



**UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA LUSOFONIA
AFRO-BRASILEIRA
INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL
CURSO DE ENGENHARIA DE ENERGIAS**

FAUSTA JOAQUIM FAUSTINO

**MODELAGEM DE BATERIA DE CHUMBO-ÁCIDO ATRAVÉS DE REDE MLP:
UM ESTUDO COMPARATIVO COM UM MODELO PARAMÉTRICO**

**ACARAPE
2020**

Universidade da Integração Internacional da Lusofonia Afro-Brasileira
Sistema de Bibliotecas da UNILAB
Catalogação de Publicação na Fonte.

Faustino, Fausta Joaquim.

FA268m

Modelagem de Bateria de Chumbo-Ácido Através de Rede MLP: um Estudo Comparativo com um Modelo Paramétrico / Fausta Joaquim Faustino. - Redenção, 2020.

81f: il.

Monografia - Curso de Engenharia De Energias, Instituto De Engenharias E Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2020.

Orientador: Prof°. Mestre Humberto Ícaro Pinto Fontinele.

1. Bateria de chumbo-ácido, modelo paramétrico. 2. modelo não paramétrico, MLP. 3. curva de descarga, estado de carga (SOC). I. . II. Título.

CE/UF/BSCA

CDD 621.31242

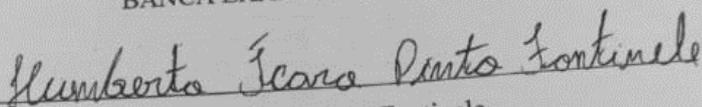
FAUSTA JOAQUIM FAUSTINO

MODELAGEM DE BATERIA DE CHUMBO-ÁCIDO ATRAVÉS DE REDE
MLP, UM ESTUDO COMPARATIVO COM UM MODELO PARAMÉTRICO.

Monografia apresentada ao curso de
Engenharia de Energias do Instituto de
Engenharia e Desenvolvimento
Sustentável da Universidade da
Integração Internacional da Lusofonia
Afro-Brasileira, como requisito para
obtenção do Título de Bacharel em
Engenharia de Energias.

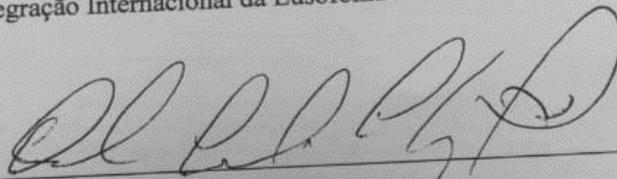
Aprovado em 08/01/2020

BANCA EXAMINADORA

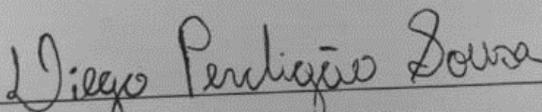


Prof. Humberto Ícaro Pinto Fontinele

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)



Prof. David Ciarlini Chagas Freitas
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)



Prof. Diego Perdigão Sousa
Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me ajudado a chegar a até aqui, por nunca ter me abandonado e por ter me fortalecido nos momentos mais difíceis desta caminhada.

Agradeço a minha família, que foram os responsáveis pela realização deste sonho, que me deram toda ajuda e apoio, emocional, financeiro e espiritual

A minha mãe Domingas Amade Filipe, que me ensinou a nunca desistir e persistir no meu sonho. Pelo seu incentivo de mostrar-me que eu sou capaz de muita coisa, desde que me esforce e me dedique o bastante. Foi graças ao seu ensinamento dos métodos de estudo que hoje estou conseguindo ir muito além do que poderia imaginar.

Agradeço ao meu pai Joaquim Jose Faustino (em memória), pela força e apoio.

Agradeço aos meus irmãos Januario, Dercia, Zanilde e Denisse, que sempre me apoiaram em todos os momentos da minha vida e que abraçaram o meu sonho como sendo seus. Aos meus sobrinhos Kenzo e Tayson que sempre me encheram de alegria.

As minhas tias Maria Isabel e Carolina, que contribuíram com a minha educação e me ensinaram valores importantes.

Ao meu primo Ajumar, que junto embarcou comigo nessa caminhada em busca de um futuro melhor e que sempre foi o meu braço direito e meu pilar presente em todos os momentos.

A minha madrinha Birgit, que contribuiu com a minha educação e esteve comigo em todas as horas, me dando muito apoio.

Aos meus colegas e amigos da faculdade Neyla, Atalia, Leila, Gabriel, Guilherme, Milva, Elisa, Hiliene e Heliane, Carlos Subuhana que acabaram sendo a minha família durante este percurso, pelos conselhos, grupo de estudo, companheirismo, momento de lazer, angustia e tristezas compartilhadas.

Em especial agradeço ao meu orientador Humberto Ícaro Pinto Fontinele, pelo companheirismo e confiança depositada em mim, pelo incentivo e pelas dicas, e por proporcionar toda a estrutura para a concretização deste trabalho.

A esta Universidade, seu corpo docente, direção e administração, pela oportunidade e confiança a mim concedidos. Agradeço a todos os professores, por me proporcionar o conhecimento necessário, além do caráter e afetividade da educação voltada ao processo de formação profissional.

A todos aqueles que de alguma forma estiveram e estão próximos de mim, fazendo esta vida valer a pena, o meu muito obrigada.

RESUMO

As baterias desempenham papéis importantes no dia a dia da sociedade contemporânea sendo utilizadas em veículos elétricos, veículos a combustão, smartphones, notebooks, relógios, controles remotos, entre outros. A maioria das baterias podem ser recarregadas e a vida útil destes dispositivos é expressa em termos de número médio de recargas admitidas. Quanto mais preciso for o processo de recarga, mais ciclos de recarga a bateria suporta e, conseqüentemente, maior é a sua vida útil. Um processo de recarga preciso consiste em aplicar um nível de tensão controlado aos terminais da bateria, de acordo com o estágio de carga que o dispositivo assume ao longo do processo de carregamento. Portanto, a implementação de uma recarga precisa requer um modelo que permita identificar o estágio de carga da bateria através de informações como tensão, corrente e temperatura. Por este motivo diversos estudos relacionados a modelagem de baterias são desenvolvidos, almejando o desenvolvimento de novas tecnologias que permitam otimizar os processos de recargas, aumentando assim a vida útil desses dispositivos e viabilizando novas soluções, como os veículos elétricos. Este trabalho apresenta dois métodos para modelagem de baterias de chumbo-ácido, a partir de dados reais de descarga de uma bateria para testar os modelos. Um dos métodos, proposto por Tremblay *et al* (2007), permite a construção de um modelo paramétrico que pode ser utilizado para a construção de curvas de descargas de baterias de chumbo-ácido, níquel-cádmium, íon de lítio e níquel metal híbrido, o segundo método constroi um modelo não paramétrico utilizando a rede neural artificial MLP. No final é feito um estudo comparativo entre os modelos, utilizando os dados reais de descargas, para identificar qual modelo é mais preciso.

Palavras-Chave: Bateria de chumbo-ácido, modelo paramétrico, modelo não paramétrico, MLP, curva de descarga, estado de carga (SOC).

ABSTRACT

Batteries play an important role in day to day life in contemporary society, and are used in electric vehicles, combustion vehicles, smartphones, notebooks, watches, remote controls, among others. Most batteries can be recharged and the use life of these devices is expressed in terms of the average number of recharges they support. The more accurate the recharging process, the more recharging cycles the battery can handle and therefore the longer the battery life. An accurate recharging process needs consistent application of controlled voltage to the battery terminals, in accordance with the charge stage the device needs during the charging process. Therefore, the implementation of an accurate recharge requires a model that allows for the identification of the battery charge stage through information such as voltage, current and temperature. As a result, several studies related to battery modeling have been developed in order to develop new technologies that optimize recharging processes, thus extending the life of these devices and enabling new solutions, like for electric vehicles. This paper presents two methods for modeling lead acid batteries, using actual battery discharge data to test the models. One of the methods, proposed by Tremblay et al (2007), builds a parametric model that can be used for the construction of discharge curves of lead acid, nickel cadmium, lithium ion and nickel metal hybrid batteries. The other method builds a nonparametric model using the MLP artificial neural network. This paper concludes with a comparative study of these models using the actual discharge data, to identify which model is more accurate.

Keywords: lead acid battery, parametric model, not parametric model, MLP, discharge curve, charge state (SOC).

LISTA DE FIGURAS

Figura 1: Curva de descarga de uma bateria VRLA de 7,2 Ah.....	21
Figura 2: Modelo esquemático do processo de descarga de uma bateria de chumbo-ácido.....	23
Figura 3: Modelo de bateria não linear.....	28
Figura 4: Curva de descarga do modelo paramétrico.....	30
Figura 5: Bateria de chumbo-ácido 12V 1.2Ah.....	32
Figura 6: Bateria de íões de lítio 3.6V 1Ah.....	33
Figura 7: Bateria de níquel-cádmio 1.2V 1.3Ah.....	33
Figura 8: Bateria de níquel-metal-hidreto 1.2V 6.5Ah.....	34
Figura 9: Representação dos neurônios e conexões.....	35
Figura 10: Modelo não linear de neurônio artificial.....	36
Figura 11: Função de limiar.....	37
Figura 12: Função linear.....	38
Figura 13: Função sigmoide logística.....	39
Figura 14: Função tangente hiperbólico.....	39
Figura 15: Exemplo de uma rede recorrente.....	40
Figura 16: Rede de alimentação direta com uma única camada de neurônios.....	41
Figura 17: Rede com alimentação direta com uma camada oculta e uma camada de saída.....	42
Figura 18: Grafo arquitetural de uma rede MLP com duas camadas escondidas.....	44
Figura 19: Sentido direto da rede MLP.....	45
Figura 20: Treinamento com <i>overfitting</i>	51
Figura 21: Taxa de aprendizado pequena com problema de mínimo local.....	52
Figura 22: Taxa de aprendizado grande, com problema de oscilações.....	52
Figura 23: Aprendizado com termo <i>momentum</i>	53
Figura 24: Treinamento online.....	55
Figura 25: Bancada experimental.....	56
Figura 26: Circuito de descarga da bateria- um banco de resistores.....	57
Figura 27: Topologia da rede.....	60
Figura 28: Curva de descarga 1-Tensão- Dados originais.....	64
Figura 29: Curva de descarga 1-Tensão-Dados compactados.....	65
Figura 30: Curva de descarga 1-Tensão-Dados compactados e filtrados.....	65
Figura 31: Curva de descarga 1-corrente- Dados originais.....	65

Figura 32: Curva de descarga 1-Corrente-Dados compactados.....	66
Figura 33: Curva de descarga 1-Corrente-Dados compactados e filtrados.....	66
Figura 34: Curva de descarga 2-Tensão- Dados originais.....	66
Figura 35: Curva de descarga 2-Tensão-Dados compactados.....	67
Figura 36: Curva de descarga 2-Tensão-Dados compactados e filtrados.....	67
Figura 37: Curva de descarga 2-corrente- Dados originais.....	67
Figura 38: Curva de descarga 2-Corrente-Dados compactados.....	68
Figura 39: Curva de descarga 2-Corrente-Dados compactados e filtrados.....	68
Figura 40: Erro quadrático médio por época para os dados de treinamento, com 5 neurônios na camada oculta.....	69
Figura 41: Erro quadrático médio por época para os dados de treinamento, com 6 neurônios na camada oculta.....	70
Figura 42: Erro quadrático médio por época para os dados de treinamento, com 7 neurônios na camada oculta.....	70
Figura 43: Erro quadrático médio por época para os dados de teste, com 5 neurônios na camada oculta.....	71
Figura 44: Erro quadrático médio por época para os dados de teste, com 6 neurônios na camada oculta.....	71
Figura 45: Erro quadrático médio por época para os dados de teste, com 7 neurônios na camada oculta.....	72
Figura 46: Curva de descarga 1- MLP.....	73
Figura 47: Curva de descarga 2-MLP.....	73
Figura 48: Curva de descarga 1- Modelo Paramétrico.....	74
Figura 49: Curva de descarga 2- Modelo paramétrico.....	74
Figura 50: Curva do modelo MLP vs Curva real vs Modelo parametrico para descara 1.....	75
Figura 51: Curva do modelo MLP vs curva real vs modelo parametrico para descara 2.....	76

LISTA DE TABELAS

Tabela 1: Vantagens e desvantagens das baterias de Chumbo-Ácido.....	25
Tabela 2: Parâmetros do modelo paramétrico.....	32
Tabela 3: Características dos instrumentos de medição.....	58
Tabela 4: Arquitetura da rede MLP.....	62
Tabela 5: Parâmetros calculados para a curva de descarga 1.....	63
Tabela 6: Parâmetros calculados para a curva de descarga 2.....	63
Tabela 7: Desempenho da rede para conjunto de dados de treinamento e teste.....	69
Tabela 8: Erro Quadrático Total – MLP e Paramétrico.....	75

LISTAS DE SIGLAS E ABREVIATURAS

SOC	State-of-Charge
MCE	Modelo de circuito equivalente
RNAs	Redes neurais artificiais
SLI	Starting Lighting and Ignition
VRLA	Valve Regulated Lead Acid
AGM	Absorved Glass Mat
RBP	Recursive Backpropagation
MLP	Multilayer Perceptrons
EQM	Erro quadrático médio

SUMÁRIO

1. INTRODUÇÃO	14
1.1 Objetivo	15
<i>1.1.1 Objetivo Geral</i>	15
<i>1.1.2 ObjetivoEspecifico</i>	15
1.2 Metodologia	16
1.3 Motivação	16
1.4 Estrutura do Trabalho	16
2. BATERIAS DE CHUMBO-ÁCIDO	18
2.1. Fatores que afetam o desempenho das baterias	18
<i>2.1.1 Nível de Tensão</i>	18
<i>2.1.2 Ciclo de Vida</i>	19
<i>2.1.3 Temperatura</i>	19
<i>2.1.4 Corrente de descarga</i>	20
2.2 Descarga de Baterias	20
<i>2.2.1 Curva de Descarga</i>	20
<i>2.2.2 Capacidade de armazenamento da Bateria</i>	21
<i>2.2.3 Auto-Descarga</i>	21
2.3 Bateria chumbo-Ácido	22
3. MODELAGEM PARAMÉTRICA E NÃO-PARAMÉTRICA DE BATERIAS DE CHUMBO-ÁCIDO	26
3.1 Modelo Paramétrico	27
<i>3.1.1 O modelo da bateria</i>	27
<i>3.1.2 Pressupostos do modelo</i>	29
<i>3.1.3 Limitações do Modelo</i>	29
<i>3.1.4 Parâmetros do modelo</i>	31
3.2 O Modelo Neural	34
<i>3.2.1 Redes Neurais</i>	34

3.2.2 Neurônios artificias	35
3.2.3 Arquitetura das RNAs	40
3.2.4 Aprendizagem e treinamento de RNAs.....	42
3.3 Perceptrons de Múltiplas Camadas (MLP)	43
3.3.1 Treinamento da rede MLP.....	45
3.3.2 Treinamento, Convergência e Generalização.....	48
3.3.3 Convergência.....	51
3.3.4 Taxa de aprendizado.....	51
3.3.5 Termo de Momentum.....	53
3.3.6 Avaliação da Rede Treinada.....	54
3.4 Treinamento Online	54
4 METODOLOGIA.....	56
4.1 Aquisição de dados.....	56
4.1.1 bancada experimental.....	56
4.1.2 Descarga da bateria.....	56
4.2 Material Utilizado.....	57
4.3 Tratamentos dos dados.....	58
4.4 Metodologia para construção dos modelos paramétrico e não paramétrico.....	59
4.4.1 Modelo 1: Modelo Não Paramétrico Através de RNA MLP.....	59
4.4.1.1 Treinamento da rede.....	59
4.4.1.2 Seleção de Hiperparâmetros.....	60
4.4.1.3 Critério de Parada.....	61
4.4.1.4 Avaliação da rede treinada.....	61
4.4.1.5 Arquitetura da rede de melhor desempenho.....	62
4.4.2 Modelo 2: Modelo Paramétrico.....	62
5. RESULTADO E DISCUSSÃO.....	64
5.1 Tratamento dos dados.....	64
5.2 Avaliação da rede MLP.....	68
5.3 Curva de descarga estimada pela MLP.....	72
5.4 Curva de descarga do modelo paramétrico.....	73

5.5 Modelo paramétrico verso modelo Neural.....	74
6. CONCLUSÃO.....	77
6.1 Introdução.....	77
6.2 Resumo das contribuições dessa monografia.....	77
6.3 Sugestões de trabalhos Futuros.....	78
REFERÊNCIAS.....	79

1. INTRODUÇÃO

O sistema de conservação de energia através de baterias desperta grande interesse na população em geral. Elas permitem que a energia gerada em um dado momento possa ser utilizada posteriormente. Para se ter uma ideia da importância das baterias basta observar que praticamente todos os veículos automotores que conhecemos fazem uso de acumuladores de energia, ou como fonte efetiva de energia (veículos elétricos) ou ainda para o arranque de motores a combustão interna. Outros dispositivos como smartphones, notebooks, relógios, controles remotos, entre outros, utilizam baterias como fonte de energia (ANDRADE, 2005).

O uso de baterias tem um papel importante quando se fala em energias renováveis, por exemplo, as células fotovoltaicas estão sempre relacionadas com o uso de banco de baterias, isso porque no momento de geração da energia elétrica nem sempre coincide com o da sua necessidade de uso. O mesmo acontece com a energia eólica (ANDRADE, 2005). Existem inúmeros tipos de baterias, porém a bateria de chumbo-ácido é a mais adequada para as aplicações citadas, por ser mais econômica e por hoje já adotar tecnologias avançadas, que torna esses dispositivos bastante eficientes. (ANDRADE, 2005).

Este meio de conservação de energia enfrenta alguns desafios relacionados a sua durabilidade, capacidade, potência disponível, tempo de descarga, confiabilidade e vida útil (OLIVEIRA, 2016). Por este motivo um grande número de baterias é descartada de forma inadequada, acarretando assim poluição ao meio ambiente, devido aos resíduos perigosos como eletrodos metálicos, eletrólitos, plásticos e gases de efeito estufa (BRONDANI, 2015).

Este problema pode e deve ser mitigado através do desenvolvimento de baterias mais eficientes e seguras. Para tanto, é imprescindível a realização de estudos sobre o comportamento das baterias, especificamente, acerca dos modelos para gerenciamento de carga na bateria, pois este influencia diretamente na vida útil da bateria e, conseqüentemente, no número de baterias descartadas.

Estes modelos devem descrever de forma precisa a relação dinâmica entre a corrente, a tensão nos terminais da bateria e a quantidade de energia armazenada no dispositivo. No campo da modelagem, pesquisas voltadas a modelagem de baterias já propõem diversos modelos para dinâmica de curto e longo tempo. Esses modelos podem ser amplamente classificados nas seguintes categorias: modelos de circuitos equivalentes (MCE), modelos eletroquímicos,

modelos analíticos e baseados em impedância, modelos empíricos e modelos semi-empírico. (RELAN, *et al.*,2017)

O modelo empírico estudado neste trabalho é construído através de Rede Neural Artificial (RNA) do tipo MLP, que mapeia a variação de tensão e corrente com o, o estado de carga (SOC, do igles *state of charge*) da bateria a qualquer condição de funcionamento da bateria. Este modelo é comparado a um modelo matemático analítico, que serve de referência para análise comparativa de desempenho.

1.1 Objetivos

1.1.1 *Objetivos Geral*

- Desenvolver um modelo não paramétrico para relacionar tensão e corrente com SOC de baterias de chumbo-ácido, de forma que se possa estimar a curva de carga/descarga da bateria utilizando a RNA MLP, que possa ser utilizado para otimizar o controle de carga desta bateria.

1.1.2 *Objetivos Específicos*

- Realizar ensaios de descarga em uma bateria de chumbo ácido de 12 Vcc, realizando a aquisição de dados dos ensaios para compor um banco de dados;
- Construir o banco de dados para estimar um modelo paramétrico, baseado no método proposto pelos autores Tremblay *et al.* (2007) e utilizar aos dados reais para identificar os parâmetros do modelo;
- Aplicar uma RNA MLP para construir um modelo que permita identificar o SOC da bateria, através do histórico de medições de tensão e corrente.
- Utilizar o modelo da MLP para reconstruir a curva de descarga da bateria, realizando um comparativo desta estimação com o modelo estimado pelo método proposto por Tremblay *et al.* (2007);

1.2 Metodologia

A metodologia adotada nesse trabalho teve início com a criação de um banco de dados formado por curvas de tensão e corrente de bateria de chumbo-ácido, durante os processos de descarga realizados em ensaios de bancada.

A etapa seguinte consiste nos tratamentos dos dados para que estes possam ser utilizados para construção de modelos que descrevam comportamento de tensão e corrente da bateria.

O primeiro modelo consiste em um modelo não paramétrico construído por uma rede MLP, enquanto o segundo modelo consiste no modelo paramétrico proposto por Tremblay *et al.* (2007).

Ao final, realiza-se um estudo comparativo de desempenho entre os dois modelos, com intuito de identificar qual mapeamento captura melhor a dinâmica da bateria.

1.3 Motivação

A eficiência, o custo de fabricação e a vida útil das baterias impacta diretamente na viabilidade técnica e financeira de uma gama de sistemas elétricos que dependem do armazenamento de energia para o seu funcionamento.

O sucesso de novas tecnologias, como carros elétricos, usinas fotovoltaicas e entre outras dependem diretamente do custo de armazenamento de energia em baterias. Conseqüentemente, mais novas pesquisas são desenvolvidas para reduzir cada vez mais este custo.

A motivação central desta pesquisa é contribuir de alguma forma para desenvolvimento de controladores de carga mais eficientes que possam trazer avanços ao sistema de armazenamento de energia, em especial no que diz respeito a vida útil das baterias.

1.4 Estrutura do Trabalho

Os capítulos seguintes deste trabalho se organizam conforme segue:

- Capítulo 2 – Baterias de chumbo-ácido. Neste capítulo é apresentada uma revisão bibliográfica sobre baterias de chumbo-ácido, descrevendo suas principais características construtivas e físico-químicas.
- Capítulo 3 – Modelagem paramétrica e não paramétrica de baterias de chumbo-ácido. Neste capítulo é apresentada a metodologia proposta por Tremblay *et al.* (2007) para a construção de um modelo paramétrico da bateria de chumbo-ácido, assim como é

apresentado o algoritmo de aprendizagem da rede MLP, aplicado a tarefa de modelagem da curva de descarga da bateria.

- Capítulo 4 – Metodologia. No capítulo 4 encontra-se uma descrição detalha sobre a aquisição e tratamento dos dados e a metodologia adotada para a seleção dos hiperparâmetros e avaliação do aprendizado da rede MLP.
- Capítulo 5 - Resultados e Discussões. Nesse capítulo é apresentado e discutido os resultados alcançados por cada um dos métodos, sendo realizado um comparativo de desempenho entre as diferentes propostas consideradas neste trabalho.
- Capítulo 6 – Conclusões. Finalmente, no capítulo 6, são apresentadas as conclusões desta pesquisa e são feitas sugestões para trabalhos futuros.

2. BATERIAS DE CHUMBO-ÁCIDO

De acordo com MARCOS (2007) e REIS (2008) bateria é um conjunto de células, integradas e associadas em série ou em paralelo, que converte diretamente a energia química contida nos materiais ativos em energia elétrica, permitindo se obter os níveis de tensões ou correntes desejadas. Este tipo de reação envolve transferência de elétrons de um material para outro, através de um circuito elétrico. Portanto, baterias são acumuladores de energia, e podem ser subdivididas em duas categorias, as primárias, que não permitem recargas, e as secundárias, que são recarregáveis.

As baterias podem ser classificadas ainda de acordo com os materiais ativos usados na sua construção, podendo ser classificadas em acumulador chumbo-ácido, alcalinas, íons de lítio, níquel-cádmio, hidreto metálico de níquel, níquel-zinco, entre outras. (MARCOS 2007).

As baterias mais difundidas no meio automotivo é a bateria chumbo-ácido. Foi bastante usada desde a década de 90, nos primeiros veículos elétricos e híbridos construídos, e até hoje ainda é muito difundida pelo fato de ter um custo reduzido (MOLINA *et al* 2017). Nesse trabalho será abordada esta categoria de baterias.

2.1 Fatores que afetam o desempenho das baterias

A energia armazenada em uma bateria é diferente da energia extraível e o seu desempenho pode variar completamente, dependendo das condições de operação a que está sujeita. Existem diversos fatores que influenciam as características operacionais da bateria, tais como nível de tensão, o ciclo de vida, a temperatura e a corrente de descarga. Estes fatores são descritos a seguir.

2.1.1 Nível de Tensão

A tensão nos terminais das baterias de chumbo-ácido é um dos principais parâmetros a ser monitorado, pois está diretamente relacionado às suas condições de operação. As principais tensões de referência são descritas a seguir (CHAGAS, 2007).

- **Tensão nominal:** O valor de tensão nominal de uma bateria geralmente é uma unidade de medida da capacidade de armazenamento energético. Indica a quantidade de energia que esta bateria possui quando está plenamente carregada, ou seja, o quanto esta pode oferecer de energia em uma descarga, a uma determinada corrente;

- **Tensão em vazio:** é a tensão na total ausência de carga;
- **Tensão teórica:** é a tensão teórica que a bateria deve alcançar, em função dos materiais adotados para o ânodo e o cátodo, em dadas condições;
- **Tensão de corte:** é a tensão em que se define se a bateria está descarregada
- **Tensão de flutuação:** É a tensão que é aplicada ao banco de baterias, para evitar a auto descarga. Pelas baterias submetidas à tensão de flutuação correta, circula uma corrente chamada corrente de flutuação, que compensa as perdas devidas as reações de auto descarga. Quando submetida à tensão de flutuação, a bateria é mantida carregada, ou seja, pronta para fornecer energia quando necessário. A tensão de flutuação depende da temperatura e do tipo de bateria.
- **Tensão Final de Descarga:** É o menor nível de tensão que uma célula da bateria alcança ao final do processo de descarga. Normalmente, o valor da tensão final de descarga de uma bateria de chumbo-ácido é de 1,75 V/célula. Se o processo de descarga forçar a bateria alcançar um nível de tensão abaixo desse valor, existe o risco de correr dano irreversível às células, devido a sulfatação das placas ou a inversão de polaridade destas, podendo até inutilizar definitivamente a bateria.

2.1.2 Ciclo de Vida

O tempo de vida útil de uma bateria depende de uma série de fatores, mas depende sobretudo da temperatura e da amplitude da descarga. A medida que a bateria vai sendo utilizada, os ciclos de cargas e descargas levam naturalmente a perda da capacidade de armazenamento da bateria. Quando a perda de capacidade, ou seja, a diferença entre a capacidade inicial e a atual, chega a 20%, considera-se que a bateria chegou ao fim da sua vida útil (REIS, 2008).

2.1.3 Temperatura

A temperatura a que uma bateria é sujeita tem influências ao nível da sua vida útil e das características da tensão, pois promove a redução ou o aumento de velocidade de processamento das atividades químicas. As baterias de chumbo-ácido operam melhor a temperaturas moderadas, que seriam aquelas ideais para maximizar a vida útil. Tais informações são fornecidas pelo fabricante, podendo variar de $T = 20^{\circ}\text{C}$ a $T = 25^{\circ}\text{C}$. A operação de baterias em locais de temperaturas elevadas contribui para diminuição da vida útil, embora as baterias

chumbo-ácido forneçam a maior capacidade a temperaturas acima de 30°C. O prolongado uso sob tais condições diminui a vida útil da bateria, devido a aceleração dos fenômenos de corrosão (REIS, 2008).

2.1.4 Corrente de descarga

De acordo com REIS (2008), correntes de descarga elevadas implicam em maiores perdas e menores níveis de tensão de trabalho, o que reduz a vida útil da bateria. Existem vários métodos para definir leis que descrevam as correntes de carga ou descarga contidas nos catálogos do fabricante. A convenção dos fabricantes de baterias é definir as correntes em função da capacidade nominal da bateria, designada por Cn , conforme mostrado na Equação 2.1. (REIS, 2008)

$$I = M \cdot Cn \quad (\text{Equação 2.1})$$

Onde,

I = intensidade de corrente, ampères;

M = constante, em hora⁻¹;

Cn = capacidade nominal, ampère.hora;

2.2 Descarga de Baterias

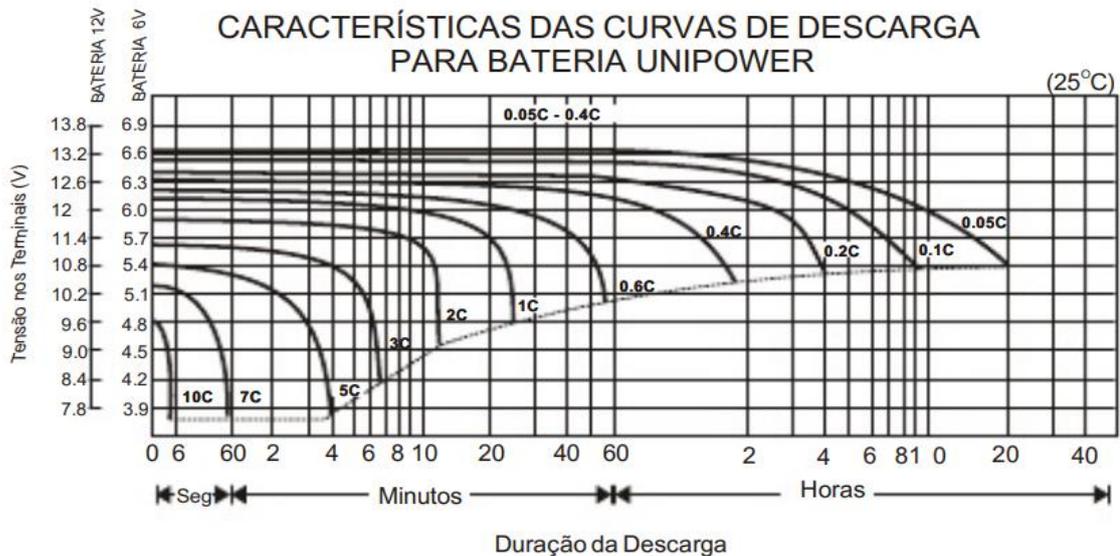
As baterias são dispositivos que convertem energia química em energia eléctrica, sob a forma de corrente contínua, quando estão no processo de descarga. Durante o processo de descarga as baterias perdem energia sob a forma de calor, devido às reações químicas que ocorrem internamente, e por esse motivo sempre apresentam rendimento inferior a 100% (SOUSA e MURTA, 2019).

2.2.1 Curvas de Descarga

As curvas de descarga de baterias são funções não lineares de modelagem matemática complexa. Esses gráficos apresentam a variação da tensão da bateria em função do tempo, para uma determinada corrente de descarga. Com a variação dessa corrente de descarga, são obtidas diferentes curvas de descarga. Espera-se que quanto maior a corrente drenada da bateria, maior é o decréscimo de sua tensão, diminuindo o tempo restante de fornecimento de energia. (PEIXOTO,2012).

A Figura 1 mostra a característica de descarga das baterias Unipower, uma bateria chumbo-ácido selada regulada por válvula, compostas por células de 2 V, em temperatura ambiente de 25°C, com tempo de descarga de 20 horas.

Figura 1 :Curva de descarga de uma bateria VRLA de 7,2 Ah



Fonte: Peixoto, (2012)

2.2.3 Capacidade de armazenamento da Bateria

A energia máxima que pode ser acumulada numa bateria é especificada através da sua capacidade de carga, geralmente declarada em Ampères-hora. Esta capacidade, que é o produto da corrente de descarga vezes o tempo de descarga, quando medida experimentalmente, regulando a corrente para um valor fixo. Depende da corrente utilizada, da tensão final de descarga permitida e da temperatura em que foi realizado o teste (CHAGAS,2007).

2.2.4 Auto-Descarga

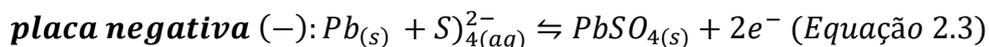
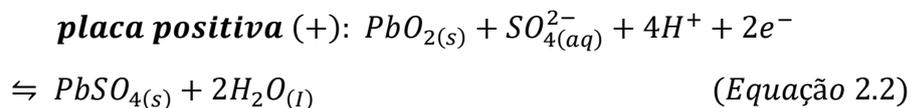
A auto-descarga de uma bateria é determinada pela comparação de duas medidas de capacidade realizadas com um intervalo de tempo entre elas (o tempo no qual se quer avaliar a auto-descarga).

A bateria que possui menor taxa de auto-descarga é a do tipo chumbo-ácido. Esta bateria possui uma auto-descarga inferior a 5% ao mês, podendo chegar a 2% para sistemas otimizados, sobre condições de temperaturas próximas a temperatura ambiente. Em todos os tipos de

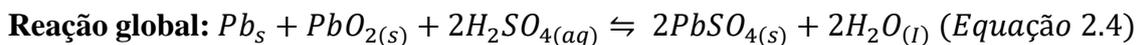
baterias a auto-descarga se intensifica com a elevação da temperatura e na bateria de chumbo-ácido uma variação de 10°C pode até duplicar a taxa de auto-descarga. A auto-descarga é influenciada ainda pela presença de substâncias contaminantes no eletrólito, como íons Fe, Mg, etc. Por isso, a pureza dos materiais utilizados na produção das baterias é de vital importância para diminuir a auto-descarga (CHAGAS,2007).

2.3 Bateria Chumbo-Ácido

As baterias chumbo-ácido são constituídas por células eletroquímicas ligadas em paralelo ou em série. As células são formadas por um catodo (polo positivo), que é uma placa de dióxido de chumbo, e um anodo (polo negativo), que é uma placa de chumbo, imersas em um eletrólito de ácido sulfúrico, onde ocorre a reação química (PEIXOTO,2012). De acordo com MOLINA *et al* (2017) a reação de redução produz sulfato de chumbo partir de dióxido de chumbo conforme apresenta a Equação 2.2, por sua vez a reação de oxidação que envolve a conversão do chumbo em sulfato de chumbo ocorre conforme a Equação 2.3.



A reação global de descarga da célula é a reação de duplo sulfato, apresentada na Equação 2.4. Os agentes oxidantes e redutores são ambos sólidos, assim não existe a necessidade de uma ponte salina para separar os agentes. Sem uma ponte salina, a resistência interna da célula é muito baixa (MOLINA *et al* 2017).

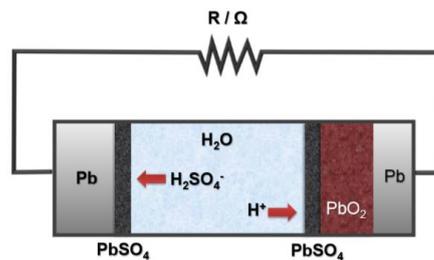


Após serem submergidas as placas positiva e negativa na solução de ácido sulfúrico, obtém-se como resultado a geração de uma tensão de aproximadamente 2,1 V. Ao conectar-se um circuito elétrico, surge uma corrente elétrica e, após a descarga estes elementos, podem retornar as condições iniciais mediante uma recarga, fazendo circular uma corrente elétrica no sentido contrário ao da descarga (MOLINA *et al* 2017).

No processo de descarga, o chumbo do material ativo das placas positivas (PbO_2) se combina com os íons sulfato (SO_4^{2-}) do ácido sulfúrico, formando nas placas positivas o sulfato de chumbo ($PbSO_4$). Ao mesmo tempo, ocorre uma reação similar nas placas negativas onde o

chumbo esponjoso (Pb) se combina com os íons (SO_4^{-2}) do ácido, formando também sulfato de chumbo o esquema da bateria é apresentado na Figura 3. Deste modo ambas as reações consomem o sulfato (SO_4^{-2}) do ácido, fazendo com que haja cada vez menos ácido sulfúrico na solução. Portanto, quanto mais descarregada estiver uma bateria menor será sua densidade. À medida que a energia elétrica se esgota, a tensão da célula diminui, pois, o ácido sulfúrico é consumido para produzir o sulfato de chumbo e no processo de carga, ocorre a reação inversa (MOLINA *et al* 2017).

Figura 1: Modelo esquemático do processo de descarga de uma bateria de chumbo-ácido



Fonte: Molina et al, (2017)

Os acumuladores podem ser utilizados em diversas aplicações. Dependendo da aplicação, pode existir a necessidade de se definir a quantidade e o tipo de placas, densidade de eletrólito e o modelo da caixa onde são acomodados. De acordo com a aplicação, as baterias de chumbo-ácido podem ser classificadas em 4 grupos: baterias de arranque SLI (do inglês *Starting Lighting and Ignition*), que podem ser seladas ou ventiladas, baterias tracionárias, bateria estacionárias, bateria VRLA (do inglês *Valve Regulated Lead Acid*), em gel e as AGM (do inglês *Absorbed Glass Mat*).

Como é dito por MOLINA *et al* (2017), as baterias de arranque são as responsáveis pelo fornecimento de energia para iniciar o ciclo de combustão interna do motor e para fornecer energia ao sistema elétrico do veículo quando este não está em funcionamento. Estas são classificadas em duas diferentes subdivisões, as baterias ventiladas e as baterias seladas. Nas baterias ventiladas ocorre a decomposição de hidrogênio, ocasionando uma maior perda de água. Por isto é necessário a reposição de água para que não ocorra um superaquecimento e posterior desfalecimento da bateria. Já as baterias seladas não emitem gases, e, portanto, contrário das baterias ventiladas, não tem perda de água.

As baterias tracionárias funcionam em ciclos de descarga muito profundas e recargas em curto prazo de tempo. As principais aplicações desta bateria são carrinhos para transporte

de pessoas (hotéis, campos de futebol, entre outros) e cargas, prateleiras, plataformas elétricas, lavadoras, entre outras (MOLINA *et al* 2017).

Já as baterias estacionárias são usadas como fonte de energia reserva, na maior parte do tempo elas trabalham carregadas e quando a energia é cortada elas substituem a energia e mantêm o componente na qual estão conectadas funcionando. Essa aplicação é observada em iluminações de emergência, sistemas fotovoltaicos *off-grid*, alarmes, hospitais, entre outras. Sua vida útil é maior do que as baterias de arranque e tracionarias (MOLINA *et al* 2017).

As baterias VRLA são consideradas de última geração, por possuir uma válvula reguladora. Neste tipo de bateria o eletrólito não é líquido, e sim imobilizado na forma de gel ou absorvido por um separador de microfibras de vidro. Esta bateria foi desenvolvida para diminuir a frequência de manutenção.

As VRLA são classificadas em dois diferentes tipos a saber: Gel e AGM. Na bateria em gel, o eletrólito é misturado em partículas de dióxido de silício (SiO_2) e óxido de alumínio (Al_2O_3), resultando assim em uma consistência gelatinosa. O separador é de polietileno, como nas baterias convencionais, porém, quando ocorre a perda de água, o gel encolhe e causa fissuras no separador. Devido a estas fissuras, o oxigênio gerado pelas placas positivas migra para as placas negativas, dando início ao ciclo do oxigênio. Estas fissuras não são grandes o suficiente para que haja curto circuito entre as placas e este processo permite que a bateria trabalhe em condições de altas temperaturas e elevados regimes de vibrações. Porém, a bateria necessita ser carregada lentamente, para que o excesso de vapores não danifique a célula.

A bateria AGM (*Absorbed Glass Mat*) apresenta vantagens como resistência ao congelamento, alta eficiência no ciclo de recombinação do oxigênio e do hidrogênio, que chega muito próximo de 100%, e baixo nível de auto-descarga, devido à baixa resistência elétrica. Por isto possui um rendimento superior às outras baterias (MOLINA *et al.* 2017). Para determinar a energia armazenada na bateria é importante conhecer a sua capacidade de descarga de corrente no tempo e a sua tensão. É possível saber com estes dados a quantidade de energia armazenada na bateria, a partir da Equação 2.5. (PEIXOTO, 2012)

$$\text{Energia} = \text{Tensão} \times \text{Capacidade} \quad (\text{Equação 2.5})$$

Onde,

Energia= (WH)

Tensão= (V)

Capacidade=(AH)

As baterias podem ser classificadas ainda de acordo sua resistência interna, podendo ser normal, baixa ou muito baixa. Esse fator influencia na capacidade de corrente de descarga e na energia útil de uma bateria, de acordo com a Equação 2.5 (PEIXOTO, 2012 *apud* MARCOS, 2007).

De acordo com PEREIRA (2016), a bateria de chumbo-ácido tem as suas vantagens e desvantagens, que são apresentadas na tabela 1.

Tabela 1: Vantagens e desvantagens das baterias de Chumbo-Ácido

Vantagens	Baixo custo e simples de fabricar, a bateria VRLA é a menos cara em termos de custo por densidade de energia.
	Tecnologia madura e confiável, quando usada corretamente, a bateria de VLRA é durável e fornece um serviço confiável.
	Baixa taxa de auto descarga, esta bateria está entre as mais baixas das baterias recarregáveis.
	Permite taxas elevadas de descarga.
Desvantagens	Baixa densidade de energia.
	Permite um número limitado de ciclos de descarga completos, sendo adequada para aplicações que exigem descargas profundas apenas ocasionalmente.
	Prejudicial ao meio ambiente, o eletrólito e o teor de chumbo pode causar danos ambientais significativos.
	Restrições de transporte e manipulação, pois existem preocupações ambientais sobre o derrame do eletrólito em caso de acidente.

Fonte: Adaptado de PEREIRA (2016)

3. MODELAGEM PARAMÉTRICA E NÃO-PARAMÉTRICA DE BATERIAS DE CHUMBO-ÁCIDO

A autonomia de baterias depende diretamente da tecnologia adotada na sua construção, pois está define a densidade da carga máxima destes acumuladores. Porém, a eficiência energética dos sistemas alimentados e o rendimento dos controladores de carga também influenciam significativamente na autonomia, na vida útil e na segurança das baterias (PEIXOTO, 2012).

A estimação de modelos matemáticos que descrevam com precisão o comportamento de carga e descarga das baterias são de fundamental importância para promover elevada autonomia aos veículos elétricos e híbridos, pois esses modelos auxiliam no projeto dos sistemas elétricos mais eficientes para o veículo (Leão, 2014).

Outro fator fundamental para promover a autonomia destes veículos é monitorar continuamente o estágio de carga da bateria, o que permite a implantação de controladores de carga energeticamente mais eficientes, que também contribuem com a confiabilidade e vida útil das baterias. Atualmente, os sistemas de gerenciamento de carga de baterias de veículos elétricos e híbridos incluem controladores de carga, monitores de capacidade, informações de tempo de carga disponível, contadores de ciclos, entre outros. Todos esses sistemas têm o objetivo de tornar mais eficiente o aproveitamento da energia armazenada nas baterias e garantir o seu funcionamento opere dentro de limites seguros.

Atualmente existem muitos métodos de modelagem matemática aplicados às baterias, desde modelos experimentais, eletroquímicos e baseados em teoria dos circuitos elétricos. Esses modelos podem ainda ser classificados em paramétricos e não paramétricos, de acordo com o método utilizado para estimar o mapeamento entre as variáveis de entrada e saída.

GUO, 2010 apresentada uma investigação a partir do desenvolvimento de um algoritmo genético, utilizado como ferramenta para identificar os parâmetros relacionados com a bateria, incluindo resistência interna, capacidade e estado de carga. Neste trabalho, inicialmente é realizada uma descrição matemática sobre baterias de chumbo ácido, e com base neste estudo, é desenvolvido e implementado um modelo matemático com a finalidade de descrever o processo de descarga das baterias. Os resultados mostram que o modelo proposto é capaz de simular adequadamente o processo de descarga das baterias.

Outro estudo é apresentado por BRAND, 2014, demonstrando um modelo relativamente simples com base em circuitos equivalentes, é utilizado para modelar o desempenho de uma

bateria, investigando o seu potencial como um dispositivo de armazenamento de energia. Um algoritmo genético é desenvolvido para extrair os parâmetros da bateria. Os resultados demonstram que, com os parâmetros extraídos de forma otimizada, o modelo de bateria desenvolvido pode prever com precisão o desempenho de várias baterias de diferentes tamanhos, capacidades e materiais. Vários casos de teste demonstram que o algoritmo genético pode servir como uma ferramenta robusta e com variável para extrair os parâmetros de baterias.

Esse trabalho aborda um modelo não paramétrico, construído através de uma RNA do tipo MLP, e no final faz um comparativo de desempenho com um modelo paramétrico proposto por Tremblay *et al.* (2007).

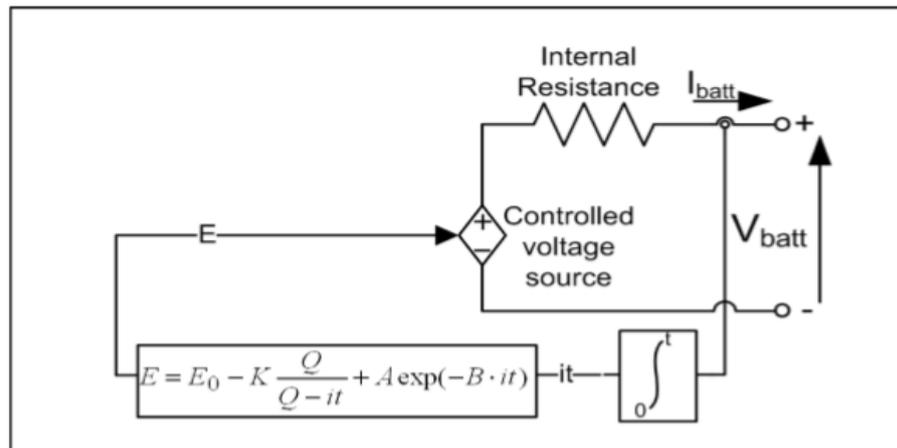
3.1 Modelo Paramétrico

O modelo paramétrico abordado neste trabalho é o modelo proposto por Tremblay *et al.* (2007), que utiliza como parâmetros alguns dados fornecidos pelo fabricante, sejam estes dados de placa ou dados retirados das curvas de descarga. Este método propõe a estimação de curva de descarga para os quatro principais tipos de bateria, Chumbo-Ácido, Lítio-Íon (Li-Ion), Níquel-Cádmio (NiCd) e Níquel-Metal-Hidreto (NiMH).

3.1.1 O modelo da bateria

O modelo paramétrico que esse trabalho adota para a bateria é o modelo proposto por Tremblay *et al.* (2007), que consiste de uma fonte de tensão controlada, em série com uma resistência constante, conforme mostrado na Figura 3. Este modelo assume as mesmas características para os ciclos de carga e descarga, gerando assim uma curva única para descrever tanto o processo de carga, quanto o de descarga. Em outras palavras, considera-se que o tempo de carga e descarga é muito inferior ao tempo necessário para um envelhecimento significativo da bateria.

Figuar 3 : Modelo de bateria não linear



Fonte: Tremblay, (2007)

A fonte de tensão é calculada com uma referência baseada na bateria real. Para o modelo de bateria, a fonte de tensão controlada é descrita pela Equação 3.1:

$$E = E_0 - K \frac{Q}{Q - it} + A \exp\left(-B \cdot \int_0^t idt\right) \quad (\text{Equação 3.1})$$

A equação tem os seguintes parâmetros:

E = tensão sem carga (V)

E_0 = tensão constante da bateria (V)

K = tensão de polarização (V)

Q = capacidade da bateria (Ah)

$\int idt$ = carga real da bateria (Ah)

A = amplitude da zona exponencial (V)

B = inverso da constante de tempo da zona exponencial (Ah)⁻¹

V_{batt} = tensão da bateria (V)

R = resistência interna da bateria (Ω)

i = corrente da bateria (A)

O modelo proposto da Equação 1 representa uma tensão de comportamento não linear, devido ao termo $K \frac{Q}{Q - it} i$, que depende da amplitude da corrente e da carga real da bateria. Isso significa que quando a bateria estiver quase completamente descarregada e, portanto, não houver corrente, a tensão de saída será apenas E_0 , que é um valor próximo de zero. Este modelo

produz resultados precisos do comportamento da bateria, porém é baseado em suposições específicas e tem limitações, que são apresentadas nos itens 3.1.2 e 3.1.3, respectivamente.

3.1.2 Pressupostos do modelo

O modelo assume alguns pressupostos, conforme descrito a seguir:

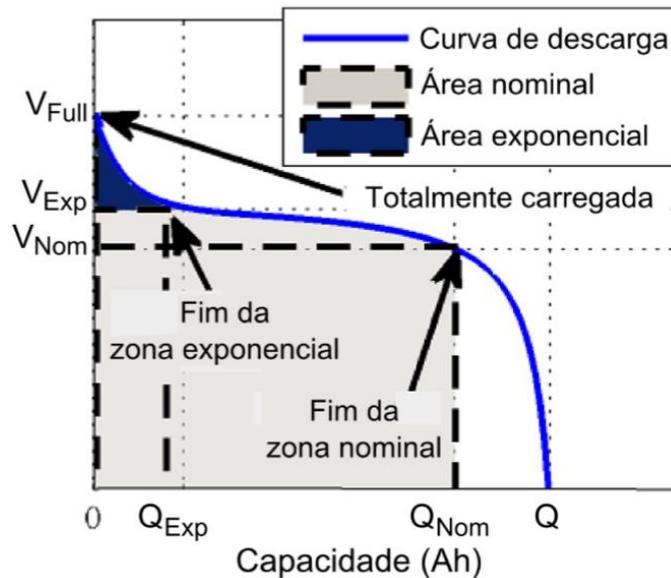
- A resistência interna é supostamente constante durante os ciclos de carga e descarga e não varia com a amplitude da corrente.
- Os parâmetros do modelo são deduzidos das características de descarga e assumidos da mesma forma para o carregamento.
- A capacidade da bateria não muda com a amplitude da corrente (efeito No Peukert).
- A temperatura não afeta o comportamento do modelo.
- A Auto-descarga da bateria não está representada.
- A bateria não tem efeito de memória.

3.1.3 Limitações do Modelo

O modelo proposto por Tremblay *et al.* (2007) tem algumas limitações, as quais são apresentadas abaixo:

- A tensão mínima da bateria sem carga é zero volts e a tensão máxima da bateria não é limitada.
- A capacidade mínima da bateria é de zero amperé-hora e a capacidade máxima não é limitada. Portanto, o máximo em um SOC pode ser maior que 100% se a bateria estiver sobrecarregada.

Figura 4: Curva de descarga do modelo paramétrico



Fonte: Adaptado de TREMBLAY, (2007)

A Figura 4 representa uma curva característica de descarga de uma bateria de células de níquel-metal-hidreto. Através dessa curva é possível extrair com precisão os parâmetros necessários para construir o modelo que pode ser utilizado para representar comportamento da bateria. Existem outros parâmetro importantes para o modelo, que não estão representados na curva, porém que pode ser encontrados na folha de dados do fabricante, tais como a impedância interna.

A impedância não é um parâmetro muito interessante para o modelo proposto, pois testes determinaram que o seu valor, especificado pelo fabricante, não permite representar com precisão a diferença de potencial causada pela variação da corrente (TREMBLAY *et al.* (2007).

Ja a resistência interna é muito importante para representar adequadamente a queda de tensão causada por uma variação de corrente na bateria. Desta forma, Tremblay *et al.* (2007) propõe-se a estabelecer uma relação analítica ligando a resistência interna do modelo à capacidade nominal de carga e do nível de voltagem da bateria. Vale salientar que a resistência interna afeta a tensão de saída da bateria e a sua eficiência. Existem mais de 30 testes empíricos capazes de estabelecerem a resistência interna necessária para que a curva do modelo se aproxime com boa precisão da curva de descarga fornecida pelo fabricante. Tremblay *et al.* (2007) propôs a Equação 3.2 para relacionar a resistência interna com a eficiência.

$$R = V_{nom} \cdot \frac{1 - n}{0,2 \cdot Q_{nom}} \quad (\text{Equação 3.2})$$

Esta equação é utilizada quando nenhuma informação estiver disponível sobre a resistência interna.

3.1.4 Parâmetros do modelo

Para a construção do modelo paramétrico, três pontos precisam ser mensurados, com os respectivos instantes de tempo em que são alcançados, os quais são a tensão de carga completa, tensão no final da região da curva exponencial e a tensão de descarga completa quando a tensão cai rapidamente.

A amplitude da zona exponencial pode ser calculada através da Equação 3.2

$$A = E_{full} - E_{exp} \quad (\text{Equação 3.3})$$

A inversa da constante de tempo da região de curva exponencial calcula-se usando a Equação 3.2.

$$B = \frac{3}{Q_{exp}} \quad (\text{Equação 3.4})$$

A tensão de polarização K pode ser deduzida da tensão de carga completa, E_{full} , e do terceiro ponto, situado no final da zona nominal, Q_{Nom} (capacidade nominal da bateria) e E_{Nom} (tensão nominal da bateria).

$$K = \frac{(E_{full} - E_{Nom} + A(\exp(-B \cdot Q_{Nom}) - 1)) \cdot (Q - Q_{Nom})}{Q_{Nom}} \quad (\text{Equação 3.5})$$

A constante de tensão E_0 é deduzida da tensão de carga completa, conforme mostrado na Equação 3.6:

$$E_0 = E_{full} + K + R \cdot i - A \quad (\text{Equação 3.6})$$

Na tabela 2 são apresentados os parâmetros calculados para as seguintes baterias: Chumbo-Ácido, Li-Ion, NiCd e NiMH, enquanto nas Figuras 5,6,7 e 8 mostradas, respectivamente, as curvas de descarga dos fabricantes destas baterias. Os resultados obtidos por Tremblay (2007) permitem construir curvas que praticamente se sobrepõem as curvas fornecidas pelos fabricantes, o que mostra que o modelo proposto pode representar com boa precisão o comportamento dessas baterias, independentemente da corrente circulante nos ciclos de carga e descarga.

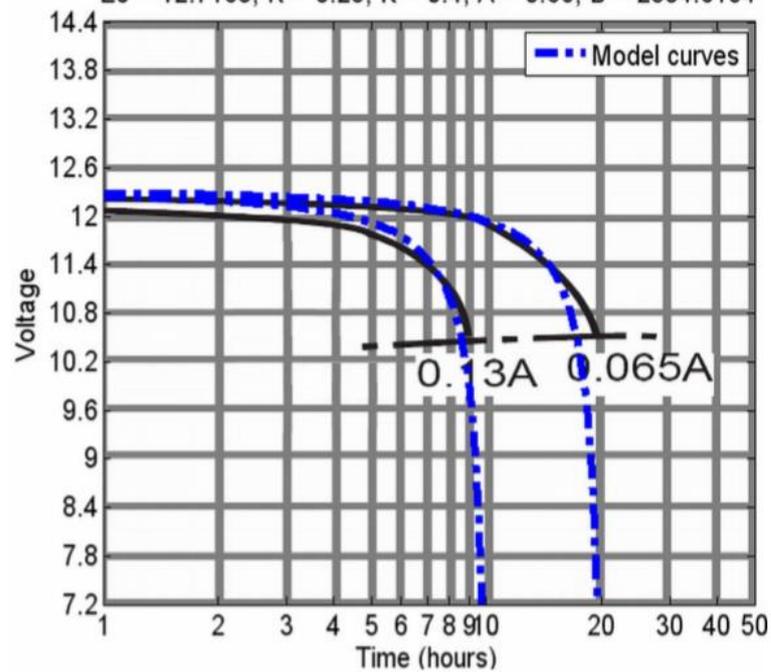
Tabela 2 :Parâmetros do modelo paramétrico

Tipo de parâmetro	Chumbo-ácido 12V 1.2Ah	Níquel-cádmio 1.2V 1.3Ah	Iões de lítio 3.6V 1Ah	Níquel-metal- hidreto 1.2V 6.5Ah
$E_o(V)$	12.6463	1.2505	3.7348	1.2848
$R(\Omega)$	0.25	0.023	0.09	0.0046
$K(V)$	0.33	0.00852	0.00876	0.01875
$A(V)$	0.66	0.144	0.468	0.144
$B(Ah)^{-1}$	2884.61	5.7692	3.5294	2.3077

Fonte: Adaptado de TREMBLAY, (2007)

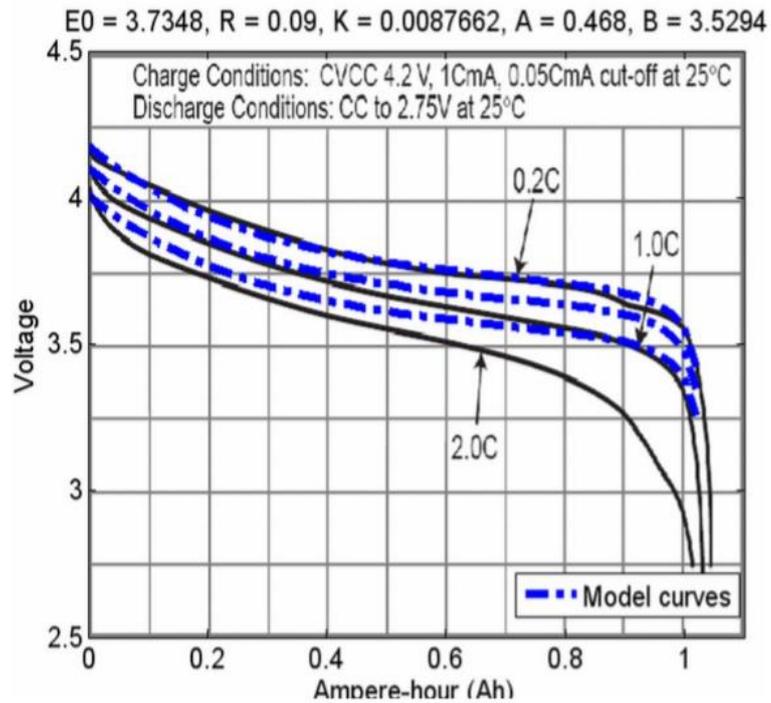
Figura 5: Bateria de chumbo-ácido 12 V 1.2 Ah

$E_0 = 12.7163$, $R = 0.25$, $K = 0.4$, $A = 0.66$, $B = 2884.6154$



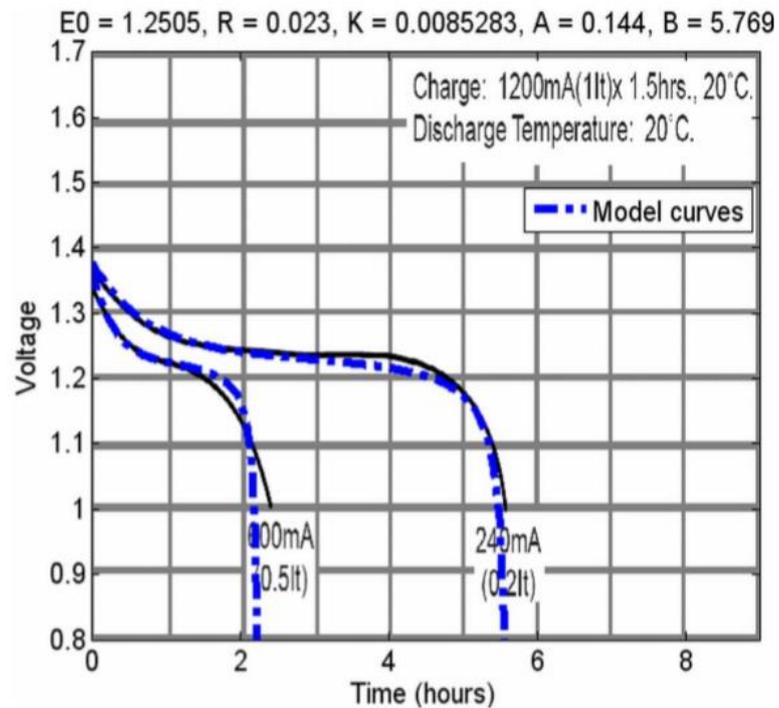
Fonte: Tremblay, (2007)

Figura 6: Bateria de íões de lítio 3.6 V 1 Ah



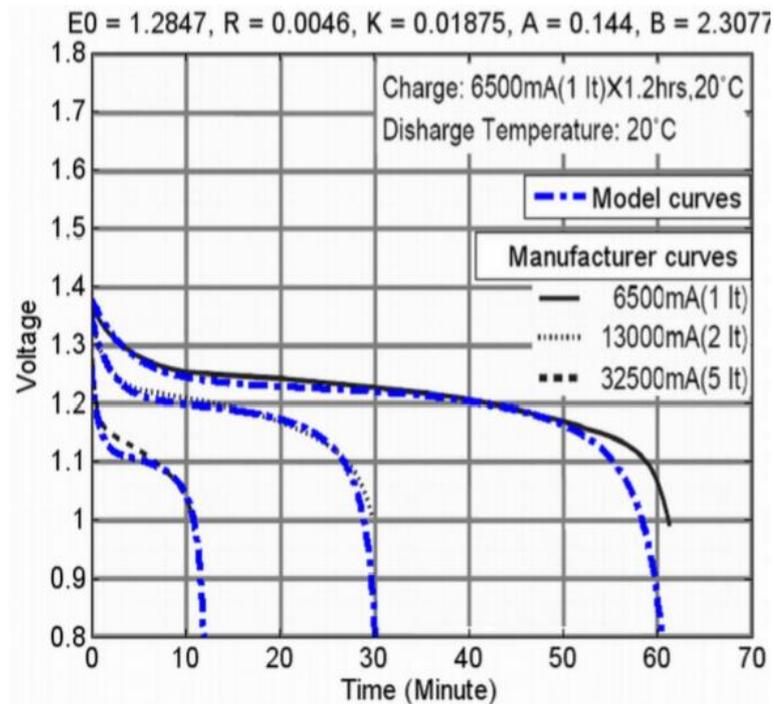
Fonte: Tremblay, (2007)

Figura 7: Bateria de níquel-cádmio 1.2 V 1.3 Ah



Fonte: Tremblay, (2007)

Figura 8: Bateria de níquel-metal-hidreto 1.2 V 6.5 Ah



Fonte: Tremblay, (2007)

3.2 O MODELO NEURAL

3.2.1 Redes Neurais

O cérebro humano é considerado o mais fascinante processador, sendo composto por aproximadamente 10 bilhões de neurônios. Todas as funções e movimentos do organismo estão relacionados ao funcionamento dos neurônios, que estão conectados uns aos outros através de sinapses, e, juntos, formam uma grande rede, chamada rede neural (BRAGA, 2000, *apud* PINTO, 2016, p.23).

Para FLECK *et al.* (2016) “a ideia principal de desenvolver as redes neurais artificiais é projetar um sistema para modelar a maneira como o cérebro realiza uma tarefa particular, utilizando-se componentes eletrônicos, simulações por propagação em um computador digital”

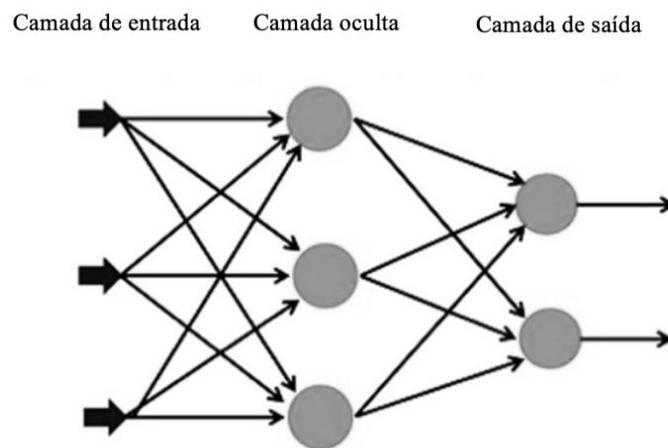
As Redes Neurais Artificiais (RNAs) são algoritmos computacionais que apresentam um modelo matemático inspirado na estrutura de organismos inteligentes, os quais possibilitam inserir simplificado o funcionamento do cérebro humano em computadores. Dessa forma, a exemplo do cérebro humano, a RNA é capaz de aprender e tomar decisões baseadas em seu próprio aprendizado. A RNA corresponde a um esquema de processamento capaz de armazenar conhecimento baseado em aprendizagem e disponibilizar este conhecimento para a aplicação à qual se destina (SPÖRL *et al.*, 2011 *apud* FLECK *et al.* 2016, p.49).

A rede neural se assemelha ao cérebro humano em dois aspectos básicos, o conhecimento é adquirido pela rede a partir de seu ambiente, por intermédio do processo de aprendizagem, e forças de conexão entre neurônios, chamadas de pesos sinápticos são utilizadas para armazenar o conhecimento adquirido (Haykin ,2001 *apud* FLECK *et al.* 2016, p.49).

Na Figura 9 são apresentadas as unidades de processamento chamadas de neurônios artificiais, assim como as ligações entre eles, que são chamados de conexões ou sinapse.

Os neurônios recebem estímulos a partir dos sinais propagados pelos neurônios que estão conectados a eles. Os que recebem sinais de fora da rede são chamados neurônios de entrada, os que fornecem sinais para fora da rede são chamados neurônios de saída e os que recebem estímulos de outros neurônios são conhecidos como neurônios ocultos (SOARES, 2013, P.21).

Figura 9: Representação dos neurônios e conexões



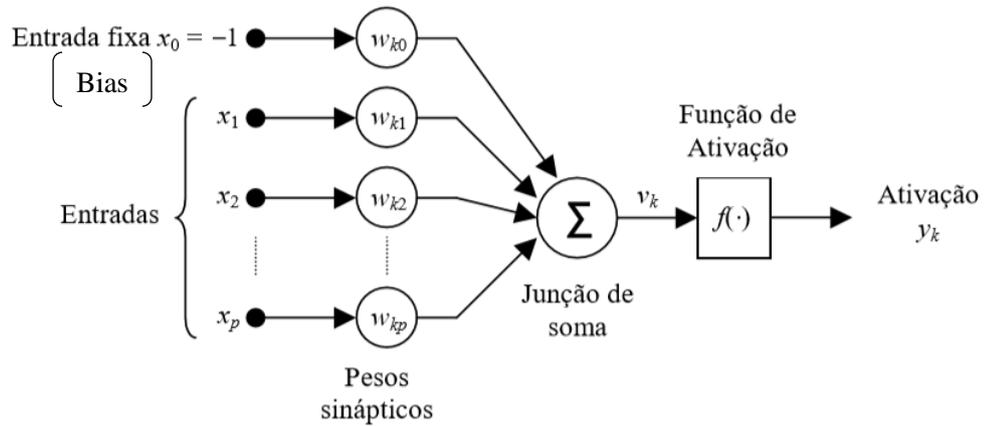
Fonte: Adaptado de Turkson et al. (2016)

3.2.2 Neurônios artificiais

Os neurônios artificiais, assim como os neurônios biológicos, possuem conexões de entrada (dendritos) e de saída (axônios). Entretanto, enquanto a saída de um neurônio biológico está em constante alteração no tempo, a de um neurônio artificial muda somente em intervalos discretos no tempo, isto é, quando os dados de entrada mudam (BATTISTELLA, 2004 *apud* SOARES, 2013, P.23).

A partir da Figura 10 se pode formular um modelo matemático do neurônio artificial descrito pelas Equações 7 e 8.

Figura 10: Modelo não linear de neurônio artificial



Fonte: Adaptado de VANZUBEN (2019)

$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (\text{Equação 3.7})$$

$$y_k = f(v_k) \quad (\text{Equação 3.8})$$

As equações acima são compostas basicamente pelos elementos:

- sinais de entrada $(X_1(t), X_2(t), \dots, X_p(t))$;
- conjunto de pesos $(W_{k1}(t), W_{k2}(t), \dots, W_{kp}(t))$;
- somatório Σ ;
- função de ativação $f(\cdot)$;
- saída $(y_k(t))$.

Os elementos $(X_1(t), X_2(t), \dots, X_p(t))$ são os atributos que compõe as entradas, cada atributo de entrada é multiplicado por um peso correspondente $(W_{k1}(t), W_{k2}(t), \dots, W_{kp}(t))$, gerando valores ponderados. Logo após, todas as entradas ponderadas são somadas e o valor de saída do combinador linear (V_k) é comparado com um valor limite para ativação do neurônio. Caso o valor da soma alcance o valor limite para ativação, o neurônio será ativado, caso contrário, ficará inativo se a função de ativação for linear. A saída $y_k(t)$ é o valor processado pela função de ativação $f(\cdot)$. As conexões possuem pesos sinápticos associados a elas e pode-se dizer que é neles que reside todo o conhecimento adquirido pela rede.

De acordo com SOARES (2013) o 'bias' (b_k) é um valor fixo que, ponderado pelo respectivo peso sináptico, compõe o sinal de ativação dos neurônios da camada a qual está

conectado, permitindo o deslocamento da função de ativação para a direita ou para a esquerda, dentro do espaço de busca. Esse deslocamento é fundamental para o processo de aprendizado da rede, pois confere a flexibilidade necessária para o completo ajuste do hiperplano do modelo, além de evitar erro numérico quando os dados de entrada são nulos ”.

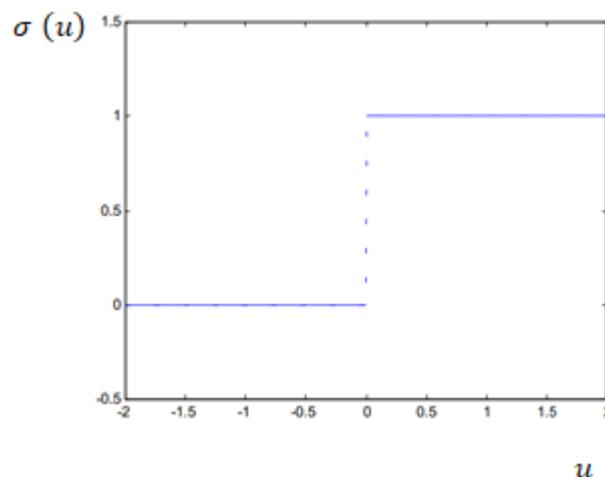
A função de ativação, também pode ser conhecida como função de transferência ou função restritiva já que restringe (limita) a amplitude do valor do sinal de saída de um neurônio a um valor finito (FLECK *et al.* 2016). Os dados de entrada da rede devem ser normalizados para uma faixa de valores compatível com os limites numéricos da função de ativação. A ordem de amplitude normalizada da saída do neurônio pode ser no intervalo $[0, 1]$ ou alternativamente $[-1, 1]$ (HAYKIN, 2001 *apud* SOARES, 2013, P.23).

Cada neurônio possui a sua função de ativação, responsável pela intensidade do sinal a ser transmitido para as camadas seguintes. Segundo Haykin (2001) existem diversos tipos de funções de ativação, sendo as mais populares: degrau, linear e a sigmoide.

Função de Limiar ou (degrau): Neste tipo de função, a saída de um neurônio assume valor 1 se o valor for positivo e zero caso contrário como é visto na Figura 11. Esse comportamento é matematicamente descrito pela Equação 3.9.

$$\sigma(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (\text{Equação 3.9})$$

Figura 11: Função de limiar



Fonte: Vanzuben, (2019)

Vale salientar que a função limiar não pode ser empregada em RNAs que utilizam métodos de aprendizado baseado em gradientes, pois essa função apresenta singularidade em sua derivada no ponto $x = 0$.

Função linear: Geralmente utilizado em neurônios da camada de saída em aplicações de modelagem. Os neurônios que possuem esta função atuam como aproximadores lineares como pode-se ver na Figura 12. As expressões dessa função e da sua derivada são apresentadas nas Equações 3.10 e 3.11.

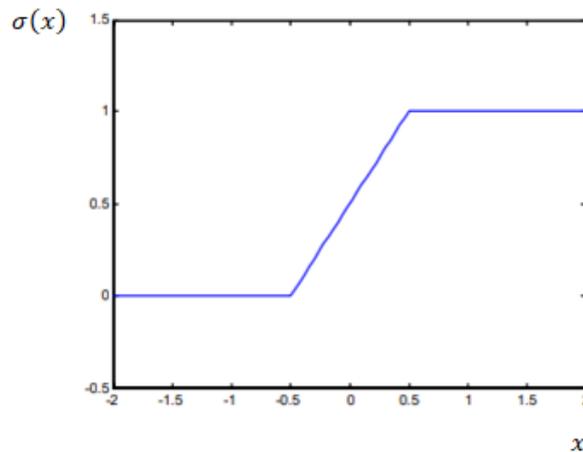
$$\sigma(x) = a \cdot x \quad \forall x \in [-0,5, +0,5] \quad (\text{Equação 3.10})$$

$$\sigma(x) = 1 \quad \forall x > 0,5$$

$$\sigma(x) = 0 \quad \forall x < -0,5$$

$$\sigma'(x) = a \quad \forall x \in [-0,5, +0,5] \quad (\text{Equação 3.11})$$

Figura 12: Função linear



Fonte: Vanzuben, (2019)

Função Sigmoide: É definida como uma função crescente que exibe um balanceamento adequado entre comportamento linear e não linear e assume um intervalo de variação entre 0 e 1 como é visto na Figura 13. Existem dois tipos possíveis de implementação para funções sigmóides: A sigmoide logística assume valores entre 0 (não ativação) e 1 (ativação), a função e sua derivada é dada pelas Equações (3.12) e (3.13).

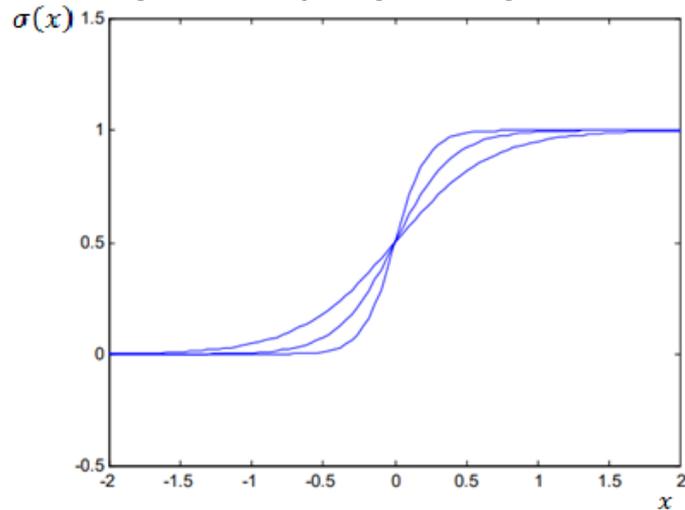
$$\sigma(x) = \frac{1}{1 + e^{(\alpha x)}} \quad (\text{Equação 3.12})$$

$$\sigma'(x) = \sigma(x)(1 - \sigma(x)) \quad (\text{Equação 3.13})$$

Onde,

α = parâmetro de inclinação da função.

Figura 13: Função sigmoide logística



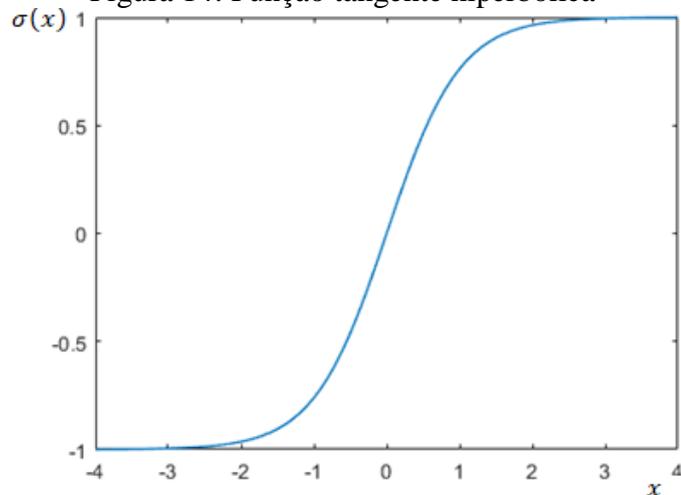
Fonte: Vanzuben, (2019)

Similar a função sigmoide logística, a função Tangente Hiperbólica (TanH) apresentada na Figura 14, também tem um formato de ‘S’, mas varia de -1 a 1, em vez de 0 a 1 como na sigmoide. A TanH se aproxima mais da identidade, sendo assim uma alternativa mais atraente do que a sigmoide para servir de ativação às camadas ocultas das RNAs. A TanH sua derivada são dadas, respectivamente, por:

$$\sigma(x) = 2\sigma(2x) - 1 \quad (\text{Equação 3.14})$$

$$\sigma'(x) = 1 - \tanh^2(x) \quad (\text{Equação 3.15})$$

Figura 14: Função tangente hiperbólica



Fonte: do autor (2019)

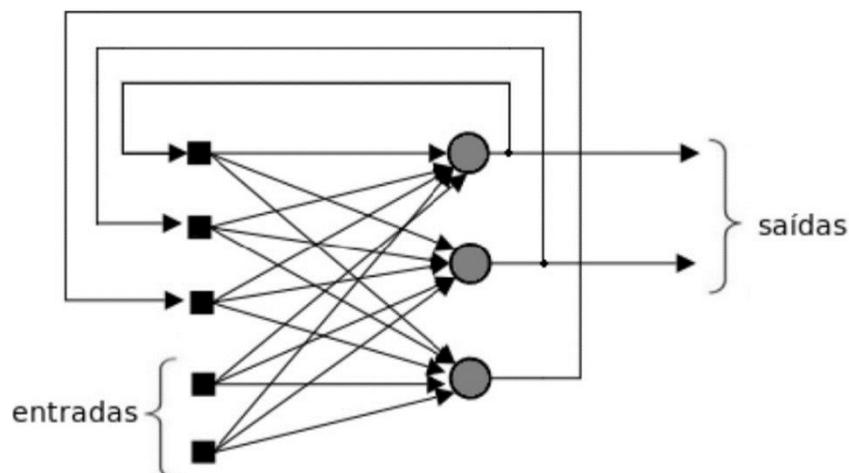
3.2.3 Arquitetura das RNAs

As arquiteturas das RNAs, também conhecida como topologia, se referem à maneira como os neurônios da rede estão organizados. Existem várias estruturas que diferem umas das outras em função do número de camadas e de neurônios, bem como pela forma como seus neurônios interagem (SILVA et al., 2004 *apud* SOARES, 2013, P.26).

Quanto à forma na qual a informação se propaga na rede, elas podem ser subdivididas principalmente em duas classes de arquiteturas: redes recorrentes (*feedback*) e redes de alimentação direta (*feedforward*), que se divide em duas classes, camada única e múltiplas camadas (*multilayer feedforward*) (SOARES, 2013, P.26).

As redes recorrentes são caracterizadas principalmente por terem pelo menos um laço de realimentação. A ocorrência de realimentação, na qual a saída de um neurônio é aplicada como entrada no próprio neurônio e ou em outros neurônios de camadas anteriores, ou seja, há a ocorrência de um ciclo no grafo. A Figura 15 mostra uma rede neural, na qual alguns neurônios são realimentados. (SOARES, 2013, P.27).

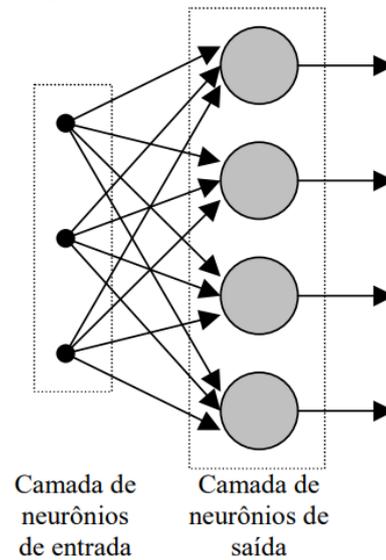
Figura 15: Exemplo de uma rede recorrente



Fonte: Vanzuben, (2019)

Nas redes de alimentação direta (*feedforward*) os neurônios são organizados na forma de camadas. A rede se caracteriza pela propagação dos sinais em apenas uma direção, a partir da camada de entrada até a camada de saída. Na forma mais simples de uma rede em camadas, temos as redes de alimentação direta com camada única que se caracteriza por possuir um único neurônio entre cada entrada e saída de rede conforme está ilustrado na Figura 16 (HAYKIN, 2001).

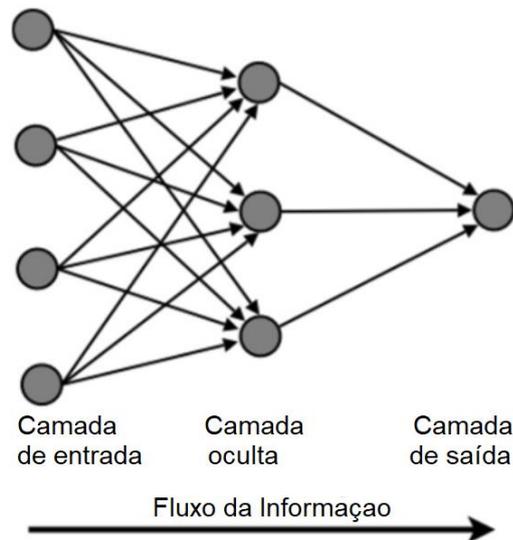
Figura 16: Rede de alimentação direta com uma única camada de neurônios.



Fonte: Vanzuben, (2019)

As redes neurais com alimentação adiante, de múltiplas camadas, tornam-se diferentes pelo fato de ter uma ou mais camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos ou unidades ocultas (HAYKIN, 2001 *apud* SOARES, 2013, P.26). O neurônio oculto tem a função de intervir entre a entrada externa e a saída da rede neural de uma maneira útil, tornando a mesma capaz de extrair estatísticas de ordem elevada. As redes com alimentação direta de múltiplas camadas (multilayer feedforward), conhecida como MLP (do inglês Multilayer Perceptrons), são as redes mais difundidas na literatura (SOARES, 2013, P.26). É esse tipo de rede que é explorada no estudo de caso deste trabalho. A Figura 17 mostra um exemplo de rede de alimentação direta, com uma camada oculta.

Figura 17: Rede com alimentação adiante, com uma camada oculta e uma camada de saída.



Fonte: Adaptado de Vanzuben, (2019)

Alguns autores discutem sobre as camadas de uma rede neural, para XUEPING MA et al. (2009) a rede neural típica possui três ou mais camadas (entrada, meio ou oculta e saída), como é mostrado na Figura 17. Para KALIRAJ e BASKAR (2010), não existe método analítico para escolher o número de camadas e neurônios ocultos de uma rede neural, uma vez que estes dependem da complexidade do problema, o qual na maioria das vezes não se tem conhecimento a priori, sendo então o número de camadas determinado experimentalmente por tentativa e erro.

3.2.4 Aprendizagem e treinamento de RNAs

Uma característica relevante das redes neurais é sua capacidade para identificar padrões a partir de informações do ambiente e de melhorar o seu desempenho através da aprendizagem. A sua eficiência está vinculada diretamente com a capacidade que ela possui de fornecer respostas próximas, o suficiente, dos dados de saída reais (PINTO, 2016, P.24).

A rede neural aprende acerca do seu ambiente através de um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de bias. Ao final do processo de treinamento, a rede terá adquirido conhecimento sobre o ambiente em que está operando, sendo este, “armazenado” parâmetros (Eyng, 2008).

Conforme Haykin (2001), o processo de aprendizado de uma rede neural pode ser definido como: Um processo pelo qual os parâmetros da rede e os pesos das conexões são ajustados através de um processo de estimulação pelo ambiente no qual a rede está inserida, e que no final do processo o conhecimento que a rede adquiriu é armazenado.

Existem diversos métodos para o treinamento de redes neurais e estes podem ser agrupados em dois paradigmas principais: aprendizagem supervisionada e aprendizagem não supervisionada (SILVA et al., 2004 *apud* SOARES, 2013, P.30)

- a) **Aprendizagem supervisionada:** Este aprendizado que é também denominado aprendizagem com um supervisor, é um método implementado através da disponibilização de um professor que verifique os desvios da rede a um determinado conjunto de dados de entrada e saída. O supervisor externo fornece á RNA a saída desejada em relação a um padrão de entrada. É possível comparar a saída da RNA com a saída desejada, obtendo-se o erro referente à resposta atual. A partir do erro, os pesos sinápticos são ajustados de forma a minimizar o erro. A minimização do erro é incremental, pois a cada resposta gerada pela rede, são efetuados pequenos ajustes nos pesos das conexões.
- b) **Aprendizagem não supervisionada:** Neste tipo de aprendizagem não há um supervisor externo para supervisionar o processo de aprendizagem. São fornecidos para a rede somente os padrões de entrada. A rede trabalha essas entradas e se organiza de modo que acabe classificando-as, usando para isso os seus próprios critérios. Esse tipo de rede utiliza os neurônios como classificadores, e os dados de entradas como elementos para classificação.

3.3 Perceptron de Múltiplas Camadas (MLP)

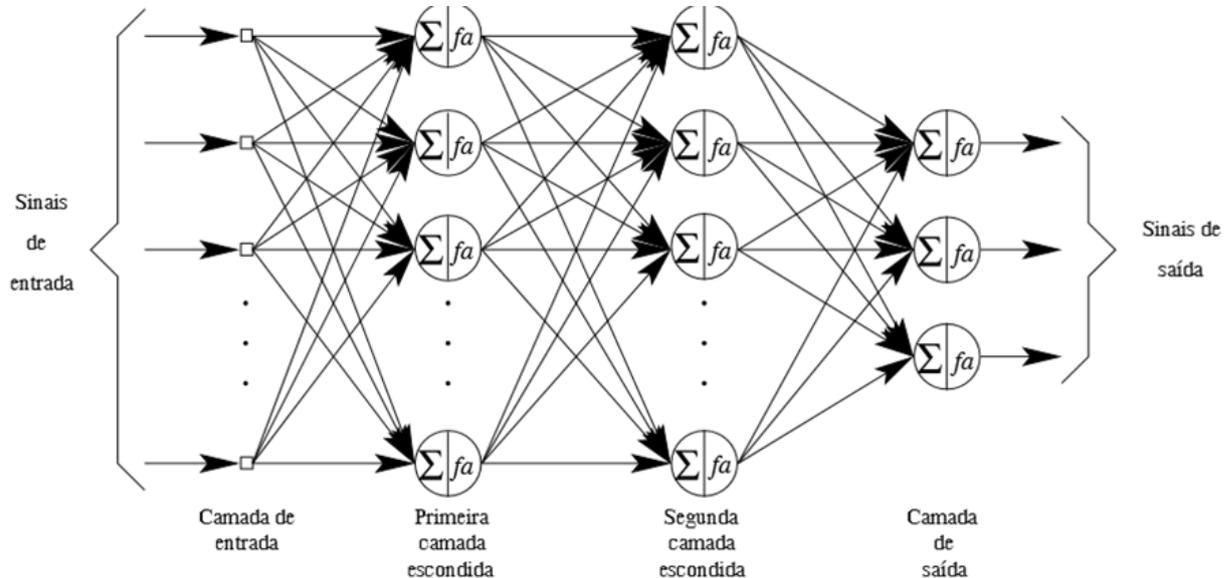
Segundo Fleck *et al.* (2016) o Perceptron, é o modelo mais simples de RNA, cuja principal aplicação se dá nos problemas de classificação de padrões. As RNAs do tipo MLP são caracterizadas por apresentar uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, todas elas compostas por um conjunto de nós sensoriais também conhecidos por neurônios (MANZAN, 2016).

As redes MLP representam uma generalização do perceptron de camada única, proposto por Rosenblatt, e podem tratar com dados que não são linearmente separáveis, ou seja, apresentam um poder computacional muito maior do que aquele demonstrado pelas redes sem camada intermediária (NIED, 2007, p.7).

As camadas de uma rede MLP são classificadas em: camada de entrada (*input layer*), camada (s) intermediárias (*hidden layers*) ou escondida (s) e camada de saída (*output layer*) (NIED, 2007, p.8). A Figura 18 mostra o grafo arquitetural de uma rede MLP com duas camadas escondidas e uma camada de saída. Os nós de fonte da camada de entrada da rede fornecem os respectivos elementos do padrão de ativação (vetor de entrada), que constituem os sinais de entrada aplicados aos neurônios (nós computacionais) na segunda camada (ou primeira camada

escondida). Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada, e assim por diante para o resto da rede. (MANZAN, 2016).

Figura 18: Grafo arquitetural de uma rede MLP com duas camadas escondidas.



Fonte: Nied, (2007)

Os neurônios da camada escondida, também chamada de ‘camada oculta’ ou ‘camada intermediária’ (primeira camada de pesos sinápticos), recebem este nome por não terem acesso direto à saída da rede MLP, onde são calculados os erros de aproximação.

As suas considerações e definições dos cálculos estão apresentados a seguir pela Figura 19 que representa, uma arquitetura de rede neural do tipo MLP com apenas uma camada escondida de neurônios treinados com o algoritmo de retropropagação do erro (*Error Backpropagation*). Os neurônios da camada escondida (primeira camada de pesos sinápticos) são representados conforme mostrado na Figura 19a, enquanto os neurônios da camada de saída (segunda camada de pesos sinápticos) são representados conforme mostrado na Figura 20b. O vetor de pesos associado a cada neurônio *i-ésima* da camada escondida é representada como:

$$\mathbf{w}_i = \begin{pmatrix} w_{i0} \\ \cdot \\ \cdot \\ \cdot \\ w_{ip} \end{pmatrix} = \begin{pmatrix} \theta_i \\ \cdot \\ \cdot \\ \cdot \\ w_{ip} \end{pmatrix} \quad (\text{Equação 3.16})$$

Onde,

θ_i : É o limiar (*bias ou threshold*) associado ao neurônio *i*.

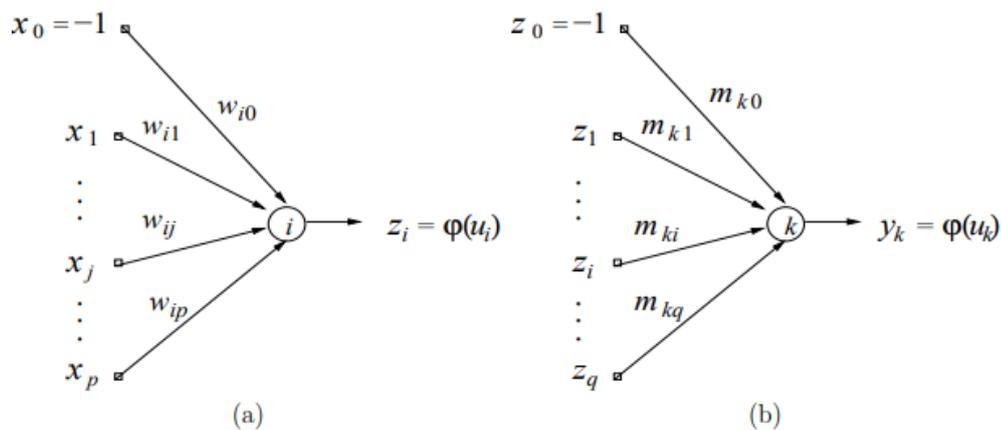
Os neurônios da camada de saída (segunda camada de pesos sinápticos) são representados conforme mostrado na Figura 19 b. o vetor de pesos associado a cada neurônio k da camada de saída é representado como.

$$m_k \begin{pmatrix} m_{k0} \\ \vdots \\ \vdots \\ w_{kp} \end{pmatrix} = \begin{pmatrix} \theta_k \\ \vdots \\ \vdots \\ w_{qp} \end{pmatrix} \quad (\text{Equação 3.17})$$

θ_k : É o limiar associado ao neurônio de saída K .

Figura 19: Sentido direto da rede MLP

(a) Neurônio da camada escondida. (b) Neurônio da camada de saída.



Fonte: Barreto, (2007)

A seguir são descritas as duas etapas do treinamento da rede MLP.

3.3.1 Treinamento da rede MLP

O algoritmo de aprendizagem de rede MLP mais utilizado é o backpropagation, também chamado de retropropagação de erros (PATNAIK e MISHRA, 2000 *apud* SOARES, 2013, P.231). O Erro *Backpropagation* se fundamenta no treinamento supervisionado e utiliza pares de entrada e saída para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. O ajuste dos pesos realizado pelo algoritmo de retropropagação de erros é baseado na regra delta, conhecida como “Regra Delta Generalizada”. O treinamento através do algoritmo

de retropropagação de erros consiste de dois passos através das diferentes camadas da rede: o processamento direto e o processamento reverso.

Processamento direto: é também chamado de fase de propagação. O curso de sinais (informação) segue dos neurônios de entrada para os neurônios de saída, passando pelos neurônios da (s) camada (s) oculta (s). Nesta etapa são executados a computação das funções de ativações e saídas de todos os neurônios da camada escondida e de todos os neurônios da camada de saída (Barreto, 2007). Durante o processamento, os pesos da rede permanecem fixos. O sentido direito tem a função de propagar o sinal de entrada até a saída da rede, que então é comparado com o valor desejado, sendo calculado o erro, que segue para a etapa de retropropagação. Como a retropropagação atualiza os pesos numa proporção (taxa de aprendizado) do inverso do gradiente descendente (ou seja, atualiza os pesos no sentido de gerar a redução do erro), a tendência é que, após várias rodadas de treinamento, o processamento no sentido direto leve a um valor que se aproxima do valor desejada para a saída da rede (OLIVEIRA, 2019).

O fluxo de sinais (informação) se dá dos neurônios de entrada para os neurônios de saída, passando obviamente pelos neurônios da camada escondida. Por isso, diz-se que a informação está fluindo no sentido direto (*forward*) (Barreto, 2007).

Entrada → Camada Intermediária → Camada de Saída

O primeiro passo é calcular as ativações dos neurônios da camada escondida, começando por inserir um vetor de dados de entrada x , chamado de vetor de atributos, para cada iteração t . Para todo dado apresentado na camada de entrada é acrescentado uma variável independente, chamada bias, que geralmente assume o valor -1e que exerce influência na resposta da rede (Barreto, 2007).

Na Equação 3.18, apresenta-se o cálculo das ativações dos neurônios da camada escondida.

$$u_i(t) = \sum_{j=0}^p w_{ij}(t)x_j(t) = \mathbf{w}_i^T(t)\mathbf{x}(t), \quad i = 1, \dots, q \quad (\text{Equação 3.18})$$

Onde:

T = transposição da matriz do vetor de peso.

q = número de neurônios da camada oculta em questão.

Através da Equação 3.19 é possível calcular a saída correspondente da rede:

$$z_i(t) = \phi_i\left(\sum_{j=0}^p w_{ij}(t)x_j(t)\right) = \phi_i(w_i^T(t)x(t)) \quad (\text{Equação 3.19})$$

Em que, $z_i(t)$ representa as saídas dos neurônios da camada intermediária.

Oliveira (2019) ressalta que a função de ativação deve ser diferenciável em todo o seu domínio, de modo que se possa calcular a derivada parcial do erro em relação a um dado peso. Oliveira (2019) ressalta ainda que cada neurônio pode assumir uma função de ativação distinta, porém usualmente adota-se a mesma função de ativação para todos, quando não, dependendo da aplicação, pode-se fazer necessário que o neurônio da camada de saída seja diferente do restante.

Processamento inverso: Dá-se do fluxo de sinais (informação) dos neurônios da camada de saída para os da (s) camada (s) escondida (s). Esta etapa de processamento de aprendizado envolve o cálculo dos gradientes da função de erro e o ajuste dos pesos de todos os neurônios da camada escondida e da camada de saída (Barreto, 2007).

O primeiro passo nesta etapa se inicia com o cálculo dos gradientes locais dos neurônios da camada de saída, conforme é apresentado na Equação 3.20.

$$\delta_k(t) = e_k(t)\phi'(u_k(t)), \quad k = 1, \dots, M \quad (\text{Equação 3.20})$$

Onde, $e_k(t)$ representa o erro entre a saída desejada $d_k(t)$ para o neurônio k e a saída gerada por ele $y_k(t)$.

$$e_k(t) = d_k(t) - y_k(t), \quad k = 1, \dots, M \quad (\text{Equação 3.21})$$

Como o erro entre valor desejado e saída da rede é calculado apenas para a camada de saída, o algoritmo de *backpropagation* responde como determinar a influência do erro nas camadas intermediárias da rede. Essa influência é definida pelo cálculo do gradiente local também para estas camadas. O cálculo desse gradiente é definido pela derivada $\phi'((u_k(t)))$, onde o seu resultado será influenciado diretamente pela forma da função de ativação adotada.

O segundo passo consiste em calcular os gradientes locais dos neurônios da camada escondida:

$$\delta_i(t) = \phi'_i(u_i(t)) \sum_{k=1}^n m_{ki} \delta_k(t), \quad i = 1, \dots, q \quad (\text{Equação 3.22})$$

O último passo corresponde ao processo de atualização ou ajuste dos parâmetros (pesos sinápticos e o peso do limiar) da camada escondida da rede MLP. Assim, para a camada escondida a regra de atualização destes parâmetros, w_{ij} , é feita através da equação:

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \Delta w_{ij}(t) && (\text{Equação 3.23}) \\ &= w_{ij}(t) + \alpha \delta_i(t) x_j(t) \end{aligned}$$

Onde $\alpha(t)$ é a taxa de aprendizagem, que pode assumir valores entre 0 e 1.

E para cada camada de saída, a regra de atualização dos pesos, m_{ki} é calculada conforme mostrado na Equação 3.24:

$$\begin{aligned} m_{ki}(t+1) &= m_{ki}(t) + \Delta m_{ki}(t) && (\text{Equação 3.24}) \\ &= m_{ki}(t) + \alpha \delta_k(t) z_i(t) \end{aligned}$$

3.3.2 Treinamento, Convergência e Generalização

Um bom aprendizado da rede não depende apenas da disponibilidade de um conjunto de dados relevantes para a tarefa que se deseja realizar, mas também da correta especificação dos hiperparâmetros, como por exemplo o número de neurônios nas diversas camadas, taxa de aprendizado, fator de momentum, entre outros (Barreto, 2007).

Para cada hiperparâmetro existe uma faixa de valores que influencia significativamente no desempenho do algoritmo de treinamento. De acordo com BARRETO (2007), os principais fatores a serem observados durante o projeto de uma RNA são:

1. Seleção e tratamento dos dados: É necessária uma análise prévia da tarefa a ser realizada no intuito de identificar quais informações são relevantes para o modelo a ser construído. A utilização de informações não relevantes pode impedir ou dificultar um aprendizado satisfatório. Os dados precisam ser condicionados a faixa de valores compatíveis com as funções de ativação da

rede. Além disso, *outliers* devem ser identificados e eliminados do conjunto para que não dificultem o processo de aprendizado.

2. Tamanho da rede: definido pela dimensão do vetor de entrada (p), dimensão do vetor de saída (M) e pelo número de neurônios na camada escondida (q).
3. Funções de ativação φ_i e (φ_k) : é o mapeamento local implementados por cada um dos neurônios da rede. Usualmente essas funções combinam regiões de linearidade com regiões de não linearidade e as mais utilizadas são tangente hiperbólica, sigmoide logística.
4. Critério de Parada e Convergência: o treinamento é um processo iterativo que aperfeiçoa gradualmente o aprendizado da rede. Quando o resultado é considerado satisfatório, o processo de aprendizado deve encerrado. Usualmente se utiliza o erro quadrático médio e a variância desse erro, tanto para dados de treinamento quanto de teste, para identificar um aprendizado satisfatório da rede, ou taxas de acerto quando a tarefa é de natureza de classificação.
5. Avaliação da Rede Treinada: Após o encerramento do treinamento, se faz necessário avaliar o desempenho da rede apresentando a esta, dados que não foram utilizados durante o treinamento ou teste. A este processo dar-se o nome de validação. Em que mais uma vez se contabiliza o erro quadrático médio. Para quantificar o desempenho da rede.

Dimensão do vetor de entrada (p): A aplicação pode assumir em tese dimensões entre 1 a ∞ . Existe um limite superior que depende da aplicação de interesse em casos em que os dados de entrada possuem alta dimensionalidade, o número de conexões sinápticas pode assumir valores extremamente elevados, o que não indica necessariamente um melhor desempenho para a rede neural, pois pode haver redundância no processo de medição. Neste caso devem ser selecionados os dados mais relevantes para o processo de treinamento que então passarão a compor os atributos de entrada da rede. Esse processo de seleção nem sempre é simples, muitas vezes requer diversas tentativas até que se identifique os atributos mais significantes para o processo. Quando é difícil medir um determinado número de variáveis deve-se escolher aqueles que o especialista da área considera como mais relevante ou representativa para o problema. O ideal seria que cada variável $X_j, j = 1 \dots, P$ “carregasse” informação que somente ela contivesse. Estatisticamente isto significa afirmar que as variáveis são independentes ou não correlacionadas entre si (Barreto, 2007).

Tamanho do vetor de saída (M): Este item depende da aplicação de interesse podendo esta ser de aproximação de funções $y = F(x)$ ou classificação de padrões. Se o interesse está em problemas de aproximação de função, o número de neurônios deve refletir diretamente a quantidades de funções de saída desejadas (ou seja, a dimensão de y). Caso o interesse está em problemas de classificação de padrões neste caso, o número de neurônios deve codificar o número de classes desejadas. Porém, é possível treinar uma rede para cada classe de modo que está se torne especialista em reconhecer os dados dessa classe. Neste caso, os dados de entrada são apresentados para todas as redes e aquela que apresentar maior valor de saída define a classe do dado. Em uma rede neural apenas valores numéricos podem ser processados, porém, na maioria das vezes, os rótulos das classes são compostos por dados não numéricos. Por isso se faz necessário codificar esses dados em valores numéricos para que possam ser utilizados no cálculo do erro, que ocorre na fase de treinamento da rede MLP. A técnica mais simples para codificar os dados da saída de rede é a binária, onde o valor “1” será atribuído apenas a saída referente a classe ao qual o dado pertence, quanto o número zero deve ser atribuído a todos os outros campos do vetor de saída (Barreto ,2007).

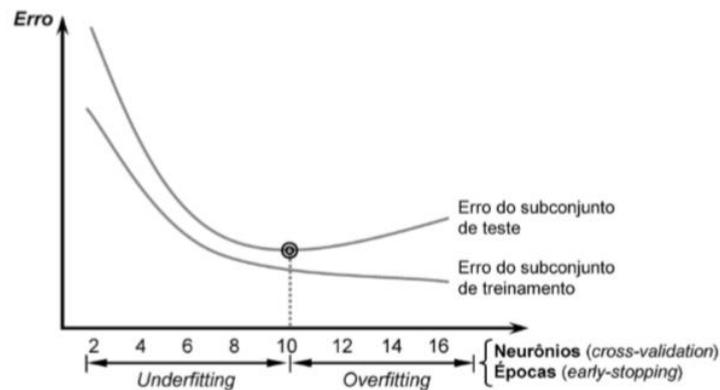
Número de neurônios na camada escondida (q): Encontrar o número ideal de neurônios da camada escondida pode ser uma tarefa árdua, pois depende de muitos fatores que não se tem controle. Segundo (Barreto 2007), entre os fatores os mais importantes estão:

1. Quantidade de dados disponíveis para treinar e testar a rede.
2. Qualidade dos dados disponíveis (ruidosos, com elementos faltantes, etc.)
3. Número de parâmetros ajustáveis (pesos e limiares) da rede.
4. Nível de complexidade do problema (não linear, descontínuo, etc.).

O valor do número de neurônios na camada escondida (q) comumente é encontrado através da técnica por tentativa-e-erro, baseado no nível da habilidade de generalização da RNA. Esta propriedade avalia o desempenho da rede neural no caso do valor de q gerar um desempenho satisfatório para os dados de treinamento, apresenta-se a rede, dados que não foram utilizados no processo de treinamento, esses dados são chamados dados de teste. Caso a rede permaneça apresentando uma boa taxa de acerto ou um baixo valor de erro, pode-se concluir que o valor adotado para q é satisfatório. Adotar um número de q superior ao necessário para a captura do modelo pode reduzir a capacidade de generalização da rede. Neste caso, dizemos que a rede “decorou” os dados de treinamento, porém não é capaz de apresentar bons resultados

novos. Esse processo pode ser identificado através das curvas de aprendizado de treinamento e teste, ao longo das épocas, como é ilustrado na Figura 20 (Barreto ,2007).

Figura 20: Treinamento com *overfitting*



Fonte: Junior, (2017)

3.3.3 Convergência

A convergência do treinamento da MLP significa a atualização dos pesos da rede num sentido de estabilizar os gradientes descendentes, preferencialmente para valores bem próximos de zero, resultando na estagnação do aprendizado da rede.

A taxa de convergência do algoritmo *backpropagation* é, geralmente, analisada a partir dos valores do erro quadrático médio (EQM) por iteração (época) de treinamento. Essa taxa tende evoluir no sentido de se tornar relativamente baixa, o que torna este algoritmo lento no aspecto computacional. Entretanto, se a aplicação da rede for uma tarefa de classificação de padrões, a performance da rede usualmente é balizada pela taxa de acerto:

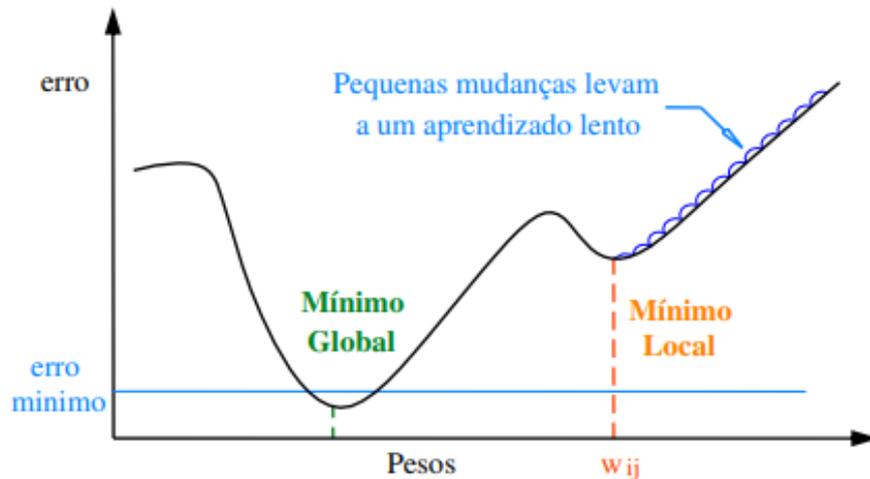
$$p_{\text{época}} = \frac{\text{Número de vetores classificados corretamente}}{\text{Número total de vetores}}$$

3.3.4 Taxa de aprendizado

A taxa de aprendizado é um parâmetro contido no intervalo $[0,1]$, que interfere na convergência do processo de aprendizado. Esse parâmetro define a taxa de atualização dos pesos sinápticos. Uma taxa de aprendizado muito pequena provoca mudanças muito pequenas nos pesos a cada interação, o que torna o processo de aprendizado mais estável, no entanto o tempo de treinamento fica muito longo, e dependendo da inicialização dos pesos é possível cair no problema de mínimo local. Nesse caso não se consegue calcular uma mudança nos pesos

que faça a rede sair do mínimo local, como pode ser observado na Figura 21, efeito esse produzido por taxas de aprendizado pequenas.

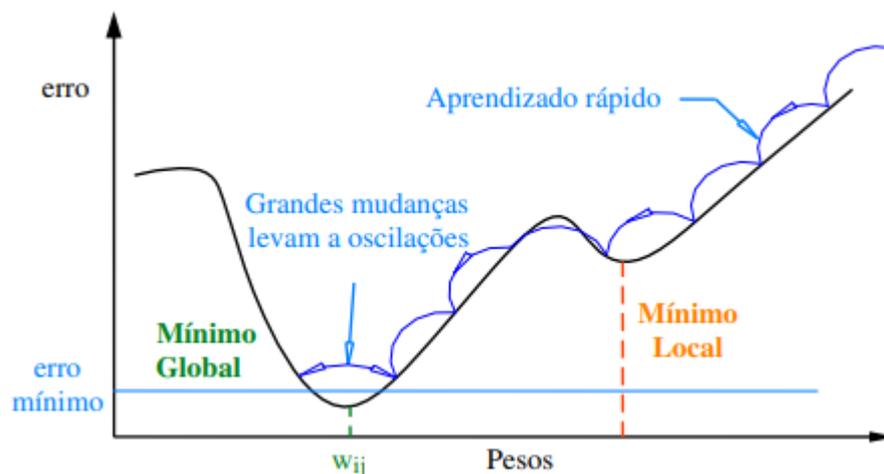
Figura 21: Taxa de aprendizado pequena, com problema de mínimo local



Fonte: Sanchez, (2009)

Na Figura 22 nota-se outro efeito causado pela taxa de aprendizado, porém neste caso quando a taxa de aprendizado é muito grande. Entretanto quando o valor da taxa de aprendizado é grande (perto de 1), ocorre uma maior mudança nos pesos, aumentando a velocidade do aprendizado, o que pode levar a oscilações em torno do mínimo global.

Figura 22: Taxa de aprendizado grande, com problema de oscilações.



Fonte: Sanchez, (2009)

A taxa de aprendizado não pode ser muito pequena e nem muito grande. O ideal é usar uma taxa de aprendizado adaptativa, a qual inicia com um valor grande, que não leve a uma oscilação exagerada, obtendo um aprendizado mais rápido no início do processo, e que decresce

à medida que o treinamento evolui. É muito comum se aplicar uma taxa de decaimento exponencial para a taxa de aprendizado, no intuito de evitar o problema do mínimo local e também permitir a convergência do aprendizado (SANCHEZ, 2009).

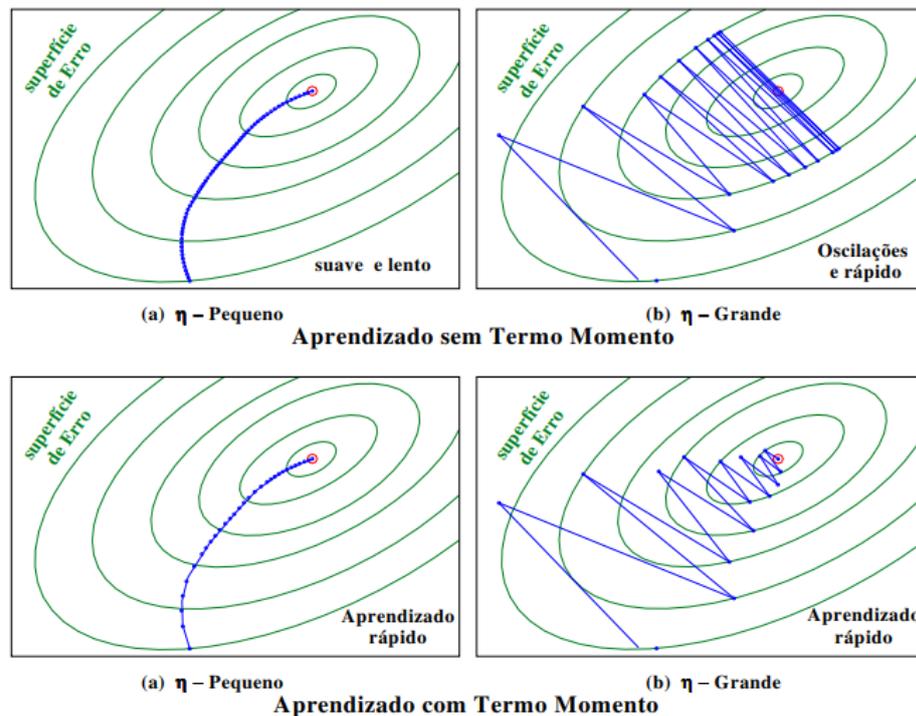
3.3.5 Termo de Momentum

O termo de momentum é uma maneira de aumentar a taxa de aprendizado sem que haja oscilações durante a execução do algoritmo *backpropagation*. O termo momento é incluído para determinar as mudanças nos pesos, levando em consideração o efeito das mudanças anteriores dos pesos na direção do movimento atual dos pesos. A mudança dos pesos, tomando em consideração o efeito do termo de momentum, é determinado por:

$$\Delta w_{ij}^{t+1} = n \cdot s_i \cdot e_j + \alpha \cdot \Delta w_{ij}^t \quad (\text{Equação 3.25})$$

Onde, Δw_{ij}^{t+1} e Δw_{ij}^t são as variações de pesos do neurônio j em relação a conexão i no instante $t+1$ e t respectivamente, n é a taxa de aprendizado e α é o termo de momentum. Na Figura 23 é apresentado o efeito do termo de momentum na aprendizagem da rede.

Figura 23: Aprendizado com termo *momentum*



Fonte: Sanchez, (2009)

3.3.6 Avaliação da Rede Treinada

Para validar a rede treinada é necessário testar a sua resposta (saída) para dados de entrada diferentes daqueles vistos durante o treinamento. Os novos dados podem ser obtidos de novas medições que nem sempre é viável. Durante os testes com novos dados os pesos da rede não são ajustados. Para reverter esse problema, deve-se treinar a rede com uma parte dos dados escolhidos aleatoriamente, o restante é guardado para testar o desempenho da rede. Deste modo tem-se dois conjuntos de dados um para treinamento, de tamanho $N_1 < N$, e outro de tamanho $N_2 = N - N_1$ (SANCHEZ, 2009).

O valor de ε_{epoch} calculado com os dados de teste é chamado de *erro de generalização* da rede. Este dado permite testar a capacidade da rede em extrapolar o conhecimento aprendido durante o treinamento para novas situações. Geralmente o erro de generalização é maior que o erro de treinamento, porque trata-se de um novo conjunto de dados.

3.4 Treinamento Online

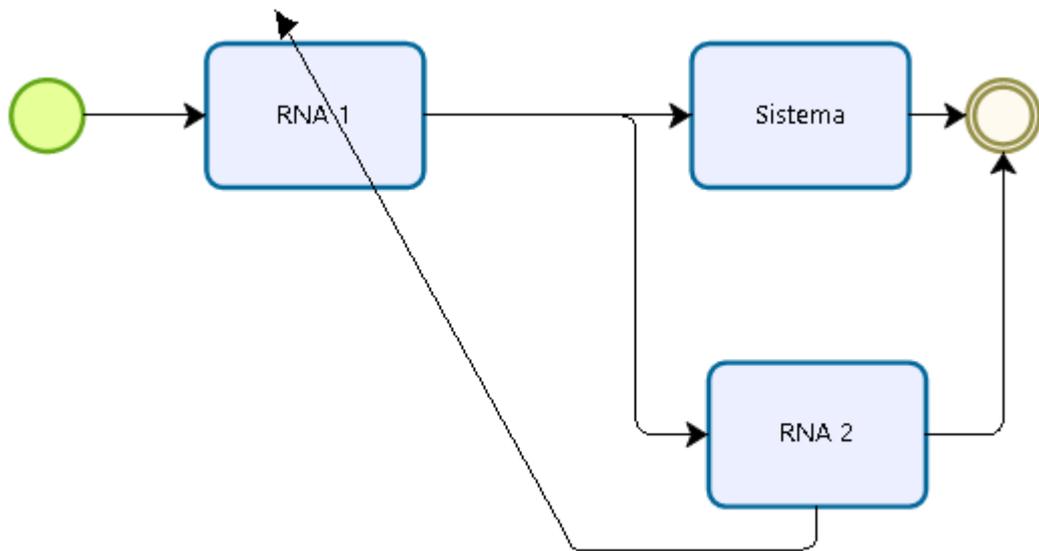
O aprendizado em redes neurais pode ser amplamente dividido em duas categorias, a saber, aprendizado off-line (ou em lotes) e aprendizado on-line (ou incremental). O aprendizado off-line lida com ambiente da rede estacionária, enquanto que o aprendizado on-line lida com ambientes dinâmicos variáveis. Quando um sistema baseado em rede neural é usado para resolver problemas do mundo real que exigem portabilidade e adaptabilidade do sistema às condições locais, o aprendizado online se torna útil. A utilidade do aprendizado online é fazer com que a rede se adapte às condições alteradas no novo ambiente, aprendendo de forma incremental as amostras de dados recebidas do novo local (LAKHMI *et al.* 2014).

De acordo com Carlos (2017), a aprendizagem online permite a extração ininterrupta do conhecimento em relação ao problema abordado, favorecendo a adaptação da RNA para possíveis mudanças de comportamento dos dados de entrada, no decorrer do diagnóstico. No entanto, requer que o modelo possua uma arquitetura flexível. O aprendizado on-line é altamente popular para resolução de problemas de classificação de padrões por duas importantes razões práticas (SIMON, 2008):

- O aprendizado on-line é simples de implementar;
- Fornece soluções eficazes para classificação de padrões em larga escala e problemas difíceis.

O recurso do aprendizado on-line pode ser agrupado a várias arquiteturas de redes neurais artificiais, como as redes feedforward, redes neurais recorrentes, redes neurais difusas e outras redes relacionadas. A Figura 24 mostra o diagrama de um esquema de um treinamento on-line onde a RNA 2 aprende continuamente o modelo do sistema e atualiza o modelo da RNA 1, de forma que esta gere o sinal necessário para que sistema apresente a resposta desejada, mesmo que a dinâmica do sistema evolua no tempo.

Figura 24 – Treinamento On-line



Fonte: do autor (2019)

4. METODOLOGIA

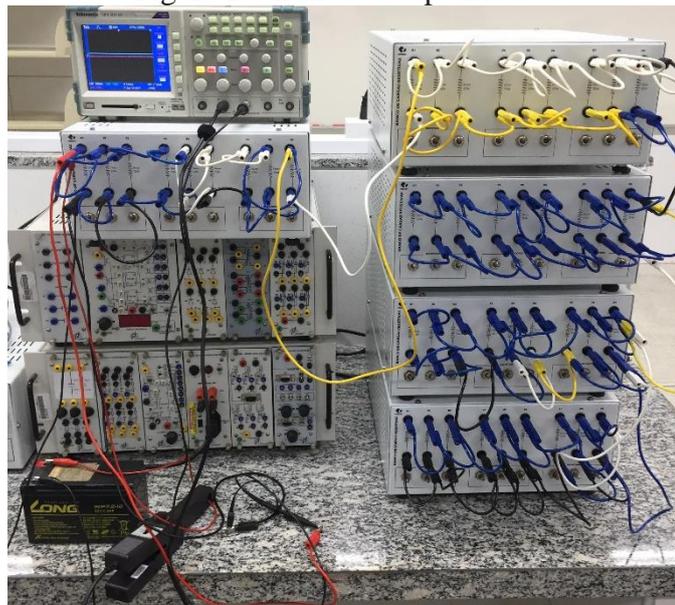
4.1 Aquisição de dados

Neste trabalho é utilizado um amplo conjunto de dados reais, obtidos a partir de uma bancada experimental, instalada no laboratório de máquinas elétricas da UNILAB. Os dados gerados são utilizados para validar as metodologias avaliadas nesta pesquisa, tanto para a estimação dos parâmetros dos modelos quanto para a validar o próprio modelo, permitindo realizar um estudo comparativo de desempenho.

4.1.1 Bancada experimental

A bancada experimental foi utilizada para capturar a evolução dos valores de tensão e corrente, ao longo do tempo, durante processos de descarga. Esta bancada é usada para realizar ciclos de descargas na bateria, utilizando banco de resistores, além de um osciloscópio, para a medição da tensão de terminal e a corrente de saída da bateria, como pode ser visto na figura 25.

Figura 25: Bancada experimental



Fonte: Autor (2019)

4.1.2 Descarga da bateria

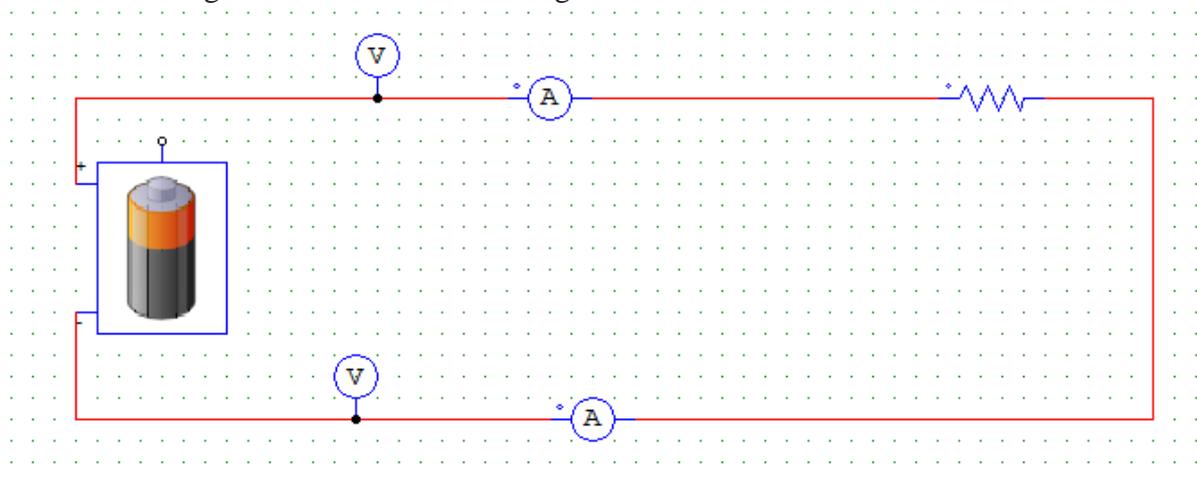
Para a geração dos dados, foram realizados dois ciclos de descarga, respeitando a tensão de segurança informada pelo fabricante. Entre cada ciclo de descarga é realizado um processo

de carga completa da bateria, aplicando-se uma tensão de 14.4 volts durante 4 a 5 horas, de forma que a bateria passa a apresentar uma tensão a vazio de 13.5 volts.

No primeiro processo de descarga foi conectada a bateria um banco de 45 resistores ligados em paralelo, que resultou em uma corrente de descarga inicial de 2.4 A. Este processo durou 16 horas e 13 minutos, até que a bateria alcançou 9,5 volts, que corresponde a tensão de segurança informada pelo fabricante.

No segundo processo de descarga foi conectada a bateria um banco de 30 resistores ligados em paralelo, que resultou em uma corrente de descarga inicial de 2.1 A. este processo durou em 3h e 26 até que a bateria alcançou 9,5 volts, que corresponde a tensão de segurança informada pelo fabricante. A figura 26 apresenta o circuito montado para o processo de descarga.

Figura 26: Circuito de descarga da bateria- um banco de resistores



Fonte: PSIM (2019)

4.2 Material Utilizado

Para realizar a aquisição de dados utilizou-se: Bateria WP7.2-12, do fabricante *Kung long Batteries ind.co.Ltd*, cinco bancos de resistores, um osciloscópio e cabos. O software *Octave* foi utilizado para realizar o tratamento dos dados e a construção dos modelos.

Na tabela 3 encontram-se as especificações da bateria utilizada nos ciclos de descargas, enquanto na tabela 4 encontram-se as especificações dos instrumentos de medição utilizados na aquisição dos dados.

Tabela 3: Característica dos instrumentos de medição

Bateria	Tipo de bateria	Chumbo-ácido
	Tensão nominal	12V
	Capacidade dada pelo fabricante	7,2Ah
	Tecnologia	VRLA
Osciloscópio	Taxa de aquisição	125 amostras por segundo
Banco de resistores	Número de resistores por banco	9
	Impedância do resistor	39 ohms
	Potência máxima do resistor	350 w

Fonte: Autoral (2019)

4.3 Tratamento dos dados

É de extrema importância o tratamento dos dados para que o processo de treinamento da rede neural seja satisfatório. Os dados adquiridos tiveram que passar por 3 etapas de tratamento, conforme escrito a seguir:

Para a aquisição dos dados foi necessário configurar a taxa de aquisição para valor mínimo permitido pelo osciloscópio. Essa taxa de aquisição ainda é elevada quando comparada com a velocidade do sistema, gerando dois problemas elevado custo computacional para tratamento dos dados de treinamento da rede e alta redundância de informações. Por isso a primeira etapa consiste na redução do tamanho de banco de dados, de forma que a cada 5000 dados, apenas um é mantido. Assim, o novo conjunto de dados passa a ter uma mediação a cada 40 segundos, tendo 1982 dados de primeira descarga e 985 dados de segunda descarga. Essa amostragem foi adotada pois o sistema é muito lento, tendo em vista que a bateria leva horas para descarregar completamente.

A segunda etapa consiste na adequação da escala de tempo de milissegundos para minutos, pois o osciloscópio entrega os dados na casa de milissegundos e optou-se por construir os gráficos na escala de minutos.

O terceiro passo consiste na filtragem dos *outliers*. Estes foram filtrados através do filtro de média móvel com uma janela de 60 medições, em que sempre que o dado desvia mais que 1% da média este é substituído pelo valor médio.

4.4 Metodologia para construção dos modelos paramétrico e não paramétrico

A metodologia para construção do modelo paramétrico consiste na utilização de dados específicos de tensão e corrente para o cálculo dos parâmetros que são utilizados na Equação 3.1, enquanto que a metodologia para a construção do modelo da rede neural cria um mapeamento entre o histórico de medição de tensão e corrente com o estágio de carga da bateria.

4.4.1 Modelo 1: Modelo Não Paramétrico Através de RNA MLP

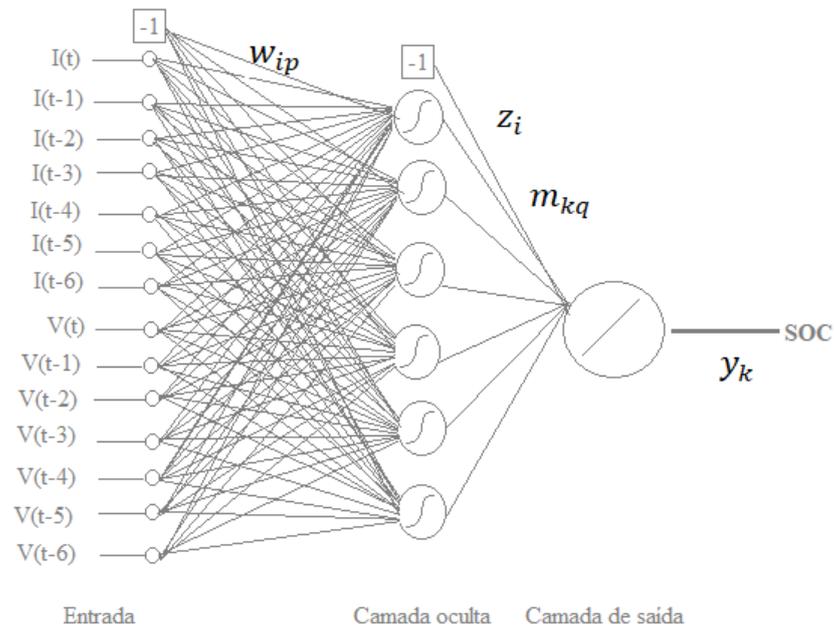
4.4.1.1 Treinamento da rede

Antes do início do treinamento da rede, foram estabelecidas algumas especificações para a rede. O primeiro critério adotado para a rede foi a função de ativação, a qual a escolhida foi sigmoide logística por exibir um balanceamento adequado entre comportamento linear e não linear. Por essa escolha de função de ativação os dados precisam ser normalizados, para reduzir a probabilidade de estagnação prematura do aprendizado da rede. A normalização mais coerente para RNAs com sigmoide logística é rescalar os dados na faixa de 0,25 a 0,75. Os passos seguintes de pré-processamento para o treinamento da rede são: separação em conjunto de treinamento e teste, inicialização dos pesos sinápticos, treinamento através do algoritmo *backpropagation*, cálculo do EQM de treinamento, teste do desempenho da rede através do cálculo do EQM para os dados de teste, repetição das etapas de treinamento e de teste por 10 repetições, com embaralhamento dos dados de cada conjunto a cada nova época. A repetição de treinamento e de teste ocorreu por 100 épocas de treinamento, pois percebeu-se que essa quantidade de épocas é suficiente para um bom aprendizado da rede, não tendo sido verificado, em nenhum dos casos, o comportamento de memorização dos dados pela rede.

A rede tem como entrada uma medição de tensão e o respectivo histórico das últimas seis medições de tensão, assim como uma medição de corrente e o respectivo histórico das últimas seis medições de corrente como pode ser observado na Figura 27, que representa a topologia da rede. Esses dados são embaralhados, de forma aleatória, selecionando-se 80% dos dados para compor o conjunto de treinamento e 20% para o conjunto de teste.

Ao final do treinamento, espera-se que para cada dado de entrada a rede gere em sua saída o valor que indica o estágio de carga (SOC), que consiste na energia remanescente na bateria, medida em Ah.

Figura 27: Topologia da rede



Fonte: Autor (2019)

4.4.1.2 Seleção de Hiperparâmetros

Sabe-se que um bom aprendizado da rede não depende apenas da disponibilidade de um conjunto de dados relevantes para a tarefa que se deseja realizar, mas também da correta especificação da topologia da rede e dos seus hiperparâmetros, como o número de neurônios nas camadas ocultas e na camada de saída, taxa inicial de aprendizado e fator de momentum.

A topologia adotada é a rede de propagação adiante (*feedforward*), com uma camada oculta, em que todos os neurônios adotam a sigmoide logística como função de ativação, e uma camada de saída com apenas um neurônio, que adota a função linear unitária como função de ativação, visto que se trata de um problema de modelagem de um sistema MISO (múltiplas entradas e saída simples).

Para cada hiperparâmetro existe uma faixa de valores que influencia significativamente no desempenho do algoritmo de treinamento. Os principais valores de hiperparâmetros que devem ser adotados durante o projeto de uma RNA do tipo MLP são:

Número de neurônios nas camadas escondida e de saída: Como não é fácil encontrar o número ideal de neurônios na camada escondida (q), por depender de muitos fatores que não se tem controle, o número de neurônios adequado para a camada escondida usualmente é encontrado através da técnica de tentativa e erro, adotando-se um número inicial de neurônios

baixo na camada escondida e aumentando gradualmente, até que se alcance um resultado de estimação satisfatório. Adotou-se inicialmente apenas 1 neurônio na camada oculta, incluindo um neurônio a cada nova rodada de treinamento e teste. O intuito deste trabalho é realizar uma estimação da carga remanescente na bateria, em ampères hora, e, como essa grandeza é formada por apenas por um número, a camada de saída deve ser composta por apenas 1 neurônio.

Taxa inicial de aprendizado: Em uma busca por uma boa taxa inicial de aprendizado, por tentativa e erro, percebeu-se que taxas iniciais de aprendizado menores que 0.1 tornava o treinamento muito lento, enquanto que taxas superiores a [0.5] dificultavam a estabilização do processo. Por isto, optou-se por variar a taxa inicial de aprendizado numa faixa de 0.1 a 0.5, até encontrar o valor que leva a rede ao melhor aprendizado para os conjuntos de dados. A taxa de aprendizado sofre decaimento exponencial, a medida que o treinamento evolui através das épocas.

Fator de Momentum: Variou-se o fator de momento entre 0,2 e 0,4, pois percebeu-se que fatores de momento inferiores a 0,2 não influenciam de forma significativa o comportamento da rede e que valores acima de 0,4 não resultam em uma boa evolução no aprendizado da rede.

4.4.1.2 Critério de Parada

Percebeu-se que com o total de 100 épocas ocorreu a convergência do aprendizado da rede, tanto para dados de treinamento quanto para dados de teste, para todas as topologias testadas, além de que em todos os casos não se percebeu comportamento que caracteriza memorização dos dados.

4.4.1.4 Avaliação da Rede Treinada

Uma das formas de avaliar a rede treinada é testar o desempenho da rede com dados que não foram utilizados no treinamento, que são chamados de dados de teste. Para validação foram utilizados 20% dos dados disponíveis, como dados de teste, que correspondem a 396 amostras para descarga 1 e 197 para descarga 2. Para cada dado apresentado a MLP, calcula-se o erro entre a saída gerada e a desejada. Após o término de cada época, soma-se o erro gerado por cada um dos dados e divide-se pelo número total de dados disponíveis, tanto para o conjunto de treinamento quanto para o de teste, calculando-se assim o erro quadrático médio.

4.4.1.5 Arquitetura da rede de melhor desempenho

Foram treinadas 240 redes, uma para configuração de número de neurônios ocultos, taxa inicial de aprendizado e fator de momento, conforme descrito na Tabela 4.

Tabela 4: Arquitetura da rede MLP

Hiperparâmetro	Configurações adotadas
Função de ativação	Sigmoide logística
Número de camada escondida	1
Número de neurônios na camada escondida	6
Número de neurônios na camada de saída	1
Tipo de rede	MLP
Taxa inicial de aprendizado	0.1
Fator de momento	0.2
Variação da taxa de aprendizado	Decaimento exponencial

Fonte: Autor (2019)

A configuração descrita na tabela 4 descreve a topologia da rede que alcançou o melhor desempenho. Utilizou-se os dados de EQM de treinamento para identificar as topologias que alcançaram bom aprendizado e buscou-se o menor valor de EQM de teste, com convergência para se definir a melhor topologia.

4.4.2 Modelo 2: Modelo Paramétrico

A segunda metodologia utilizada consiste em construir um modelo matemático com parâmetros que permitam gerar uma curva que se aproxime da curva fornecida pelo fabricante. O primeiro passo consiste em observar a curva de descarga da bateria, para extrair os valores necessários para se calcular os parâmetros previstos no modelo, conforme mostrado na Equação 3.1. Os parâmetros calculados através dos dados gerados no ciclo de descarga 1 e descarga 2 são representados na tabela 5 e 6, respectivamente.

Tabela 5: Parâmetros calculados para a curva de descarga 1

Parâmetro	Calibração	Valor
V_{full}	Tensão de carga completa (v)	12,30
V_{exp}	Tensão no final da zona exponencial (v)	12,10
Q_{exp}	Carga remanescente ao final da zona exponencial Ah	1,43
E_0	Tensão constante da bateria (V)	12,10
k	Tensão de polarização (V)	0,34
A	Amplitude da zona exponencial (V)	0,20
B	Inversão da constante de tempo da zona exponencial $(Ah)^{-1}$	2,10
R	Resistência interna (Ω)	0,22

Fonte: Autor (2019)

Tabela 6: Parâmetros calculados para a curva de descarga 2

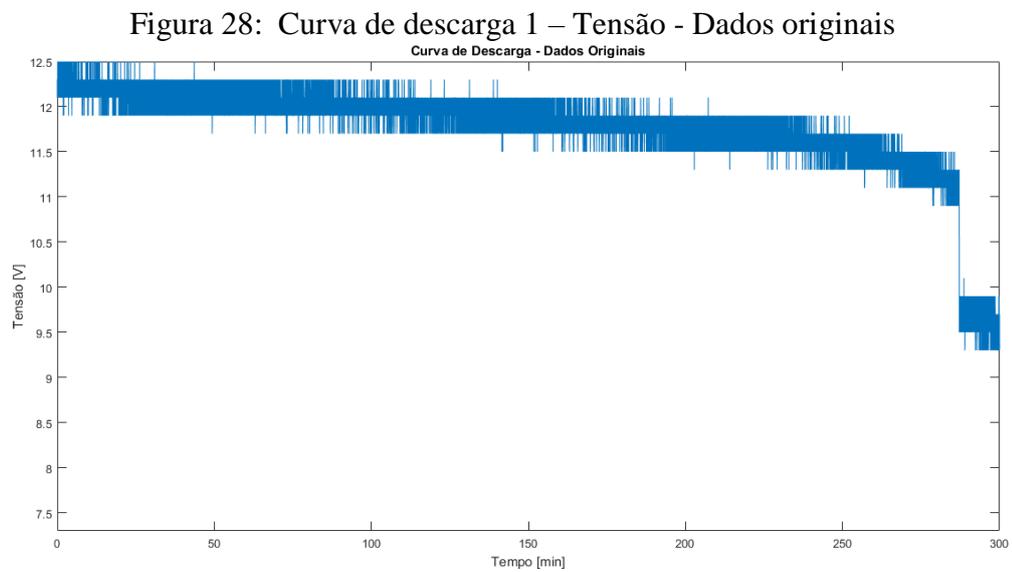
Parâmetro	Calibração	Valor
V_{full}	Tensão de carga completa (v)	11,92
V_{exp}	Tensão no final da zona exponencial (v)	7,50
Q_{exp}	Carga remanescente ao final da zona exponencial Ah	1,78
E_0	Tensão constante da bateria (V)	7,00
k	Tensão de polarização (V)	0,34
A	Amplitude da zona exponencial (V)	4,42
B	Inversão da constante de tempo da zona exponencial $(Ah)^{-1}$	1,68
R	Resistência interna (Ω)	0,22

Fonte: Autor (2019)

5. RESULTADOS E DISCUSSÕES

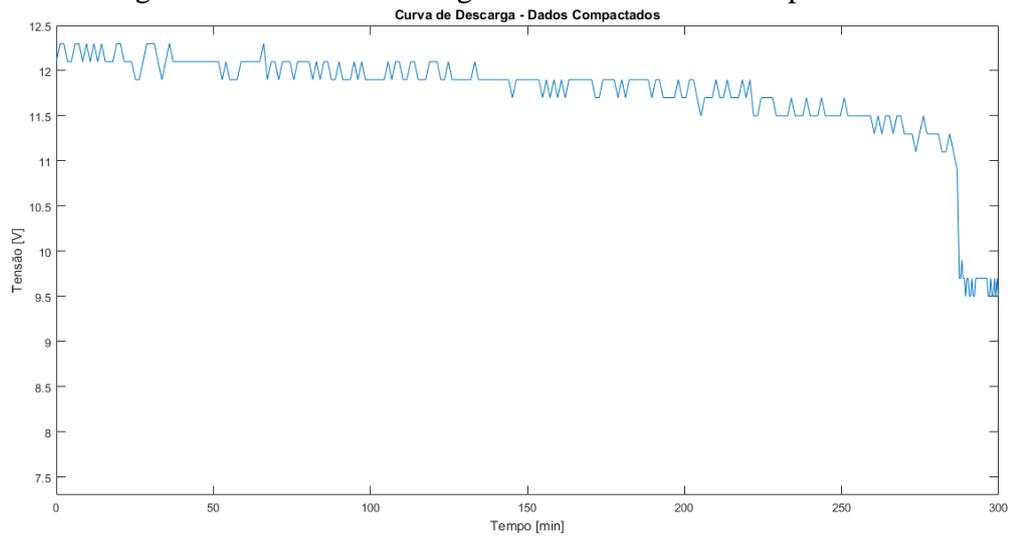
5.1 Tratamento dos dados

Nesta sessão são apresentadas as curvas de tensão e de corrente geradas durante os 2 processos de descargas, após cada etapa de processamento de dados. Nas Figura 28 a 33 são apresentadas as curvas de tensão e corrente referente a descarga 1, Na Figura 34 a 39 estão apresentadas as curvas de tensão e corrente para descarga 2. Estão presente nessas figuras as curvas de tensão e corrente dos dados originais, as curvas de tensão e corrente com os dados compactados e a acurva de tensão e corrente com os dados filtrados e compactados.



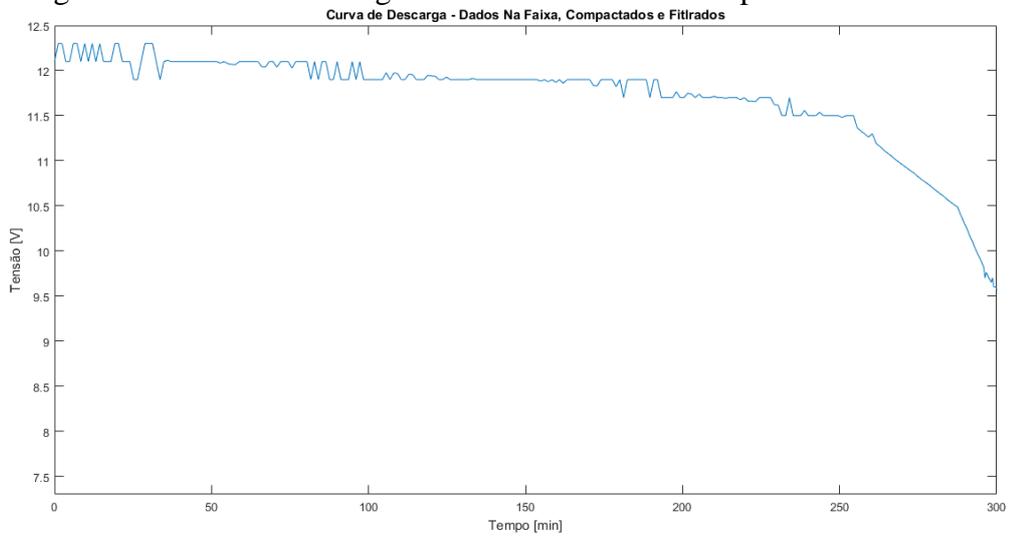
Fonte: Autor (2019)

Figura 29: Curva de descarga 1- Tensão- Dados compactados



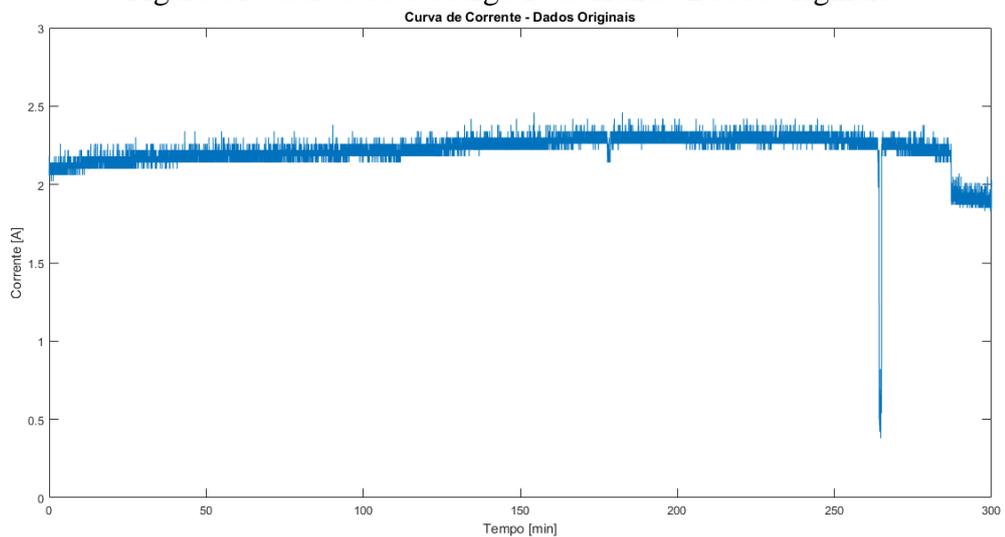
Fonte: Autor (2019)

Figura 30: Curva de descarga 1 – Tensão – Dados Compactados e filtrados



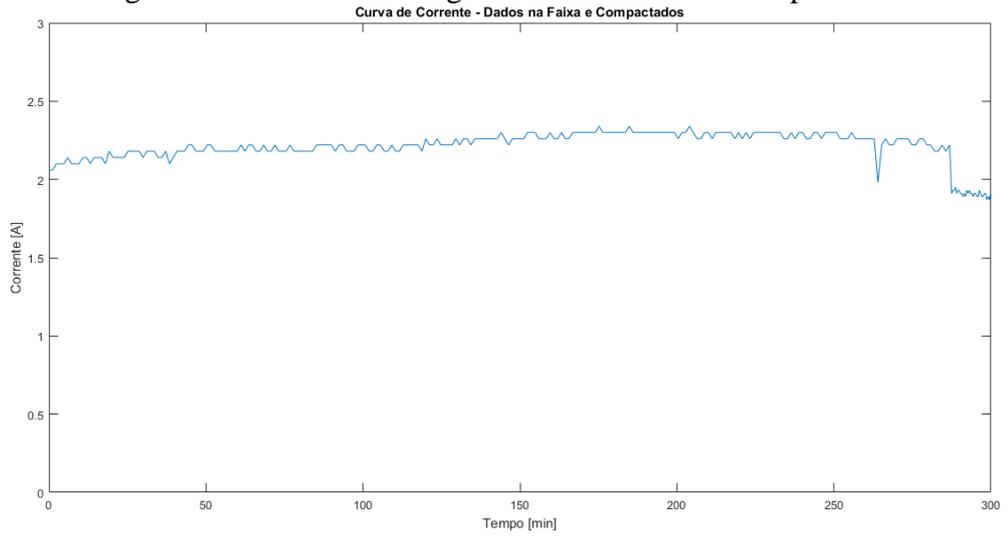
Fonte: Autor (2019)

Figura 31: Curva de descarga 1- Corrente- Dados originais



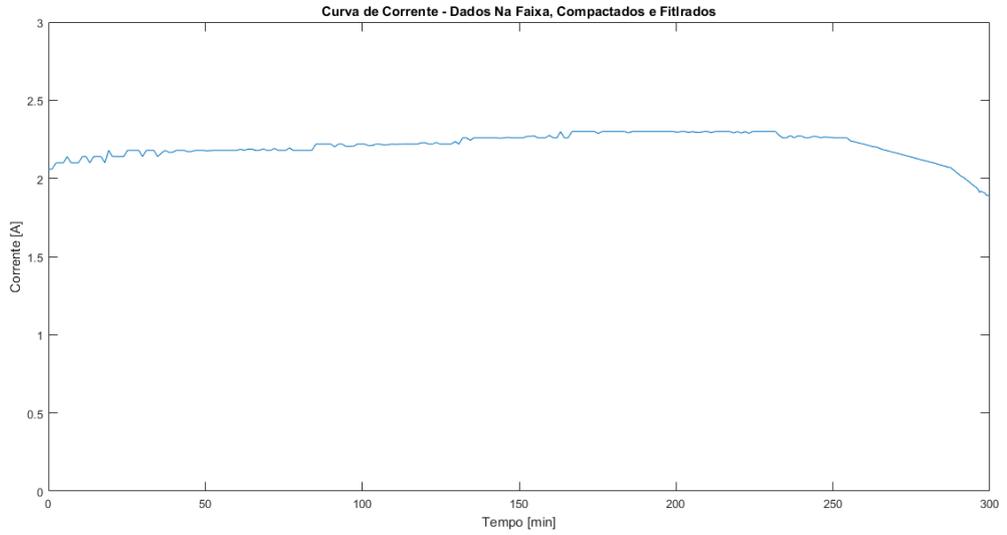
Fonte: Autor (2019)

Figura 32: Curva de descarga 1- corrente- Dados compactados



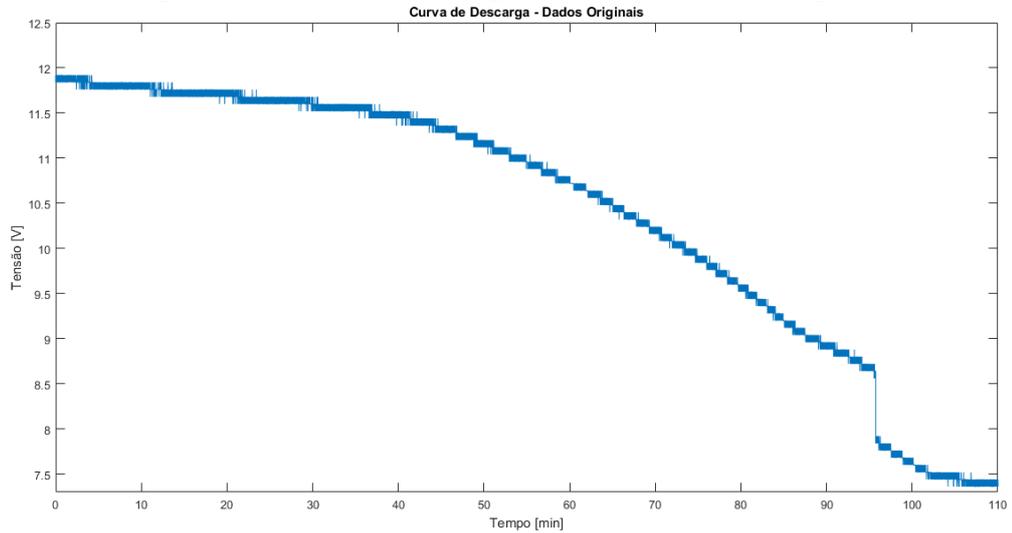
Fonte: Autor (2019)

Figura 33: Curva de descarga 1- Corrente- Dados compactados e filtrado



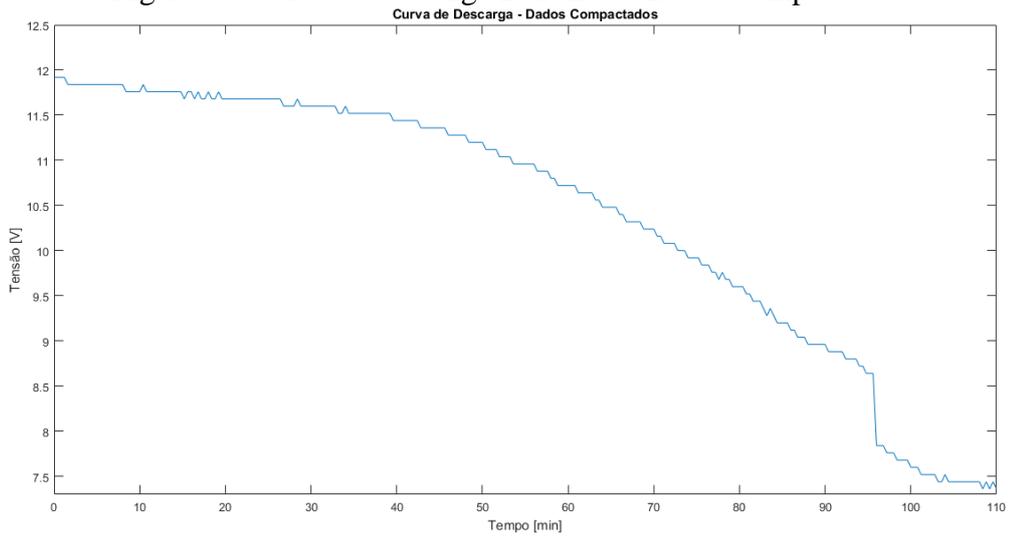
Fonte: Autor (2019)

Figura 34: Curva de descarga 2- Tensão - Dados originais



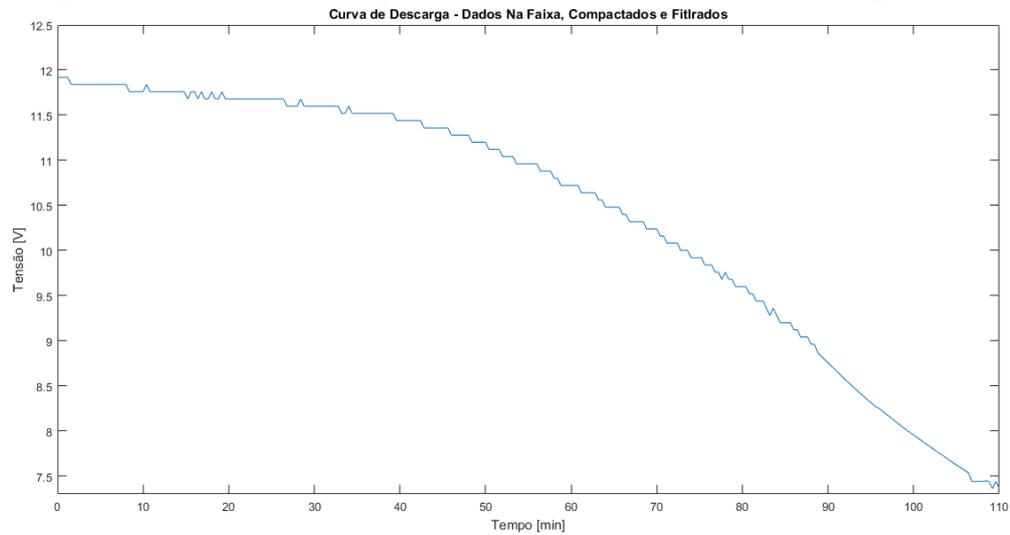
Fonte: Autor (2019)

Figura 35: Curva de descarga 2- Tensão- Dados compactados



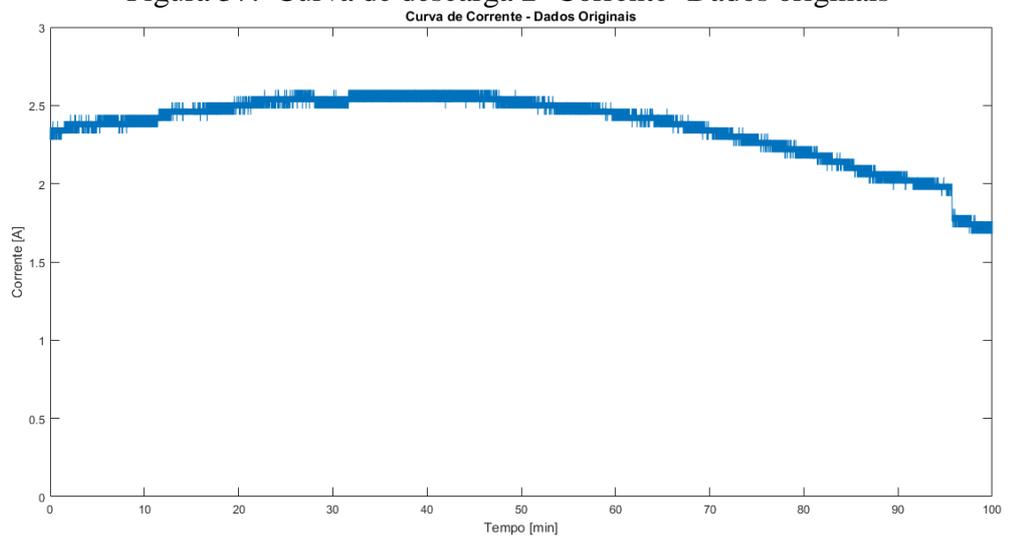
Fonte: Autor (2019)

Figura 36: Curva de descarga 2 – Tensão – Dados filtrados e compactados



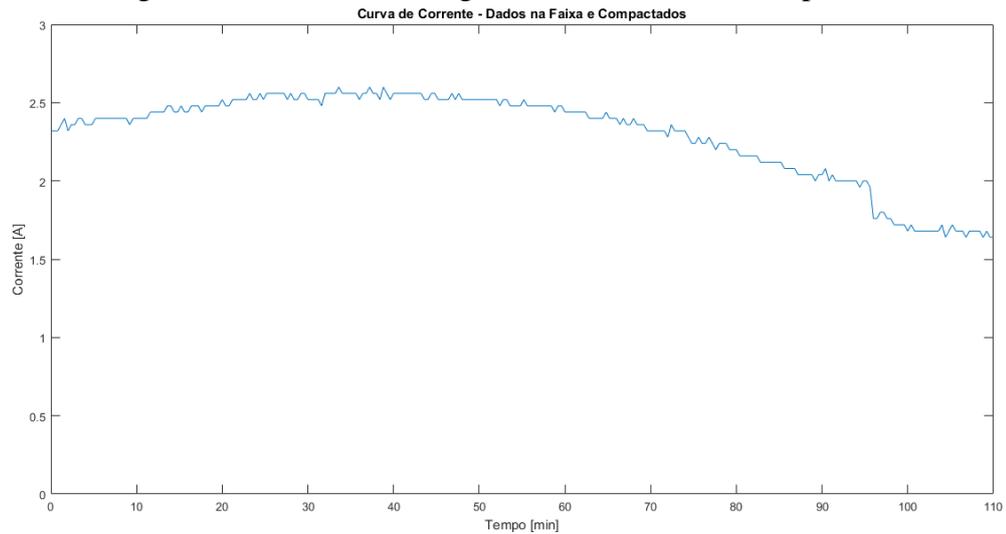
Fonte: Autor (2019)

Figura 37: Curva de descarga 2- Corrente- Dados originais



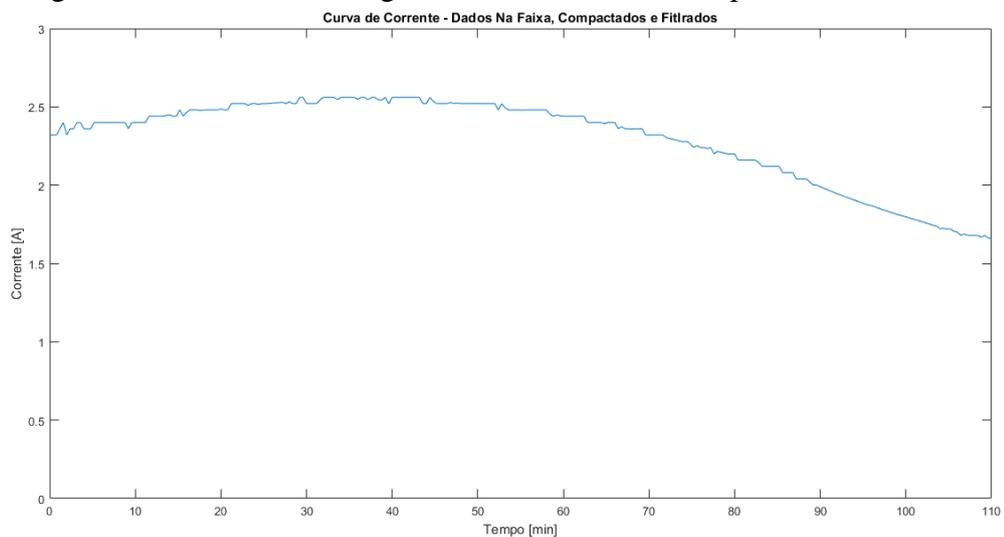
Fonte: Autor (2019)

Figura 38: Curva de descarga 2- corrente- Dados compactados



Fonte: Autor (2019)

Figura 39: Curva de descarga 2- Corrente- Dados compactados e filtrados



Fonte: Autor (2019)

5.2 Avaliação da rede MLP

Nesta etapa é calculado o erro Quadrático Médio (EQM) da saída da rede em relação aos dados reais, tanto para os dados de treinamento quanto para os de teste. O EQM dos dados de treinamento foram utilizados como métrica para seleção dos modelos de melhor performance e, entre esses modelos, foi selecionado o que alcançou o menor EQM para os dados de teste, tendo sido verificado convergência. Na Tabela 7 estão apresentados os valores de erros quadráticos médio mínimos que foram obtidos para o modelo selecionado, tanto para os dados de treinamento quanto para o de teste.

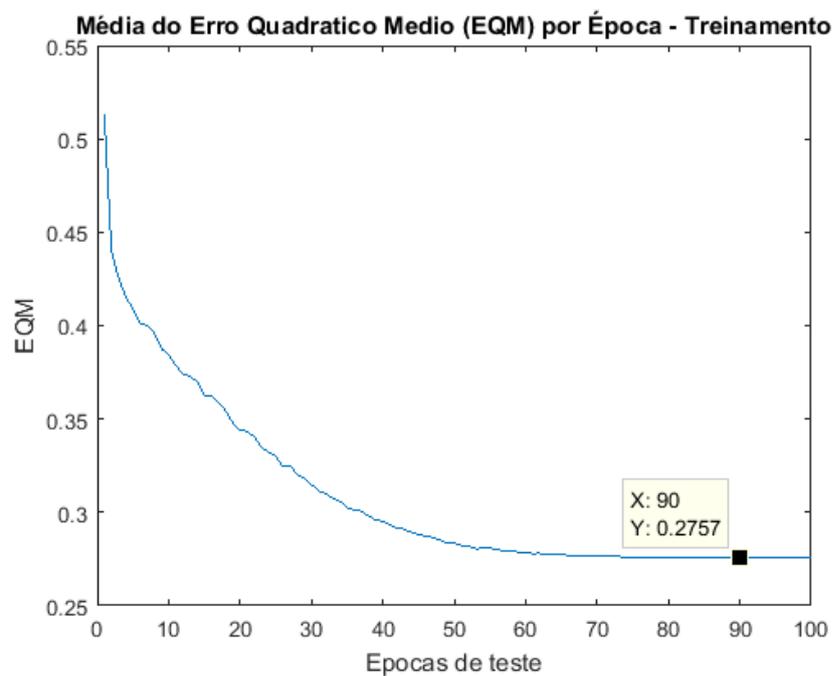
Tabela 7: Desempenho da rede para conjunto de dados de treinamento e teste

EQM	Valor
Treinamento	0.2765
Teste	0.01775

Fonte: Autor (2019)

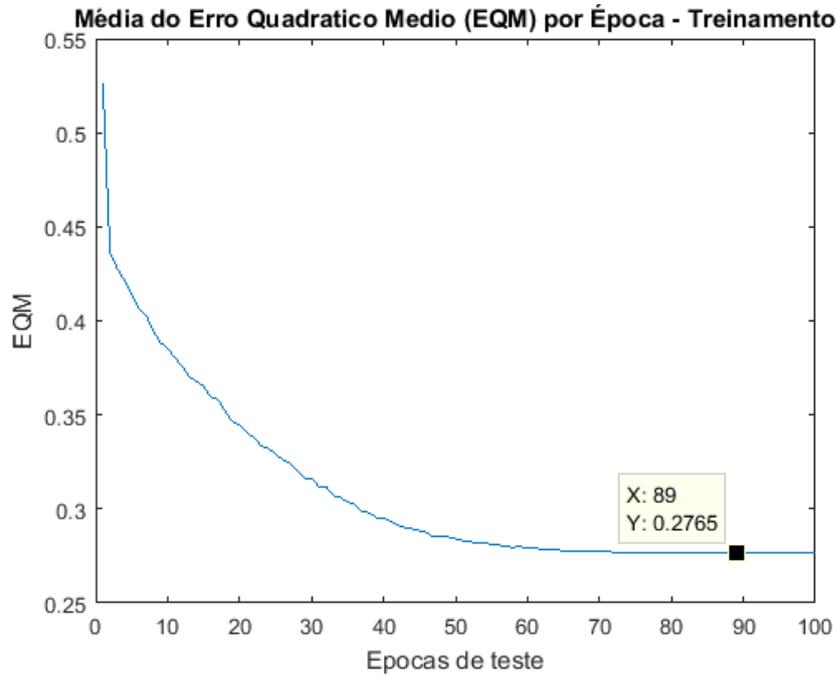
Nas Figuras de 40 a 45 observam-se as curvas de aprendizado para o treinamento e teste, para a topologia com 5, 6 e 7 neurônios na camada escondida, onde o eixo y representa o EQM e o eixo x o número da época.

Figura 40: Erro quadrático médio por época para os dados de treinamento, com 5 neurônios na camada oculta



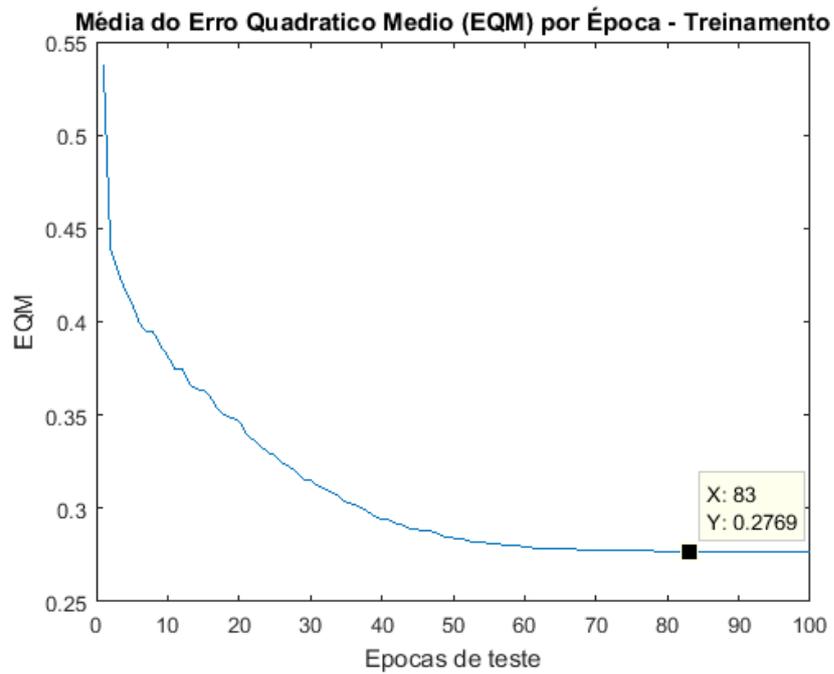
Fonte: Autor (2019)

Figura 41: Erro quadrático médio por época para os dados de treinamento, com 6 neurônios na camada oculta



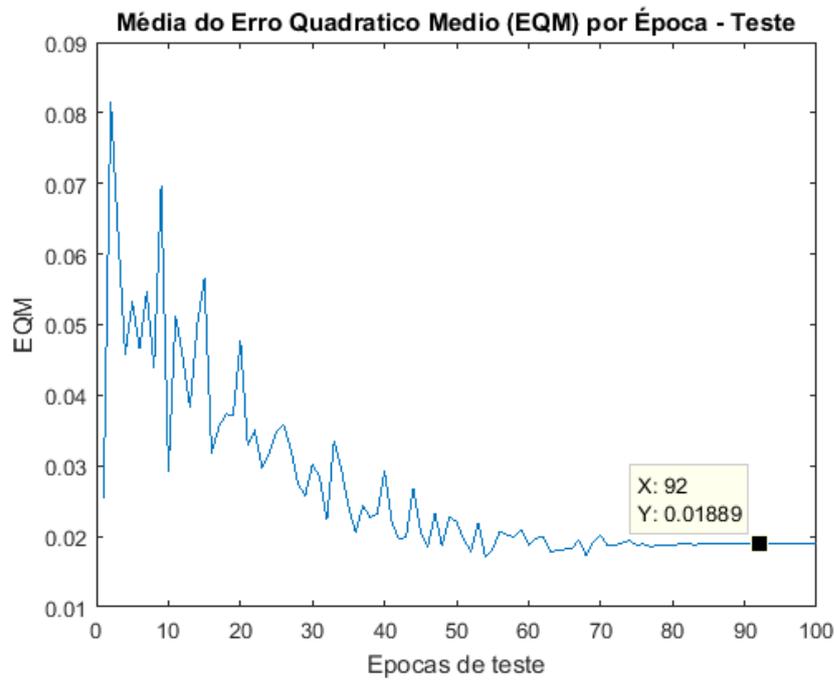
Fonte: Autor (2019)

Figura 42: Erro quadrático médio por época para os dados de treinamento, com 7 neurônios na camada oculta



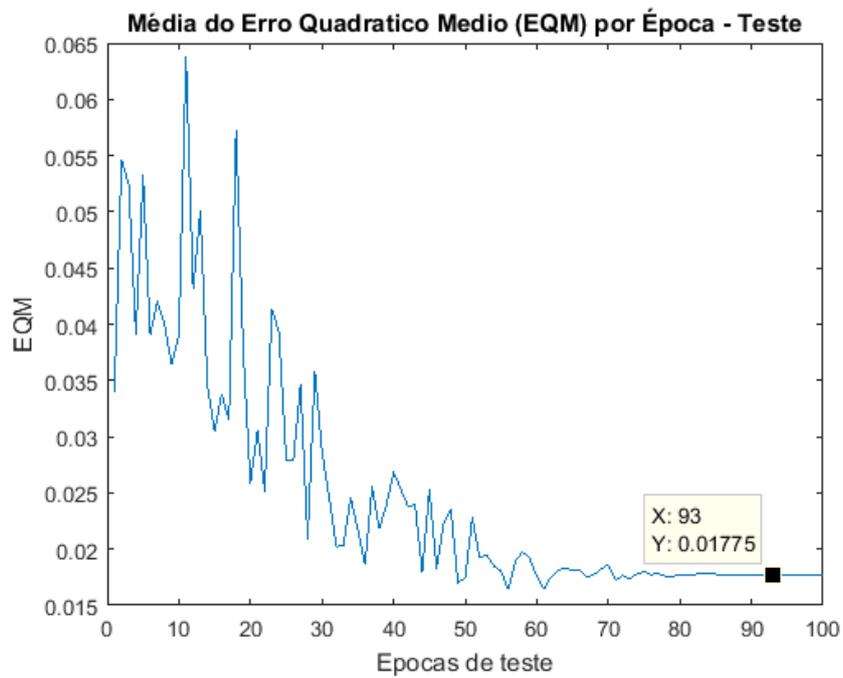
Fonte: Autor (2019)

Figura 43: Erro quadrático médio por época para os dados de teste com 5 neurônios na camada oculta



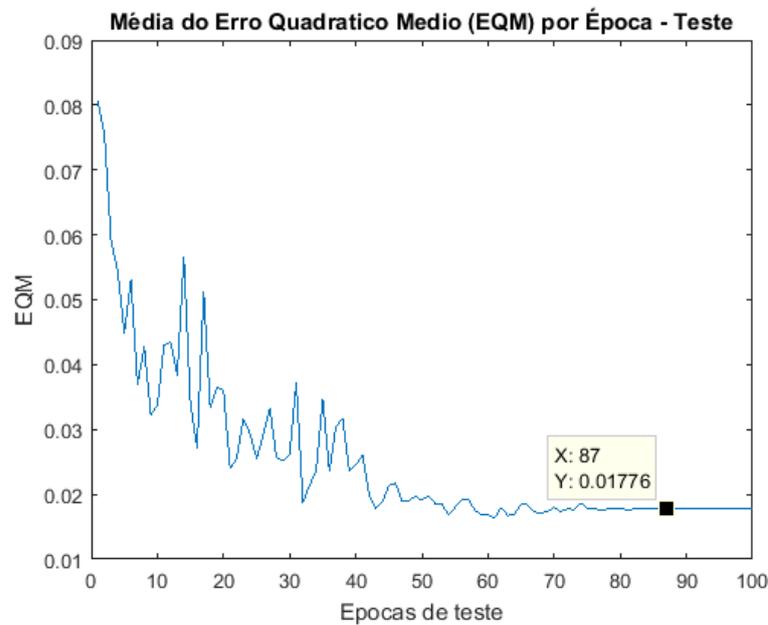
Fonte: Autor (2019)

Figura 44: Erro quadrático médio por época para os dados de teste com 6 neurônios na camada oculta



Fonte: Autor (2019)

Figura 45: Erro quadrático médio por época para os dados de teste com 7 neurônios na camada oculta



Fonte: Autor (2019)

Observou-se que mais de 10 neurônios na camada oculta leva a generalização da rede e que 6 neurônios resultam em um bom desempenho para essa tarefa. Percebeu-se que o número máximo de interações de 100 épocas era suficiente para convergir a rede em todos os treinamentos que foram realizados. Para o teste, aplicou-se 10 rodadas de treinamento.

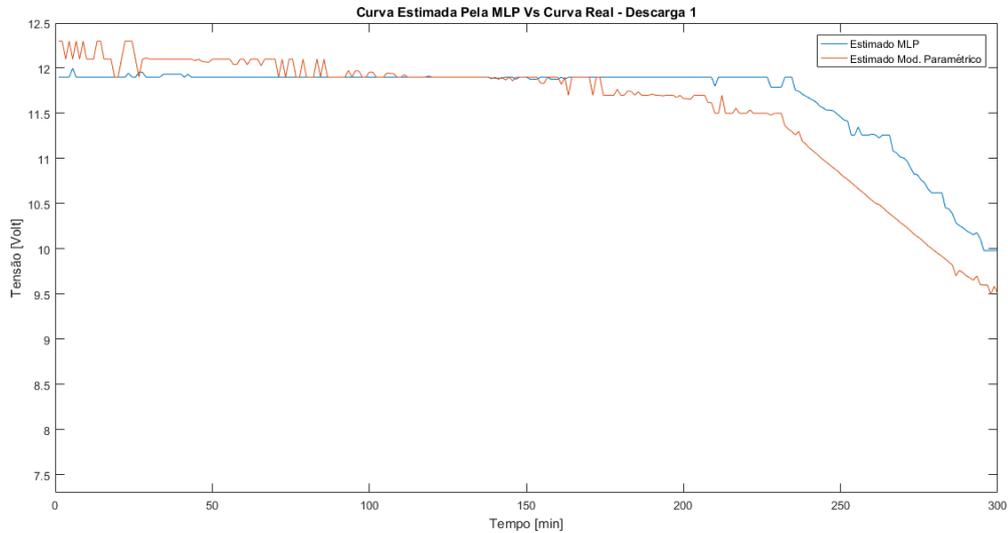
5.3 Curva de descarga estimada pela MLP

Para testar a capacidade da rede em estimar as curvas de descarga da bateria, tanto para tensão quanto para corrente, utilizou-se o modelo capturado pela MLP selecionada, para calcular valores de SOC para os dados de tensão e corrente gerados experimentalmente. Esses dados, com seus respectivos históricos de medição, são apresentados em sequência aleatória para a rede MLP, que estima o valor de SOC. Em seguida, o valor estimado é comparado com os valores de SOC calculados para todos os dados disponíveis, sendo qual a medição este mais se aproxima e então é armazenado o respectivo valor de tensão e corrente vinculado o SOC selecionado. Por fim, os dados selecionados são organizados em ordem decrescente na escala de tempo, montando-se assim as curvas de descarga. Estas curvas estão apresentadas nas Figuras 46, 47, referentes as curvas de descarga 1 e 2, respectivamente.

Observando-se a figura 46, percebe-se que a MLP conseguiu capturar bem o modelo da bateria, pois a curva estimada se aproxima bastante da curva real. Já para os dados da segunda

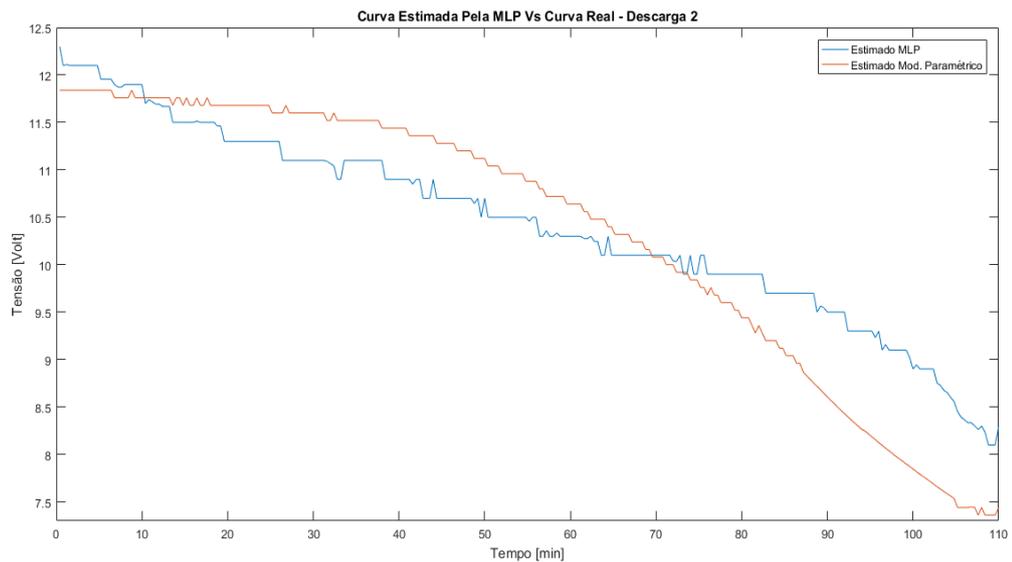
curva de descarga, o modelo não apresenta resultado tão bom, conforme pode ser observado na figura 47.

Figura 46: Curva de descarga 1- MLP



Fonte: Autor (2019)

Figura 47: Curva de descarga 2- MLP



Fonte: Autor (2019)

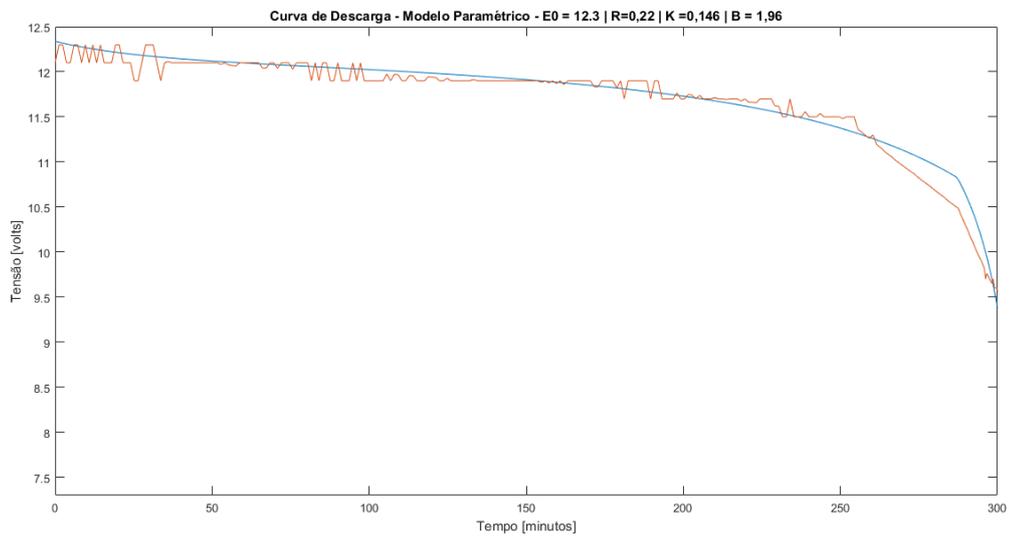
5.4 Curva de descarga do modelo paramétrico

Para a construção da curva de descarga através do modelo paramétrico fez-se necessário o uso das equações 3.3, 3.4, 3.5 e 3.6, juntamente com os parâmetros listados nas tabelas 8 e 9.

A Equação 3.1 fornece o modelo que estima a evolução da tensão de terminal da bateria ao longo do tempo.

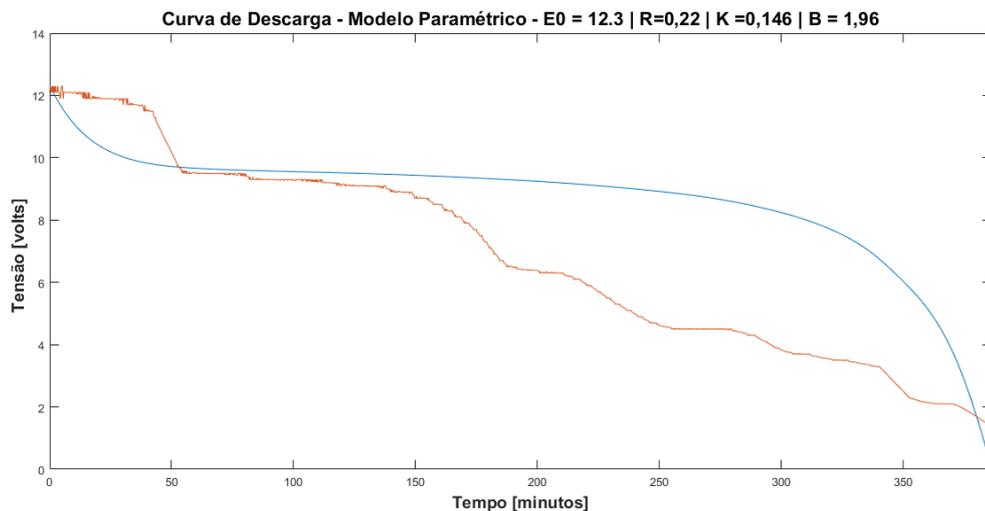
A Figura 48 mostra a curva estimada através do modelo paramétrico para o primeiro conjunto de dados enquanto a Figura 49 apresentada a curva estimada pelo modelo paramétrico, para o segundo conjunto de dados.

Figura 48: Curva de descarga 1- Modelo Paramétrico



Fonte: Autor (2019)

Figura 49: Curva de descarga 2- modelo paramétrico



Fonte: Autor (2019)

5.5 Modelo paramétrico versus modelo Neural

Observando as Figuras 50 e 51, percebe-se que a rede MLP capturou bem o modelo da bateria para as variações de tensão e corrente da descarga 1, porém o resultado não foi bom

para a descarga 2. Isso pode se justificar devido ao baixo número de dados, pós-processamento, gerados pela descarga 2.

Observando as curvas de descarga é claro perceber que na descarga 1 o modelo capturado pela MLP é mais preciso que o modelo estimado pelo método paramétrico, porém para a curva de descarga 2 não é possível afirmar quais dos dois modelos é mais preciso apenas observando os gráficos. Para quantificar a precisão de cada modelo foi adotado como métrica de desempenho o Erro Quadrático Total, para ambos os modelos, para cada curva de descarga, como é mostrado na tabela 8.

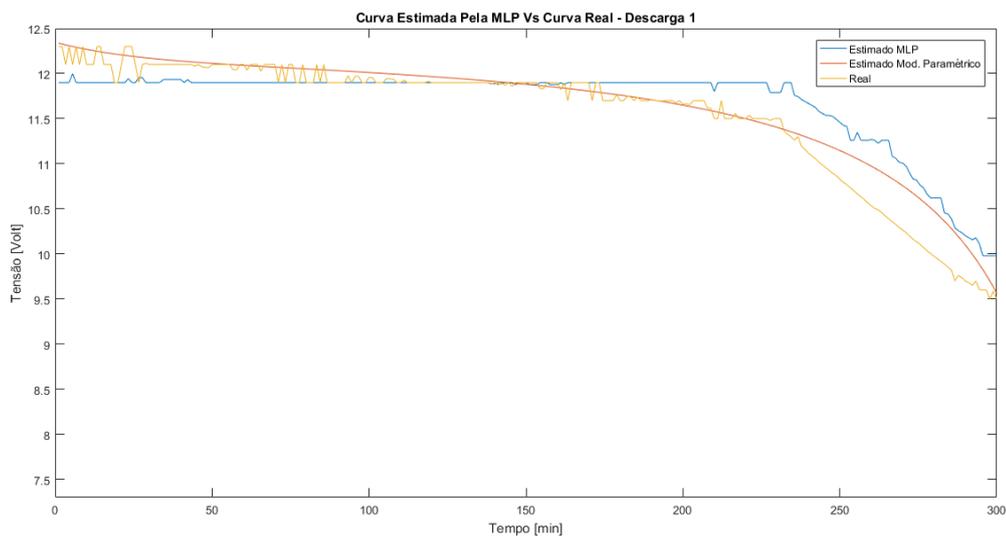
Tabela 8 – Erro Quadrático Total – MLP e Paramétrico

Descarga	MLP	Paramétrico
1	6.98	4.34
2	10.85	11.53

Fonte: Autor (2019)

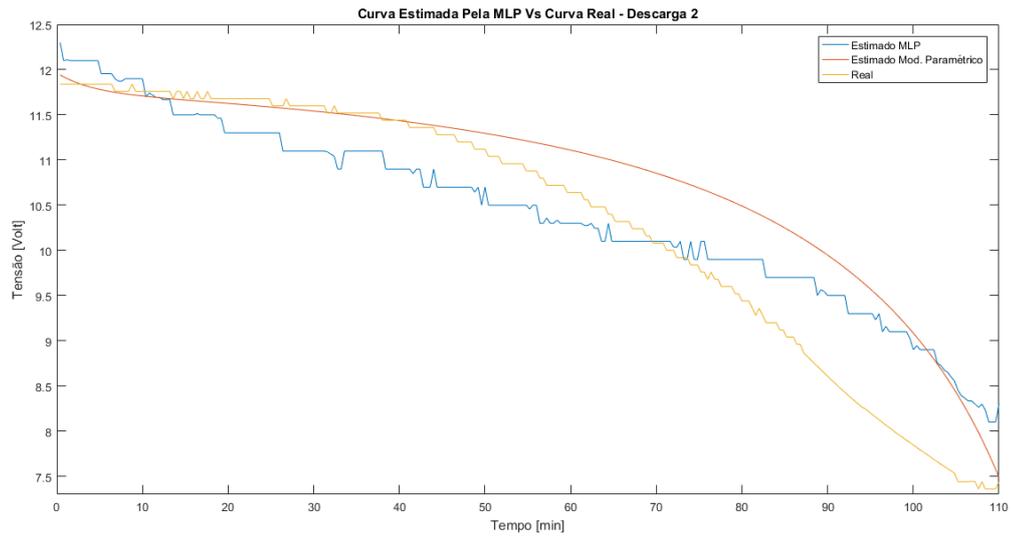
Percebe-se que o modelo capturado pela MLP é mais preciso que o modelo paramétrico para as condições da descarga 1, porém é inferior para as condições da descarga 2. Esses dados justificam-se pelo baixo número de dados, pós-processamento, gerados no segundo processo de descarga, tornando o mapeamento do modelo pobre para essa região do espaço amostral. O modelo é melhor para a primeira descarga, pois a bateria não foi tão degradada. Porém, para a segunda descarga, a curva da bateria está bem diferente e o modelo não consegue representar realmente a bateria.

Figura 50: Curva do modelo MLP vs Curva real vs Modelo parametrico para descara 1



Fonte : Autor (2019)

Figura 51: Curva do modelo MLP vs curva real vs modelo parametrico para descarga 2



Fonte : Autor (2019)

Os resultados obtidos reforçam a importância de se dispor de um número de dados adequado e representativo do modelo, além de todos os outros cuidados que se deve adotar durante o projeto de um modelo neural, para se alcançar resultados satisfatórios em tarefas de modelagem.

6. CONCLUSÃO

6.1 Introdução

Com a crescente demanda por energia elétrica, decorrente especialmente do surgimento de novas tecnologias, como carros elétricos e geração fotovoltaica, as baterias assumem a cada dia um papel mais importante para a sociedade moderna.

A eficiência destes dispositivos de armazenamento de energia está diretamente relacionada aos custos de armazenamento da energia e a viabilidade dos dispositivos que dependem destas baterias. Uma forma de tornar as baterias mais eficientes é otimizar o processo de recarga, permitindo que o processo de recarga seja mais rápido e que a vida útil do dispositivo possa ser estendida. A eficiência dos controladores de cargas está diretamente relacionada com a precisão do controlador em identificar o estágio de carga da bateria, baseado em medições de tensão, corrente e temperatura da bateria. No intuito de contribuir com pesquisas nesta área, este trabalho apresentou-se uma proposta de modelagem de baterias de chumbo-ácido através de RNA MLP e fez um estudo comparativo de desempenho com um modelo paramétrico tradicional.

Conhecendo o potencial das RNAs em tarefas de modelagem de sistemas não lineares, este trabalho apresentou uma proposta de metodologia de estimação de estágio de carga de baterias de chumbo-ácido, através de modelos estimados por MLP, com o algoritmo de aprendizado por *backpropagation*. Ao concluir as simulações, foi possível concluir que a utilização das RNAs é viável para a estimação de modelos que permitam identificar o estágio de carga de baterias, através de séries de medições de tensão e corrente. Os resultados alcançados reforçam o poder da MLP em tarefas de regressão modelos não lineares.

6.2 Resumo das contribuições dessa monografia

De modo mais específico as principais contribuições desta monografia foram as seguintes:

1. Uma revisão bibliográfica das baterias de chumbo ácido;
2. Uma revisão bibliográfica das redes neurais artificiais;
3. Uma revisão bibliográfica de RNA MLP e aplicação desta rede a problemas de modelagem, incluindo o conceito de treinamento on-line;
4. Uma breve revisão de métodos de tratamento de dados aplicável a dados reais;

5. Teste da eficiência da metodologia de modelagem paramétrica proposta por Tremblay *et al.* (2007), utilizando dados reais;
6. Descrição de metodologia para a construção de modelos não paramétricos através do paradigma do aprendizado de redes MLP por *backpropagation*, aplicáveis a modelagem de bateria.

6.3 Sugestões de trabalhos futuros

A pesquisa que se iniciou neste trabalho pode avançar e oferecer novas contribuições, além do que foram devolvidos aqui. Como recomendações de avanços a essa pesquisa são sugeridos os seguintes temas para trabalhos futuros.

1. Simular o envelhecimento da bateria e atualizar, em tempo real, o modelo estimado pela rede MLP;
2. Aplicar a metodologia utilizada neste trabalho a outro tipo de baterias;
3. Implementar uma plataforma de teste, compreendendo *software* e *hardware*, para construir um carregador inteligente para baterias, baseado em modelos construídos por RNAs.
4. Ampliar a metodologia utilizada, levando em conta o efeito da temperatura na capacidade de armazenamento das baterias, e verificar se os modelos construídos são mais precisos que os modelos baseados apenas em tensão e corrente.
5. Aplicar a metodologia utilizada neste trabalho utilizando dados artificiais.

REFERÊNCIAS

- ANDRADE Juliano. **Estudo do mecanismo da carga pulsada em eletrodos planos de pb e em eletrodos porosos de baterias chumbo ácido Trabalho de conclusão de curso.** Dissertação (Mestrado em Engenharia e Ciências dos Materiais.)- Universidade Federal do Paraná- Curitiba 2005.
- BARAN, Renato. **A introdução de veículos elétricos no Brasil: Avaliação do impacto no consumo de gasolina e eletricidade.** 2012. 123 f. Tese (Doutorado em planejamento energético) - instituto Alberto Luiz coimbra pós- graduação e pesquisa de engenharia, universidade federal de Rio de janeiro, Rio de janeiro, 2012.
- BATTISTELLA, E. **Extração de regras de redes neurais aplicadas ao problema de previsão da estrutura secundária de proteínas.** 2004. 119f. Dissertação (Mestrado em Computação Aplicada) – Centro de Ciências Exatas e Tecnológicas, Universidade do Vale do Rio dos Sinos, São Leopoldo, 2004.
- BRAND. J, ZHANG. Z; Agarwal. AGARWAL R. K. **Extraction of battery parameters of the equivalent circuit model using a multi-objective genetic algorithm, Journal of Power Sources.** vol. 247, pp. 729 737, 2014.
- BRONDANI Marcia de Fatima. **Modelagem Matemática do Tempo de Vida de Baterias de Lítio Íon Polímero utilizando Algoritmos Genéticos.** Dissertação (Mestrado em Modelagem Matemática)- Pontifícia Universidade Regional do Noroeste do Estado do Rio Grande do Sul - Ijuí, RS, Brasil, Fevereiro 2015.
- CARLOS Roberto Dos Santos Júnior. **Uma Nova Abordagem de Treinamento On-line Para Rede neural Artificial Artmap Fuzzy.**2017. 54f. dissertação (Mestrado em engenharia elétrica) -Campus de ilha nova, Faculdade de engenharia, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira 201.
- CASTRO.B.H.R; FERREIRA.T.T: **Veículos elétricos: aspectos básicos, perspectivas e oportunidades.** BNDES biblioteca digital, 2019.
- CHAGAS, Marcos Wilson Pereira. **Novas Tecnologias para Avaliação de Baterias.** 2007.84f. Dissertação (Mestrado em desenvolvimento de tecnologia)-IEP/LACTEC, Curitiba 2007.
- Data Science Academy. **Deep Learning Book,** 2019. Disponível em: <<http://www.deeplearningbook.com.br/>>. Acesso em: 27 de dezembro de 2019.
- Departamento Técnico da Unicoba, "Manual Técnico UNIPOWER Série UP Bateria Chumbo-Ácida Selada Regulada por Válvula," São Paulo, Manual Técnico 2003.
- FALCÃOA.E.A.M; TEIXEIRA. Ana.C.R; SODRÉA. José.R. **Analysis of CO2 emissions and techno-economic feasibility of an electric commercial vehicle.** 2017.
- FLECK, Leandro; TAVARES, Maria Hermínia Ferreira; EYNG, Eduardo; HELMANN, Andrieli Cristina; ANDRADE, Minéia Aparecida de Moares. **Redes neurais artificiais: princípios básicos.** Revista eletrônica Científica inovação e tecnologia. Medianeira, paraná, ISSN, v. 1, n. 13, jan/jun. 2016.

GUO S. **The application of genetic algorithms to parameter estimation in lead-acid battery equivalent circuit models.** July 2010. [Online]. Available: <http://etheses.bham.ac.uk/956/>

HAYKIN, S. **Redes Neurais: Princípios e prática.** 2.ed. Porto Alegre: Bookman, 2001. 900p.

IMBASCIATI, Henrique. **Estudo descritivo dos sistemas, subsistemas e componentes de veículos elétricos e híbridos.** Especialização (Engenharia automotiva), centro de educação continuada do instituto Mauá de tecnologia. São Caitano Do Sul, 2012.

KALIRAJ, G.; BASKAR, S. **An efficient approach for the removal of impulse noise from the corrupted image using neural network based impulse detector, Image and Vision Computing,** v. 28, no. 3, p. 458–466, mar. 2010.

KUMARA M. Satyendra; REVANKAR Shripad.T. **Development scheme and key technology of an electric vehicle: An overview.2017**

Lakhmi C. Jain; Manjeevan Seera ; Chee Peng Lim ; P. Balasubramaniam. **A review of online learning in supervised neural networks.** 2014.

LINARDI, Marcelo. **Introdução a ciência e tecnologia de células a combustíveis.** São Paulo: Artliber,2010.

LIMA Maria Júlia Godoy Ferreira. **O uso de métodos de detecção de outliers na identificação de fraudes em anúncios mobile.** Trabalho de conclusão de curso (Bacharel em Ciência da computação)- Universidade Federal de Pernambuco-Recife Dezembro de 2017.

MARCOS Wilson Pereira Chagas. **Novas Tecnologias para Avaliação de Baterias.** IEP/LACTEC, Curitiba, Tese de Mestrado 2007.

Mark, Spance. **EV – Charging towards a greener future. Energy Digital,** v. 58, p. 3845, May 2018. Disponível em: <https://www.energydigital.com/magazine> Acessado em 15 de maio de 2018.

MANZAN, José Ricardo Gonçalves. **Análise de desempenho de redes neurais artificiais do tipo multilayer perceptron por meio do distanciamento dos pontos do espaço de saída.** Tese (Doutorado em Engenharia Elétrica) –Universidade Federal de Uberlândia Faculdade de Engenharia Elétrica Pós-graduação em Engenharia Elétrica. Setembro 2016.

NIED, Ademi. **Treinamento de redes neurais artificiais baseado e sistemas de estrutura varável com taxa de aprendizado adaptativa** 207. 107f. Tese (Doutorado e Engenharia elétrica) - Universidade federal de Minas gerais, Belo Horizonte, 2007.

OLIVEIRA André Luiz Barros. **Modelo neural para predição de carga elétrica de curto prazo na região metropolitana da cidade de fortaleza-ce.** Trabalho de conclusão de curso (Bacharel em engenharia de energias)- Universidade Da Integração Internacional Da Lusofonia Afro-Brasileira Instituto De Engenharias E Desenvolvimento Sustentável. Redenção-ce 2019

OLIVEIRA Arthur Filgueiras. **Modelagem, Parametrização e Otimização de Baterias Chumbo-Ácido em Aplicações Ferroviárias via Análise de Big Data.** Trabalho de conclusão

de curso (Bacharel em engenharia elétrica)- Pontifícia Universidade Federal de Juiz de Fora- Juiz de fora 2016

PEIXOTO, Rafael Lima. **Monitoramento da descarga de bateria com o uso de microprocessador ARM.** Rio de Janeiro, 2012.

PEREIRA, Nuno Miguel Couto. **Simulação de Regimes de Carga e Descarga em Baterias.** Dissertação (Mestrado em Engenharia Eletrotécnica) – Instituto Superior de Engenharia de Lisboa Área Departamental de Engenharia Eletrotécnica de Energia e Automação. 2016

PINTO, André Hffmann. **Controle baseado em redes neurais artificiais, aplicado a m sistema híbrido de tratamento para remoção do corante reativo azul 5G de solução sintética.** 2016. 63f. Dissertação (Mestrado e tecnologia ambientais) - Universidade tecnológica federal do paran , Medianeira, 2016.

REIS, Nuno Alexandre Oliveira. **O autom vel h brido como elemento fornecedor-consumidor de eletricidade: Modela o de baterias.** 2008. 88f. Disserta o (Mestrado em engenharia eletrot cnica e de computadores) - Instituto superior t cnico, Universidade t cnica de Lisboa, Lisboa 2008.

RELAN Rishi; FIROUZ Yousef; TIMMERMANS Jean-Marc; SCHOUKENS Johan; FELLOW. **Data driven nonlinear identification of Li-ion battery based on a frequency domain nonparametric analysis.** 2017

SILVA, A. N. R.; RAMOS, R. A. R.; SOUZA, L. C. L.; RODRIGUES, D. S.; MENDES, J. F. G. **SIG. uma plataforma para introdu o de t cnicas emergentes no planejamento urbano regional e de transporte: uma ferramenta 3D para an lise ambiental urbana, avalia o multicrit rio, rede neurais artificiais.** S o Carlos: EdUFSCar, 2004. 221p.

SIMON Haykin. *Neural Networks and Learning Machines.* 3d. 2008.

SANCHEZ Eleazar Cristian Mejia. **Controle por aprendizado acelerado e neuro-fuzzy de sistemas servo-hidr ulicos de alta frequ ncia.** Disserta o (Mestrado em Engenharia Mec nica)- Pontifícia Universidade Cat lica do Rio de Janeiro- Puc-Rio. Setembro 2009

SOARES, pablo Luiz bragas. **Aplica o de redes neurais m conjunto com wavelets na detec o e atenua o de r udos em imagens digitais s smicas.** 201. 68f. Disserta o (Mestrado em ci ncia de computa o) – Universidade do estado do rio grande do Norte programa de p s-gradua o em ci ncias da computa o. 2013.

SOUSA Cristina; MURTA Joel. **Baterias.** Instituto Superior Polit cnico de Viseu Escola Superior de Tecnologia. Disponivel em: http://www.estgv.ipv.pt/PaginasPessoais/paulomoises/Controlo_carga/baterias.pdf. Acesso em: Dezembro de 2019 10:05

TEIXEIRA. Ana.C.R; SODR A. Jos .R. Impacts of replacement of engine powered vehicles by electric vehicles on energy consumption and CO2 emissions.p 375-384 Fevereiro de 2018. THEOTONIO, Sergio Barcelos. **Ve culos el tricos e h bridos panorama patent rio no brasil.** Minist rio da ind stria, com rcio exterior e servi os instituto nacional da propriedade industrial. Rio de Janeiro 2018.

TREMBLAY, O., DESSAINT, L.-A., & Dekkiche, A.-I. (2007). A Generic Battery Model for the Dynamic Simulation of Hybrid Electric Vehicles. 2007 IEEE Vehicle Power and Propulsion Conference.

VANZUBEN. **Redes neurais multicamadas**. Universidade Estadual DE Campinas. Biblioteca digital Disponível em: ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/theses/emi_mest/cap2.pdf12. Acesso em: dezembro 2019, 11:22.

VECCHIA, Rodnei. **O meio ambiente e as energias renováveis** instrumentos de liderança visionaria para a sociedade. 1 ed. são Paulo: Manole Ltda,2010.

XUEPING MA; ZHANG, J.; SONG, A. **3D reservoir modeling with the aid of artificial neural networks**. **International Colloquium on Computing, Communication, Control, and Management**. v. 4, n. ?, p. 8–9, aug. 2009.

ZSOLT L. Kovas. **Redes neurais artificiais**. Fundamentos e aplicação. 4 ed. São Paulo: editora da física,2016.