Disponível em <https://www.eaton.com/content/dam/eaton/products/electronic-components/resources/data-sheet/eaton-hv-supercapacitors-cylindrical-cells-data-sheet.pdf>
- FINK, Olga *et al.* Potential, challenges and future directions for deep learning in prognostics and health management applications. **Engineering Applications of Artificial Intelligence**, v. 92, p. 103678, 2020.
- FODOR, Jerry A.; PYLYSHYN, Zenon W. Connectionism and cognitive architecture: A critical analysis. **Cognition**, v. 28, n. 1-2, p. 3-71, 1988.
- GONZÁLEZ, Ander *et al.* Review on supercapacitors: Technologies and materials. **Renewable and sustainable energy reviews**, v. 58, p. 1189-1206, 2016.
- BENGIO, Yoshua; GOODFELLOW, Ian; COURVILLE, Aaron. **Deep learning**. Cambridge, MA, USA: MIT press, 2017.
- HASHEMIAN, Hashem M. State-of-the-art predictive maintenance techniques. **IEEE Transactions on Instrumentation and measurement**, v. 60, n. 1, p. 226-236, 2010.
- HINTON, Geoffrey E.; OSINDERO, Simon; TEH, Yee-Whye. A fast learning algorithm for deep belief nets. **Neural computation**, v. 18, n. 7, p. 1527-1554, 2006.
- HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. **Neural computation**, v. 9, n. 8, p. 1735-1780, 1997.
- JAMES, Gareth *et al.* Deep learning. In: **An Introduction to Statistical Learning: with Applications in Python**. Cham: Springer International Publishing, 2023. p. 399-467.
- KAPUR, Kailash C.; PECHT, Michael. **Reliability engineering**. John Wiley & Sons, 2014.
- KINGMA, Diederik P.; BA, Jimmy. Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014.
- LAADJAL, Khaled; MARQUES CARDOSO, Antonio J. A review of supercapacitors modeling, SoH, and SoE estimation methods: Issues and challenges. **International Journal of Energy Research**, v. 45, n. 13, p. 18424-18440, 2021.
- LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **nature**, v. 521, n. 7553, p. 436-444, 2015.
- LEI, Yaguo *et al.* Machinery health prognostics: A systematic review from data acquisition to RUL prediction. **Mechanical systems and signal processing**, v. 104, p. 799-834, 2018.

- MATHEW, Sony; OSTERMAN, Michael; PECHT, Michael. Considerations in implementing canary based prognostics. In: **2015 IEEE Conference on Prognostics and Health Management (PHM)**. IEEE, 2015. p. 1-7.
- MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, p. 115-133, 1943.
- MERKT, Oana. On the use of predictive models for improving the quality of industrial maintenance: An analytical literature review of maintenance strategies. In: **2019 Federated Conference on Computer Science and Information Systems (FedCSIS)**. IEEE, 2019. p. 693-704.
- MODARRES, Mohammad; KAMINSKIY, Mark P.; KRIVTSOV, Vasilii. **Reliability engineering and risk analysis: a practical guide**. CRC press, 2016.
- RAMAKRISHNAN, Arun; PECHT, Michael G. A life consumption monitoring methodology for electronic systems. **IEEE Transactions on Components and Packaging technologies**, v. 26, n. 3, p. 625-634, 2003.
- REN, Jiahao et al. Engineering early prediction of supercapacitors' cycle life using neural networks. **Materials Today Energy**, v. 18, p. 100537, 2020.
- ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.
- RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **nature**, v. 323, n. 6088, p. 533-536, 1986.
- SAVITZKY, Abraham; GOLAY, Marcel JE. Smoothing and differentiation of data by simplified least squares procedures. **Analytical chemistry**, v. 36, n. 8, p. 1627-1639, 1964.
- SIKORSKA, Joanna Z.; HODKIEWICZ, Melinda; MA, Lin. Prognostic modelling options for remaining useful life estimation by industry. **Mechanical systems and signal processing**, v. 25, n. 5, p. 1803-1836, 2011.
- HAYKIN, Simon. **Neural networks and learning machines**, 3/E. Pearson Education India, 2009.
- SIMON, Patrice; GOGOTSI, Yury. Perspectives for electrochemical capacitors and related devices. **Nature materials**, v. 19, n. 11, p. 1151-1163, 2020.
- SI, Xiao-Sheng et al. Remaining useful life estimation—a review on the statistical data driven approaches. **European journal of operational research**, v. 213, n. 1, p. 1-14, 2011.
- SRIVASTAVA, Nitish et al. Dropout: a simple way to prevent neural networks from overfitting. **The journal of machine learning research**, v. 15, n. 1, p. 1929-1958, 2014.
- WANG, Chenxu et al. Rapid ultracapacitor life prediction with a convolutional neural network. **Applied Energy**, v. 305, p. 117819, 2022.
- WIDROW, Bernard et al. Adaptive switching circuits. In: **IRE WESCON convention record**. 1960. p. 96-104.
- WIENER, Norbert. Cybernetics. **Scientific American**, v. 179, n. 5, p. 14-19, 1948.
- ZHANG, Lei et al. A review of supercapacitor modeling, estimation, and applications: A control/management perspective. **Renewable and Sustainable Energy Reviews**, v. 81, p. 1868-1878, 2018.

ZIO, Enrico. Some challenges and opportunities in reliability engineering. **IEEE Transactions on Reliability**, v. 65, n. 4, p. 1769-1782, 2016.

NEMANI, Venkat et al. Uncertainty Quantification in Machine Learning for Engineering Design and Health Prognostics: A Tutorial. **arXiv preprint arXiv:2305.04933**, 2023.

GAL, Yarin; GHAHRAMANI, Zoubin. Dropout as a bayesian approximation: Representing model uncertainty in deep learning. In: **international conference on machine learning**. PMLR, 2016. p. 1050-1059.

ZHAO, Jingyuan; BURKE, Andrew F. Review on supercapacitors: Technologies and performance evaluation. **Journal of Energy Chemistry**, v. 59, p. 276-291, 2021.