



**INSTITUTO LATINO-AMERICANO DE
CIÊNCIAS DA VIDA E DA NATUREZA
(ILACVN)**

ENGENHARIA FÍSICA

**PREDIÇÃO DO ESTADO DE SAÚDE DE BATERIAS DE ÍON-LÍTIO POR MEIO DE
TÉCNICAS DE APRENDIZAGEM DE MÁQUINA E SÉRIES TEMPORAIS**

BRUNO OZIEL FERNANDEZ

Foz do Iguaçu
2021



**INSTITUTO LATINO-AMERICANO DE CIÊNCIAS
DA VIDA E DA NATUREZA (ILACVN)**

ENGENHARIA FÍSICA

**PREDIÇÃO DO ESTADO DE SAÚDE DE BATERIAS DE ÍON-LÍTIO POR MEIO DE
TÉCNICAS DE APRENDIZAGEM DE MÁQUINA E SÉRIES TEMPORAIS**

BRUNO OZIEL FERNANDEZ

Trabalho de Conclusão de Curso apresentado ao Instituto Latino-Americano de Ciências da Vida e da Natureza da Universidade Federal da Integração Latino-Americana, como requisito parcial à obtenção do título de Bacharel em Engenharia Física.

Orientador: Prof. Dr. Marcelo Napomoceno Kapp.

Foz do Iguaçu
2021

**PREDIÇÃO DO ESTADO DE SAÚDE DE BATERIAS DE ÍON-LÍTIO POR MEIO DE
TÉCNICAS DE APRENDIZAGEM DE MÁQUINA E SÉRIES TEMPORAIS**

Trabalho de Conclusão de Curso apresentado ao Instituto Latino-Americano de Ciências da Vida e da Natureza da Universidade Federal da Integração Latino-Americana, como requisito parcial à obtenção do título de Bacharel em Engenharia Física.

BANCA EXAMINADORA

Orientador: Prof. Dr. Marcelo Napomoceno Kapp
UNILA

Prof. Dr. Willian Zalewski
UNILA

Dr. Daniel Cantane
Fundação Parque Tecnológico Itaipu - Centro de Energias Renováveis.

Foz do Iguaçu, 07 de outubro de 2021.

Homens fortes criam tempos fáceis e tempos fáceis geram homens fracos, mas homens fracos criam tempos difíceis e tempos difíceis geram homens fortes.”

(Provérbio oriental)

Agradecimentos

Ao professor Marcelo Kapp pela orientação, amizade e paciência em conduzir este trabalho. Obrigado por aceitar me orientar neste TCC e pela confiança depositada e pela oportunidade de ter compartilhado essa experiência.

Aos professores de Engenharia Física, por todos os conhecimentos compartilhados.

Aos meu pais, Cristiane Kliemann Fernandez e Cesar Darwin Fernandez, por todas as forças, incentivos, compreensão e apoio nessa jornada de faculdade.

Agradeço ao meus familiares que me ajudaram de alguma forma a fazer possível concluir este curso.

Aos meus colegas de curso e amigos, Ana Carolina, Anton Simen, Mauro Nooblath. Por sempre estarem comigo desde o início desta jornada.

Aos meus amigos, Bruno Ecker, Felipe Tonis, Felipe Lujan, Danillo Gimenes, Diego Luiz e Jean Carlos, pelo companheirismo e amizade.

Agradeço ao prof. Willian Zalewski e ao pesquisador Daniel Cantane por terem aceitado participar da banca.

Fernandez, Bruno Oziel. **Predição do estado de saúde de baterias de íon-Lítio por meio de técnicas de aprendizagem de máquina e séries temporais.** 49 páginas. 2021. Trabalho de Conclusão de Curso (Graduação em Engenharia Física) – Universidade Federal da Integração Latino-Americana, Foz do Iguaçu, 2021.

Resumo

Poder determinar um sistema de confiabilidade de uma bateria pode garantir que ela trabalhe com segurança e confiabilidade. A principal abordagem de avaliação de um sistema de confiabilidade é determinar o estado de saúde (SOH) da bateria. Os avanços das ferramentas e algoritmos computacionais levaram a uma nova era de abordagens de análise preditiva baseada em dados, usando algoritmos de aprendizado de máquina e séries temporais. O objetivo deste trabalho é utilizar métodos de aprendizagem de máquinas e séries temporais para prever o estado de saúde de baterias de íon-Lítio. Com base no banco de dados disponível no site da NASA, *Ames Prognostics Center of Excellence* (PcoE), dois experimentos foram realizados. No primeiro, realizou-se a comparação dos resultados entre os algoritmos de aprendizagem de máquinas proposto, *Support Vector Regression* (SVR) e *Multi-Layer Perceptron* (MLP), numa abordagem global dos dados. No segundo experimento incluí-se o algoritmo de série temporal, *Auto Regressive Integrated Moving Average* (ARIMA), e comparou-se com os algoritmo de aprendizagem de máquina, numa abordagem mais local dos dados. Como os resultados, verifica-se que os melhores desempenhos, foram para os algoritmos de aprendizagem de máquinas, com destaque para o MLP.

Palavras chave: Predição do Estado de Saúde de Bateria; Aprendizagem de Máquina; Séries Temporais; Bateria de íon-Lítio.

Fernandez, Bruno Oziel. **Prediction the state of health of lithium-ion batteries using machine learning and time series techniques**. 49 páginas. 2021. Trabalho de Conclusão de Curso (Graduação em Engenharia Física) – Universidade Federal da Integração Latino-Americana, Foz do Iguaçu, 2021.

Abstract

Being able to determine a battery's reliability system can ensure that it works safely and reliably. The main approach to evaluating a reliability system is to determine the state of health (SOH) of the battery. Advances in computational tools and algorithms have ushered in a new era of data-driven predictive analytics approaches using machine learning algorithms and time series. The objective of this work is to use machine learning methods and time series to predict the state of health of lithium-ion battery. Based on the database available on the NASA website, Ames Prognostics Center of Excellence (PcoE), we performed two experiments. In the first, we compared the results between the proposed machine learning algorithms, Support Vector Regression (SVR) and Multi-Layer Perceptron (MLP). In the second experiment we included the time series algorithm, Auto Regressive Integrated Moving Average (ARIMA), and compared it with the machine learning algorithms. As a result, we found that the best performances were for machine learning algorithms, with emphasis on MLP.

Keywords: Prediction of Battery State of Health ; Machine Learning; Time Series; Lithium-ion battery.

Fernandez, Bruno Oziel. **Predicción del estado de salud de las baterías de iones de litio utilizando técnicas de aprendizaje automático y series de tiempo.** 49 páginas. 2021. Trabalho de Conclusão de Curso (Graduação em Engenharia Física) – Universidade Federal da Integração Latino-Americana, Foz do Iguaçu, 2021.

Resumen

Ser capaz de determinar el sistema de confiabilidad de una batería puede garantizar que funcione de manera segura y confiable. El enfoque principal para evaluar un sistema de confiabilidad es determinar el estado de salud (SOH) de la batería. Los avances en herramientas y algoritmos computacionales han marcado el comienzo de una nueva era de enfoques de análisis predictivo basados en datos que utilizan algoritmos de aprendizaje automático y series de tiempo. El objetivo de este trabajo es utilizar métodos de aprendizaje automático y series de tiempo para predecir el estado de salud de las baterías de iones de litio. Sobre la base de la base de datos disponible en el sitio web de la NASA, *Ames Prognostics Center of Excellence* (PcoE), realizamos dos experimentos. En el primero, comparamos los resultados entre los algoritmos de aprendizaje automático propuestos, *Support Vector Regression* (SVR) y *Multi-Layer Perceptron*(MLP). En el segundo experimento, incluimos el algoritmo de series de tiempo, *Auto Regressive Integrated Moving Average* (ARIMA), y lo comparamos con los algoritmos de aprendizaje automático. Como resultado, descubrimos que los mejores rendimientos fueron para los algoritmos de aprendizaje automático, con énfasis en MLP.

Keywords: Predicción del estado de salud de la batería; Aprendizaje automático; Series de tiempo; Batería de iones de litio.

Lista de Figuras

3.1	Representação dos casos de classificação e regressão, respectivamente. . . .	24
3.2	Tipos de kernels	25
3.3	Ilustração dos limites de decisão e hiperplano.	26
3.4	Representação SVR.	27
3.5	Exemplo ilustrativo	27
3.6	SVR com $\epsilon = 5$ e $C = 6, 13$	28
3.7	Representação simplificada do neurônio biológico.	30
3.8	Modelo <i>Peceptron</i>	31
3.9	Função Linear.	33
3.10	Função sigmóide.	34
3.11	Função retificadora	35
3.12	Função tangente hiperbólica.	36
3.13	Arquitetura de uma MLP.	37
4.1	Perfil da curva de tensão e corrente durante a etapa de descarga da bateria 5 para os ciclos 1, 50, 100 e 168: (a) tensão de descarga, (b) corrente de descarga.	41
5.2	Estimando o SOH com os algoritmos SVR e MLP para as baterias (a) 6, (b) 7 e (c) 18.	48
5.3	Um exemplo de previsão do comportamento do SOH por série temporal. . .	49
5.5	Estimando o SOH com os algoritmos SVR, MLP e ARIMA para as baterias (a) 6, (b) 7 e (c) 18.	51

Lista de Abreviações e Siglas

AR	Autoregressivos
ARIMA	<i>Auto Regressive Integrated Moving Average</i>
ECM	Modelo circuito equivalente
EV	Carro elétrico
IL	Íon-Lítio
P2D	<i>Pseudo two-dimensional</i>
PDE	Equações diferenciais parciais
PCM	Modelo baseado na física
MA	Média móvel
MAE	Erro médio absoluto
MLP	<i>Multi-Layer Perceptron</i>
SOC	<i>State of charge</i>
SOH	<i>State of health</i>
SVM	<i>Support vector machine</i>
SVR	<i>Support vectgor regression</i>
RBF	Função de base radial
RMSE	Raiz quadrada do erro médio
RNA	Redes neurais artificiais

Conteúdo

1	INTRODUÇÃO	12
1.1	OBJETIVOS	13
1.2	ORGANIZAÇÃO DO TRABALHO	13
2	REVISÃO DA LITERATURA	15
2.1	SOBRE BATERIAS DE ÍON LÍTIO (IL)	15
2.2	DETERMINANDO A CONFIABILIDADE DE UM SISTEMA DE BATERIA	16
2.3	ABORDAGENS RELACIONADAS NA LITERATURA	18
3	FUNDAMENTAÇÃO TEÓRICA	21
3.1	FUNDAMENTOS DAS SÉRIES TEMPORAIS	21
3.1.1	Técnicas de séries temporais	22
3.2	FUNDAMENTOS DE APRENDIZAGEM DE MÁQUINA	24
3.2.1	<i>Support Vector Regression</i> (SVR)	24
3.2.2	Rede Neural Artificial (RNA)	29
3.2.3	<i>Multi-Layer Perceptron</i> (MLP)	36
4	MÉTODO	39
4.1	AQUISIÇÃO E DESCRIÇÃO DOS DADOS	39
4.2	PRÉ-PROCESSAMENTO DOS DADOS	40
4.3	DESCRIÇÃO DO PROTOCOLO DE EXPERIMENTO	43
4.3.1	Descrição Experimental	43
4.3.2	Configuração dos Parâmetros dos algoritmos	44
4.4	MÉTRICA DE AVALIAÇÃO	45
5	RESULTADOS E DISCUSSÃO	46
5.0.1	RESULTADOS DO EXPERIMENTO I	46
5.0.2	RESULTADOS DO EXPERIMENTO II	49
	Conclusões	53
	Referências bibliográficas	54

Capítulo 1

INTRODUÇÃO

Atualmente, as baterias de íon-lítio (IL) são a fonte de energia elétrica mais utilizada para diversos aparelhos. Elas são versáteis, pois podem ser utilizadas em aplicações de alta e baixa potência, como carros híbridos, carros elétricos, *smartphones*, *tablets*, *laptops*, etc. A tecnologia íon-lítio possibilitou um grande avanço tecnológico e hoje é considerada referência como fonte de energia. As principais vantagens da bateria de íon-lítio são: alta densidade de energia (23-70 Wh/kg), alta eficiência (aproximadamente 90%), e longo ciclo de vida (KHUMPROM; YODO, 2019).

A condição da bateria pode ser expressa pelo estado de saúde (SOH, *state of health*), que pode ser utilizada para monitoramento e controle dessas baterias com objetivo de maximizar a viabilidade de operação. A geração de calor aumenta nas baterias conforme seu envelhecimento e se não for monitorado, isso pode causar pequenos curtos circuitos internos e comprometer a segurança. No entanto, essas baterias ainda podem ser utilizadas na "segunda vida", com uma demanda menor de armazenamento. Aproveitar uma bateria no seu estado de "segundo vida" pode ser muito valioso, pois ao invés de ser descartada seria possível destinar essa bateria a uma aplicação, como o gerenciamento de energia sustentável de armazenamento de *Smart City* (HUOTARI et al., 2021).

Para garantir que um sistema de gerenciamento da bateria íon-lítio forneça informações sobre a vida útil da bateria, existe o parâmetro SOH da bateria. Através do SOH é possível saber quando a bateria deve ser removida ou substituída. Uma das formas mais recentes de realizar a previsão do tempo de vida da bateria é a partir da utilização de modelos computacionais de aprendizagem de máquinas (*machine learning*) capazes de aprender o comportamento da bateria e realizar previsões futuras do SOH.

A dificuldade nos modelos de aprendizagem de máquina de previsão de vida útil das baterias é realizar previsões futuras com alta acurácia, tornando-se um campo de pesquisa útil pela comunidade acadêmica, e conseqüentemente empresas do setor que podem utilizar a técnica de previsão para estender a vida útil das baterias utilizadas em aplicações comerciais.

1.1 OBJETIVOS

Neste trabalho, como objetivo geral será realizado a previsão do SOH da bateria e a comparação das acurácias dos resultados entre as técnicas de aprendizagem de máquina e a técnica de séries temporais. Como objetivos especificamos, primeiro, será realizado uma análise comparativa da acurácia da previsão entre as técnicas de aprendizagem de máquina, *Support Vector Regression* (SVR) e *Multi Layer Perceptron* (MLP) para uma abordagem de dados mais global. Em segundo, também será realizado uma análise comparativa da acurácia da previsão entre as técnicas de aprendizagem de máquina e séries temporais, *Auto Regressive Integrated Moving Average* (ARIMA) para uma abordagem de dados mais local.

1.2 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado do seguinte modo:

- **Capítulo 2 - REVISÃO DA LITERATURA:** neste capítulo inicialmente são apresentadas uma introdução sobre as baterias de íon-Lítio, como determinar a confiabilidade de um sistema de bateria e expor abordagens relacionadas na literatura.
- **Capítulo 3 - FUNDAMENTAÇÃO TEÓRICA:** neste capítulo são apresentados conceitos de aprendizagem de máquina, tais como os princípios de funcionamentos e os paradigmas dos algoritmos de regressão. Conceitos referentes às séries temporais, a amostragem, tendência e normalização.
- **Capítulo 4 - MÉTODO :** neste capítulo são apresentados a aquisição, a descrição dos dados, métrica utilizada para desempenho e a configuração experimental do trabalho.

- **Capítulo 5 - RESULTADO E DISCUSSÕES:** neste capítulo são apresentados os resultados obtidos e é realizada uma discussão sobre as técnicas propostas.
- **Capítulo 6 - CONCLUSÃO:** neste capítulo são apresentadas as conclusões deste trabalho, as limitações e trabalhos futuros.

Capítulo 2

REVISÃO DA LITERATURA

2.1 SOBRE BATERIAS DE ÍON LÍTIO (IL)

As baterias de IL comerciais são basicamente compostas por óxidos de metal de transição contendo íons de Lítio inseridos na sua estrutura no catodo ($LiCoO_2$) e de materiais à base de carbono no anodo (grafite). O eletrólito é composto de sal de Lítio ($LiCoO_4$) dissolvido em solvente orgânico aprótico (VARELA et al., 2002)(MOSHTEV; JOHNSON, 2000). Quando o íon Lítio (Li^+) é intercalado ou desintercalado da estrutura cristalina dos eletrodos ocorrem as reações de oxirredução, ou seja, no processo de carga da bateria, sob ação de um campo elétrico (não espontâneo), os íons de Lítio desintercalam do catodo e intercalam no anodo, no processo de descarga (espontâneo) o processo inverso ocorre. Assim, a capacidade da bateria será determinada pela quantidade de íons de Lítio disponíveis para o processo descrito.

A diminuição da capacidade de carga da bateria se deve a diminuição da quantidade de íons de Lítio disponíveis para os processos de desintercalação e intercalação, que ocorre devido as várias reações secundárias nos eletrodos a cada ciclo de carga e descarga (JOHNSON; WHITE, 1998). Esses fenômenos resultam no aumento da resistência elétrica ou de transferência de carga entre os mesmos (WU; LU; PRAKASH, 2000). A perda de íons disponíveis para o ciclo de carregamento e descarregamento ocorre quando a estrutura cristalina dos eletrodos é alterada via transformação de fase estrutural, ou quando íons de Lítio reagem formando camadas passivantes nas superfícies dos eletrodos (processos irreversíveis) (BERG et al., 1997).

Uma bateria nova possui baixa resistência interna e de transferência de carga, no entanto ao longo de muitos ciclos de carregamento e descarregamento seus componentes internos se modificam, aumentando essas resistências. A consequência deste fenômeno reflete no aumento global de impedância, que é a combinação da resistência e reatância interna da bateria. Com isso, experimentos que buscam determinar a impedância da bateria são utilizados para análise de vida útil da bateria.

A capacidade de carga da bateria diminui tanto pela diminuição da quantidade de íons de lítio disponíveis, como pelo aumento da sua impedância, que acarreta diminuição no potencial de trabalho, a qual é proporcional ao aumento da corrente elétrica solicitada (DEISS et al., 2001). O tempo de vida de uma bateria de IL está relacionado com o número de ciclos a que foi submetida. Saber a vida útil de uma bateria é importante para determinar sua aplicabilidade. Um importante parâmetro que corresponde ao número de ciclos que a bateria secundária ainda pode fornecer durante sua vida útil, é o estado de saúde (SOH, *State of Health*) que será definido na próxima seção.

2.2 DETERMINANDO A CONFIABILIDADE DE UM SISTEMA DE BATERIA

Na literatura, alguns parâmetros que ajudam a analisar e determinar o estado e a confiabilidade do sistema de uma bateria são: estado de carga (SOC, *State of Charge*) e estado de saúde (SOH, *State of Health*).

O estado de carga de uma bateria determina o nível de carga em relação a sua capacidade atual, ou seja, seu estado totalmente carregado. É dado em porcentagem, e normalmente as baterias possuem uma faixa limite de porcentagem de descarga, que se ficar abaixo desse limite pode causar descargas profundas que reduzem significativamente a vida útil da bateria e a destroem completamente. Saber este parâmetro é a maneira mais confiável de evitar uma descarga profunda durante a descarga de uma bateria. O SOC pode ser expresso matematicamente como:

$$SOC = \frac{C_{atual}}{C_{carregado}} \cdot 100\%, \quad (2.1)$$

onde C_{atual} representa a capacidade da bateria em seu estado atual e $C_{carregado}$ representa a capacidade da bateria em seu estado totalmente carregado (capacidade reversível).

Apesar do estado de carga ser útil para determinar a confiabilidade do sistema da bateria, é um parâmetro que não possui uma forte correlação com a vida útil da bateria. Sendo isto, um ponto vital para fazer uma estimativa de longo prazo da integridade da bateria, uma vez que a capacidade é a principal indicação da integridade da bateria, que irá diminuir com o tempo.

O estado de saúde da bateria é outro importante parâmetro de avaliação de uma bateria secundária, pois determina seu tempo de vida útil (números de ciclos) e auxilia na manutenção dos sistemas eletrônicos abastecidos com estas baterias. O SOH corresponde ao número de ciclos que a bateria recarregável ainda pode fornecer durante sua vida útil. Pois, está diretamente ligado com a condição de saúde do sistema da bateria. A equação que permite calcular o SOH é da seguinte forma:

$$SOH = \frac{C_{carregado}}{C_{nominal}} \cdot 100\%, \quad (2.2)$$

onde $C_{nominal}$ representa a capacidade nominal de fábrica, que pode desaparecer com o tempo devido ao efeito do envelhecimento da bateria.

Os parâmetros C_{full} e $C_{nominal}$ podem ser obtidas diretamente, e com baixo erro, procedendo de um ciclo completo de carga e descarga da bateria. Normalmente, a medida direta do SOH é realizada aplicando se um ciclo completo de carga e descarga na baterias, e na etapa de descarga avalia-se a quantidade de carga disponível na bateria. A desvantagem desse procedimento é o longo tempo, que pode levar de 4 a 6 horas, dependendo da corrente elétrica utilizada. O motivo dessa demora é que precisa determinar o $C_{nominal}$. Para isso, o sistema deve estar próximo do equilíbrio termodinâmico. Por este motivo, busca-se processos de medida indireta do SOH de uma bateria que reduzam o tempo de análise com o máximo de confiabilidade.

2.3 ABORDAGENS RELACIONADAS NA LITERATURA

Antes do surgimento dos algoritmos de aprendizagem de máquina, os estudos de uma bateria eram realizados por diferentes tipos de modelagem de bateria. Alguns dos modelos clássicos de modelagem para baterias IL são modelo de circuito equivalente (ECM, *equivalent circuit model*) e modelos baseado na física (PBM, *physics-based model*). A modelagem de bateria é a parte central para o sistema de gerenciamento da bateria e é vital para manter a segurança e o ideal funcionamento da bateria. A modelagem mais recente que vem ganhando espaço nesta área de pesquisa são os modelos de aprendizagem de máquina (NG et al., 2020). Cada modelo tem seus próprios méritos e desafios. Por exemplo, ECM são computacionalmente eficiente e, portanto, adequado para previsões de status de bateria, mas obter alta precisão continua sendo um desafio. O PBM fornece informações internas sobre um bateria, como a concentração de íons de lítio dentro dos eletrodos e eletrólitos, mas resolver a equação diferenciais parciais (PDEs) que governa o modelo requer recursos computacionais significativos e um grande número de parâmetros de entrada. Além disso, um modelo de bateria precisa funcionar com suficiente memória de acesso aleatório que é usada para armazenar os dados instantâneos para um sistema de gerenciamento de bateria. A memória requerida depende altamente da complexidade das equações de modelagem. As características intrínsecas dos modelos ECM e PBM, e as estratégias comumente usadas para melhorar sua adaptabilidade e previsibilidade serão discutidas a seguir.

- **Abordagens ECMs:** este modelo é muito utilizado para sistemas de gerenciamento da bateria de carros elétricos (EV) para estimar o SOC, junto com sua habilidade de prever o comportamento da bateria em tempo real (NG et al., 2020). Os modelos são essencialmente derivado de conhecimento empírico e dados experimentais em que as baterias são representados por grupos de componentes elétricos, como resistores e capacitores, formando redes resistor-capacitor que são usadas para monitorar o comportamento da bateria em diferentes constantes de tempo associadas aos processos de difusão e transferência de carga. Os ECMs típicos são os modelos Rint, os modelos de histerese, os modelos Randles e os modelos resistor-capacitor ou Thevenin. Apesar de sua eficiência computacional, os ECMs geralmente mos-

tram acurácia limitada na previsão das características da bateria em uma gama de condições de operação, como envelhecimento e ambientes dinâmicos em aplicações da vida real, devido à parametrização do modelo com base nas condições de laboratório. Além disso, segundo (NG et al., 2020) a falta de informações baseadas na física dos estados e parâmetros do sistema torna difícil prever o SOH das baterias com precisão.

- **Abordagens PBMs:** são modelos de bateria mais precisos. O trabalho pioneiro de modelos de bateria de íon-lítio totalmente baseados em física é o desenvolvimento de um modelo de eletrodo poroso *pseudo two-dimensional* (P2D). O modelo oferece insights sobre a dinâmica interna das baterias, como difusão de íons de lítio, efeitos ôhmicos e cinética eletroquímica (NG et al., 2020). Isso abre a possibilidade de analisar os mecanismos de degradação da bateria, prevendo o SOC e SOH com efeitos de envelhecimento e projetando estratégias de carregamento ideais. No entanto, o modelo P2D é geralmente descrito por vários PDEs e é considerado um PBM de ordem completa. Resolver os PDEs requer cálculos intensivos, o que torna impraticável incorporar o modelo P2D em um controlador de um sistema de gerenciamento de bateria para aplicações em tempo real.
- **Abordagens com técnicas de aprendizagem de máquina:** o principal desafio dos modelos de bateria atuais está em alcançar um adequado equilíbrio entre a fidelidade do modelo e a complexidade computacional. Recentemente, as técnicas de aprendizagem de máquina tem recebido importância devido ao seu imenso potencial em alcançar alta precisão com baixo custo computacional. Em seu trabalho sobre a previsão do tempo de vida útil das baterias, Zhu (2019) comparou vários algoritmos de aprendizagem de máquinas de classificação com base em dados de ciclos iniciais da bateria. O trabalho realizado por Huotari (2021), mostrou a combinação de séries temporais com diferentes métodos de aprendizagem de máquina para prever o SOH da bateria de íon Lítio. Khumprom (2019) apresentou o uso de algoritmos de aprendizagem profunda de classificação para determinar o estado da saúde e da vida útil remanescente de bateria por redes neurais artificiais. O trabalho compara o algoritmo de redes neurais com outros algoritmos de aprendizagem de máquinas.

O foco deste trabalho será realizar um *benchmark* inicial sobre este assunto, e para isso será utilizado técnicas de aprendizagem de máquina como *support vector regression* (SVR) e *multi-layer perceptron* (MPL). No entanto, será introduzido um método de séries temporais (*Auto Regressive Integrated Moving Average* (ARIMA) no qual comparações serão realizados sob dois cenários entre os algoritmos. No próximo capítulo serão descritos conceitos e detalhes sobre as técnicas de aprendizagem de máquina e de séries temporais que serão utilizadas.

Capítulo 3

FUNDAMENTAÇÃO TEÓRICA

3.1 FUNDAMENTOS DAS SÉRIES TEMPORAIS

Pode-se definir uma série temporal como sendo um conjunto de dados observados e ordenados segundo parâmetro de tempo e com dependência serial (horários, diário, semanal, mensal, trimestral, anual, etc.). Segundo (WILHER, 2020), uma série temporal é, basicamente, uma sequência de observações tomada ao longo de um período de tempo.

Para que uma determinada série seja classificada como uma série temporal, é necessário que ela preencha outro pré-requisito: os dados também devem apresentar uma dependência serial entre eles. Por exemplo: os dados de uma variável aleatória z (consumo de energia) no instante t , com t variando de 1 até N , possa, de certa maneira, conter informações necessárias para que seja determinado o valor dessa variável no instante $t + 1$. Cabe mencionar que, N representa o número de observações da série temporal em questão. As séries temporais podem ser classificadas como discretas, contínuas, determinísticas, estocásticas, multivariadas e multidimensionais (SILVA, 2010).

Segundo a abordagem de componentes não observáveis, as séries temporais podem ser representadas como a combinação de quatro componentes:

- **Tendência:** as componentes de tendência são frequentemente, aquelas que produzem mudanças graduais em longo prazo. São normalmente provocadas, por exemplo, pelo crescimento constante na população, no produto interno bruto, no efeito da competição, ou por outros fatores que falham na tentativa de produzir mudanças repentinas, mas produzem variações graduais e regulares ao longo do tempo.

- **Sazonal:** são oscilações de subida e de queda que sempre ocorrem em um determinado período do ano, do mês, da semana, do dia ou horário.
- **Erro:** apresenta movimentos ascendentes e descendentes da série após a ocorrência de um efeito de tendência, um efeito cíclico, ou de um efeito sazonal.

A maioria dos métodos de previsão baseia-se na ideia de que as observações passadas contêm informações sobre o padrão de comportamento da série temporal. O propósito dos métodos é distinguir o padrão de qualquer ruído que possa estar contido nas observações e então usar esse padrão para prever valores futuros da série. Uma grande classe de modelos de previsão, tenta tratar ambas as causas de flutuações em séries de tempo e a das suavizações (média móvel e amortecimento exponencial). Técnicas específicas desse tipo assumem que os valores extremos da série representam a aleatoriedade e assim, por meio da suavização desses extremos, pode-se identificar o padrão básico (SILVA, 2010).

Os modelos de previsão podem ser classificados em univariados, os quais têm a previsão dos valores futuros explicados somente pelos valores passados da própria série ou causais, os que levam em conta outras informações relevantes como influentes para a previsão de uma variável. Neste trabalho vamos utilizar o modelo de previsão univariados, no qual o a variável de previsão é o SOH. Na próxima seção, vamos apresentar uma breve descrição das técnicas de séries temporais.

3.1.1 Técnicas de séries temporais

Neste capítulo vamos apresentar uma breve descrição dos modelos de séries tempoais mais comuns.

- **Modelos Autoregressivos (AR):** é uma abordagem comum para modelar séries temporais univariadas. Um modelo autoregressivo é simplesmente uma regressão linear dos valores atuais da série contra um ou mais valores da série (BERTOLO, 2021):

$$X_t = \delta + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + A_t \quad (3.1)$$

onde X_t é a série temporal, A_t é o ruído e

$$\delta = (1 - \sum_{i=1}^p \phi_i)\mu \quad (3.2)$$

com μ denotando a média do processo. O valor de p é chamado ordem do modelo AR. Os modelos AR podem ser analisados com um dos vários métodos, incluindo técnicas dos mínimos quadrados lineares padrões. Eles também têm uma interpretação simples.

- **Modelos de média móvel (MA):** é outra abordagem comum para modelar séries temporais univariadas:

$$X_t = \mu + A_t - \Theta_1 A_{t-1} - \Theta_2 A_{t-2} - \dots - \Theta_q A_{t-q} \quad (3.3)$$

onde X_t é a série temporal, μ é a média da série, A_{t-i} são os ruídos, e Θ_q são os parâmetros do modelo. O valor de q é chamado de ordem do modelo MA. Isto é, um modelo de média móvel é conceitualmente uma regressão linear do valor corrente da série contra o ruído ou choques aleatórios de um ou mais valores anteriores da série. Os choques aleatórios em cada ponto são assumidos ser da mesma distribuição, geralmente uma distribuição normal, com localização em zero e escala constante. A distinção neste modelo é que estes choques aleatórios são propagados aos valores futuros da série temporal. Ajustar as estimativas MA é mais complicado do que com modelos AR devido aos erros não observáveis. Isto significa que procedimentos de ajuste não lineares iterativos precisam ser usados no lugar dos mínimos quadrados lineares. Os modelos MA também têm uma interpretação menos óbvia que os modelos AR (BERTOLO, 2021).

- **Modelo ARIMA:** o modelo ARIMA de Box-Jenkins é uma combinação dos modelos AR e MA:

$$X_t = \delta + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + A_t - \Theta_1 A_{t-1} - \Theta_2 A_{t-2} - \dots - \Theta_q A_{t-q} \quad (3.4)$$

onde os termos na equação 3.4 tem o mesmo significado dados para os modelos AR e MA.

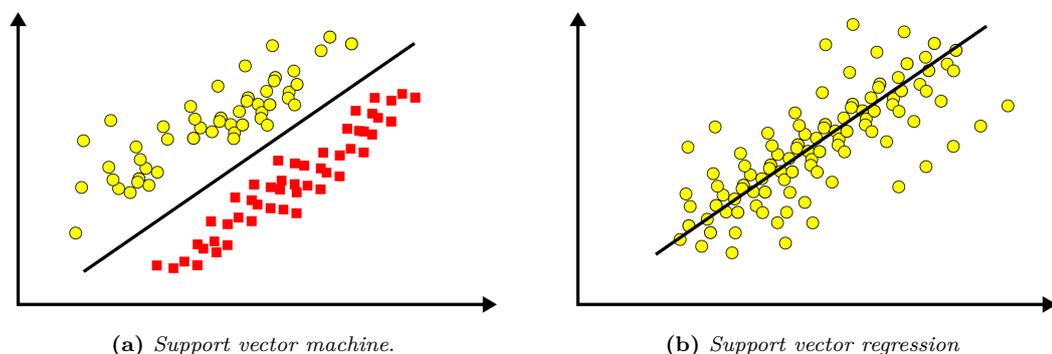
Neste trabalho será utilizado o modelo ARIMA para realizar as previsões do SOH da bateria.

3.2 FUNDAMENTOS DE APRENDIZAGEM DE MÁQUINA

3.2.1 *Support Vector Regression* (SVR)

O *Support Vector Machine* (SVM) é um algoritmo de aprendizagem de máquina supervisionado que pode ser usado para problemas de classificação e regressão (linear ou não linear) (SHARP, 2020). Na Figura 1, em (a) pode-se observar a ilustração do caso mais simples de um problema de classificação do SVM, onde o algoritmo traça uma linha que realiza a separação dos dados em duas classes; (b) temos a representação de um problema de regressão linear. Neste trabalho, utilizamos a implementação *Support Vector Regression* (SVR) que é uma extensão do SVM, usado para prever valores discretos de regressão. A ideia básica por trás do SVR é encontrar a linha que melhor se ajuste aos dados. No caso do SVR a linha de melhor ajuste é o hiperplano que possui o número máximo de pontos (YAOHAO, 2016).

Figura 3.1: Representação dos casos de classificação e regressão, respectivamente.



Fonte: Autor.

Diferente de outros modelos de regressão que tentam minimizar o erro entre o valor real e o previsto, o SVR tenta ajustar a melhor linha dentro de um valor limite. O

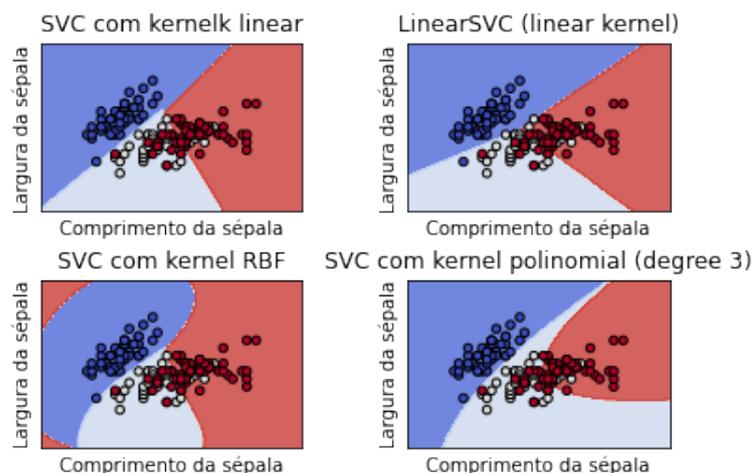
valor limite é a distância entre o hiperplano e a linha limite. No entanto, para conjunto de dados grandes, são utilizadas variações do método como, *Linear SVR* ou *SGD Regressor*. O modelo produzido pelo SVR depende unicamente do subconjunto dos dados de treinamento, devido a função de custo ignorar as amostras cujas previsões está próxima de seu destino.

Hiperparâmetros

Existem alguns parâmetros importantes do SVM que ajudam a melhorar a performance do algoritmo. Os parâmetros são:

- **Hiperplanos:** são limites de decisão para prever a saída contínua. Os pontos de dados em cada lado do hiperplano que estão mais próximos do hiperplano são chamados de Vetores de Suporte . Eles são usados para traçar a linha necessária que mostra a saída prevista do algoritmo.
- **Kernel:** é um conjunto de funções matemáticas que pega dados como entrada e os transforma na forma necessária. Eles geralmente são usados para encontrar um hiperplano no espaço dimensional superior. Os kernels mais usados são: linear, não linear, polinomial, função de base radial (RBF) e sigmóide. Cada um desses kernels é usado dependendo do conjunto de dados.

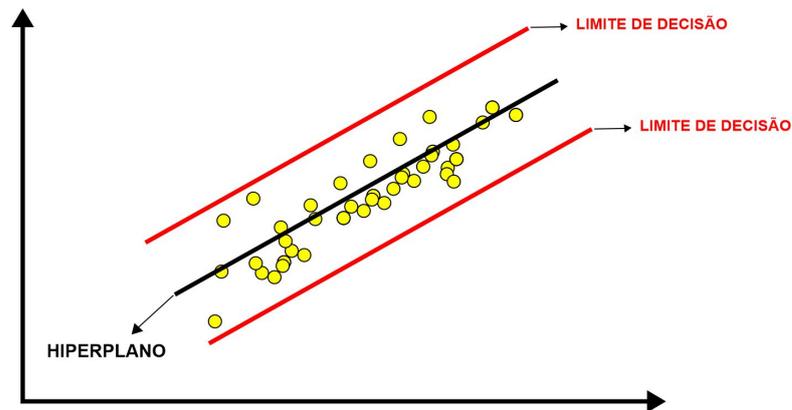
Figura 3.2: Tipos de kernels



Fonte: Sci Kit-Learn.

- **Limite de decisão:** um limite de decisão pode ser pensado como uma linha de demarcação (para simplificação) em um lado da qual estão os exemplos positivos e do outro lado estão os exemplos negativos. Nesta mesma linha, os exemplos podem ser classificados como positivos ou negativos. Este mesmo conceito de SVM também será aplicado no SVR. Essa distância do hiperplano até a linha de decisão pode ser representado por ϵ (epsilon).

Figura 3.3: Ilustração dos limites de decisão e hiperplano.



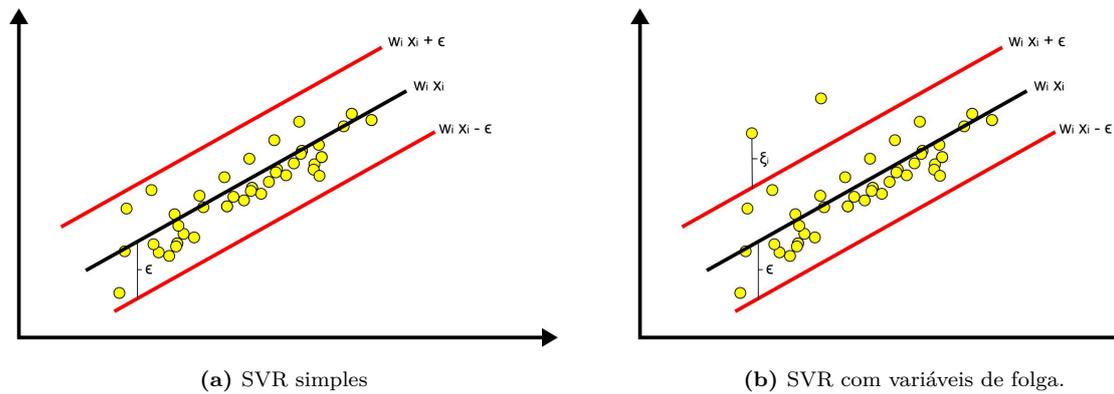
Fonte: Autor.

Explicando o princípio do algoritmo SVR Linear

O objetivo do SVR é minimizar coeficientes em vez do erro quadrático. O termo de erro é tratado nas restrições, onde definimos o erro absoluto menor ou igual ao limite de decisão (ϵ). Pode-se ajustar ϵ para obter a precisão desejado de nosso modelo. Nossa função objetivo e restrições são as seguintes:

- Minimizar: $\min \frac{1}{2} \|w\|^2$
- Restrições: $|y_i - w_i x_i| \leq \epsilon$

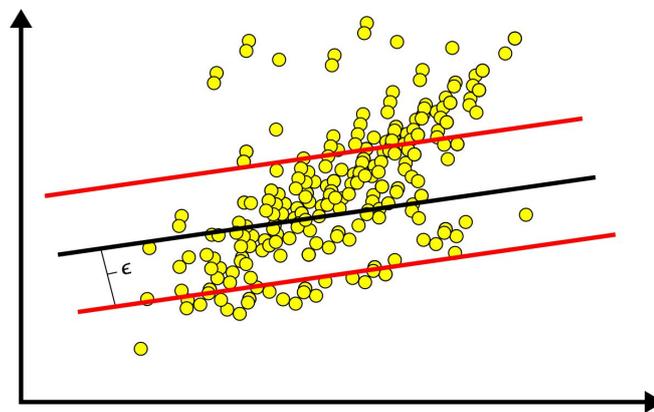
Figura 3.4: Representação SVR.



Fonte: Autor.

Considerando a distribuição de dados quaisquer da Figura 5, será utilizado os princípios do SVR simples para entender o funcionamento do algoritmo. O gráfico abaixo possui uma distribuição aleatória de dados. A linha preta representa a linha de melhor ajuste e as linhas vermelhas representam os limites de decisão (ϵ), que definimos como $\epsilon = 5$.

Figura 3.5: Exemplo ilustrativo



Fonte: Autor.

Percebe-se rapidamente que esse algoritmo não funciona para todos os pontos de dados. O algoritmo resolveu a função objetivo da melhor maneira possível, mas alguns dos pontos ainda estão fora das margens. Como tal, precisa-se levar em consideração a possibilidade de erros maiores que ϵ . Isso pode ser feito com variáveis de folga.

Observa-se na Figura 4 - (b) o caso de variáveis de folga, que para qualquer valor que esteja fora de ϵ , podemos denotar seu desvio da margem como ξ . Sabemos que

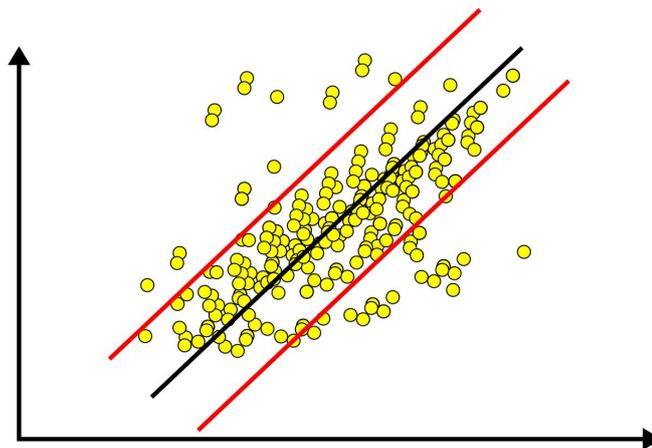
esses desvios têm potencial para existir, mas ainda assim gostaríamos de minimizá-los ao máximo. Assim, podemos adicionar esses desvios à função objetivo.

- Minimizar: $\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n |\xi|$
- Restrições: $|y_i - w_i x_i| \leq \epsilon + |\xi|$

A adição do hiperparâmetro adicional C , pode ser ajustável. A medida que C aumenta, a tolerância para pontos fora de ϵ também aumenta. Conforme C se aproxima de zero, a tolerância se aproxima de zero e a equação colapsa para forma simplificada. Para encontrar o melhor valor de C , pode-se utilizar a métrica $\% \epsilon$, que mede quantos pontos totais em do conjunto de teste estão dentro dos limites de decisão. Também é útil monitorar como o erro médio absoluto (MAE) varia com C .

Busca-se encontrar um valor de C que maximize $\% \epsilon$. Neste exemplo, o valor de melhor C , é $C = 6,13$.

Figura 3.6: SVR com $\epsilon = 5$ e $C = 6,13$



Fonte: Autor.

O gráfico acima mostra que o modelo SVR foi aprimorado com $\epsilon = 5$ e $C = 6,13$. Percebe-se que o algoritmo em globaliza mais pontos comparado ao modelo anterior (Figura 5).

O SVR é um algoritmo que permite escolher o quão tolerantes somos aos erros, tanto por meio de uma margem de erro aceitável (ϵ) quanto por meio do ajuste de nossa tolerância de ficar fora dessa taxa de erro aceitável.

3.2.2 Rede Neural Artificial (RNA)

As RNAs são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência (LEON F. DE CARVALHO, 2008). A RNA pode ser definida como uma estrutura complexa interligada por elementos de processamento simples (neurônios), que possuem a capacidade de realizar operações como cálculos em paralelo, para processamento de dados e representação de conhecimento (GRÜBLER, 2018). Seu primeiro conceito foi introduzido em 1943, e desde que foi desenvolvida, essa técnica vem sendo amplamente utilizada e validada por diversas áreas de pesquisa que pretendem antever acontecimentos e auxiliar na tomada de decisão. Atualmente, há diversas topologias das RNA's que buscam resolver diferentes tipos de problemas, tais como:

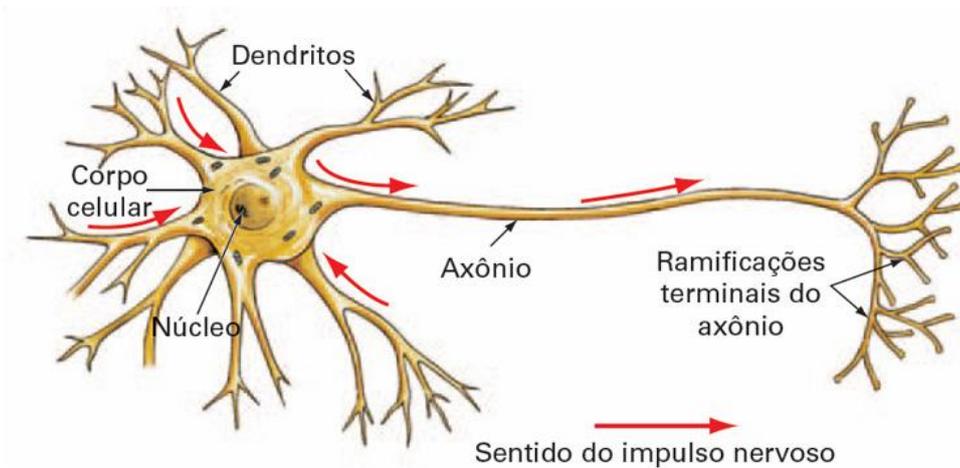
- Processamento de linguagem natural
- Reconhecimento de fala e imagens
- Previsão de valores

Para entendermos o funcionamento de redes neurais artificiais, vamos, antes, buscar compreender como funciona um neurônio biológico.

Neurônio biológico

O neurônio é uma célula especializada na transmissão de informações, pois nelas estão introduzidas propriedade de excitabilidade e condução de mensagens nervosas. O neurônio é constituído por 3 partes principais: a soma ou corpo celular, do qual emanam algumas ramificações denominadas de dendritos, e por uma outra ramificação descendente da soma, porém mais extensa, chamada de axônio. Nas extremidades dos axônios estão os nervos terminais, pelos quais é realizada a transmissão das informações para outros neurônios. Esta transmissão é conhecida como sinapse.

Figura 3.7: Representação simplificada do neurônio biológico.



Fonte: deeplearningbook.com

Cada neurônio possui um corpo central, diversos dendritos e um axônio. Os dendritos recebem sinais elétricos de outros neurônios através das sinapses, que constitui o processo de comunicação entre neurônios. O corpo celular processa a informação e envia para outro neurônio.

Observe na Figura 7 que a superfície de entrada é formada pelos dendritos e corpo celular e a superfície de saída do fluxo de informação pelo axônio. A transmissão de informação ocorre através de impulsos elétricos. O impulso elétrico é a mensagem que os neurônios transmitem uns aos outros, ou seja, é a propagação de um estímulo ao longo dos neurônios que pode ser qualquer sinal captado pelos receptores nervosos.

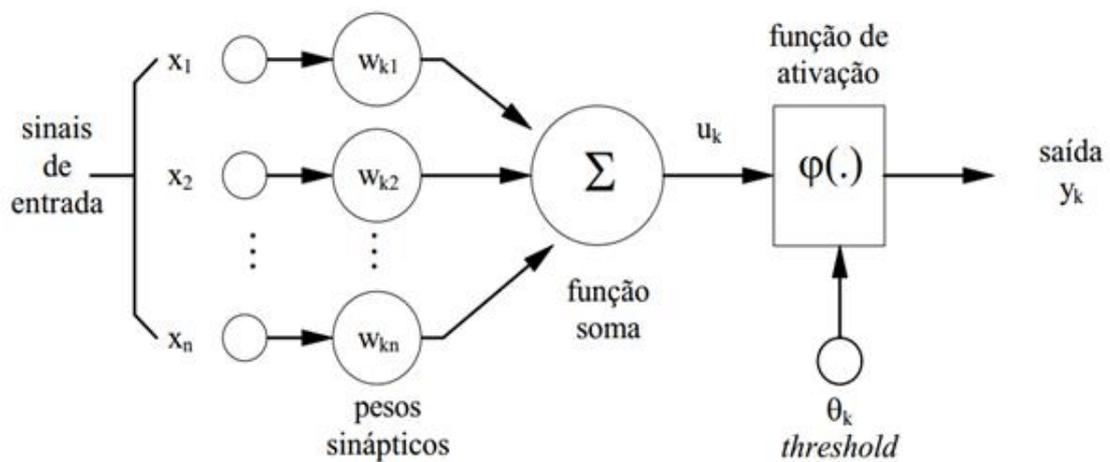
Os dendritos tem como função receber informações e conduzi-los até o corpo celular, onde a informação é processada e novos impulsos são gerados. Estes impulsos são transmitidos a outros neurônios, passando pelo axônio e atingindo os dendritos de neurônio seguintes. O corpo do neurônio é responsável por coletar e combinar informações vindas de outros neurônios.

O contato entre neurônio é chamado de sinapse. É através das sinapses que os neurônios se unem funcionalmente, formando as redes neurais. As sinapses funcionam como válvulas, sendo capazes de controlar a transmissão ou fluxo de informação na rede neural. O efeito das sinapses é variável e é esta variação que dá ao neurônio capacidade de adaptação.

Neurônio matemático (*Peceptron*)

Com base na estrutura e funcionamento do neurônio biológico, o modelo Perceptron foi o mais bem aceito e foi proposto por Warren McCulloch e Walter Pitts em 1943. Este modelo é um dos mais antigos e lida com um único neurônio, classificando o resultado de forma linear (GRÜBLER, 2018). A Figura 8 mostra um neurônio matemático, conhecido como modelo Perceptron.

Figura 3.8: Modelo *Peceptron*.



Fonte: ResearchGate.

Na figura 8 temos os sinais de entrada (x_n), são os dados normalmente normalizados que alimentam o modelo preditivo. Esses dados são ponderados por pesos sinápticos, determinados durante o treinamento da rede e são denotados por (w_{kn}) onde k é um índice que denota uma camada anterior da rede e n representa a posição do peso para um respectivo dado de entrada. Posteriormente, os resultados ponderados passam pela função soma, onde formam um conjunto de entrada afim de produzir um potencial de ativação. Este processo pode ser representado matematicamente pela equação (3.5).

$$U_k = \sum w_{kn} \cdot x_n \quad (3.5)$$

Após os dados passarem pela função soma, o valor somado é submetido a uma função de ativação (φ) que determina se o neurônio ativa ou não ativa, dependendo da informação determinada pelos pesos sinápticos. Caso a o valor da função de ativação aplicada no valor somado for maior que o viés de ativação (b_k), a informação chega na

saída do neurônio, caso contrário a informação é retida no mesmo. A equação (3.6) representa esta ação.

$$\varphi(U_k) = \begin{cases} 1, & U_k \geq b_k \\ 0, & U_k \leq b_k \end{cases} \quad (3.6)$$

onde $\varphi(U_k)$ é a função de ativação aplicada no valor do somatório U_k . Na próxima seção vamos falar sobre os tipos de função de ativação.

Função de Ativação

A função de ativação é um componente matemático incluído na estrutura de redes neurais artificiais a fim de permitir a solução de problemas complexos. Ela é responsável por difundir ou não difundir a informação para os outros neurônios que constituem uma rede neural. Neste trabalho, será realizada uma breve descrição de 4 tipos de função de ativação, que são as seguintes:

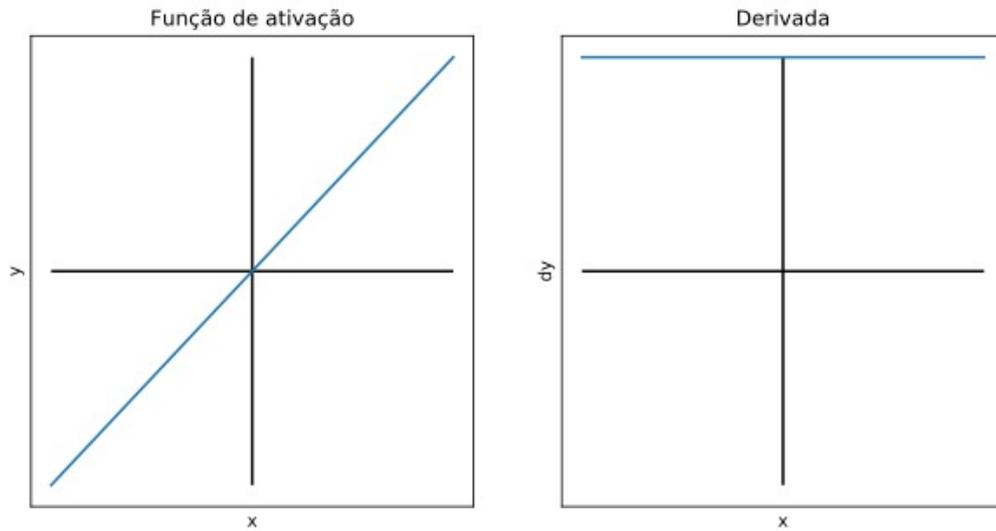
- Função Linear
- Função Sigmóide
- Função Retificadora
- Função Tangente Hiperbólica

Função Linear

É a função de ativação mais simples, ela apenas aplica um fator de multiplicação ao valor que recebe. Podemos definir a função como:

$$\varphi(U_k) = a \cdot U_k \quad (3.7)$$

Essa função é limitada em sua capacidade de compreender relações mais complexas entre os dados, justamente por ser linear (CECCON, 2020). Além disso, sua derivada é constante, o que faz com que o gradiente a cada etapa de *backpropagation* seja constante. E este é um grande problema, pois não estamos realmente melhorando o erro, já que o gradiente é o mesmo. Na camada de saída, a função de ativação linear pode ser utilizada em problemas de regressão, já que produz resultados em todo o domínio dos números reais.

Figura 3.9: Função Linear.

Fonte: aiexpert.

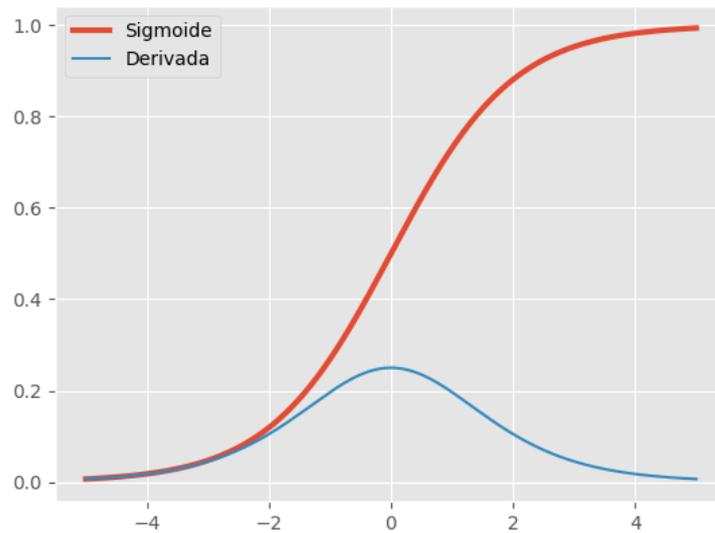
Função Sigmóide

A função sigmóide e sua derivada são dadas, respectivamente, por:

$$\varphi(U_k) = \frac{1}{1 + e^{U_k}} \quad (3.8)$$

$$\varphi'(U_k) = \varphi(U_k)(1 - \varphi(U_k)) \quad (3.9)$$

Em virtude de serem biologicamente mais plausíveis, a equação (3.8) era a mais utilizada em RNAs. Como neurônios biológicos funcionam de forma binária (ativando vs não ativando), a função sigmoide é uma boa forma de modelar esse comportamento, já que assume valores apenas entre 0 (não ativação) e 1 (ativação). No entanto, observa-se o comportamento de sua derivada na Figura 9, pode-se ver que ela satura para valores acima de 5 e abaixo de -5. Com essas derivadas tendendo a zero, a propagação do gradiente desvanece nessas regiões, causando dificuldades no treinamento.

Figura 3.10: Função sigmóide.

Fonte: matheusfacure.github.io.

A função sigmóide ainda pode ser utilizada na saída da RNA, para modelar variáveis binárias. Além disso, alguns modelos probabilísticos, redes neurais recorrentes e alguns modelos não supervisionados tem restrições que tornam uma função sigmoidal necessária.

Função Retificadora (ReLU)

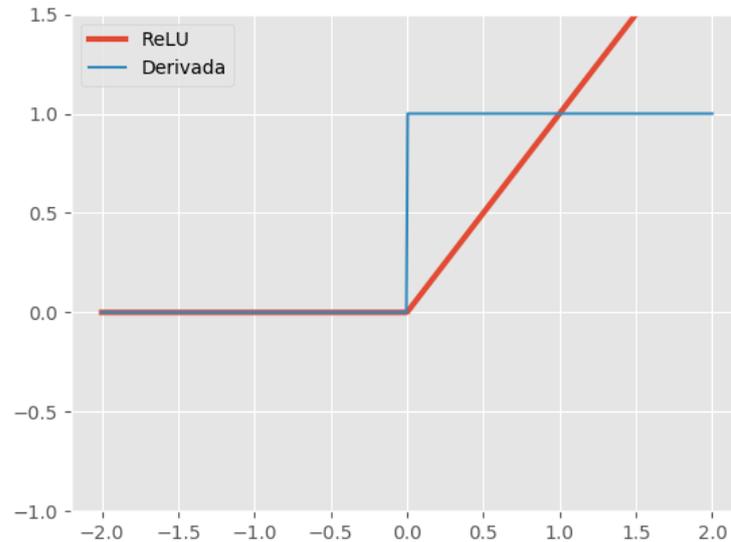
As Redes com a função ReLU são fáceis de otimizar, já que a ReLU é extremamente parecida com a função identidade. A única diferença, segundo, é que a ReLU produz zero em metade do seu domínio. Como consequência, as derivadas se mantêm grandes enquanto a unidade estiver ativa. A função retificada (ReLU) e sua derivada são dadas, respectivamente, por:

$$\varphi(U_k) = \max\{0, U_k\} \quad (3.10)$$

$$\varphi'(U_k) = \begin{cases} 1, & \text{se } U_k \geq 0 \\ 0, & \text{c.c.} \end{cases} \quad (3.11)$$

A derivada da função ReLU, são estáveis, pois assumem 1 para $U_k \geq 0$ e 0 para $U_k \leq 0$. Isso implica em uma função de ativação mais eficiente.

Figura 3.11: Função retificadora



Fonte: matheusfacure.github.io

No entanto, a função Relu possui uma desvantagem, é que unidades tendem a ‘morrer’ durante o treinamento, um fenômeno que faz com que o neurônio passe a produzir apenas zeros. Isso acontece quando a soma ponderada antes da aplicação da ReLU se torna negativa, fazendo com que a unidade produza zero. Nessa região, a derivada também é zero, fazendo com que os parâmetros w 's da unidade deixem de ser atualizados com gradiente descendente.

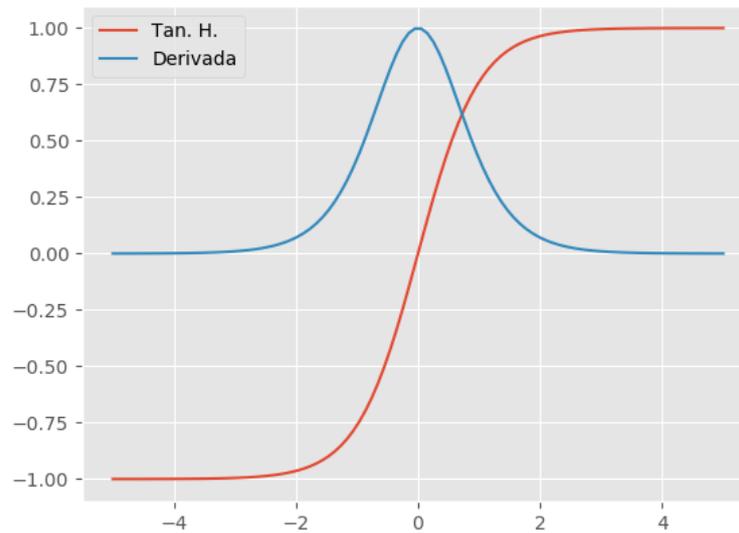
Função Tangente Hiperbólica

A função de ativação tangente hiperbólica é a sucessora da sigmóide, uma vez que seus valores de saída tem média zero, diferentemente de sua antecessora. A função e sua derivada são dadas, respectivamente, por:

$$\varphi(U_k) = \frac{1 - e^{2U_k}}{1 + e^{-2U_k}} \quad (3.12)$$

$$\varphi'(U_k) = 1 - \left(\frac{1 - e^{2U_k}}{1 + e^{2U_k}}\right)^2 \quad (3.13)$$

Figura 3.12: Função tangente hiperbólica.



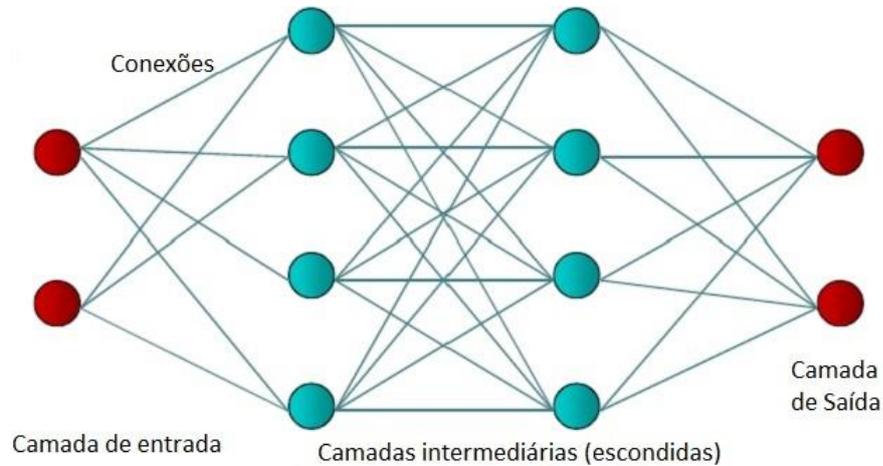
Fonte: matheusfacure.github.io.

Observa-se figura 11 que as saturações ainda estão presentes, mas o valor da derivada é maior, chegando ao máximo de 1 quando $U_k = 0$. Quando há grandes camadas ocultas de redes neurais recomenda-se utilizar a função tangente hiperbólica.

3.2.3 *Multi-Layer Perceptron* (MLP)

Uma MLP é uma rede neural artificial composta por mais de um *Perceptron*. Sua arquitetura é formada por uma camada de entrada para receber o sinal, uma camada de saída que toma uma decisão ou previsão sobre a entrada, e entre esses dois, possui pelo menos uma camada intermediária, conhecida como camada de neurônios oculta. Para que a MLP não seja reduzida a uma *Perceptron*, deve-se usar uma função de ativação diferenciável e com fator de não-linearidade suave. Para isso, utiliza-se as funções de ativação. Um modelo de MLP é demonstrado na Figura 13.

Figura 3.13: Arquitetura de uma MLP.



Fonte: ResearchGate.

A informação nessa topologia de rede é passada em um único sentido, arquitetura chamada de *feedforward*. Já seu treinamento é feito por meio do algoritmo de *backpropagation*, de forma supervisionada, em que deseja-se encontrar o mínimo local ou global da função do erro entre entrada e a saída (ACADEMY, 2020).

As redes *feedforward* são envolvidas em dois movimentos, uma constante de ida e volta. Na passagem para a frente, o fluxo de sinal se move da camada de entrada através das camadas ocultas para a camada de saída e a decisão da camada de saída é medida em relação às saídas esperadas.

Na passagem para trás, usando o *backpropagation* e a regra da cadeia (Chain Rule), derivadas parciais da função de erro dos vários pesos e bias são reproduzidos através do MLP. Esse ato de diferenciação nos dá um gradiente, ao longo do qual os parâmetros podem ser ajustados à medida que movem o MLP um passo mais perto do erro mínimo. A rede continua o processo até que o erro não possa mais ser reduzido. Este estado é conhecido como convergência.

O algoritmo de aprendizado da MLP é composto de 4 passos:

- 1º Passo: Inicialização
 - Atribuir valores aleatórios para os pesos e limites
 - Escolha dos valores iniciais influencia o comportamento da rede
 - Na ausência de conhecimento prévio os pesos e limites devem ter valores iniciais aleatórios e pequenos uniformemente distribuídos

- 2º Passo: Ativação
 - Calcular os valores dos neurônios da camada oculta
 - Calcular os valores dos neurônios da camada de saída
- 3º Passo: Treinar os Pesos
 - Calcular os erros dos neurônios das camadas de saída e oculta
 - Calcular a correção dos pesos
 - Atualizar os pesos dos neurônios das camadas de saída e oculta uniformemente distribuídos
- 4º Passo: Iteração
 - Repetir o processo a partir do passo 2 até que satisfaça o critério de erro

Capítulo 4

MÉTODO

Neste capítulo é apresentado o método proposto para o desenvolvimento deste trabalho, partindo da coleta e pré-processamento dos dados, incluindo as técnicas aplicadas para evitar problemas de treinamento, como o sobre-ajuste, a escolha dos algoritmos de regressão, a configuração dos parâmetros para cada algoritmo e a métrica de avaliação dos modelos utilizadas.

4.1 AQUISIÇÃO E DESCRIÇÃO DOS DADOS

O banco de dados de baterias de íon-lítio utilizado neste trabalho foram adquiridos do repertório online da *NASA Ames Prognostics Center of Excellence* (PCoE). No site da NASA na página onde estão contidas os PCoE Datasets e selecionamos o quinto conjunto de dados (*Battery Data Set*). Realizou-se então a aquisição de um arquivo (*Download Battery Data Set 6*) em formato MAT contendo os dados referentes a etapa de carga, descarga e impedância (neste trabalho utiliza-se somente os dados da etapa de descarga, pois é o único que fornece o parâmetro da capacidade). A tabela da etapa de descarga contem os valores de tensão nos terminais da bateria (*voltage_measured*), corrente de saída (*current_measured*), os valores de temperatura da bateria em °C (*temperature_measured*), a tensão (*voltage_load*) e corrente de carga (*current_load*), tempo do experimento (*time*) e os valores de capacidade da bateria (*capacity*), conforme representado na tabela 1.

As baterias foram submetidas a três perfis de operação diferentes (carga, descarga e impedância) a temperatura ambiente. A etapa carga foi realizada a uma corrente

Tabela 4.1: Colunas de dados de descarga do repertório da NASA.

Voltage_measured	Current_measured	Temperature_measured	Current_load	Voltage_load	Time	Capacity
[[4.199359521791473, 4.199497433806136, 3.9856...	[[[-0.0018658918833680202, -0.00213942698980712...	[[23.93704394613529, 23.92407356409745, 24.004...	[[[-0.0004, -0.0004, -2.0, -2.0, -2.0, -2.0, -2...	[[[0.0, 4.215, 3.003, 2.987, 2.972, 2.963, 2.95...	[[[0.0, 16.781, 35.702999999999996, 53.781, 71....	[[[1.89105229539079]]
[[4.198257409594461, 4.198510349854315, 3.9902...	[[[0.0007130504619326776, -0.002120291194335483...	[[24.267087815290243, 24.261106709876195, 24.3...	[[[-0.0006, -0.0004, -2.0, -2.0, -2.0, -2.0, -2...	[[[0.0, 4.214, 3.007, 2.992, 2.978, 2.969, 2.96...	[[[0.0, 16.672, 35.703, 53.828, 71.891, 90.047,...	[[[1.880637027686859]]
[[4.198280074112568, 4.198222961146791, 3.9921...	[[[-0.0025133817380137142, -0.00274772782733043...	[[24.328571506102985, 24.3190033925327, 24.386...	[[[-0.0004, -0.0004, -2.0, -2.0, -2.0, -2.0, -2...	[[[0.0, 4.215, 3.009, 2.994, 2.98, 2.971, 2.97,...	[[[0.0, 16.796999999999997, 35.766, 53.891, 72....	[[[1.8806626717011388]]

Fonte: ti.arc.nasa.gov.

constante de 1,5 A até a tensão de corte alcançar 4,2 V e então continuar no modo de tensão constante até a corrente de carregamento cair para 20 mA. A descarga também foi realizada a corrente contante de 2 A até a tensão cair para 2,7 V, 2,5 V, 2,2 V e 2,5 V para as baterias 05, 06, 07 e 18, respectivamente. O teste de impedância foi realizado usando um Espectrômetro de Impedância Eletroquímica (EIS) ajustando a frequência de 0,1 kHz para 5kHz. Repetir as etapas de carga e descarga resulta no aceleração do envelhecimento da bateria. O experimento foi encerrado quando as baterias alcançaram o critério *end-of-life* (EOL), que é a perda de 30% da capacidade nominal da bateria, ou seja, de 2 Ah para 1.4 Ah.

4.2 PRÉ-PROCESSAMENTO DOS DADOS

Após importar os dados da etapa de descarga algumas tarefas de pré-processamento foram realizadas como a seleção de variáveis, transformação das tabelas e normalização.

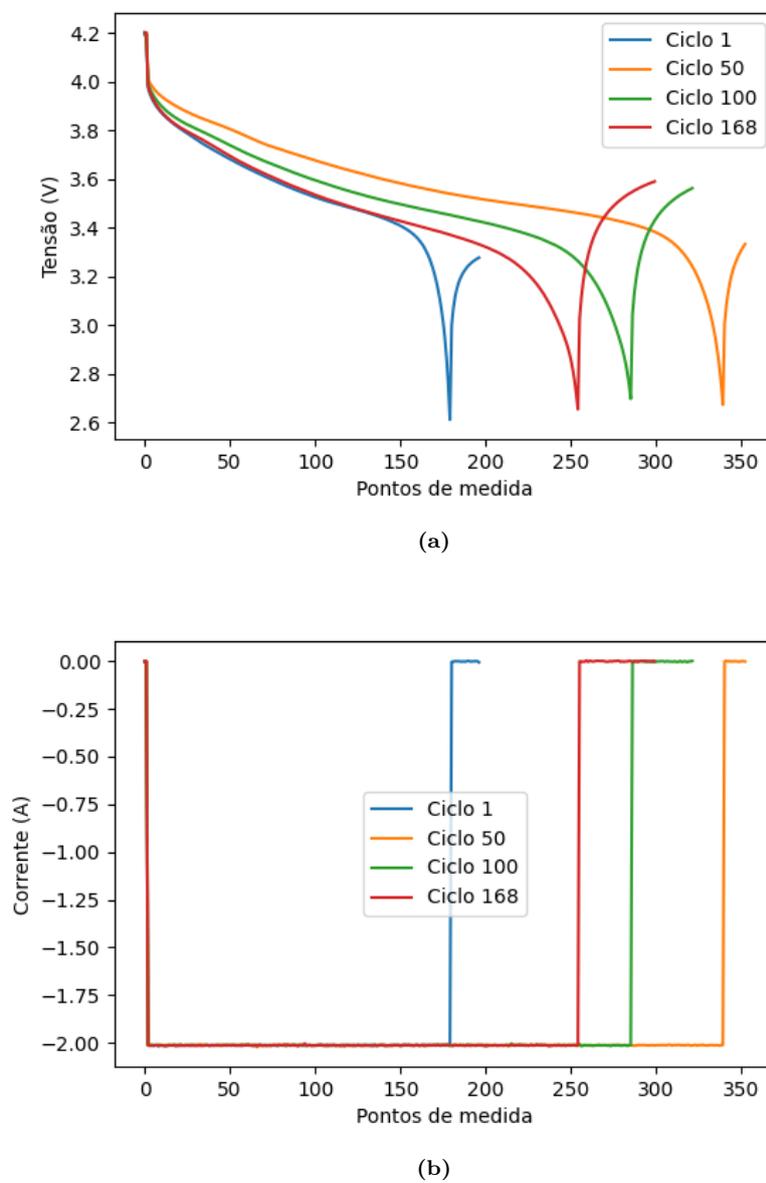
- **Seleção de variáveis:**

Apesar do conjunto de dados fornecer sete parâmetros sobre a bateria. Decidiu-se trabalhar apenas com as mais utilizadas em trabalhos que buscam prever o estado de saúde da bateria (NUHIC et al., 2013)(WU; LU; PRAKASH, 2000). As variáveis escolhidas são tensão (*voltage_measured*), corrente (*current_measured*), temperatura (*temperature_measured*), tempo (*time*) e capacidade (*capacity*).

- **Preparação da base de dados**

Foi realizado uma transformação nos dados com base no comportamento da média das variáveis (com exceção do tempo que utilizou-se o tempo total de cada ciclos). Para cada ciclo (cada linha da tabela) a média e o tempo de experimento foram extraídos, dando forma a uma tabela de dado como mostra a tabela 2. A figura 14 mostra curva de tensão e corrente, que demonstra as variações nas médias dos vetores de tensão e corrente ao longo dos ciclos.

Figura 4.1: Perfil da curva de tensão e corrente durante a etapa de descarga da bateria 5 para os ciclos 1, 50, 100 e 168: (a) tensão de descarga, (b) corrente de descarga.



Fonte: autor.

A partir dos bancos de dados realizou-se a transformação dos dados como mostra a tabela 2.

Tabela 4.2: Novas colunas de dados de descarga realizada da extração de parâmetros do banco de dados original.

Ciclo	Tensão média (V)	Corrente média (A)	Temperatura média (°C)	Tempo total (s)	Capacidade (Ah)	SOH (%)
1	3,530	-1,819	32,572	3,690	1856,487	92,824
2	3,537	-1,818	32,725	3,672	1846,327	92,316
3	3,544	-1,816	32,643	3,652	1835,349	91,767
4	3,544	-1,826	32,515	3,632	1835,263	91,763
5	3,542	-1,826	32,382	3,629	1834,646	91,732
...
164	3,466	-1,674	33,276	2,793	1293,464	64,673
165	3,469	-1,667	33,321	2,793	1288,003	64,400
166	3,467	-1,667	33,373	2,792	1287,453	64,373
167	3,471	-1,689	33,714	2,802	1309,015	65,451
168	3,475	-1,698	33,865	2,820	1325,079	66,254

Fonte: ti.arc.nasa.gov.

- **Normalização**

As colunas foram normalizadas utilizando a normalização *StandardScaler*, nessa técnica de normalização todos os valores são padronizados removendo a média e escalonando para variância da unidade, por meio da equação (4.1). Onde u e s são média e desvio padrão, respectivamente.

$$z_i = \frac{x_i - u}{s}. \quad (4.1)$$

4.3 DESCRIÇÃO DO PROTOCOLO DE EXPERIMENTO

Nesta seção é descrito o procedimento experimental adotado para realização dos testes de comparação entre os algoritmos de predição de estado de saúde da bateria. Nesse sentido, é apresentado a descrição do procedimento, a configuração dos parâmetros para cada algoritmo e o modelo utilizado como métrica de avaliação.

4.3.1 Descrição Experimental

As tecnologia usadas neste experimento foram linguagem de programação Python, biblioteca scikit-learn, um processador Intel Core i5-7200U e memória RAM de 8,00GB. Os experimentos foram organizados considerando dois cenários, o primeiro somente para os algoritmos de aprendizagem de máquinas, com uma abordagem global dos dados, e o outro para os algoritmos de aprendizagem de máquinas e o algoritmo de série temporal com uma abordagem mais local dos dados. Na primeira parte, os dados da bateria 5 foram utilizados por completo como conjunto de treinamento para os algoritmos SVR e MLP (KHUMPROM; YODO, 2019). Os dados de validação nas previsões foram utilizados os dados das baterias 6, 7 e 18. Na segunda parte, por conta da série temporal o conjunto de dados de treinamento foi composto por dois terços dos dados de cada respectiva bateria (6, 7 e 18) que foi realizado a predição.

4.3.2 Configuração dos Parâmetros dos algoritmos

Na realização do experimento com os algoritmos de aprendizagem de máquinas buscou-se a melhor combinação parâmetros através da função *GridSearch()* da biblioteca scikit-learn, a qual realiza diversas combinações entre os parâmetros fornecidos e realiza a validação cruzada de forma. No algoritmo de série temporal, a função utilizada foi *sarima_grid_search()*, que buscam parâmetros para compreender a tendência dos dados. O resultados desses parâmetros podem ser

Tabela 4.3: Resultados dos melhores parâmetros utilizados nos algoritmos.

Algoritmos	Parâmetros
Support Vector Regression	C = 1001 degree = 3 epsilon = 0.0003 gamma = 0.008 kernel = 'rbf'
Multi-Layer Perceptron	activation = 'identity' hidden_layer_sizes = (25) learning_rate = 'constant' solver= 'lbfgs'
Autoregressive Integrated Moving Average	p = 1 d = 1 q = 1 P = 0 D = 1 Q = 1 m = 15

Fonte: autor.

4.4 MÉTRICA DE AVALIAÇÃO

Nesta seção vamos apresentar métricas adotada neste trabalho para avaliar nossos algoritmos de regressão.

- **Raiz quadrada do erro médio (RMSE)**

O RMSE é uma métrica frequentemente usada para medir a diferença entre os valores previstos por um modelo e os valores reais. O RMSE é sempre positivo, e um valor 0 representa um ajuste perfeito aos dados. A sua representação matemática é dada pela equação (4.2).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n |e_t|} \quad (4.2)$$

Capítulo 5

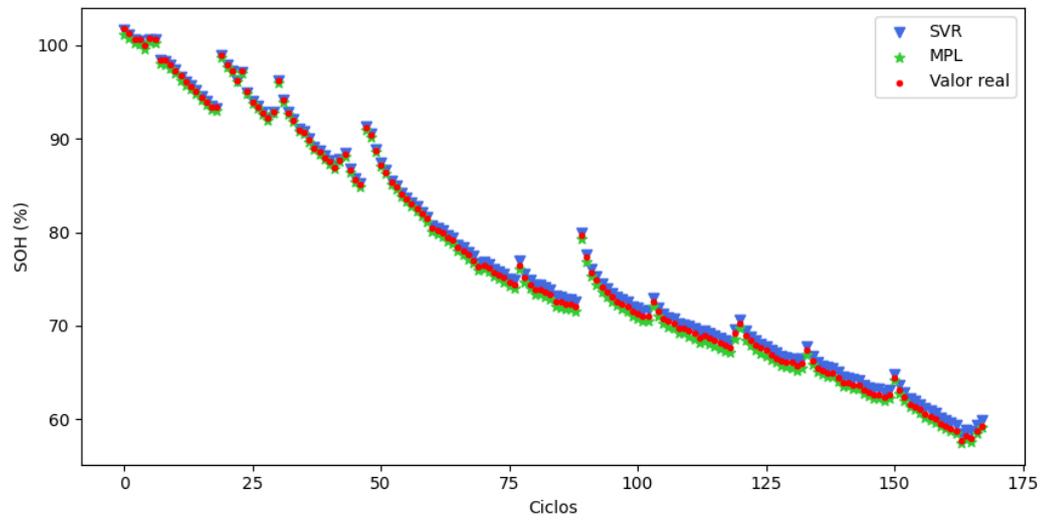
RESULTADOS E DISCUSSÃO

A motivação para propor uma comparação entre os métodos de regressão de aprendizagem de máquinas e o método de séries temporais, baseou-se na importância que o estudo de algoritmos de previsão do estado de saúde de bateria vem ganhando nos últimos anos.

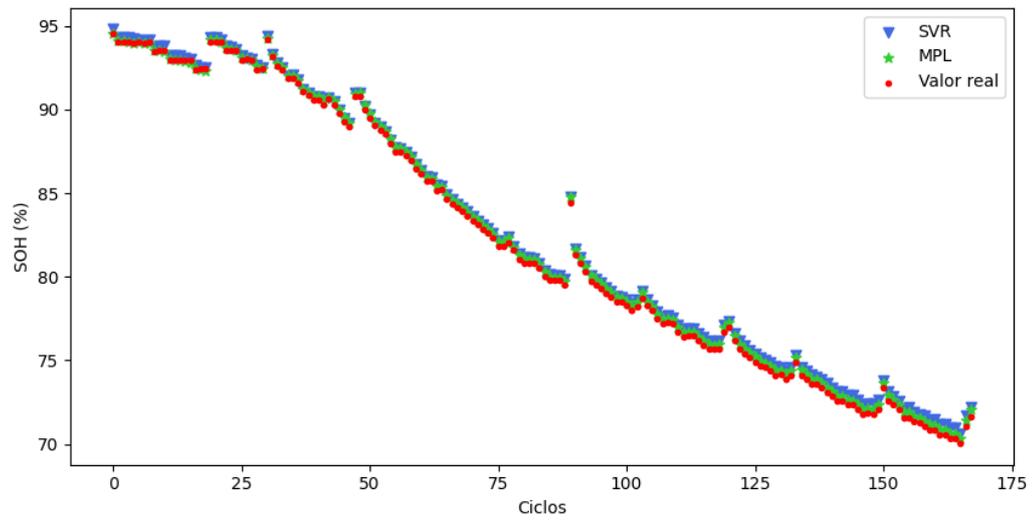
Neste capítulo destaca-se os resultados obtidos durante o desenvolvimento deste trabalho. Inicialmente apresenta-se os resultados do experimento I, que realiza a comparação entre os algoritmos de aprendizagem de máquinas e, posteriormente, no experimento II realiza-se a comparação entre os algoritmos de aprendizagem de máquinas e séries temporais.

5.0.1 RESULTADOS DO EXPERIMENTO I

Nesta seção são apresentados os resultados obtidos a partir dos experimentos realizados com os dados da NASA aplicados aos algoritmos de regressão SVR e MLP. Os dois modelos foram treinados com o mesmo conjunto de treinamento (bateria 5) e testado nos dados das baterias 6, 7 e 18. A figura 16 mostra os resultados da previsão do SOH para as baterias 6, 7 e 18, para os algoritmos SVR e MLP.

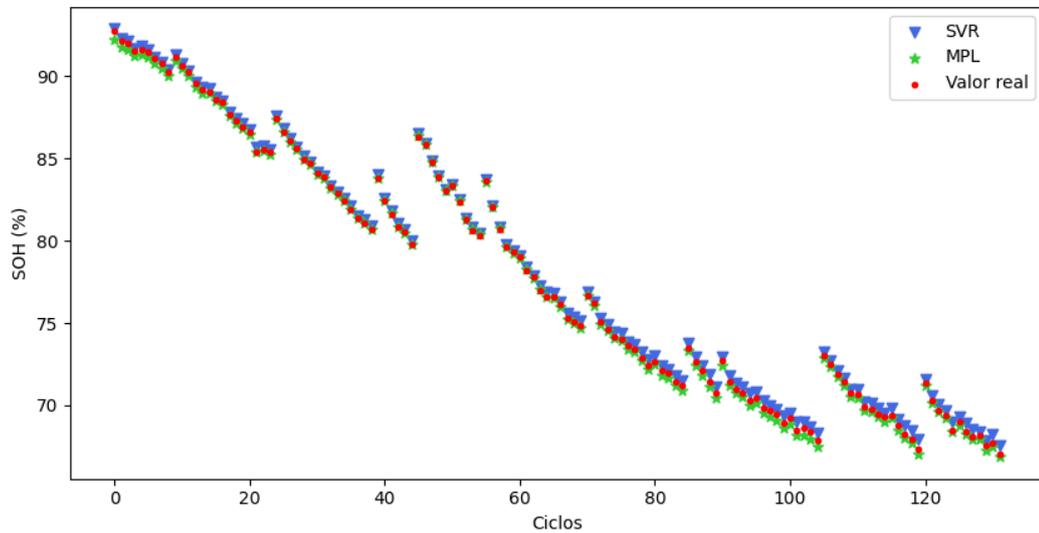


(a) Bateria 6



(b) Bateria 7

Figura 5.2: Estimando o SOH com os algoritmos SVR e MLP para as baterias (a) 6, (b) 7 e (c) 18.



(c) Bateria 18

Fonte: autor.

Com base nos gráficos é possível observar que os dois algoritmos de aprendizagem de máquinas realizaram previsões estatísticas muito próximas dos valores reais. A tabela 4 apresenta os valores de RMSE dos algoritmos para cada bateria. Na bateria 6 observa-se que tanto o SVR e o MLP obtiveram valores próximos, 0.407 e 0.419, respectivamente. Nos dados da bateria 7 observa-se uma melhora no desempenho dos dois algoritmos, desta vez o RMSE do MLP foi menor comparado ao SVR, o que indica melhores previsões, com 0.241 para o MLP e o 0.385 para o SVR. Por fim, na bateria 18, novamente observa-se uma melhora nas previsões nos dois algoritmos, com destaque para o MLP.

Tabela 5.1: RMSE da estimativa do SOH usando SVR e MLP de todas as baterias.

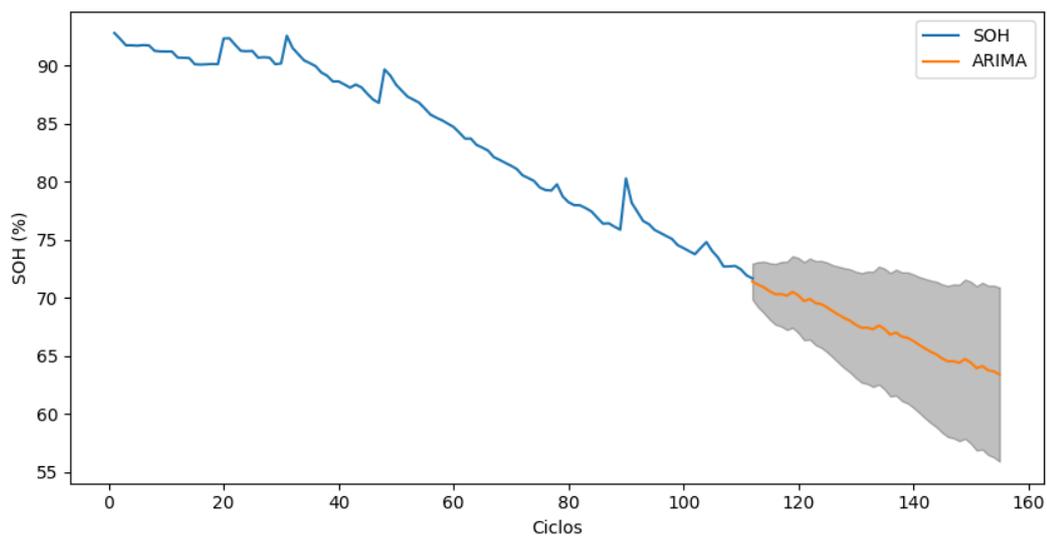
Bateria	RMSE	
	SVR	MLP
6	0,407	0,419
7	0,385	0,241
18	0,280	0,201

Fonte: autor.

5.0.2 RESULTADOS DO EXPERIMENTO II

Neste segundo experimento há algumas mudanças, além dos algoritmos de aprendizagem de máquinas, também aplicou-se o algoritmo de séries temporais (ARIMA). Para que a comparação entre os algoritmos ficasse justa o conjunto de treinamento foi organizado de maneira similar para os algoritmos de aprendizagem de máquina e de séries temporais. As series temporais funcionam de forma diferente e necessitam que o conjunto de treinamento sejam os valores passados da mesma bateria que estiver realizando a previsão. A figura 17 representa um exemplo de previsão usando séries temporais. O sombreado ao redor da linha laranja representa a margem de erro.

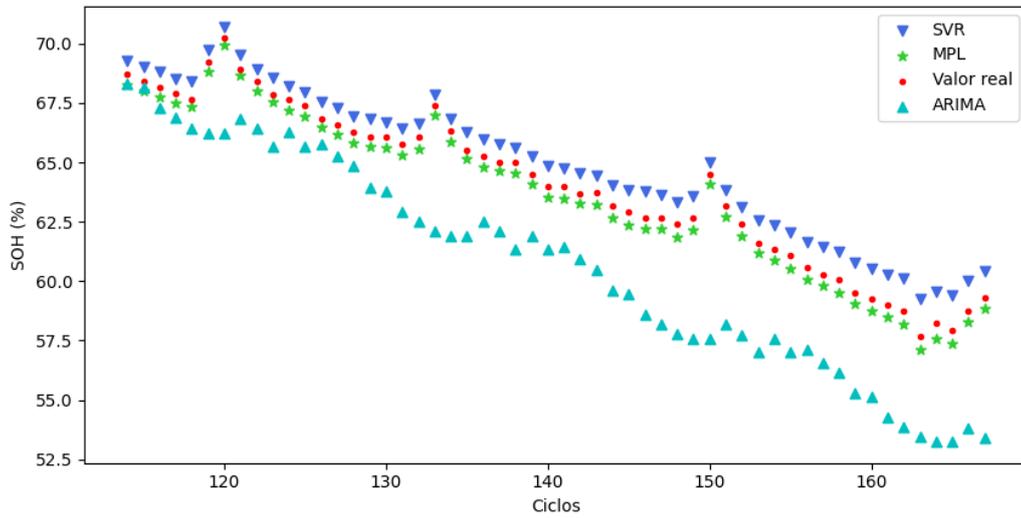
Figura 5.3: Um exemplo de previsão do comportamento do SOH por série temporal.



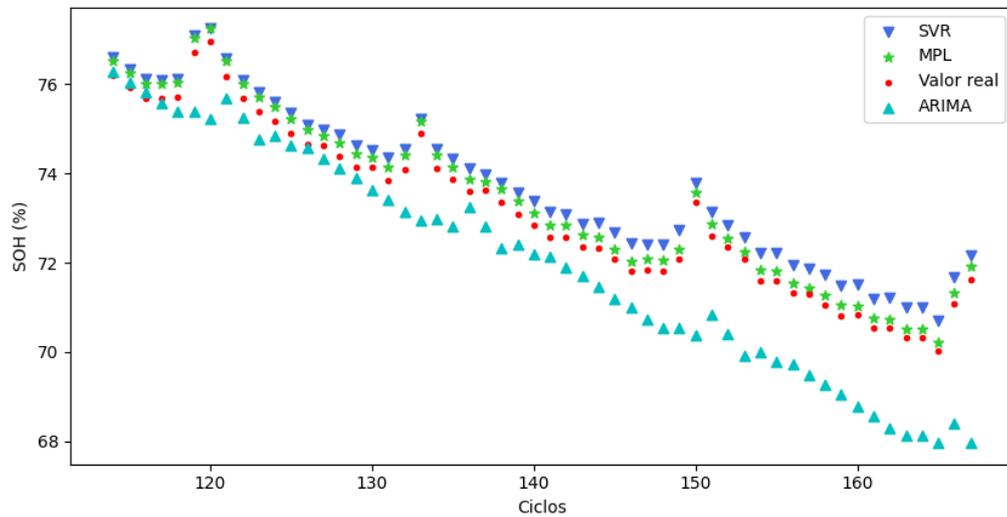
Fonte: autor.

Para realizar este experimento II, para cada previsão de uma determinada bateria, o conjunto de treinamento foi composto por 2/3 dos dados da respectiva bateria. Os dados das baterias 6 e 7 totalizam 168 ciclos (ou 168 linhas), então os primeiros 112 ciclos foram usados como conjunto de treinamento e o restante 56 para teste. No caso da bateria 18, o numero total de ciclos são de 132, logo 88 ciclos foram utilizados como conjunto de treinamento e o restante 44 para teste.

A figura 19 representa as previsões do SOH para as baterias (a) 6, (B) 7 e (c) 18, usando os algoritmos SVR, MLP e ARIMA. Na tabela 5 é possível observar os valores de RMSE para cada algoritmo de previsão.

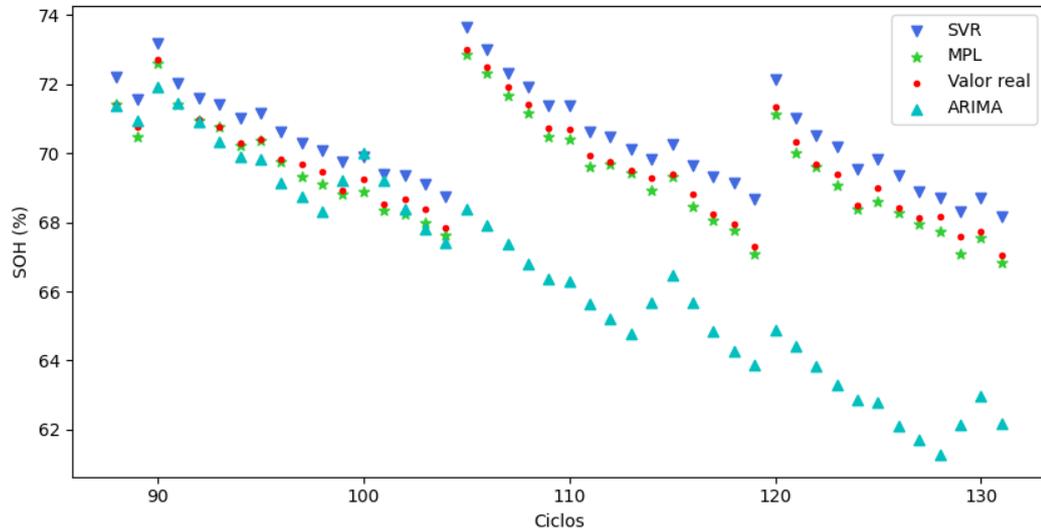


(a) Bateria 6



(b) Bateria 7

Figura 5.5: Estimando o SOH com os algoritmos SVR, MLP e ARIMA para as baterias (a) 6, (b) 7 e (c) 18.



(c) Bateria 18

Fonte: autor.

Tabela 5.2: RMSE da estimativa do SOH usando SVR, MLP e ARIMA de todas as baterias.

Bateria	RMSE		
	SVR	MLP	ARIMA
6	0,888	0,462	3,625
7	0,523	0,264	1,434
18	0,780	0,252	3,939

Fonte: autor.

Com base nos resultados observa-se que o algoritmo ARIMA apresentou previsões de menos acurácia comparado com os algoritmos de aprendizagem de máquinas. Na figura 19 fica evidente que o comportamento do ARIMA não acompanhou as variações nos valores de SOH tão bem quanto os algoritmos SVR e MLP, e percebe-se uma tendência linear em suas previsões. Na Tabela 5 os valores RMSE confirmam que o algoritmo ARIMA obteve o pior desempenho nas três baterias, tendo o melhor desempenho na bateria 7 com RMSE de 1,434. Enquanto que para os algoritmos de aprendizagem de máquinas o MLP se destacou com os menores valores de RMSE em todas as baterias,

mesmo com a mudança e a redução do conjunto de dados. O SVR teve seu desempenho afetado a mudança no conjunto de treinamento, no entanto não apresentou valores muito altos de RMSE .

Considerações finais

Neste trabalho temos duas conclusões. A primeira referente ao experimento I, ao analisarmos os resultados obtidos, verificamos que o algoritmo MLP obteve melhor desempenho comparado ao SVR, em termos dos valores do RMSE. No experimento II, com base nos dados, observamos que o algoritmo de séries temporais obteve o pior desempenho, em termos de RMSE, enquanto que o MLP novamente se destacou como sendo superior aos métodos de SVR e ARIMA, mesmo com as mudanças e diminuições no conjunto de treinamento. Acreditamos que o método de séries temporais tenha desempenhado dessa forma por ser um modelo mais simples de séries temporais, que se baseia somente na variável de predição, enquanto que o SVR e MLP possuem seis variáveis de entrada para explicar o comportamento da variável de predição. Com isso, para predições do estado de saúde de bateria os algoritmos de aprendizagem de máquinas obtiveram melhor desempenho. No entanto, as séries temporais podem ser muito eficientes, quando somente a variável de previsão (SOH) for conhecida.

Referências bibliográficas

ACADEMY, D. S. **Capítulo 4 - O Neurônio, Biológico e Matemático - Deep Learning Book**. 2020. Disponível em: <<https://www.deeplearningbook.com.br/o-neuronio-biologico-e-matematico/>>.

BERG, H.; GUSTAFSSON, T.; KELDER, E.; THOMAS, J. S. **Structural aspects of lithium insertion in transition metal oxide electrodes**. v. 68. [S.l.], 1997. p. 24–29.

BERTOLO. **Common Approaches to Univariate Time Series**. 2021. Disponível em:

<<http://www.bertolo.pro.br/MetodosQuantitativos/Previsao/pmc444.htm#AR>>.

CECCON, D. **Funções de ativação: definição, características, e quando usar cada uma – IA Expert Academy**. 2020. Disponível em:

<<https://iaexpert.academy/2020/05/25/funcoes-de-ativacao-definicao-caracteristicas-e-quando-usar-cada-uma/>>.

DEISS, E.; HÄRINGER, D.; NOVÁK, P.; HAAS, O. **Modeling of the charge-discharge dynamics of lithium manganese oxide electrodes for lithium-ion batteries**. v. 46. [S.l.], 2001. p. 4185–4196. Disponível em:

<www.elsevier.com/locate/electacta>.

GRÜBLER, M. **Entendendo o funcionamento de uma Rede Neural Artificial | by Murillo Grübler | aibrasil Medium**. 2018. Disponível em:

<<https://medium.com/brasil-ai/entendendo-o-funcionamento-de-uma-rede-neural-artificial-4463fcf44dd0>>.

HUOTARI, M.; ARORA, S.; MALHI, A.; FRÄMLING, K. Comparing seven methods for state-of-health time series prediction for the lithium-ion battery packs of forklifts.

Applied Soft Computing, Elsevier Ltd, v. 111, nov. 2021. ISSN 15684946. DOI: 10.1016/j.asoc.2021.107670.

JOHNSON, B. A.; WHITE, R. E. **Characterization of commercially available lithium-ion batteries**. v. 70. [S.l.], 1998. p. 48–54.

KHUMPRON, P.; YODO, N. A data-driven predictive prognostic model for lithium-ion batteries based on a deep learning algorithm. **Energies**, MDPI AG, v. 12, 4 fev. 2019. ISSN 19961073. DOI: 10.3390/en12040660.

LEON F. DE CARVALHO, A. P. de. **Redes Neurais Artificiais**. 2008. Disponível em: <<https://sites.icmc.usp.br/andre/research/neural/>>.

MOSHTEV, R.; JOHNSON, B. **State of the art of commercial Li ion batteries**. v. 91. [S.l.], 2000. p. 86–91. Disponível em: <www.elsevier.com/locate/jpowsour>.

NG, M.-F.; ZHAO, J.; YAN, Q.; CONDUIT, G. J.; SEH, Z. W. **Predicting the State of Charge and Health of Batteries using Data-Driven Machine Learning**. [S.l.], 2020.

NUHIC, A.; TERZIMEHIC, T.; SOCZKA-GUTH, T.; BUCHHOLZ, M.; DIETMAYER, K. Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods. **Journal of Power Sources**, Elsevier B.V, v. 239, p. 680–688, 2013. ISSN 03787753. DOI: 10.1016/j.jpowsour.2012.11.146. Disponível em: <<http://dx.doi.org/10.1016/j.jpowsour.2012.11.146>>.

SHARP, T. **An Introduction to Support Vector Regression (SVR) | by Tom Sharp | Towards Data Science**. 2020. Disponível em: <<https://towardsdatascience.com/an-introduction-to-support-vector-regression-svr-a3ebc1672c2>>.

SILVA, I. V. G. da. **Previsão de Vento para Geração de Energia Elétrica**, 2010.

VARELA, H.; HUGUENIN, F.; MALTA, M.; TORRESI, R. M. **MATERIAIS PARA CÁTODOS DE BATERIAS SECUNDÁRIAS DE LÍTIO**. v. 25. [S.l.], 2002. p. 287–299.

WILHER, V. **Introdução à Séries Temporais - Análise Macro**. 2020. Disponível em: <<https://analisemacro.com.br/data-science/dicas-de-rstats/introducao-a-series-temporais/>>.

WU, Q.; LU, W.; PRAKASH, J. **Characterization of a commercial size cylindrical Li-ion cell with a reference electrode.** v. 88. [S.l.], 2000. p. 237–242.
Disponível em: <www.elsevier.com/locate/jpowsour>.

YAOHAO, P. **UNIVERSIDADE DE BRASÍLIA FACULDADE DE ADMINISTRAÇÃO, CONTABILIDADE E ECONOMIA PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO Support Vector Regression aplicado à previsão de taxas de câmbio.** [S.l.], 2016.