

UNIVERSIDADE FEDERAL DO MARANHÃO - CAMPUS BALSAS
COORDENAÇÃO DE ENGENHARIA ELÉTRICA
CURSO DE BACHARELADO EM ENGENHARIA ELÉTRICA

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS PARA A
ESTIMAÇÃO DA VIDA ÚTIL DE SISTEMAS DE ARMAZENAMENTO
EM MICRORREDES COM FONTES RENOVÁVEIS**

ITALO IURI MARINHO SANTOS

ORIENTADOR: PROF. DR. PEDRO BEZERRA LEITE NETO

BALSAS

2021

ITALO IURI MARINHO SANTOS

**APLICAÇÃO DE REDES NEURAI ARTIFICIAIS PARA A
ESTIMAÇÃO DA VIDA ÚTIL DE SISTEMAS DE ARMAZENAMENTO
EM MICRORREDES COM FONTES RENOVÁVEIS**

Trabalho de Conclusão de Curso
apresentado como parte dos requisitos
para a obtenção do título de Bacharel em
Engenharia Elétrica, da Coordenação de
Engenharia Elétrica, da Universidade
Federal do Maranhão.

Orientador: Prof. Dr. Pedro Bezerra Leite
Neto.

BALSAS

2021

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).

Diretoria Integrada de Bibliotecas/UFMA

Santos, Italo Iuri Marinho.

Aplicação de Redes Neurais Artificiais para a Estimação da Vida Útil de Sistemas de Armazenamento em Microrredes com Fontes Renováveis / Italo Iuri Marinho Santos. - 2021. 58 f.

Orientador(a): Pedro Bezerra Leite Neto.

Curso de Engenharia Elétrica, Universidade Federal do Maranhão, Balsas, 2021.

1. Baterias de Chumbo-ácido. 2. Microrredes Isoladas. 3. Redes Neurais Artificiais. I. Leite Neto, Pedro Bezerra. II. Título.

ITALO IURI MARINHO SANTOS

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA A
ESTIMAÇÃO DA VIDA ÚTIL DE SISTEMAS DE ARMAZENAMENTO
EM MICRORREDES COM FONTES RENOVÁVEIS**

Trabalho aprovado. Balsas, 22 de setembro de 2021

Trabalho de Conclusão de Curso
apresentado como parte dos requisitos
para a obtenção do título de Bacharel em
Engenharia Elétrica, da Coordenação de
Engenharia Elétrica, da Universidade
Federal do Maranhão.

Banca Examinadora:

Pedro Bezerra Leite Neto, Dr.

Universidade Federal do Maranhão
Orientador

João Eduardo Ribeiro Baptista, Me.

Universidade Federal do Maranhão
Membro Titular

Raimundo Nonato Diniz Costa Filho, Dr.

Universidade Federal do Maranhão
Membro Titular

À minha família.

AGRADECIMENTOS

Primeiramente, agradeço incondicionalmente a meus pais, Consueila e Idelfonso, por sempre terem me apoiado fazendo tudo para que eu obtivesse acesso a uma boa educação.

Agradeço à minha irmã, Kattarynny, que sempre me apoiou em minhas decisões.

Aos meus três sobrinhos lindos, Ana Clara, Eduarda e Theo, que são uma válvula de escape nos momentos de estresse.

Agradeço a meus amigos na UFMA que me apoiaram com palavras de carinho nos momentos difíceis desse trabalho. Fiz verdadeiras amizades que levarei para sempre comigo.

Agradeço a meu orientador que sempre esteve disposto a me ajudar, sempre com muita paciência.

E sobretudo, agradeço a Deus por ter me dado o dom da vida, provendo a oportunidade de concluir mais essa etapa e por ter implantado em mim o gosto em desvendar como as coisas ao nosso redor funcionam, que tenho desde criança, que com certeza foi primordial à escolha deste curso. Por fim, agradeço a todos que lerão este trabalho. Espero que gostem.

“O maior bem do homem é uma mente inquieta.”

Asimov, Isaac

RESUMO

Uma microrrede é um sistema moderno de energia distribuída usando recursos locais de energia sustentável. Nesses sistemas a prioridade são as fontes renováveis, de modo que a energia solar fotovoltaica e eólica são as principais fontes de geração, e os geradores a combustão podem complementar, aumentando a confiabilidade do sistema, juntamente com as baterias. Microrredes isoladas ainda usam amplamente a tecnologia de chumbo-ácido em seu sistema de armazenamento por apresentar uma boa relação de custo-benefício com em comparação às outras tecnologias. Porém baterias deste tipo tendem a diminuir bastante sua vida útil devido ao regime mais severo das fontes renováveis e fazer uma estimativa para o tempo de vida dessas baterias de chumbo-ácido pode ser bastante complexo. O presente trabalho busca contribuir com as soluções para tal problema, a partir do desenvolvimento de duas Redes Neurais Artificiais em MATLAB que foram usadas em três conjuntos de dados, que foram obtidos usando fatores de estresse das baterias e o modelo de *Schiffer* para vida útil, ambos presentes no algoritmo iBASST. Os três conjuntos foram bem sucedidos em seus propósitos, conseguido prever a vida útil das baterias e obtendo bons valores de R^2 . Além disso, comprovando que os fatores de estresse podem ser usados para prever a vida útil de bateria de chumbo-ácido em microrredes isoladas.

Palavras-chave: Microrredes Isoladas, Sistemas de Armazenamento, Baterias de Chumbo-ácido, Redes Neurais Artificiais.

ABSTRACT

A microgrid is a modern distributed energy system using local sustainable energy resources. In these systems, the priority is renewable sources, so that solar photovoltaic and wind energy are the main sources of generation, and combustion generators can complement, increasing the reliability of the system, together with the batteries. Isolated microgrids still extensively use lead-acid technology in their storage system as it has a good benefit-cost ratio compared to other technologies. However, batteries of this type tend to significantly shorten their lifespan due to the harsher regime of renewable sources and estimating the lifetime of these lead-acid batteries can be quite complex. The present work aims to contribute to a solution to this problem, from the development of two Artificial Neural Networks in MATLAB that were used in three data sets, which were obtained using battery stress factors and the Schiffer model for lifespan, both present in the iBASST algorithm. The three sets were successful in their purposes, being able to predict the lifespan of the batteries and obtaining good values of R^2 . In addition, proving that stress factors can be used to predict lead-acid battery lifespan in isolated microgrids.

Keywords: Isolated Microgrids, Storage Systems, Lead-acid Batteries, Artificial Neural Networks.

LISTA DE FIGURAS

Figura 1 - Capacidade anual de energia elétrica e custos de implementação em microrredes por região global de 2019 a 2028. Adaptado de (MICROGRIDS, 2019)..	14
Figura 2 - Exemplo de sistema de microrrede. Adaptado de (MICROGRID, 2021).....	14
Figura 3 - Exemplo de maior taxa de descarga (NETO, 2017).....	18
Figura 4 - Modelo de <i>Schiffer</i> . Adaptado de (SCHIFFER <i>et al.</i> , 2007).....	21
Figura 5 - Modelo de RNA em <i>backpropagation</i> . Adaptado de (RASHID, 2016).	23
Figura 6 - Estrutura dos nós. Adaptado de (RASHID, 2016).	24
Figura 7 - Função sigmoide.	25
Figura 8 - Método <i>grid search</i>	27
Figura 9 - Método <i>random search</i>	27
Figura 10 - Representação gráfica de R^2	28
Figura 11 - Fluxograma com etapas para a obtenção dos conjuntos de dados.	31
Figura 12 - Histograma dos alvos do Conjunto 1.....	33
Figura 13 - Histograma dos alvos do Conjunto 2.....	33
Figura 14 - Histograma dos alvos do Conjunto 3.....	34
Figura 15 - Relação entre vida útil no iBASST e na RNA 1 do Conjunto 1, após treino e teste.....	38
Figura 16 - Histograma de erros para resultados do Conjunto 1.....	38
Figura 17 - Relação entre vida útil no iBASST e na RNA 2 do Conjunto 2, após treino e teste.....	39
Figura 18 - Histograma de erros para resultados do Conjunto 2.....	39
Figura 19 - Relação entre vida útil no iBASST e na RNA 2 do Conjunto 3, após treino e teste.....	40
Figura 20 - Histograma de erros para resultados do Conjunto 3.....	40
Figura 21 - Pequena porção do Conjunto 1.....	47
Figura 22 - Pequena porção do Conjunto 2.....	47
Figura 23 - Pequena porção do Conjunto 3.....	48
Figura 24 - Fluxograma de rotina de treino e teste da RNA 1.	49
Figura 25 - Fluxograma de rotina de treino e teste da RNA 2.	50
Figura 26 - Estrutura de entrada dos parâmetros de armazenamento.....	52
Figura 27 - Estrutura de entrada dos parâmetros de simulação.	52
Figura 28 - Estrutura de entrada para o dimensionamento aleatório das fontes.	53
Figura 29 - Estrutura de saída do sistema de armazenamento após simulação.	53

Figura 30 - Especificações técnicas do PC usado no trabalho..... 54

LISTA DE TABELAS

Tabela 1 - Descrição sobre o alvo (vida útil das baterias), gerados pelo algoritmo iBASST.....	32
Tabela 2 - Procedimentos para definição de hiperparâmetros da RNA 1.....	35
Tabela 3 - Procedimentos para definição de hiperparâmetros da RNA 2.....	35
Tabela 4 - Hiperparâmetros da RNA 2 após os treinos.....	37
Tabela 5 - Hiperparâmetros da RNA 2 após os treinos.....	37
Tabela 6 - Análise das vidas úteis obtidas pelas RNAs após os treinos.....	37

SUMÁRIO

1. INTRODUÇÃO	10
2. MICRORREDES.....	13
3. BATERIAS DE CHUMBO-ÁCIDO.....	16
3.1. FATORES DE ESTRESSE EM BATERIAS DE CHUMBO-ÁCIDO.....	17
3.2. MODELO DE SCHIFFER.....	20
4. REDES NEURAIS ARTIFICIAIS (RNA).....	22
4.1. TREINO E TESTE.....	23
4.2. ESTRUTURA DO <i>FEEDFORWARD</i>	23
4.3. ATUALIZAÇÃO DOS PESOS	25
4.4. PARÂMETROS E HIPERPARÂMETROS.....	26
4.5. AVALIAÇÃO DA PERFORMANCE POR R^2	28
5. MONTAGEM DAS RNA	30
5.1. OBTENÇÃO DOS DADOS	30
5.2. ANÁLISE DOS ALVOS.....	32
5.3. ESTRUTURA DAS RNA.....	34
6. RESULTADOS E DISCUSSÕES	37
7. CONCLUSÕES E SUGESTÕES DE TRABALHOS FUTUROS	42
8. REFERÊNCIAS BIBLIOGRÁFICAS.....	43
APÊNDICES.....	46
APÊNDICE A – PORÇÕES DOS CONJUNTOS DE DADOS GERADOS USADOS PARA ALIMENTAR AS RNA.....	47
APÊNDICE B – FLUXOGRAMAS DE ROTINA DE TREINO E TESTE PARA RNA 1 E RNA 2.....	49
ANEXOS	51
ANEXO A – ESTRUTURA DOS DADOS DE ENTRADA E SAÍDA DO IBASST.....	52
ANEXO B – ESPECIFICAÇÕES TÉCNICAS DO COMPUTADOR PESSOAL	54

1. INTRODUÇÃO

O consumo de energia elétrica está cada dia maior ao redor do mundo e as principais fontes de energia ainda são as não renováveis: o carvão e o gás. Felizmente, essa situação está tendendo a mudar e as energias renováveis vêm ganhando mais espaço no cenário de matrizes energéticas, com destaque para as fontes solar e eólica. Estudos da *BloombergNEF* apontam que até 2050 as fontes renováveis serão responsáveis por 69% da geração de energia elétrica no planeta e fontes oriundas de combustíveis fósseis serão de apenas 24% (BLOOMBERGNEF, 2020). Essa mudança vem acontecendo através de muitos fatores, no entanto os que mais impulsionam são os incentivos governamentais e barateamento da tecnologia dessas fontes.

Junto ao surgimento das energias renováveis veio o conceito de microrredes (*microgrids* no inglês), de acordo com o *International Electrotechnical Commission* (IEC) microrredes são um grupo de cargas e fontes de energia distribuídas interconectadas e com limites bem definidos formando um sistema de potência local com tensão a nível de distribuição, que age como uma única entidade controlável e sendo possível funcionarem de forma conectada à rede principal ou ilhada (IEC, 2017). Dessa forma, as microrredes vieram para suprir demandas locais, trazendo uma boa aplicação às energias renováveis, como a solar fotovoltaica e a eólica, já que essas podem ser facilmente instaladas próximas às cargas. Essa aplicação até mesmo diminui as perdas de energia elétrica, uma vez que se reduz o fluxo de energia proveniente da rede externa, havendo apenas distribuição à demanda local.

Haja vista que a disponibilidade das fontes solar e eólica pode variar muito ao longo do dia e do ano, é muito comum o uso de baterias como dispositivos de armazenagem de energia elétrica agregado a essas microrredes, aumentando a confiabilidade do sistema e diminuindo o uso de geradores a combustão. Baterias de chumbo-ácido ainda são uma tecnologia bastante utilizada em microrredes com fontes renováveis. Isto se dá pelo fato de que essa é uma tecnologia madura, e que apresenta boa relação custo-benefício nesse tipo de aplicação (TAN; LI; WANG, 2013).

Contudo, as baterias de chumbo-ácido são dispositivos que ainda não possuem uma boa precisão em sua estimativa de vida útil, podendo desviar bastante dependendo do regime ao qual são submetidas (JENKINS; FLETCHER; KANE, 2008), possibilitando comprometer os custos de O&M (operação e manutenção) dessas microrredes.

Uma forma de mitigar esse problema pode estar no uso das Redes Neurais Artificiais (RNA). As RNA são algoritmos que se assemelham aos neurônios em um cérebro. Sabendo que os seres vivos moldam seu comportamento e fundam suas ações de acordo com experiências e observações coletadas ao longo de sua vida, as RNA

visam encontrar padrões e repetições em estruturas de dados que vão moldando esse algoritmo de forma a poder entregar uma resposta a um novo caso (GOLTSMAN, 2017).

Assim, para estimar a vida útil de baterias usando Redes Neurais Artificiais é necessário o uso de dados preexistentes acerca da operação destes dispositivos nas microrredes. Esses dados moldarão a RNA e essa, então, deverá prever a vida útil de baterias aplicadas a outras microrredes.

Esse trabalho tem como objetivo desenvolver duas Redes Neurais Artificiais com o intuito de prever a vida útil de baterias de chumbo-ácido destinadas a microrredes isoladas. Serão usados como entrada da rede seis fatores de estresse das baterias (SVOBODA *et al.*, 2007), coletados em um algoritmo, fornecido pelo Prof. Dr. Pedro Bezerra Leite Neto (NETO, 2017), capaz de prever a vida útil das baterias por equações empíricas contidas no modelo *Schiffer* (SCHIFFER *et al.*, 2007).

Para isso, três conjuntos de dados serão coletados, o primeiro trará uma configuração simples de microrrede, que será usado para a primeira RNA. O segundo conjunto trará diversas modificações mais complexas ao banco de baterias da microrrede e será usado na segunda RNA. Por último, o terceiro conjunto, trará mais uma modificação ao banco de baterias e será usado apenas como teste na segunda RNA para averiguar o comportamento da mesma em uma situação diferente da qual foi treinada.

No presente trabalho o capítulo 2 trará uma abordagem sobre as microrredes, sua definição, vantagens e desvantagens, crescimento no mercado e investimentos. Já no capítulo 3 faremos um estudo sobre baterias de chumbo-ácido, sua ligação com as microrredes e a problemática da vida útil, apresentando os fatores de estresse e um modelo simplificado de *Schiffer* para prever a vida útil das mesmas. No capítulo 4 será apresentado uma introdução de como as redes neurais artificiais funcionam, usando método de gradiente descendente e *backpropagation*. No capítulo 5 mostrará como será feita a coleta de dados para alimentar as redes neurais, bem como sua montagem. No capítulo 6 os resultados obtidos acerca das RNA e dos conjuntos de dados serão expostos. E, por fim, no capítulo 7 serão dadas as conclusões acerca do trabalho e sugestões de possíveis trabalhos futuros.

Esse trabalho possui sua relevância tanto na área tecnológica quanto econômica. Uma vez que as baterias são dispositivos que demandam boa parte do orçamento das microrredes, prever a vida útil de cada sistema específico evitará surpresas e gastos não previstos.

Bateria é um assunto que ainda possui muito potencial de exploração, principalmente com relação a sua vida útil, onde há necessidade de desenvolvimento de mais trabalhos. Em contrapartida, as RNA possuem muitos artigos publicados,

diversos métodos e já é usada em diversas áreas. Logo, esse trabalho aplicará um método consolidado a uma área pouco estudada.

2. MICRORREDES

Nota-se recentemente que os sistemas elétricos mundiais estão começando a “descentralizar, descarbonizar e democratizar”, em muitos casos de baixo para cima (GREEN, 2016). Essas tendências, também conhecidas como os “três Ds”, são impulsionadas pela necessidade de controlar os custos de eletricidade, substituir a infraestrutura envelhecida, melhorar a robustez e a confiabilidade, reduzir as emissões de CO₂ para mitigar as mudanças climáticas e fornecer eletricidade confiável para as áreas onde há falta de infraestrutura. Embora os detalhes do sistema particular possam diferir de um lugar para outro, as microrredes surgiram como uma arquitetura flexível para a implantação de recursos energéticos distribuídos que podem atender às necessidades abrangentes de diferentes comunidades (HIRSCH; PARAG; GUERRERO, 2018).

Uma microrrede é um sistema moderno de energia distribuída usando recursos locais de energia sustentável. Ele também fornece segurança energética para uma comunidade local, pois pode ser operado sem a presença de uma rede elétrica mais ampla. Este novo paradigma dos sistemas elétricos geralmente representa três objetivos importantes de uma sociedade, como confiabilidade (física, cibernética), sustentabilidade (considerações ambientais) e economia (otimização de custos, eficiência). O termo “geração distribuída” (GD) se refere à geração de energia localizada em ou próximo aos locais de consumo, a carga. Em comparação com a “geração central”, a GD pode reduzir os custos de geração, transmissão e distribuição, aumentando a eficiência. Em muitos casos, a geração distribuída pode fornecer custos de geração mais baixos, maior confiabilidade e maior segurança que não é obtida por meio de geradores tradicionais.

O *Navigant Research* identificou que o mercado de microrredes de 2019 possuía 3.480,5 MW instalados em todo o mundo, totalizando um mercado de US \$ 8,1 bilhões. Em 2028, esses números crescerão para 19.888,8 MW e US \$ 39,4 bilhões, respectivamente, em gastos anuais de implementação, o que representa um crescimento anual de 21,4% (MICROGRIDS, 2019). Na Figura 1 nota-se que a Ásia-Pacífico é a região detentora da maior parte da capacidade implementada no mundo, seguida da América do Norte.

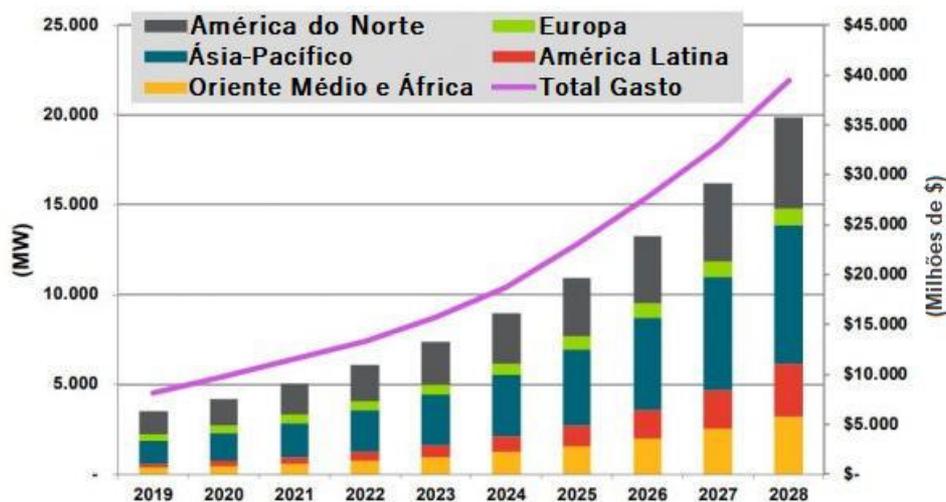


Figura 1 - Capacidade anual de energia elétrica e custos de implementação em microrredes por região global de 2019 a 2028. Adaptado de (MICROGRIDS, 2019).

Porém a região que mais crescerá em proporção, ainda segundo o *Navigant Research*, é a América Latina, com crescimento anual de 35,1%. Parte deste efeito se dá a um programa implementado em Porto Rico por representar um investimento total de US \$ 14 bilhões a longo prazo (DANIGELIS, 2019).

É possível que as microrredes possam funcionar tanto em paralelismo com a rede elétrica (conectado à rede ou *on-grid*) quando de forma independente (ilhada ou *off-grid*), e visando essa independência a microrrede pode possuir mais de uma fonte geradora de energia. Nesses sistemas a prioridade são as fontes renováveis, onde a energia solar fotovoltaica e eólica são as principais fontes de geração, e os geradores a diesel podem complementar, aumentando a confiabilidade do sistema, juntamente com as baterias (Figura 2).



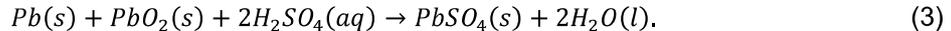
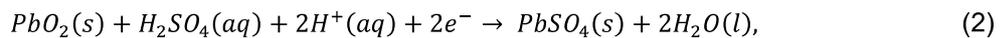
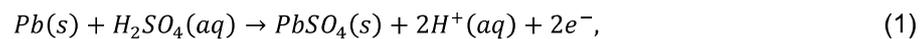
Figura 2 - Exemplo de sistema de microrrede. Adaptado de (MICROGRID, 2021).

Usando um sistema de controle, essas fontes trabalham em conjunto (MICROGRID, 2021). Administrar o uso delas é ainda algo complexo, porém tende a

seguir uma certa ordem de prioridade, para atender a demanda. Como fontes renováveis e mais baratas, os geradores fotovoltaicos e os aerogeradores são ativados em prioridade, sustentando a demanda local e recarregando as baterias. Em seguida, assim que a produção de energia elétrica nesses geradores fica abaixo da demanda, havendo carga suficiente no banco de baterias, o mesmo é ligado. Se não os geradores à combustão, fonte poluidora e mais cara, são ativados.

3. BATERIAS DE CHUMBO-ÁCIDO

As baterias armazenam energia elétrica de forma que se possa utilizá-la em outro momento. Para conseguir isso as de chumbo-ácido fazem uso de reações químicas entre duas chapas, cada uma contendo um material diferente: um eletrodo positivo (dióxido de chumbo, PbO_2) e eletrodo negativo (chumbo, Pb). Ambas são imersas em uma solução eletrolítica aquosa, H_2SO_4 . Quando o circuito entre as chapas é fechado, acontece o processo de descarga. Nesse caso, no ânodo, o chumbo reage com o eletrólito produzindo sulfato de chumbo cristalizado (PbO_4), $2H^+$ e $2e^-$. Já no cátodo, a reação entre o dióxido de chumbo, o eletrólito, $2H^+$ e $2e^+$ produzem sulfato de chumbo cristalizado e água. As equações (1) e (2) mostram as reações no ânodo e cátodo, respectivamente, e a equação (3) mostra a reação total (MAY; DAVIDSON; MONAHOV, 2018).



A reação total é capaz de produzir um potencial elétrico de aproximadamente 2 V, chamada de célula. Geralmente, nas baterias é feito um arranjo de seis células que produzem 12 V (DINIŞ; POPA; IAGØR, 2015).

De acordo com os fabricantes, as baterias de chumbo-ácido possuem uma média de vida útil de 5 anos (ZHANG *et al.*, 2018), enquanto que aplicadas às microrredes essa média cai para 2-3 anos (SOTO; MODI, 2012). As baterias em microrredes possuem um regime de trabalho muito mais rigoroso que baterias em carros, por exemplo, isso faz com que sua degradação seja muito mais rápida. Catálogos de especificações fornecidos pelos fabricantes mostram que baterias de chumbo ácido normalmente duram apenas 200-300 ciclos padrão a 100% DoD (*depth of discharge* ou profundidade de descarga, traduzindo do inglês) antes de degradar à capacidade de 80% (a medida padrão de fim de vida) (KRIEGER; CANNARELLA; ARNOLD, 2013).

3.1. FATORES DE ESTRESSE EM BATERIAS DE CHUMBO-ÁCIDO

De acordo com (SVOBODA *et al.*, 2007), existem 6 principais fatores que podem moldar o regime das baterias de chumbo-ácido, denominados *fatores de estresse*, são eles: *fator de carga*, *quantidade de Ah extraídos*, *maior taxa de descarga*, *tempo entre cargas completas*, *tempo em baixo SoC* (abreviação de Estado de Carga em inglês) e *ciclagem parcial*. Esses fatores são operacionais e estão diretamente ligados aos sinais de envelhecimento da bateria.

O fator de carga é o inverso da eficiência de *Ah*, e pode ser representado de acordo com a equação (4) (LUJANO-ROJAS *et al.*, 2016).

$$FC = \frac{Ah_{carregado}}{Ah_{descarregado}} = - \frac{\int_{t=1}^T I(t)H(I(t))dt}{\int_{t=1}^T I(t)H(-I(t))dt}, \quad (4)$$

onde geralmente o tempo T é de um ano; o I é a corrente da bateria (negativa para descarga e positiva para carga); e H é a função de Heaviside que retorna 1, caso seu argumento seja maior que 0 ou retorna 0, caso contrário. Os valores mais comuns estão entre 102% e 130%.

A quantidade de *Ah* extraídos é dito como o acúmulo de *Ah* descarregados por ano e normalizado em unidades da capacidade nominal da bateria, mostrado na equação (5) (SVOBODA *et al.*, 2007).

$$Q_{Ah} = - \frac{\int_{t=1}^T I(t)H(-I(t))dt}{C_{10}}, \quad (5)$$

onde C_{10} é a quantidade de *Ah* adquiridos pela bateria em um carregamento de 10 horas (esta é considerada a capacidade nominal da bateria), geralmente corresponde a um SoC (estado de carga) de 100%. Valores típicos deste fator de estresse estão entre 10 e 100 vezes a capacidade nominal das baterias.

A maior taxa de descarga das baterias é definida como sendo a média das correntes mais elevadas na qual 1% dos amperes-horas extraídos foram descarregados (BARING-GOULD *et al.*, 2005). Tipicamente, este fator é menor do que a corrente de referência da bateria (I_{10}), corrente necessária para descarregar por completo a bateria em 10 horas. Um exemplo pode ser visto na Figura 3.

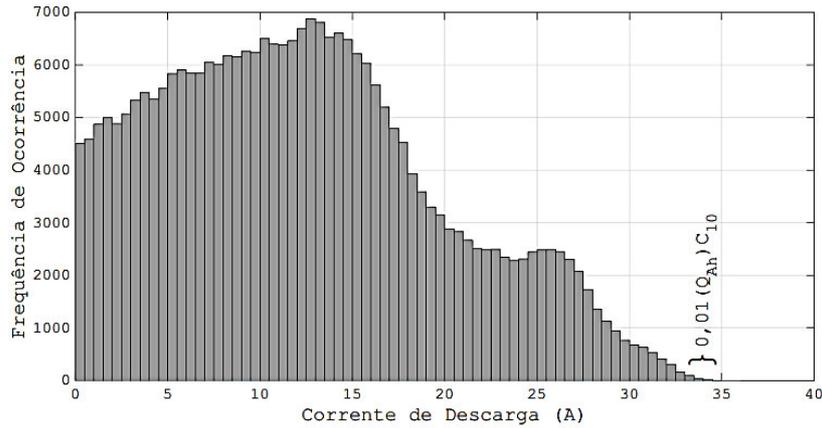


Figura 3 - Exemplo de maior taxa de descarga (NETO, 2017).

O tempo entre cargas completas é o tempo médio em dias que a bateria passou descarregada, por descarregada entende-se valores de SoC inferiores a 90% (BARING-GOULD *et al.*, 2005). Assume-se esse valor devido às medições acima de 90% serem imprecisas. A equação (6) mostra matematicamente esse fator.

$$t_{cc} = \frac{\int_{t=1}^T H(90 - SOC(t)) dt}{\eta_{90\%}}, \quad (6)$$

onde $\eta_{90\%}$ é o número de vezes em que a bateria foi considerada como carregada (maior que 90%). Esse fator de estresse possui valores típicos de 7 a 10 dias.

O tempo em baixo SoC é o percentual de tempo em que a bateria permaneceu em um SoC menor que 30% (LUJANO-ROJAS *et al.*, 2016), equação (7). Valores comuns estão entre 0% e 50%.

$$t_{lowSOC} = 100 \left(\frac{\int_{t=1}^T H(0,30 - SOC(t)) dt}{T} \right). \quad (7)$$

A ciclagem parcial representa a média ponderada de Ah extraídos de acordo com faixas de SoC:

- 100–85%: A;
- 85–70%: B;
- 70–55%: C;
- 55–40%: D;
- 40–0%: E.

O valor correspondente a região A, por exemplo, é definido pela equação (8).

$$A = - \frac{\int_{t=1}^T I(t) H(SOC(t) - 0,85) H(1 - SOC(t)) H(-I(t)) dt}{\int_{t=1}^T I(t) H(-I(t)) dt} 100\%. \quad (8)$$

As demais regiões seguem o mesmo padrão da equação (8).

Após obter os valores das 5 regiões, o valor da ciclagem parcial pode ser obtido pela equação (9). Regiões com um SoC mais alto são menos danosas à bateria. Valores típicos deste fator são entre 20% e 70%.

$$CP = \frac{A \times 1 + B \times 2 + C \times 3 + D \times 4 + E \times 5}{5} \quad (9)$$

Apesar de não ser operacional a temperatura também é um fator de estresse pois as baterias podem perder cerca de 50% da vida útil a cada acréscimo de 10°C na temperatura (NETO, 2017).

Os *mecanismos de envelhecimentos* são processos físico-químicos irreversíveis, alterando os materiais e componentes das baterias, resultando na perda de performance e o fim da vida útil (SVOBODA *et al.*, 2007). Essas alterações variam de acordo com o regime imposto a cada bateria, seu material e fabricação. Os principais mecanismos de envelhecimento são: *corrosão da placa positiva, sulfatação, perda de massa ativa, degradação da massa ativa, estratificação do eletrólito e perda de água.*

Na corrosão da placa positiva o dióxido de chumbo que compõe as placas positivas oxida, criando uma camada sobre as placas que dificulta na condução da eletricidade, além disso essa camada demanda um volume maior dentro da bateria, o que pode provocar estresses mecânicos. A corrosão está relacionada à tensão nos terminais, densidade do eletrólito e temperatura (SCHIFFER *et al.*, 2007).

A sulfatação é a conversão irreversível dos eletrodos em sulfato de chumbo, causando a perda de capacidade da bateria, aumento da resistência interna e, em alguns casos extremos, avarias mecânicas que podem ocasionar curto-circuito interno. Ocorrência deste mecanismo de envelhecimento é principalmente devido a grandes períodos sem carregamento completo (SVOBODA *et al.*, 2007).

A perda de massa ativa é perda do material na superfície dos eletrodos, depositando-se no fundo da bateria. Há ocorrência devido a corrente de gaseificação (corrente relacionada à tensão de gaseificação, que diz respeito a eletrólise da água na bateria, podendo ser notado pela formação de bolhas), quantidade de amperes-horas extraídos, descargas profundas, variações bruscas de temperatura, além de impactos mecânicos externos na bateria (NETO, 2017).

A degradação da massa ativa diz respeito aos processos relacionados aos eletrodos, como: amolecimento, perda da área de superfície e aumento da porosidade. Influenciado principalmente pela quantidade de amperes-horas extraídos, descargas profundas e carregamentos parciais (SCHIFFER *et al.*, 2007).

A estratificação do eletrólito é a não homogeneidade do eletrólito na bateria. A descarga ocorre preferencialmente no fundo, enquanto que o carregamento é

preferencialmente dado mais à superfície (SCHIFFER *et al.*, 2007). Ocorre devido à não utilização da capacidade total da bateria.

A perda de água é um processo crítico às baterias seladas, uma vez que não há a possibilidade da reposição da água. Há perda da água da bateria no processo de gaseificação. Sua ocorrência se dá por sobrecarga e altas temperaturas (NETO, 2017).

A tecnologia de chumbo-ácido apresenta diferentes vantagens, como bom desempenho e baixo custo, porém os fatores de estresse descritos acima são significativos quando estas baterias operam em microrredes isoladas devido à alta variabilidade das fontes renováveis que a compõem, uma vez que o regime de ciclo é muito irregular, os carregamentos completos são relativamente raros, mudanças bruscas entre carga e descarga e valores de corrente muito alto passando pelas baterias, de modo que a vida útil destes dispositivos pode ser reduzida drasticamente (SCHIFFER *et al.*, 2007). Esta situação tem impacto direto sobre a viabilidade econômica destas microrredes, uma vez que a troca mais frequente destes bancos de baterias pode inviabilizar os custos de O&M de toda a microrrede.

3.2. MODELO DE SCHIFFER

Alguns trabalhos já foram publicados visando estimar a vida útil de baterias de chumbo ácido em sistemas com fontes renováveis de energia (LAYADI *et al.*, 2015), um estudo comportamental da bateria de chumbo-ácido em um sistema fotovoltaico foi apresentado por (COPETTI; CHENLO, 1994). Os autores usaram modelos matemáticos para acompanhar as variações da capacitância e da resistência interna da bateria, dependendo da corrente de carga e descarga e da temperatura. Um estudo comparativo entre modelos de envelhecimento foi apresentado em (DUFO-LÓPEZ; LUJANO-ROJAS; BERNAL-AGUSTÍN, 2014). Eles são aplicados para estimar a longevidade de baterias de chumbo-ácido integradas em um sistema fotovoltaico autônomo. Outro trabalho de relevância ao assunto está em (SCHIFFER *et al.*, 2007), que também ficou conhecido como *modelo Schiffer*, nesse artigo a vida útil das baterias é dada a partir da observação de eventos, o modelo foi desenvolvido levando em consideração um sistema de fonte solar e eólica.

O modelo de *Schiffer* usa corrosão e degradação para atualizar a capacidade da bateria, a Figura 4 mostra de modo simplificado o esquema.

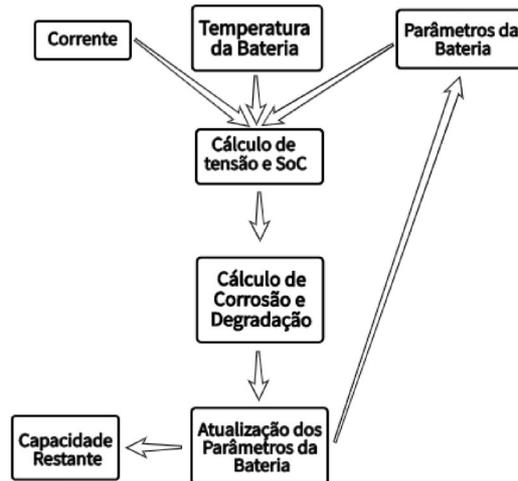


Figura 4 - Modelo de *Schiffer*. Adaptado de (SCHIFFER *et al.*, 2007).

Como já dito, entende-se por padrão que o fim da vida útil da bateria é dado quando a mesma reduz sua capacidade para 80% da capacidade nominal. Porém, a problemática está na não linearidade desse evento, não há como fazer extrapolações de resultados. Dessa forma, o modelo de *Schiffer*, se baseia em simulações que acompanham toda a vida útil da bateria. Com isso durante uma etapa da simulação, a tensão e SoC são determinados com base nos parâmetros da bateria. Em seguida, de acordo com a tensão e o SoC encontrados, os parâmetros de corrosão e degradação são determinados e usados para alterar os parâmetros da bateria e determinar a capacidade restante da bateria, que é o foco do modelo.

4. REDES NEURAIAS ARTIFICIAIS (RNA)

As Redes Neurais Artificiais são sistemas adaptativos inspirados pelos processos realizados no cérebro humano. As RNA são sistemas capazes de modificar a estrutura interna com relação a um objetivo, geralmente solucionando problemas de característica não linear, sendo capazes de encontrar padrões difíceis de serem notados e que governam a solução desses problemas (GROSSI; BUSCEMA, 2007). As RNA podem ser usadas para previsão, com exemplos fornecidos a mesma, por aprenderem a partir de reconhecimento de padrões que podem ser difíceis de descrever esses dados. Portanto, as RNA são uma espécie de aproximadores de funções universal, por conseguirem adaptarem-se de forma mais eficiente que os métodos tradicionais de estatística.

Essas RNA funcionam a partir de nós, cada nó recebe uma entrada, vinda de nós anteriores ou do meio externo, e repassa uma saída, com a qual se comunica com os nós posteriores ou com o meio externo. E por último, cada nó possui um peso que é responsável por modificar a entrada e passá-la à saída (NAZIR, 2015).

Existem dois tipos principais de Redes Neurais Artificiais com respeito à aplicação, são eles: classificação e regressão. As RNA usadas em classificação são aquelas em que sua função é determinar, ou classificar, a qual grupo pertence os dados colocados em sua entrada. Por exemplo, em uma linha de produção de peças, determinar se a peça está quebrada ou não. Já as RNA de regressão são usadas onde não há como classificar os dados, assim as respostas são dadas de forma numérica. Como exemplo temos uma concessionária de energia elétrica que queira prever a demanda para o dia, ou ainda meteorologistas que queiram saber a chance de chuva para um determinado dia.

Existem diversas formas de arranjar uma RNA, mas a forma mais simples e didática é o *backpropagation*. Com essa abordagem, a RNA pode ser dividida em três principais partes: camada de entrada, camadas ocultas e camada de saída, Figura 5. Há apenas uma camada de entrada com números de nós de acordo com a quantidade de entradas. Em seguida, o número de camadas e número de nós nas camadas ocultas pode variar. Por último, a camada de saída é única e o número de nós vai de acordo com a interpretação externa da resposta (GROSSI; BUSCEMA, 2007).

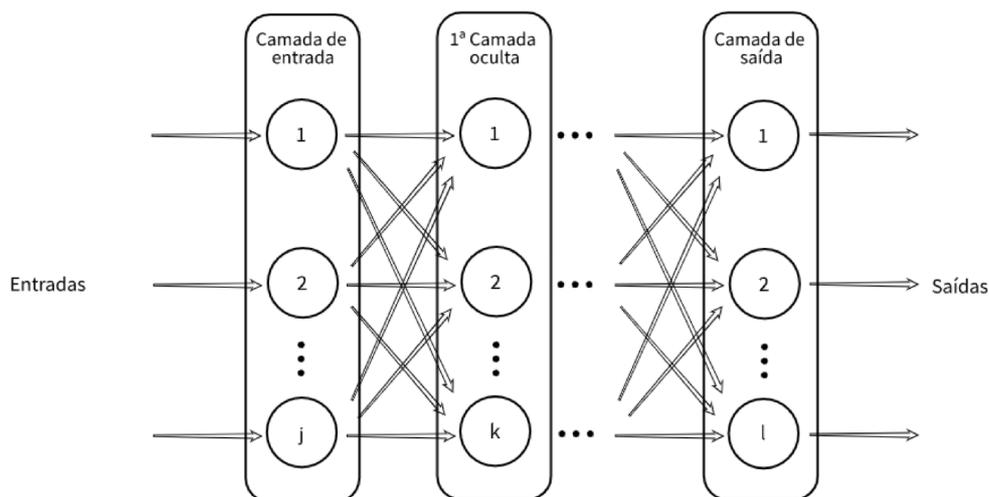


Figura 5 - Modelo de RNA em *backpropagation*. Adaptado de (RASHID, 2016).

4.1. TREINO E TESTE

Dessa forma, após construir a estrutura da RNA, é necessário fazer o *treino*, para moldar os pesos dos nós e o *teste* para verificar a funcionalidade da rede (NAZIR, 2015). O conjunto de dados deve conter as entradas e a saída almejada, chamado de alvo (*target* no inglês).

O treino deve consumir a maior parte da base de dados, inserindo os vetores de entrada na camada de entrada, um vetor de cada vez. Em seguida, após esses dados percorrerem todas as camadas, até chegar na camada de saída, o resultado obtido é comparado com o resultado esperado, no banco de dados. A diferença entre esses valores é usada para alterar os pesos dos nós para o próximo vetor de entrada. Cada vetor de entrada, faz pequenas alterações nos pesos durante o treino.

Se necessário, é possível reutilizar o mesmo conjunto de treino para refazer todo o processo do treino para melhorar a eficiência da rede, cada repetição dessa é denominada época. É preciso atenção, pois muitas épocas podem provocar o *overfitting* onde a rede não é capaz de prever corretamente para novos dados, por treino excessivo com os mesmos dados.

Encerrada essa parte, o restante do conjunto de dados é usado para o teste, para medir a eficiência da RNA.

4.2. ESTRUTURA DO *FEEDFORWARD*

Na estrutura *backpropagating* as informações de entrada estão permitidas a andar em apenas um sentido: da camada de entrada, passando pelas camadas ocultas,

até a camada de saída, denominando-se *feedforward* (VRAHATIS *et al.*, 2000). Cada nó possui uma estrutura que consiste em: entrada, pesos, somador, função de ativação e saída (Figura 6).

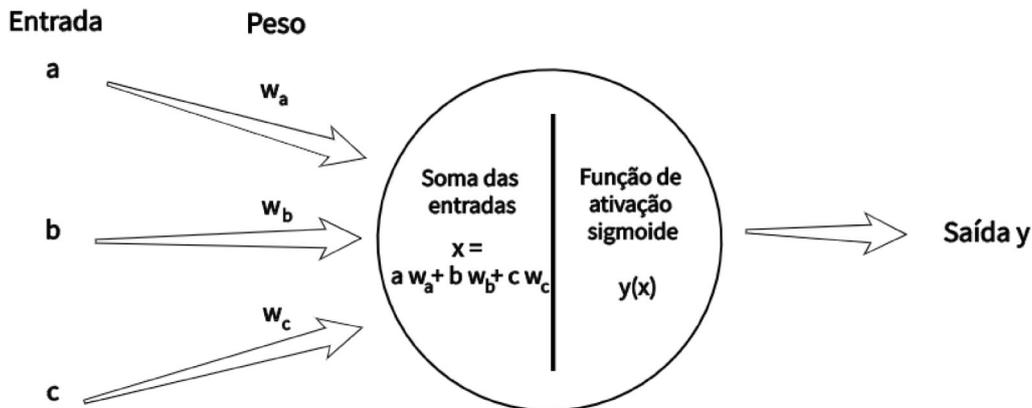


Figura 6 - Estrutura dos nós. Adaptado de (RASHID, 2016).

Os vetores de entrada podem ser representados por um vetor como I .

$$I = \begin{bmatrix} i_1 \\ i_2 \\ i_3 \\ \vdots \\ i_j \end{bmatrix}. \quad (10)$$

Em seguida, as matrizes de pesos, que será uma para cada conexão entre camadas, por exemplo, se uma Rede Neural Artificial contém a camada de entrada (com j nós), apenas uma camada oculta (com k nós) e a camada de saída (com l nós), serão necessárias duas matrizes de pesos: uma entre a camada de entrada e a camada escondida ($W_{entrada_oculta}$); outra entre a camada oculta e a camada de saída ($W_{oculta_saída}$).

$$W_{entrada_oculta} = \begin{bmatrix} W_{1,1} & W_{1,2} & W_{1,3} & \dots & W_{1,k} \\ W_{2,1} & W_{2,2} & W_{2,3} & \dots & W_{2,k} \\ W_{3,1} & W_{3,2} & W_{3,3} & \dots & W_{3,k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ W_{j,1} & W_{j,2} & W_{j,3} & \dots & W_{j,k} \end{bmatrix}, \quad (11)$$

$$W_{oculta_saída} = \begin{bmatrix} W_{1,1} & W_{1,2} & W_{1,3} & \dots & W_{1,l} \\ W_{2,1} & W_{2,2} & W_{2,3} & \dots & W_{2,l} \\ W_{3,1} & W_{3,2} & W_{3,3} & \dots & W_{3,l} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ W_{k,1} & W_{k,2} & W_{k,3} & \dots & W_{k,l} \end{bmatrix}. \quad (12)$$

Cada elemento da matriz é o peso que correspondente à conexão entre dois nós, um de cada camada.

Com a estrutura das matrizes, o resultado da interação entre as entradas e os pesos de uma camada pode ser obtida por X .

$$X_{n+1} = W^T \cdot X_n, \quad (13)$$

onde n é o número total de camadas e

$$X_1 = I. \quad (14)$$

Os valores trabalhados ao longo da RNA devem ficar entre 0 e 1, por isso é importante que o conjunto de dados contendo os vetores de entrada sejam normalizados para esses valores. Da mesma forma, na primeira iteração, os valores dos pesos podem ser gerados randomicamente dentro desse intervalo. A equação (13) pode gerar valores fora desse limite, por isso é preciso inserir uma função de ativação que será responsável por limitar as saídas dos nós a valores entre 0 e 1. Uma das funções mais usadas é a sigmoide, equação (15), na Figura 7 temos uma representação dessa função, que funciona muito bem para valores pequenos de x .

$$S(x) = \frac{1}{1 + e^{-x}}. \quad (15)$$

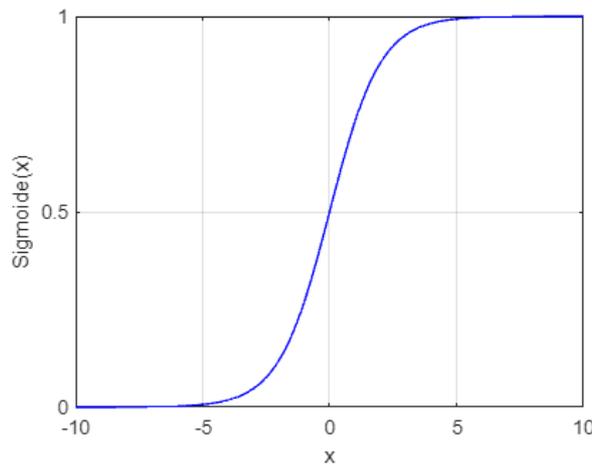


Figura 7 - Função sigmoide.

Logo, a saída de cada camada da RNA pode ser representada por O .

$$O = S(X), \quad (16)$$

4.3. ATUALIZAÇÃO DOS PESOS

Para atualizar os valores dos pesos uma das técnicas mais comuns é o *backpropagating*, que consiste em gerar um valor de erro para cada nó, que seria a diferença entre o valor da saída esperada, também conhecida como alvo (ou *target*, em inglês), e o valor da saída dada pela Rede Neural, equação (17). Costuma-se elevar a equação ao quadrado para evitar valores negativos (equação (18)).

$$e = t - o, \quad (17)$$

$$e = (t - o)^2. \quad (18)$$

Uma vez encontrado o erro para os nós na camada de saída, os erros para os nós nas camadas anteriores e proporcional aos valores dos pesos, ou seja, quanto maior o peso, maior é a parte recebida no valor do erro. Dessa forma, o erro encontrado na saída da RNA é distribuído para os nós anteriores proporcionalmente, a fim de atualizar o valor dos pesos.

De posse dos erros em cada nó, os pesos podem ser atualizados seguindo a equação (19), onde o α é o coeficiente de aprendizado e $\frac{\partial E}{\partial w}$ é o gradiente descendente do erro em relação ao peso, equação (20).

$$w_{novo,jk} = w_{atual,jk} - \alpha \frac{\partial E}{\partial w_{jk}} \quad (19)$$

$$\frac{\partial E}{\partial w_{jk}} = -(t_k - o_k) \cdot s \left(\sum_j w_{jk} \cdot o_j \right) \left(1 - s \left(\sum_j w_{jk} \cdot o_j \right) \right) \cdot o_j \quad (20)$$

O coeficiente de aprendizado corresponde a um valor dado entre 0 e 1 que indica o quanto os pesos mudaram em cada iteração, é recomendável empregar um valor baixo a fim de evitar falsos resultados. A equação (20) advém da derivação da equação (17).

4.4. PARÂMETROS E HIPERPARÂMETROS

Como é possível perceber ao longo deste trabalho, as RNA possuem diversas configurações a serem ajustadas de forma individual. Existem dois grupos de ajustes: os parâmetros e os hiperparâmetros. Os parâmetros são aqueles definidos após o treino, pela própria RNA, como é o caso dos valores dos pesos nos nós. Os hiperparâmetros são aqueles definidos antes do treino e impactam de forma direta no desempenho da rede (JÚNIOR, 2018). Os hiperparâmetros mais comuns são: números de camadas, números de nós em cada camada, função de ativação, número de épocas, proporção entre os dados de teste e treino e coeficiente de aprendizado.

Há diversas técnicas para encontrar a melhor configuração de hiperparâmetros, as mais comuns são *grid search*, *random search* e experimentação sistemática.

O *grid search* tenta pesquisar exaustivamente todas as combinações possíveis de hiperparâmetros para formar uma grade de valores de hiperparâmetros (Figura 8) (LERMAN, 1980). Na prática, o intervalo de valores de hiperparâmetros a buscar é especificado manualmente. O *grid search* é um método bastante demorado, de alto

custo computacional. Este método funciona bem quando o número de hiperparâmetros é relativamente pequeno.

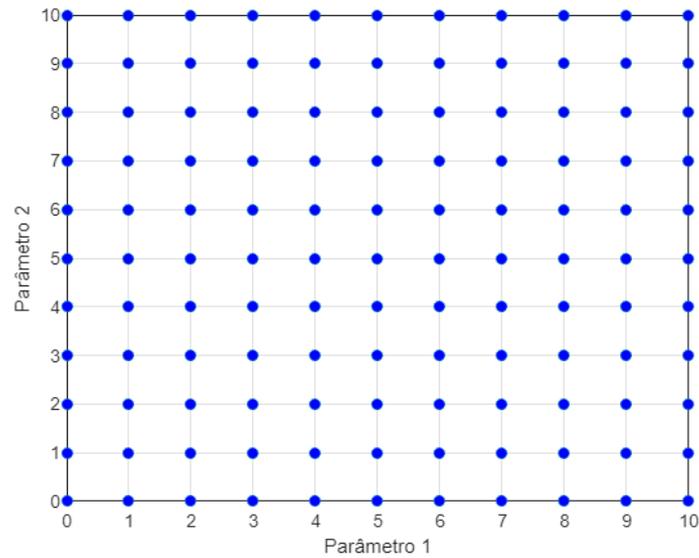


Figura 8 - Método *grid search*.

Quando o espaço de busca do hiperparâmetro é grande, a pesquisa aleatória (*random search*) é melhor do que o *grid search*. Na pesquisa aleatória, cada configuração é amostrada a partir da distribuição de valores de parâmetros possíveis, na tentativa de encontrar o melhor subconjunto de hiperparâmetros (Figura 9) (SOLIS; WETS, 1981). A pesquisa é realizada dentro de uma faixa aproximada, que então será reduzida com base em onde o melhor resultado aparece.

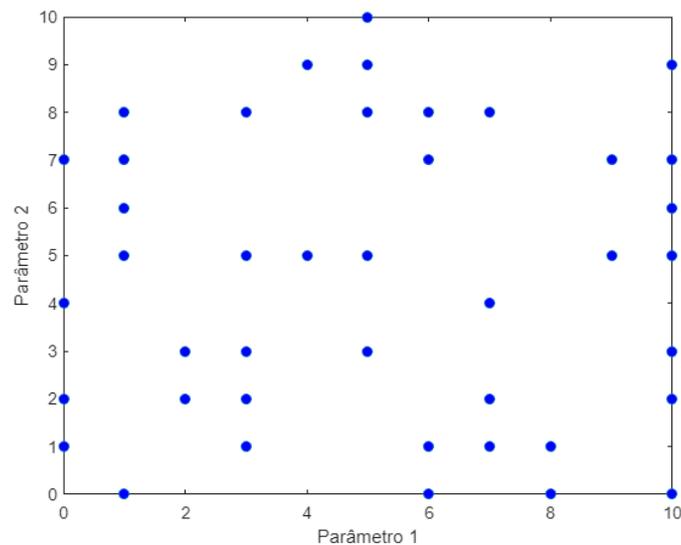


Figura 9 - Método *random search*.

Há também a experimentação sistemática que consiste em reajustar os hiperparâmetros manualmente de acordo com as experiências anteriores (BROWNLEE, 2018).

4.5. AVALIAÇÃO DA PERFORMANCE POR R^2

Com a RNA treinada e testada é necessário saber o quão próximo do resultado esperado, os alvos, foi entregue pela RNA nos testes. Há muitas maneiras de medir a eficiência de uma rede neural, porém uma das mais comuns e a usada neste trabalho é o coeficiente de determinação R^2 que pode ser visto na equação abaixo (HOFFMANN; VIEIRA, 1977).

$$R^2 = \frac{SQ_{exp}}{SQ_{total}}. \quad (21)$$

De forma que:

$$SQ_{exp} = \sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2 \quad (22)$$

e

$$SQ_{total} = \sum_{i=1}^n (y_i - \bar{y}_i)^2. \quad (23)$$

Sendo assim, R^2 é um coeficiente regressão, onde SQ_{exp} é a soma dos quadrados explicada, em que \hat{y}_i é o resultado obtido da RNA e \bar{y}_i é a média dos alvos, SQ_{total} é a soma dos quadrados total, em que y_i são os alvos e n é o tamanho do conjunto de dados. Quanto mais alto o valor de R^2 melhor é o resultado, indicando que mais próximo os resultados obtidos do treino estão dos alvos, sendo que o valor máximo é 1.

Portanto, R^2 é como um percentual entre a variação nos dados observados e a variação nos dados reais que pode ser observada de forma gráfica pela Figura 10.

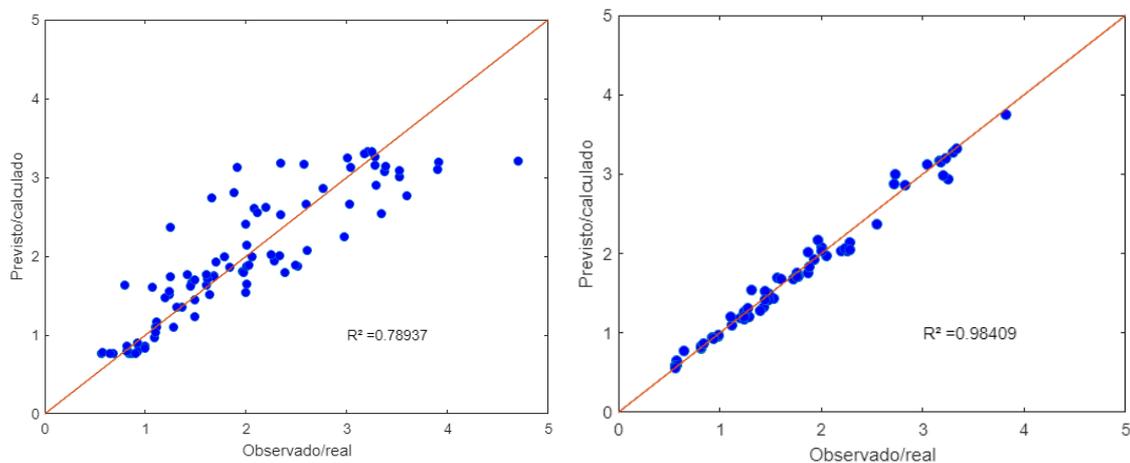


Figura 10 - Representação gráfica de R^2 .

Assim, é possível perceber que quanto menor o valor de R^2 mais distante os pontos estarão da reta, e quanto maior seu valor mais próximo os pontos estarão da reta, onde o último significa que os valores calculados estão próximos ao valor real.

5. MONTAGEM DAS RNA

5.1. OBTENÇÃO DOS DADOS

Os dados para alimentar a RNA foram adquiridos a partir de uma contribuição do Professor Dr. Pedro Bezerra Leite Neto, por ter desenvolvido uma Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão como requisito parcial para obtenção do grau de Doutor em Engenharia de Eletricidade em 2017, cujo título do trabalho foi “Contribuições Para A Operação Energética E Econômica de Microrredes Isoladas Com Fontes Renováveis Diversificadas”. Como parte da tese, foi necessário desenvolver um algoritmo, chamado iBASST, em MATLAB que visa o estudo de microrredes com fontes eólica, solar fotovoltaica, maremotriz, gerador a diesel e dois bancos de bateria. Uma das funções do iBASST é determinar os fatores de estresse das baterias, mencionados no Item 3.1: o fator de carga, quantidade de Ah extraídos, maior taxa de descarga, tempo entre cargas completas, tempo em baixo SoC e ciclagem parcial em uso das microrredes, fazendo-se de dados adquiridos sobre a Ilha Grande-MA ao longo de um ano. Além disso, outra função do algoritmo é trabalhar com o modelo de *Schiffer*, Item 3.2, para simular o uso de baterias de chumbo-ácido na microrrede e determinar a vida útil das mesmas.

Para a obtenção do conjunto de dados foi usado um recurso do iBASST que permite o dimensionamento aleatório das fontes a partir de um determinado consumo de kWh/ano. Os parâmetros usados para o dimensionamento das fontes e do banco de baterias foram:

- Quantidade máxima de turbinas eólicas: 2 turbinas Bergey Excel-R 7.5 kW;
- Capacidade máxima do sistema FV: 40 kWp;
- Quantidade máxima de turbinas maremotrizes: 1 turbina *SmartFlow* 5.0 kW;
- Consumo de energia: 46.544,19 kWh/ano;
- Quantidade de bancos de armazenamento: Somente banco 2;
- Capacidade nominal de cada bateria: 1200 Ah;
- Número de *strings*: 2;
- Número de baterias por *string*: 60;
- SoC mínimo: 50%.

Demais dados de dimensionamento da rede inseridos no iBASST estão no Anexo A. A capacidade do gerador a diesel é definida pelo algoritmo, de acordo com o dimensionamento dado às fontes renováveis.

Com isso, sempre que o algoritmo é rodado ele gera números aleatórios dentro desses parâmetros predefinidos, mudando a configuração da microrrede e assim gerando resultados diferentes.

O algoritmo foi rodado em repetição, resultados com menos de 0,5 anos e mais de 7 anos de vida útil de bateria foram descartados, pois estão muito abaixo e muito acima, respectivamente, dos resultados esperados. Uma vez que o tempo em abaixo SoC é contado a partir de 30% para abaixo, é esperado que o esse fator de estresse venha como 0 para todos os casos. Ao todo, esse conjunto de dados, denominado Conjunto 1, é composto por 5920 vetores de entrada. A Figura 11 mostra um fluxograma com os processos para a obtenção dos conjuntos.

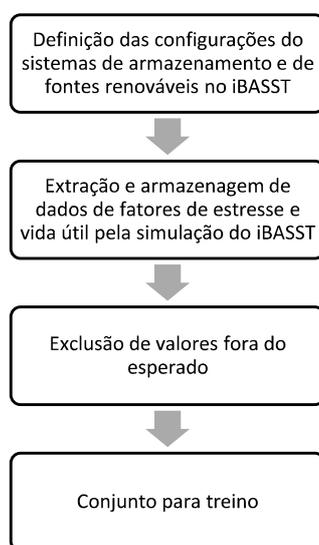


Figura 11 - Fluxograma com etapas para a obtenção dos conjuntos de dados.

Apenas sete dados foram coletados do algoritmo a cada vez que o mesmo foi rodado para compor a matriz com os vetores de entrada da RNA: fator de carga, quantidade de Ah extraídos, maior taxa de descarga, tempo entre cargas completas, tempo em baixo SoC, ciclagem parcial e vida útil das baterias, nessa exata ordem.

Após isto, uma pequena modificação no banco de baterias foi introduzida ao algoritmo do iBASST a fim de gerar mais variações ao sistema e construir o Conjunto 2:

- Temperatura ambiente média do banco de baterias: entre 20° e 35° C;
- SoC mínimo: entre 20% e 50%;
- SoC em que o banco é considerado cheio (G.G.): entre 40% e 60%;
- Equalização das baterias: fixo ou variável;
- Número de dias para carga de equalização das baterias: 7 ou 14 dias.

O algoritmo foi rodado em repetição novamente, resultados com menos de 0,5 anos e mais de 7 anos de vida útil de bateria foram descartados. Ao todo, a base de

dados é composta por 5150 vetores de entrada. Por último, para testar a eficácia da rede, uma nova modificação foi introduzida, gerando o Conjunto 3:

- Capacidade nominal da bateria: alterada de 1200 para 600 Ah;
- Número de *strings*: Alterado de 2 para 4.

Dessa forma, o banco de baterias continua com a mesma capacidade, porém com parâmetros diferentes, para testar o comportamento da RNA em condições não planejadas.

O algoritmo foi rodado em repetição mais uma vez, resultados com menos de 0,5 anos e mais de 7 anos de vida útil de bateria foram descartados. Ao todo, o Conjunto 3 é composto por 1150 vetores de entrada.

5.2. ANÁLISE DOS ALVOS

De posse dos três conjuntos de dados para a RNA, uma análise geral preliminar sobre os alvos é muito importante para dar prosseguimento à RNA. A seguir, tem-se Tabela 1 com um resumo de informações acerca dos alvos coletados, bem como a Figura 12, Figura 13 e Figura 14 que mostram o histograma. O Apêndice A apresenta uma pequena porção dos conjuntos obtidos.

Tabela 1 - Descrição sobre o alvo (vida útil das baterias), gerados pelo algoritmo iBASST.

	Conjunto 1	Conjunto 2	Conjunto 3
Contagem	5920	5150	1150
Média	2,0332	1,4118	1,4190
Desvio padrão	1,0114	0,7560	0,7731
Mínimo	0,5046	0,5013	0,5013
Máximo	6,8736	6,1829	6,1829

Era de se esperar que o Conjunto 1 obtivesse a maior média de vida útil e o maior valor máximo, uma vez que ele não está sob os efeitos do tempo em baixo SoC, nem tão pouco às demais variações dos Conjuntos 2 e 3, que estão submetidos a variações mais severas. Além disso, o Conjunto 1 é o único com a média dentro do esperado, 2 a 3 anos, pelas mesmas causas.

Também podemos notar que a grande maioria dos dados está concentrada na faixa de 0,5 a 4 anos. No Conjunto 1 apenas 151 alvos possuem mais de 4 anos, no Conjunto 2 são 19 alvos e no Conjunto 3 são apenas 4 alvos. Isso pode dificultar o desempenho da RNA para valores maiores que 4 anos.

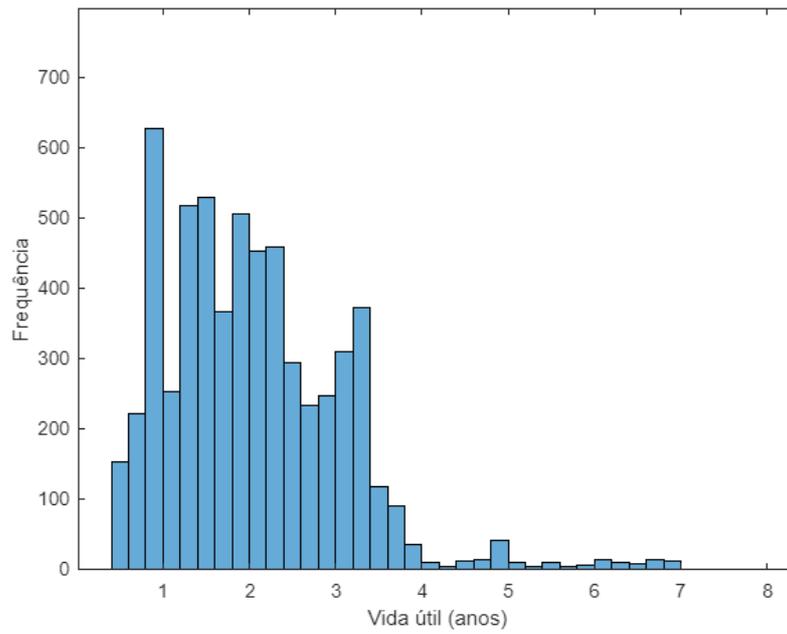


Figura 12 - Histograma dos alvos do Conjunto 1.

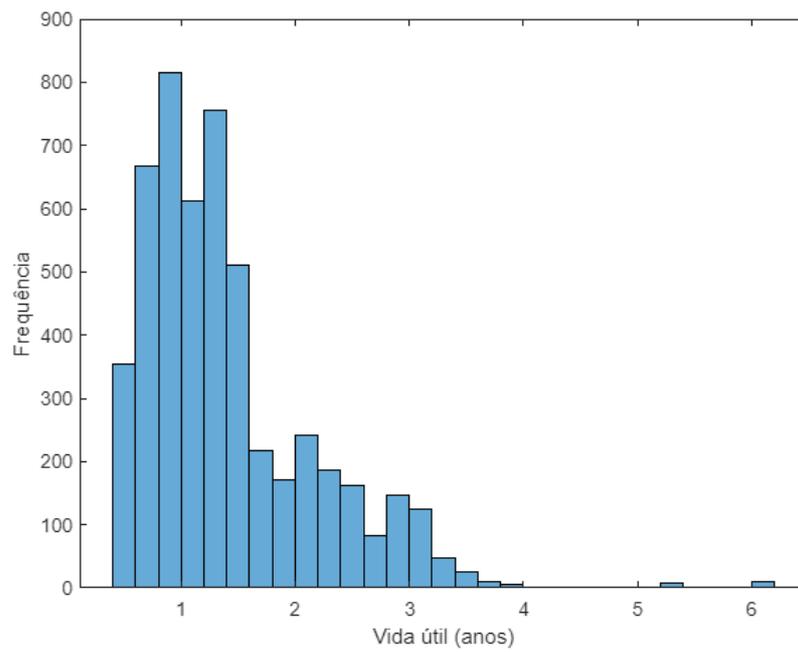


Figura 13 - Histograma dos alvos do Conjunto 2.

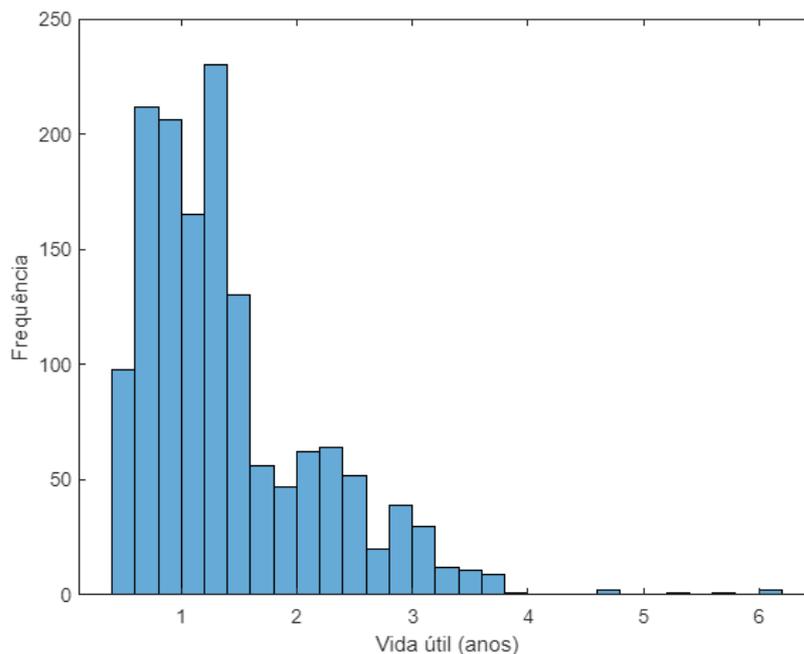


Figura 14 - Histograma dos alvos do Conjunto 3.

5.3. ESTRUTURA DAS RNA

Primeiramente, serão construídas duas RNA uma para o Conjunto 1 de dados (RNA 1) e outra para o Conjunto 2 (RNA 2). O Conjunto 3 será usado apenas como teste para RNA 2, a fim de analisar o comportamento da mesma em uma situação um pouco fora de seus parâmetros.

A ferramenta utilizada para a construção das RNA é o software MATLAB Online onde está disponível o uso da função *train* que permite o treino e teste com diversos recursos de hiperparâmetros automáticos de Redes Neurais Artificiais. Com o uso dessa função é preciso dividir os conjuntos de dados em três partes: treino, validação e teste. A validação seria uma parte do conjunto de dados dada ao algoritmo para o mesmo determinar alguns desses hiperparâmetros por si só, evitando falsos resultados. Pela Tabela 2 e Tabela 3 é possível ver o método usado para encontrar os hiperparâmetros das redes.

Tabela 2 - Procedimentos para definição de hiperparâmetros da RNA 1.

Hiperparâmetro da RNA 1	Procedimento
Número de entradas	5
Número de saídas	1
Número de camadas ocultas	Experimentação
Número de nós em cada camada oculta	Experimentação
Proporção entre treino, validação e teste	Experimentação
Função de ativação	Sigmoide
Coefficiente de aprendizado	Automático
Épocas	Automático

Tabela 3 - Procedimentos para definição de hiperparâmetros da RNA 2.

Hiperparâmetro da RNA 2	Procedimento
Número de entradas	6
Número de saídas	1
Número de camadas ocultas	Experimentação
Número de nós em cada camada oculta	Experimentação
Proporção entre treino, validação e teste	Experimentação
Função de ativação	Sigmoide
Coefficiente de aprendizado	Automático
Épocas	Automático

Durante os treinos o parâmetro a definir a eficiência mínima das RNA foi um R^2 de pelo menos 0,95 para ambas as RNA usando os Conjuntos 1 e 2, respectivamente em cada rede. Assim, após cada treino e teste o valor de R^2 foi averiguado, estando o valor abaixo do esperado foi preciso uma nova modificação nos hiperparâmetros para, dessa forma, haver um novo treino e teste. Ao R^2 atingir um valor dentro faixa esperada os treinos e testes foram cessados e os resultados analisados. Para a RNA 2 ainda houve o teste com o Conjunto 3. No Apêndice B estão contidos os fluxogramas com as rotinas desses processos.

Durante os treinos das RNA levou-se em consideração o uso do MATLAB R2020b, baixado para o computador, porém observou-se que o tempo necessário para cada treino era muito longo, podendo ir de 2 a 3 vezes mais. O que inviabiliza o uso das técnicas de *grid search* e *random search*. As especificações técnicas do computador pessoal (PC) usado podem ser encontradas no Anexo B. No MATLAB Online, apesar de realizar o mesmo treino em menos tempo, há o fechamento de sessões e alguns erros que encerram o programa que surgem quando o mesmo está aberto por muito tempo, o que também inviabiliza uso das técnicas de *grid search* e *random search*. Além disso, também foi observado que a mesma RNA com exatamente os mesmos

hiperparâmetros pode possuir resultados diferentes se rodada mais de uma vez, devido à natureza estocástica das escolhas dos pesos. Por isso, foi adotado o método de experimentação para alguns hiperparâmetros.

6. RESULTADOS E DISCUSSÕES

Após diversas abordagens, variando os valores dos hiperparâmetros, os melhores resultados de cada RNA podem ser vistos nas Tabelas 4 – 6 e Figuras 15 – 20. É válido ressaltar que na Tabela 6 podemos ver que o valor mínimo nos Conjuntos 2 e 3 estão abaixo do esperado (0,5), porém, ao longo das muitas tentativas ficou claro que para esses dois conjuntos há sempre valores que fogem do esperado, podendo ser tanto para o valor mínimo quanto para valor máximo de vida útil contido nos mesmos. No entanto, adiante do tamanho do conjunto de dados, essas divergências são irrelevantes.

Tabela 4 - Hiperparâmetros da RNA 2 após os treinos.

RNA 1	
Tempo total	10 min e 11 s
Número de camadas ocultas	3
Número de nós em cada camada oculta	50, 50, 50
Proporção entre treino, validação e teste	0.6, 0.2, 0.2
Épocas	92

Tabela 5 - Hiperparâmetros da RNA 2 após os treinos.

RNA 2	
Tempo total	24 min e 38 s
Número de camadas ocultas	3
Número de nós em cada camada oculta	70, 70, 70
Proporção entre treino, validação e teste	0,6, 0,2, 0,2
Épocas	85

Tabela 6 - Análise das vidas úteis obtidas pelas RNA após os treinos.

	Conjunto 1	Conjunto 2	Conjunto 3
R²	0,98141	0,98946	0,81936
Média	2,0226	1,4062	1,4460
Desvio padrão	1,0230	0,8132	0,8068
Mínimo	0,5408	-0,1843	-0,7916
Máximo	6,8875	6,1889	5,7889

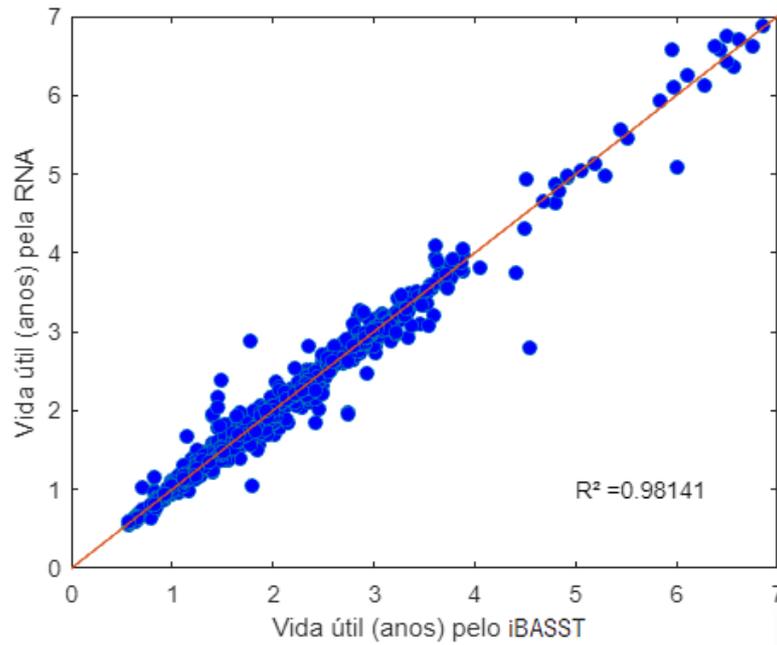


Figura 15 - Relação entre vida útil no iBASST e na RNA 1 do Conjunto 1, após treino e teste.

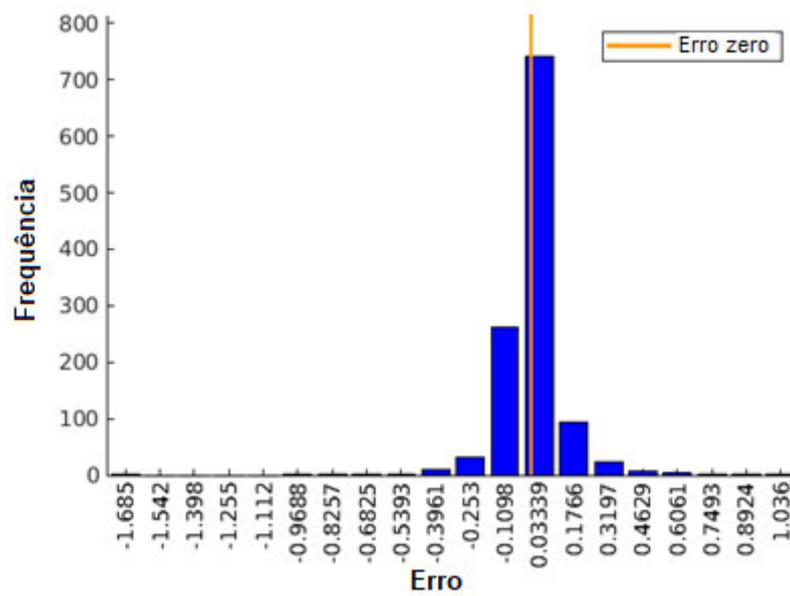


Figura 16 - Histograma de erros para resultados do Conjunto 1.

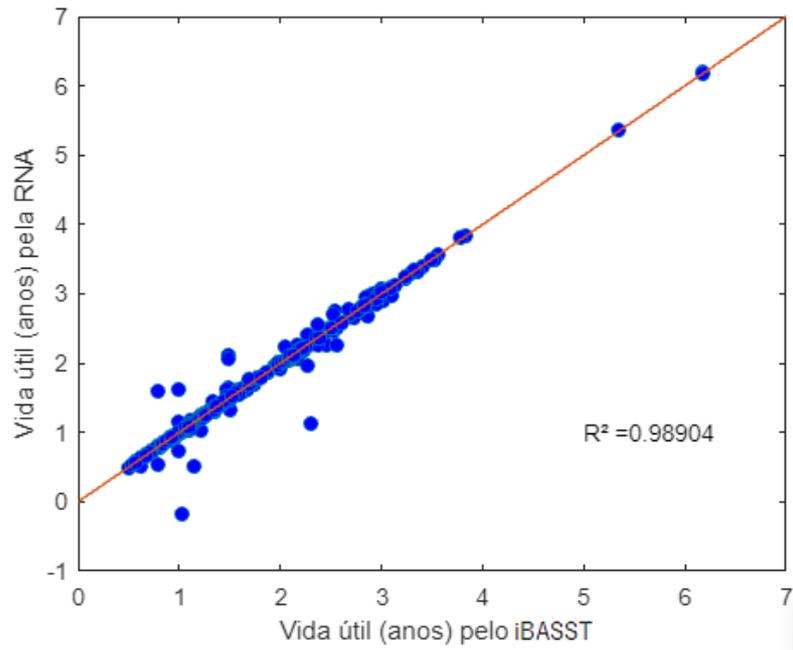


Figura 17 - Relação entre vida útil no iBASST e na RNA 2 do Conjunto 2, após treino e teste.

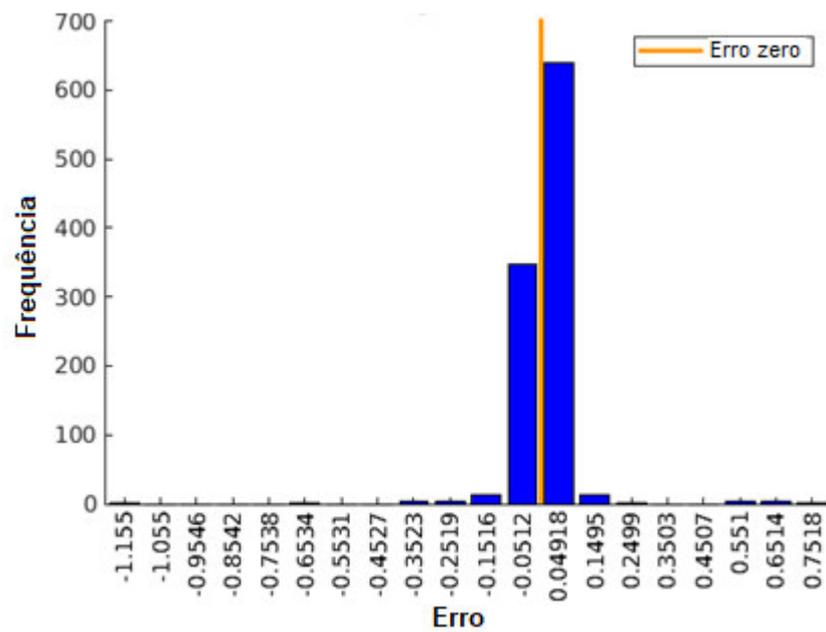


Figura 18 - Histograma de erros para resultados do Conjunto 2.

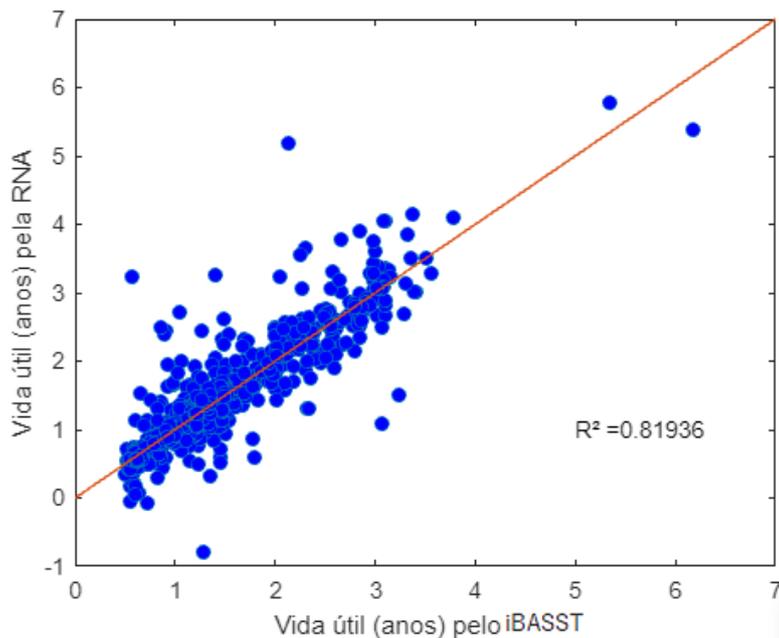


Figura 19 - Relação entre vida útil no iBASST e na RNA 2 do Conjunto 3, após treino e teste.

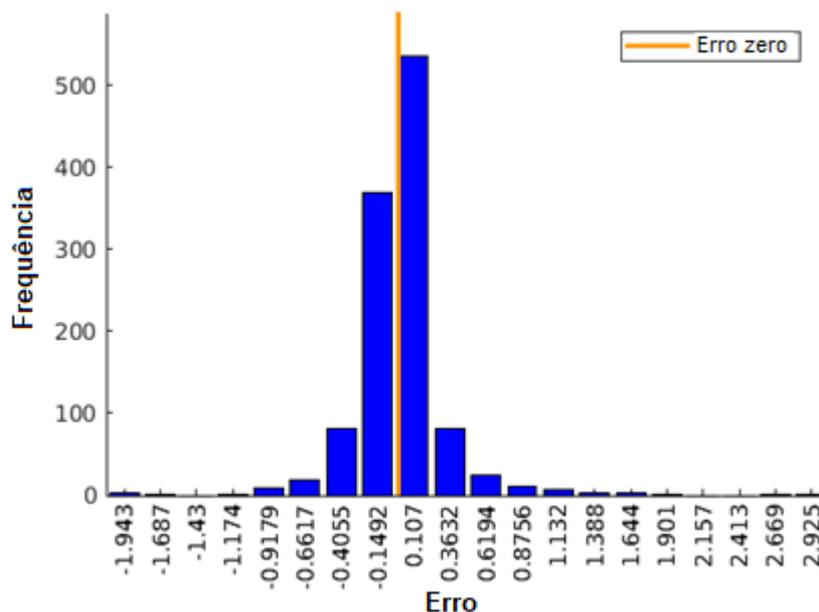


Figura 20 - Histograma de erros para resultados do Conjunto 3.

Pela Figura 15, podemos ver que o treino da RNA 1 que utiliza o Conjunto 1 pode ser considerado bem sucedido, não há grandes diferenças entre o resultado do iBASST, que usa o modelo de *Schiffer*, e da RNA, com um $R^2 = 0,98141$. A grande maioria dos resultados está concentrada em um erro por volta de 0,03339, o que significa menos de 15 dias de diferença, Figura 16. Além de, que os resultados com diferenças maiores que um trimestre ($|\text{erro}| > 0,25$) são bem poucos e não chegam a afetar muito a média, comparando Tabela 1 e Tabela 6.

Para a RNA 2 que foi treinada e testada com o Conjunto 2, Figura 17, também é possível decretar êxito à solução alcançada, com um $R^2 = 0,9804$ os resultados convergem fortemente para a linha de apoio, que representa o ideal. A prevalência dos resultados é para erros por volta de 0,5512, que equivale a um pouco mais de 15 dias, ou menos (Figura 18). Valores com mais de um trimestre de diferença em vida útil também são ínfimos, se comparadas a Tabela 1 e Tabela 6 a diferença entre as médias é muito pequena.

Já a mesma RNA 2 que foi testada com o Conjunto 3 (Figura 19) de dados tem uma convergência bem menor que os dois conjuntos anteriores, com um $R^2 = 0,81936$, isto não é surpresa, uma vez que os Conjuntos 2 e 3 possuem parâmetros diferentes em suas construções. Entretanto, é possível perceber que ainda assim há uma tendência dos resultados se agruparem seguindo a linha auxiliar. A maioria dos resultados possui um erro abaixo de dois meses ($|\text{erro}| < 0,1666\dots$), porém há ainda um número considerável de erros maiores que um trimestre, o que resulta em uma diferença nas médias um pouco maior que nos conjuntos anteriores (Figura 20). O teste do Conjunto 3 foi preciso em tender à linha auxiliar, porém faltou exatidão nos resultados para os mesmos se aproximassem mais do esperado.

Também foi mencionado anteriormente que para valores de vida útil acima de 4 anos poderiam ter uma precisão menor que as demais devido a poucos dados nessa faixa para alimentar a redes neurais. No entanto, para os três conjuntos conta-se que não há diferença discrepante entre os resultados dessa faixa de vida útil.

Logo, ambas as redes neurais foram bem sucedidas, e se mostraram competentes para determinar a vida útil de baterias de chumbo-ácido em diversos regimes de operação. Sendo admissível inferir que os seis fatores de estresse das baterias de chumbo-ácido, que formaram os vetores de entrada para as duas RNA, e o modelo de *Schiffer*, que forneceu a vida útil como alvo, verdadeiramente detêm uma relação direta entre si, do contrário os resultados não haveriam convergido. O que, por sua vez, implica que o modelo de *Schiffer*, que usa diversas equações complexas e empíricas e necessita simular o uso das baterias ano a ano, pode ser substituído, por um método mais robusto, que necessita de dados de apenas um ano.

No entanto, vale lembrar que tanto a RNA 1 quanto RNA 2 funcionam para casos específicos de microrredes, comprovado pelos resultados do Conjunto 3 estarem um pouco abaixo dos demais. Para melhorar esse método é necessário expandir os conjuntos de dados com configurações diferentes de microrredes, de modo que se cubra os casos mais comuns, logo aumentando a área de abrangência da RNA.

7. CONCLUSÕES E SUGESTÕES DE TRABALHOS FUTUROS

Uma microrrede é uma fonte de geração de energia local que pode operar sem a rede de distribuição tradicional, por isso existem dois tipos principais de microrredes: as conectadas a rede e as isoladas. Uma microrrede pode ser alimentada principalmente por fontes de energia renováveis, como a solar fotovoltaica e a eólica, podendo haver geradores, e no caso das isoladas, baterias.

A procura por microrredes tem crescido bastante nos últimos anos devido à constante evolução na tecnologia empregada nos constituintes em seus constituintes, gerando energia de baixo custo, limpa e eficiente para as comunidades locais, com menos interrupções e menos variabilidade. Elas também permitem uma forma altamente eficiente de energia, reduzindo o uso de combustível e diminuem as perdas na linha de transmissão e distribuição.

No entanto, para as microrredes isoladas há um ponto que precisa de bastante atenção, que são as baterias, principalmente as com tecnologia de chumbo-ácido, que por apresentarem um bom custo-benefício são amplamente empregadas em microrredes. Uma vez que fontes renováveis possuem grande variabilidade na geração, colocando as baterias em um sistema mais severo de carga e descarga, a vida útil das mesmas é afetada, reduzindo-as drasticamente.

Estudos que apontam que baterias de chumbo-ácido possuem 6 fatores de estresse (*fator de carga, quantidade de Ah extraídos, maior taxa de descarga, tempo entre cargas completas, tempo em baixo SoC e ciclagem parcial*) que podem moldar o regime ao qual elas estão empregadas, e são eles, concomitantemente a outro estudo desenvolvido, conhecido como *modelo Schiffer*, que pode prever a vida útil de baterias de chumbo-ácido a partir de diversas equações empíricas, serviram para gerar três conjunto de dados, que foram usados em duas RNA.

Dessa forma, a partir do desenvolvimento com êxito de duas RNA para um caso de microrredes com fontes variáveis de energia, e modificação de diversos parâmetros de operação da microrrede, o presente trabalho mostrou que os fatores de estresse e o modelo *Schiffer* possuem uma relação entre si. Portanto esses fatores de estresse podem ser usados de forma direta para prever a vida útil de baterias de chumbo-ácido, trazendo mais robustez ao processo.

Como trabalhos futuros sugere-se a expansão da RNA, criando um banco de dados maior, com mais variações nas fontes e nas baterias para aumentar a abrangência de casos da rede. E a substituição do modelo de *Schiffer* pela RNA no algoritmo iBASST, diminuindo o tempo de simulação.

8. REFERÊNCIAS BIBLIOGRÁFICAS

BARING-GOULD, I. et al. **Detailed Evaluation of Renewable Energy Power System Operation: A Summary of the European Union Hybrid Power System Component Benchmarking Project**. Preprint. 2005

BLOOMBERGNEF. **New Energy Outlook 2020**. Disponível em: <<https://about.bnef.com/new-energy-outlook/>>. Acesso em: 5 abr. 2021.

BROWNLEE, J. **How many hidden layers and nodes?**. Disponível em: <<https://machinelearningmastery.com/how-to-configure-the-number-of-layers-and-nodes-in-a-neural-network/>>. Acesso em: 26 ago. 2021.

COPETTI, J. B.; CHENLO, F. Lead/acid batteries for photovoltaic applications. Test results and modeling. **Journal of Power Sources**, v. 47, n. 1–2, p. 109–118, 1 jan. 1994.

DANIGELIS, A. **Puerto Rico's \$14 Billion Energy Plan Calls for 'MiniGrids'**. Disponível em: <<https://www.environmentalleader.com/2019/06/puerto-rico-minigrids/>>. Acesso em: 29 ago. 2021.

DINIŞ, C. M.; POPA, G. N.; IAGŢR, A. **Study on sources of charging lead acid batteries**. IOP Conference Series: Materials Science and Engineering. Institute of Physics Publishing, 18 jun. 2015

DUFO-LÓPEZ, R.; LUJANO-ROJAS, J. M.; BERNAL-AGUSTÍN, J. L. Comparison of different lead–acid battery lifetime prediction models for use in simulation of stand-alone photovoltaic systems. **Applied Energy**, v. 115, p. 242–253, 15 fev. 2014.

GOLTSMAN, K. **Introduction to Artificial Neural Networks (ANNs)**. Disponível em: <[https://datascience.foundation/sciencewhitepaper/introduction-to-artificial-neural-networks-\(anns\)](https://datascience.foundation/sciencewhitepaper/introduction-to-artificial-neural-networks-(anns))>. Acesso em: 5 abr. 2021.

GREEN, M. **Community power**. Nature Energy 2016 1:3, v. 1, n. 3, p. 1–4, 29 fev. 2016.

GROSSI, E.; BUSCEMA, M. **Introduction to artificial neural networks**. European Journal of Gastroenterology and Hepatology, v. 19, n. 12, p. 1046–1054, dez. 2007.

HIRSCH, A.; PARAG, Y.; GUERRERO, J. **Microgrids: A review of technologies, key drivers, and outstanding issues**. Renewable and Sustainable Energy Reviews, v. 90, p. 402–411, 1 jul. 2018.

HOFFMANN, R.; VIEIRA, S. **Análise de regressão; uma introdução a econometria**. 3º ed. [s.l.] Hucitec, 1977.

IEC 60050 - International Electrotechnical Vocabulary - Details for IEV number 617-04-22: "Microgrid". **International Electrotechnical Commission**, 2017. Disponível em: <<https://www.electropedia.org/iev/iev.nsf/display?openform&ievref=617-04-22>>. Acesso em: 5 abr. 2021.

JENKINS, D.; FLETCHER, J.; KANE, D. M. **Lifetime prediction and sizing of lead-acid batteries for microgeneration storage applications**. Renewable Power Generation, IET, v. 2, p. 191–200, 2008.

JÚNIOR, W. J. DE A. **Métodos de otimização hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação binária**. [s.l.] Universidade Federal de Minas Gerais, 6 fev. 2018.

KRIEGER, E. M.; CANNARELLA, J.; ARNOLD, C. B. **A comparison of lead-acid and lithium-based battery behavior and capacity fade in off-grid renewable charging applications**. Energy, v. 60, p. 492–500, 1 out. 2013.

LAYADI, T. M. et al. **Lifetime estimation tool of lead-acid batteries for hybrid power sources design**. Simulation Modelling Practice and Theory, v. 54, n. May, p. 36–48, 2015.

LERMAN, P. M. **Fitting Segmented Regression Models by Grid Search**. Applied Statistics, v. 29, n. 1, p. 77, 1980.

LUJANO-ROJAS, J. M. et al. **Operating conditions of lead-acid batteries in the optimization of hybrid energy systems and microgrids**. Applied Energy, v. 179, p. 590–600, 1 out. 2016.

MAY, G. J.; DAVIDSON, A.; MONAHOV, B. **Lead batteries for utility energy storage: A review** *Journal of Energy Storage*. Elsevier Ltd, , 1 fev. 2018.

MICROGRID Training Crash Course. **Tonex**, 2021. Disponível em: <<https://www.tonex.com/microgrid-training-crash-course/>>. Acesso em: 29 ago. 2021.

MICROGRIDS Ramp Up in Latin America but Asia Pacific Remains the Global Leader. **Microgrid Knowledge**, 2019. Disponível em: <<https://microgridknowledge.com/microgrids-navigant/>>. Acesso em: 29 ago. 2021.

NAZIR, N. **Introduction to Artificial Neural Networks**. 2015.

NETO, P. **Contribuições para a Operação Energética e Econômica de Microrredes Isoladas com Fontes Renováveis Diversificadas**. Tese (Doutorado em Engenharia Elétrica), Universidade Federal do Maranhão, São Luis, 2017.

RASHID, T. **Make Your Own Neural Network: A Gentle Journey Through the Mathematics of Neural Networks, and Making Your Own Using the Python Computer Language**. [s.l.] CreateSpace Independent Publishing, 2016.

SCHIFFER, J. et al. **Model prediction for ranking lead-acid batteries according to expected lifetime in renewable energy systems and autonomous power-supply systems**. Journal of Power Sources, v. 168, n. 1 SPEC. ISS., p. 66–78, 25 maio 2007.

SOLIS, F. J.; WETS, R. J.-B. **Minimization by Random Search Techniques**. <https://doi.org/10.1287/moor.6.1.19>, v. 6, n. 1, p. 19–30, 1 fev. 1981.

SOTO, D.; MODI, V. **Simulations of efficiency improvements using measured microgrid data**. Proceedings - 2012 IEEE Global Humanitarian Technology Conference, GHTC 2012. IEE, 2012.

SVOBODA, V. et al. **Operating conditions of batteries in off-grid renewable energy systems**. Solar Energy, v. 81, n. 11, p. 1409–1425, 1 nov. 2007.

TAN, X.; LI, Q.; WANG, H. **Advances and trends of energy storage technology in Microgrid**. International Journal of Electrical Power and Energy Systems, v. 44, n. 1, p. 179–191, 1 jan. 2013.

VRAHATIS, M. et al. **Introduction to artificial neural network training and applications**. 2000

ZHANG, Y. et al. **Life cycle planning of battery energy storage system in off-grid wind-solar-diesel microgrid**. IET Generation, Transmission and Distribution, v. 12, n. 20, p. 4451–4461, 13 nov. 2018.

APÊNDICES

APÊNDICE A – PORÇÕES DOS CONJUNTOS DE DADOS GERADOS USADOS PARA ALIMENTAR AS RNA

Figura 21 - Pequena porção do Conjunto 1.

Fator de Carga (%)	Ah Transferidos (Q/Cn)	Taxa de descarga (I/I10)	Tempo entre Cargas Completas (dias)	Tempo em baixo SoC(%)	Ciclagem parcial (%)	Vida útil esperada (anos)
104,4	48,035	0,26043	1,6451	0	30,581	1,2432
102,94	29,68	0,24682	6,7551	0	46,464	3,191
103,21	42,828	0,25994	1,9301	0	34,413	0,99241
104,12	51,069	0,25957	1,8697	0	30,673	2,2817
102,91	30,748	0,2474	6,5094	0	46,729	3,1336
102,95	70,357	0,26248	3,2027	0	33,504	2,8132
103,86	54,252	0,25916	2,0242	0	30,738	2,8929
102,57	36,637	0,25409	5,8588	0	40,36	0,65159
104,26	47,168	0,25975	1,74	0	31,525	1,2442
103,91	46,621	0,25825	1,895	0	33,365	1,4899
102,95	28,856	0,25028	7,0185	0	46,193	3,6946
102,55	40,879	0,25278	4,9026	0	47,275	2,068
103,19	42,831	0,25886	1,9966	0	35,049	0,98913
102,56	40,662	0,25271	4,9028	0	47,244	2,0678
101,55	33,125	0,24786	4,9201	0	46,337	0,91639
102,64	37,243	0,25138	5,6835	0	47,981	2,5776

Figura 22 - Pequena porção do Conjunto 2.

Fator de Carga (%)	Ah Transferidos (Q/Cn)	Taxa de descarga (I/I10)	Tempo entre Cargas Completas (dias)	Tempo em baixo SoC(%)	Ciclagem parcial (%)	Vida útil esperada (anos)
102,5156	68,60095785	0,25735	4,342595382	0,003724	51,19584	1,437987
102,2321	71,81137579	0,261367	3,715113116	0	38,45108	2,227106
101,6481	32,45037359	0,254476	4,205626417	0	55,08812	0,572905
102,4823	54,31743397	0,259663	1,918542818	0	31,78333	2,012002
99,99704	35,65610888	0,254755	5,247708333	0	57,76081	0,584785
100,2783	88,61455011	0,247796	14,0377938	0,037156	88,59383	1,149614
102,128	50,03750465	0,256857	2,400327932	0	38,91541	1,197097
104,2408	51,62453066	0,260195	2,558894033	0	39,46102	1,1971
100,1766	54,2469707	0,250461	14,22663194	0,007096	80,77491	0,780135
100,8503	47,84750609	0,259516	2,111124552	0,001395	42,48614	0,990348
102,2291	45,14213873	0,257567	2,339891975	0	37,65991	2,041884
102,9887	69,57491566	0,263173	2,632204861	0	33,98595	3,018257
101,8578	81,18655415	0,266612	5,949408015	0	40,8562	1,396969
101,8845	73,13410734	0,262531	2,634306569	0	33,39717	2,851398
102,613	29,78267601	0,25172	13,49421296	0	51,42337	0,608002
100,1631	60,19201068	0,255589	14,23791667	0,016347	77,45889	0,780529

Figura 23 - Pequena porção do Conjunto 3.

Fator de Carga (%)	Ah Transferidos (Q/Cn)	Taxa de descarga (I/I10)	Tempo entre Cargas Completas (dias)	Tempo em baixo SoC(%)	Ciclagem parcial (%)	Vida útil esperada (anos)
102,1029	67,62797841	0,257255	4,007029321	0,006368	47,29576	1,458623
100,9497	64,52546554	0,255216	4,682314214	0	48,62822	1,416455
100,1777	79,18738424	0,264124	10,1011767	0,00025	56,10374	1,230833
100,4265	80,65450533	0,251396	13,51306584	0	69,52283	1,218874
100,5249	74,17434098	0,260192	5,229518921	0,003598	55,40384	1,529256
102,2904	67,96636648	0,257457	3,809634503	0	40,03218	1,470645
101,0905	45,41978698	0,257087	9,057271242	0,001887	54,05113	0,583016
102,1294	78,54097172	0,265408	3,920070954	0	37,87438	2,601859
100,2903	70,77943248	0,257052	10,68925654	0	69,82705	1,024306
103,44	52,07858473	0,2586	2,085416667	0	34,41636	1,399878
99,96307	56,20998709	0,262693	11,37101449	0	66,42643	0,720177
102,5001	53,04077534	0,258671	2,118038618	6,05E-05	34,13294	1,863368
101,5803	72,17549231	0,2639	4,648958333	0	36,30587	2,311813
101,4914	47,64838193	0,256951	2,499131944	0	38,45684	0,916914
101,6403	36,33486149	0,250881	4,915781963	0	48,67856	1,088693
103,4493	54,78565632	0,258841	2,973352166	0	36,53851	1,539728

APÊNDICE B – FLUXOGRAMAS DE ROTINA DE TREINO E TESTE PARA RNA 1 E RNA 2

Figura 24 - Fluxograma de rotina de treino e teste da RNA 1.

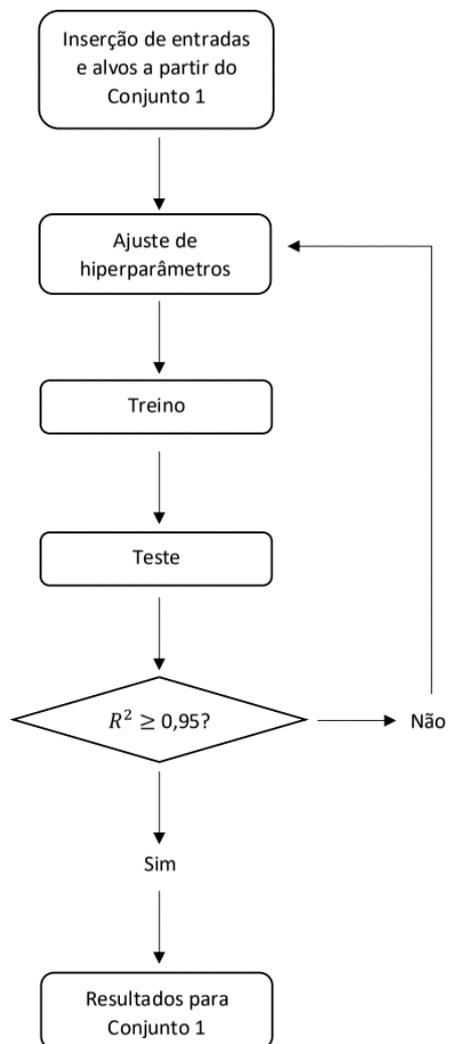
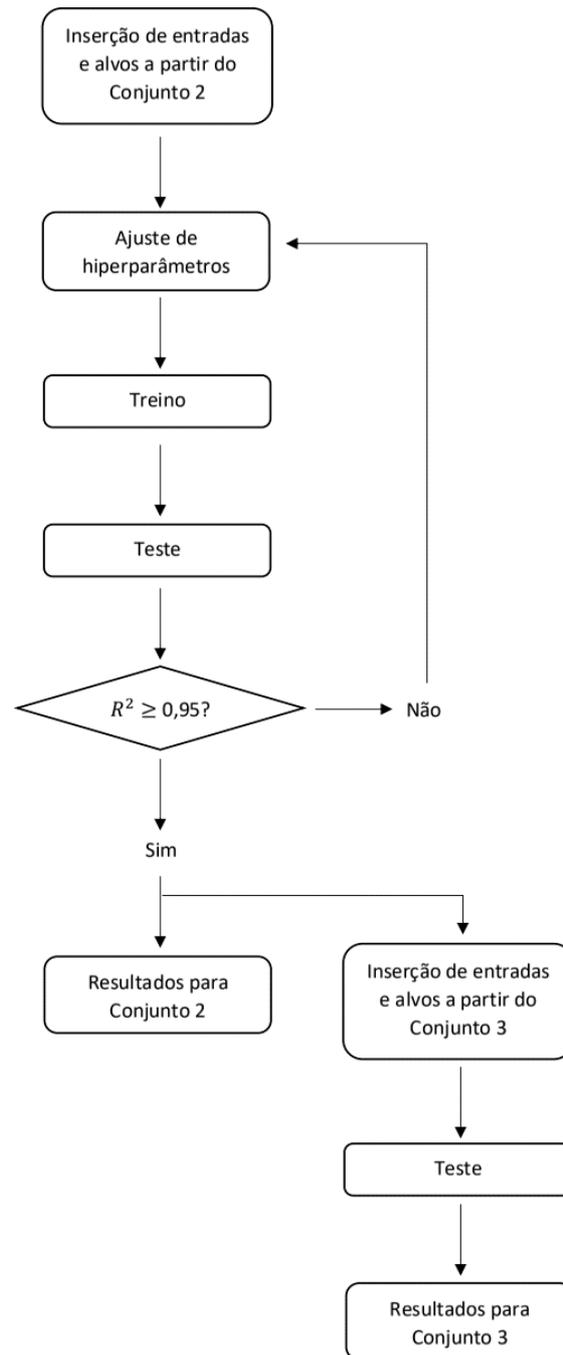


Figura 25 - Fluxograma de rotina de treino e teste da RNA 2.



ANEXOS

ANEXO A – ESTRUTURA DOS DADOS DE ENTRADA E SAÍDA DO IBASST

Figura 26 - Estrutura de entrada dos parâmetros de armazenamento.

Sistema de Armazenamento			
Quantidade de Bancos de Armazenamento	Somente Banco 2	Temperatura Ambiente Média nos Bancos de Baterias	30,00
Banco 1 (Primário)		Banco 2 (Secundário)	
Capacidade Nominal (Ah)	1200	Capacidade Nominal (Ah)	1200
Eficiência do controlador de Carga	0,96	Eficiência do controlador de Carga	0,96
Tensão nominal das baterias (V)*	2	Tensão nominal das baterias (V)*	2
Número de baterias em série por string	45	Número de baterias em série por string	60
Número de strings	2	Número de strings	2
SOC inicial das baterias (min= 0; max=1)	1	SOC inicial das baterias (min= 0; max=1)	1
SOC mínimo do banco	0,5	SOC mínimo do banco	0,5
SOC em que o banco é considerado cheio (G.G.)	0,5000	SOC em que o banco é considerado cheio (G.G.)	0,4
SOC em que o banco é considerado cheio (RENE)	0,9999	SOC em que o banco é considerado cheio (RENE)	0,9999
Curva de carregamento do banco (curva Cx)	10	Curva de carregamento do banco (curva Cx)	10
Eficiência de carregamento das baterias*	1	Eficiência de carregamento das baterias*	1
Eficiência de descarregamento das baterias*	1	Eficiência de descarregamento das baterias*	1
Ciclos IEC	700	Ciclos IEC	700
Restrição de Carga/Descarga Cíclica	No	Permitir uso de Banco 2 durante noite	Yes
Financeiro		Financeiro	
Capital (\$)	188.878,88	Capital (\$)	251.838,50
Custo Substituição (\$)	188.878,88	Custo Substituição (\$)	251.838,50
Custo O&M (\$)	1	Custo O&M (\$)	1

Figura 27 - Estrutura de entrada dos parâmetros de simulação.

Parâmetros de Simulação	
Resolução da Simulação	1 minuto
Hora do dia a partir da qual o banco principal deixará de ser utilizado	0
Hora do dia a partir da qual que o banco principal poderá ser utilizado	0
Número de anos que a simulação deve ser realizada sequencialmente	25
Método de Schiffer	
Método de estimativa de vida útil das baterias	Yes
Dimensionamento aleatório das fontes?	Yes
Período para Equalização das Baterias	
Número de dias para carga de equalização das baterias	7
Hora do dia para início da carga de equalização das baterias	16
Financeiro	
Vida Útil do Sistema - anos	31
Taxa de atratividade (%)	13

Figura 28 - Estrutura de entrada para o dimensionamento aleatório das fontes.

Valores Máximos para Dimensionamento Aleatório		
Fotovoltaico (KW)	Eólico (# Turbinas)	Maremotriz (# Turbinas)
40	2	1
Valor Da Energia Gerada Pelas Fontes Renováveis (kWh/ano):		
46544,19		

Figura 29 - Estrutura de saída do sistema de armazenamento após simulação.

***** SISTEMAS DE ARMAZENAMENTO *****

ans =

	Banco1	Banco2
Energia Recebida (kWh)	NaN	24597.04
Energia Fornecida (kWh)	NaN	22339.89
Depleção de Energia (kWh)	NaN	119.86
Perdas Internas (kWh)	NaN	2137.28
Tempo Médio Entre Cargas Completas (dias)	NaN	3.82
Fator de Carga (%)	NaN	102.71
Taxa de Descarga (I/I10)	NaN	0.27
Ah Transferidos (Q/Cn)	NaN	74.80
Tempo em Baixo SOC (%)	NaN	0.00
Ciclagem Parcial (%)	NaN	34.86
Vida Útil Esperada (a)	NaN	2.43

ANEXO B – ESPECIFICAÇÕES TÉCNICAS DO COMPUTADOR PESSOAL

Figura 30 - Especificações técnicas do PC usado no trabalho.

Modelo	Aspire 315-42G
Processador	AMD Ryzen 5 3500U com Radeon Vega Mobile Gfx 2.10 GHz
RAM instalada	8,00 GB (utilizável: 5,94 GB)
Tipo de sistema	Sistema operacional de 64 bits, processador baseado em x64
Sistema Operacional	Windows 10 Home Single Language
Versão	20H2