

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Camilo Alberto Sepúlveda Rangel

**SELEÇÃO ÓTIMA DE BATERIAS ARMAZENADORAS DE ENERGIA EM
REDES DE DISTRIBUIÇÃO COM GERAÇÃO DISTRIBUÍDA
CONSIDERANDO MODELAGEM DA OPERAÇÃO POR REDES
NEURAS**

Santa Maria, RS

2019

Camilo Alberto Sepúlveda Rangel

**SELEÇÃO ÓTIMA DE BATERIAS ARMAZENADORAS DE ENERGIA EM REDES
DE DISTRIBUIÇÃO COM GERAÇÃO DISTRIBUÍDA CONSIDERANDO
MODELAGEM DA OPERAÇÃO POR REDES NEURAIS**

Tese do doutorado apresentado ao Programa de Pós-Graduação em Engenharia Elétrica, da Universidade Federal de Santa Maria (UFSM RS), como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica.

Orientadora: Prof^a Dr^a. Luciane Neves Canha

Santa Maria, RS

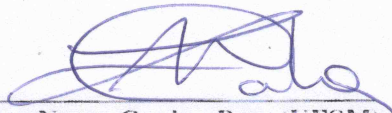
2019

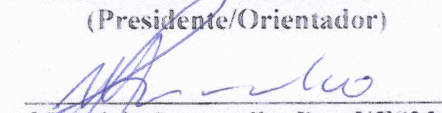
Camilo Alberto Sepúlveda Rangel

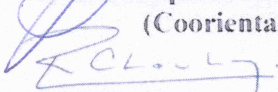
SELEÇÃO ÓTIMA DE BATERIAS ARMAZENADORAS DE ENERGIA EM REDES
DE DISTRIBUIÇÃO COM GERAÇÃO DISTRIBUÍDA CONSIDERANDO
MODELAGEM DA OPERAÇÃO POR REDES NEURAIS

Tese do doutorado apresentado ao Programa de Pós-Graduação em Engenharia Elétrica, da Universidade Federal de Santa Maria (UFSM RS), como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica.

Aprovado em 27 de maio de 2019

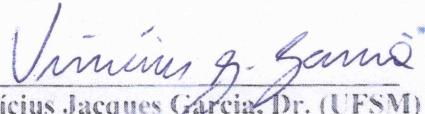

Luciane Neves Canha, Dra. (UFSM)
(Presidente/Orientador)


Maurício Sperandio, Dr. (UFSM)
(Coorientador)


Roberto Chouhy Leborgne, Dr. (UFRGS)*
(*Participação por Videoconferência)


Vladimiro Miranda, Dr. (INESC TEC)*
(*Participação por Videoconferência)


Alzenira da Rosa Abaide, Dra. (UFSM)


Vinicius Jacques Garcia, Dr. (UFSM)

Santa Maria, RS
2019

DEDICATÓRIA

Dedico este trabalho aos meus pais Jose Alberto Sepulveda Mora e Ana Cristina Rangel Alvarez e a minha amada Fernanda Ismailof, em especial, pela dedicação e apoio em todos os momentos difíceis. Eles são minha motivação para seguir adiante.

AGRADECIMENTOS

Ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, pela oportunidade de realização de trabalhos em minha área de pesquisa.

A minha orientadora Luciane Canha e ao professor Mauricio Sperandio, pela formação, motivação na pesquisa e apoio.

Aos colegas do PPGEE pelo seu auxílio nas tarefas desenvolvidas durante o curso e apoio na revisão deste trabalho.

Ao INESC TEC e seus colaboradores pelo tempo de formação durante meu estágio, especialmente ao professor Vladimiro Miranda pelas orientações.

Agradeço também a todos os membros da minha família e a meus amigos Gustavo Rosero, Mario Castañeda, Alex Prado, Esteban Ramirez, Felipe Ortiz, Faisson Teixeira, Daniela Paini, Railson Severiano, Rochele Albuquerque, Piedy Arias e meus colegas do CEESP, pela parceria oferecida, apoio e momentos compartilhados.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES/PROEX) – Código de Financiamento 001.

RESUMO

SELEÇÃO ÓTIMA DE BATERIAS ARMAZENADORAS DE ENERGIA EM REDES DE DISTRIBUIÇÃO COM GERAÇÃO DISTRIBUÍDA CONSIDERANDO MODELAGEM DA OPERAÇÃO POR REDES NEURAIS

AUTOR: Camilo Alberto Sepúlveda Rangel

ORIENTADORA: Luciane Neves Canha

Esta tese apresenta uma metodologia para a determinação ótima do tipo, barra e capacidade dos sistemas de armazenamento de energia por baterias (*Battery Energy Storage Systems*, BESS) em sistemas de distribuição com geração distribuída (GD). Os resultados da operação ótima da bateria são aproximados por meio de uma relação entrada/saída, formada por redes neurais. A seleção do armazenador é dada por um algoritmo genético, cuja função de aptidão é determinada pelo custo anual de operação do sistema de distribuição, limites de tensão e os custos associados às baterias. O modelo permite comparar diferentes tipos de baterias, observando suas características técnicas e econômicas. O tempo de vida das baterias é determinado baseado no impacto da profundidade de descarga (*Depth of Discharge*, DOD) dentro do ciclo de falha. A base de dados da rede neural é obtida por meio de uma simulação de Monte Carlo da operação ótima diária da bateria para uma amostra representativa de dados reais durante um ano. Com esta abordagem, é possível considerar o comportamento estocástico da geração distribuída, da carga e dos preços da energia. A operação diária da bateria é otimizada empregando um modelo de otimização não linear baseado num fluxo de carga determinado pelo programa OpenDSS da *Electric Power System Research Institute* (EPRI). A rede neural foi desenvolvida com a abordagem do *Group Method of Data Handling* (GDMH). A implementação do modelo entrada/saída permite reduzir o tempo de simulação onde as possíveis alternativas de seleção da bateria são determinadas por meio do algoritmo genético. Esta metodologia é testada num sistema de distribuição teste de 33 barras e as curvas de geração, demanda e preços são tomados de dados reais do *Indepent Electricity System Operator* (IESO) pertencente ao sistema de distribuição canadense, usando como fontes renováveis de geração de energia solar e eólica. O estudo de caso mostra uma boa aproximação da rede neural com os dados obtidos pelo fluxo de carga diário e permite identificar os casos críticos no sistema, como barras não recomendáveis e probabilidades de riscos nos resultados. Os resultados obtidos comparam o uso de baterias na rede de distribuição, diminuindo os custos totais e das perdas para cada dia, permitindo selecionar o melhor tipo. Além disto, os armazenadores conseguem reduzir o custo final de energia do sistema (sujeito a penalidades propostas) e as perdas, sendo possível determinar a melhor alternativa.

Palavras-chave: Sistemas de Baterias de Armazenamento de Energia. Sistemas de Distribuição. Geração Distribuída. Redes Neurais. Simulação de Monte Carlo. Perdas de Energia. Custos de Energia.

ABSTRACT

OPTIMAL SELECTION OF ENERGY STORAGE SYSTEM IN DISTRIBUTION NETWORKS WITH DISTRIBUTED GENERATION CONSIDERING OPERATION MODEL BY NEURAL NETWORKS

AUTHOR: Camilo Alberto Sepúlveda Rangel

ADVISOR: Luciane Neves Canha

This thesis presents a methodology for optimal determination of type, bar, and capacity of Battery Energy Storage Systems (BESS) in distribution systems with distributed generation (DG) where the battery optimal operation is approximated by an input/output model created with neural networks. A genetic algorithm selects the storage by a fitness function defined with the annual operation costs of the distribution system, the voltage limits, and batteries costs. The model allows to compare different types of batteries technologies, considering its technical and economical characteristics. Lifetime of the battery is based on the depth of discharge (DOD) impact to the life cycle. The database for the input/output model is obtained by a Monte Carlo simulation of the optimal daily operation of the battery for a representative sample from a yearly real data. This approach allows to consider the stochastic behavior of the distributed generation, the load and the energy prices. The daily operation of the battery is optimized by a nonlinear optimization model, considering a load flow by OpenDSS proprietary software from the Electric Power System Research Institute (EPRI). The neural network was based on the Group Method of Data Handling (GMDH). The neural network implementation allows to reduce the yearly simulation time, where the possible selection alternatives are chosen by the genetic algorithm. This methodology is tested in a distribution system of 33 nodes, and the generation, demand, and prices curves are taken from data of the Independent Electricity System Operator IESO relative to the Canadian distribution system, considering solar and wind as renewable sources. The studied case shows a good approximation of the neural network with the obtained data for the daily load flow and allows to identify the critic cases of the systems, as bar location not allowed and probability of risk of the results. The results compare the use of the batteries in the distribution network, reducing losses and operational costs along the day in the system and selecting the best type. Also, the storage systems can reduce the final energy cost of the system (limited by the proposed constraints) and the losses, with the possibility to determine the best alternative.

Keywords: Battery Energy Storage Systems. Distribution Systems. Distributed Generation. Neural Networks, Monte Carlo Simulation, Energy Losses. Energy Cost.

LISTA DE ILUSTRAÇÕES

Figura 1 - Diagrama de uma BESS.	29
Figura 2 - Diagrama de Uma Bateria de Fluxo Redox de Vanádio.....	34
Figura 3 – Representação do método proposto.	39
Figura 4 - Simulação de Monte Carlo.	40
Figura 5 - Conceito do Armazenador no OpenDSS.	44
Figura 6 - Exemplo de curva de operação do armazenador no OpenDSS.	45
Figura 7 - Representação do grupo de soluções.	46
Figura 8 - Obtenção da descendência de dois indivíduos aptos.	47
Figura 9 - Mutação.....	47
Figura 10 - Curva de Ciclo de Vida da Bateria de NaS.....	49
Figura 11-Curva de Ciclo de Vida da Bateria de Lítio.....	50
Figura 12-Curva de Ciclo de Vida da Bateria de Chumbo-Ácido.....	50
Figura 13-Curva de Ciclo de Vida da Bateria VRFB.....	51
Figura 14 - Determinação da resposta pelo AG.	51
Figura 15 – Desenvolvimento da rede neural.....	52
Figura 16 - Modelo do Neurônio.....	53
Figura 17 - Formação da primeira camada para a rede de 4 entradas.	54
Figura 18 - Formação da segunda camada para a rede de 4 entradas.....	55
Figura 19 - Escolha da melhor saída na rede de 4 entradas.....	56
Figura 20- Formação da rede neural com 4 entradas.....	56
Figura 21 - Relação das variáveis de entrada e de saída.	57
Figura 22 - Características associadas as entradas, para criação da rede neural.	58
Figura 23 -Sistema Teste.....	60
Figura 24 - Determinação do tamanho da população.....	61
Figura 25 - Histograma de capacidades de entrada.	61
Figura 26 - Histograma de Barras de entrada (Armazenador).....	62
Figura 27 - Histograma de Tipos (Armazenador).	62
Figura 28 - Histograma do SOC inicial.....	63
Figura 29 - Histograma da referência do dia de entrada.....	64
Figura 27 - Preços no dia 1.....	64
Figura 31 - Comparação de custos.	65

Figura 32 - SOC da Bateria.	65
Figura 33 - Injeção da bateria.	66
Figura 34 - Preços reduzidos ao fim do dia.	66
Figura 35 - SOC da bateria para os preços reduzidos ao final do dia.....	67
Figura 36 - Preços para os primeiros 5 dias.....	67
Figura 37 - Custos de operação para os primeiros 5 dias.	68
Figura 38- Custos de operação para a primeira semana.	68
Figura 39 - Custos das perdas dos primeiros 5 dias.	69
Figura 40 - Custos das perdas dos primeiros 5 dias.....	69
Figura 41 - Histograma SOC ao final do dia.	70
Figura 42 - Histograma tensão máxima.....	71
Figura 43 - Histograma tensão mínima.	71
Figura 44 - Histograma das barras de alocação da bateria associadas a tensão.	72
Figura 45 - Histograma das barras no caso sem bateria.	72
Figura 46 - Comparação custos totais ESS VS Caso sem Bateria.....	73
Figura 47 - Comparação custos das perdas ESS VS Caso sem Bateria.	73
Figura 48 - Correlação de dados com a rede neural. Custos totais.	74
Figura 49 - Aproximação dos resultados. Custos totais.....	75
Figura 45 - Correlação de dados com a rede neural. Custos das perdas.	82
Figura 46 - Aproximação dos resultados. Custos das perdas.....	82
Figura 47 - Correlação de dados com a rede neural. Tensão mínima.	83
Figura 48 - Aproximação dos resultados. Tensão mínima.	84
Figura 49 - Correlação de dados com a rede neural. Tensão máxima.	84
Figura 50 - Aproximação dos resultados. Tensão mínima.	85
Figura 51 - Correlação de dados com a rede neural. Desgaste da Bateria.....	85
Figura 52 - Aproximação dos resultados. Desgaste da Bateria.	86

LISTA DE TABELAS

Tabela 1 - Características de cada tipo de bateria.	63
Tabela 2 - Comparação das respostas.....	70
Tabela 3 – Resultados do Algoritmo Genético.....	76
Tabela 4 – Comparação das respostas. Caso 1.	77
Tabela 5 – Comparação das respostas. Caso 2.	77
Tabela 6 – Comparação das respostas. Caso 3.	77
Tabela 7 – Comparação das respostas. Caso 4.	77

SUMÁRIO

1. INTRODUÇÃO	14
1.1 MOTIVAÇÃO.....	15
1.2 JUSTIFICATIVA	16
1.3 OBJETIVOS DO TRABALHO	17
1.3.1 Objetivo Geral.....	17
1.3.2 Objetivos Específicos.....	17
1.4 CONTRIBUÇÕES INOVADORAS	18
1.5 ORGANIZAÇÃO DOS CAPÍTULOS	18
2 REVISÃO DE LITERATURA.....	20
2.1 ABORDAGEM ECONÔMICA	20
2.2 ABORDAGEM TÉCNICA	21
2.3 ABORDAGEM TÉCNICO-ECONÔMICA	24
2.3 RESUMO DO CAPÍTULO	27
3. SISTEMAS DE ARMAZENAMENTO POR BATERIAS (BESS).....	29
3.1 BATERIAS DE CHUMBO-ÁCIDO.....	30
3.2 BATERIAS DE LÍTIO-ÍON	31
3.3 BATERIAS DE SULFETO DE SÓDIO	32
3.4 BATERIAS DE NÍQUEL-CÁDMIO (NICD)	32
3.5 BATERIAS EM DESENVOLVIMENTO	33
3.6 BATERIAS DE FLUXO	34
3.7 BATERIAS DE FLUXO DE VANÁDIO	35
3.8 BATERIAS DE FLUXO DE BROMETO DE ZINCO	36
3.9 BATERIAS DE FLUXO DE BROMETO DE POLISSULFETO	36
3.10 RESUMO DO CAPÍTULO	37
4. METODOLOGIA PROPOSTA.....	38
4.1 SIMULACAO DE MONTE CARLO	40
4.2 DETERMINAÇÃO DA OPERAÇÃO ÓTIMA DO ARMAZENADOR.....	42
4.2.1 Conceitos para Parametrizar a Bateria no OpenDSS.....	44
4.3 ALGORITMO GENÉTICO	46
4.4 DENVOLVIMENTO DA REDE NEURAL.....	52
4.5 RESUMO DO CAPÍTULO	58

5.	ESTUDO DO CASO.....	60
5.1	RESUMO DO CAPÍTULO	78
6.	CONCLUSÕES.....	80
6.1	ESTUDOS FUTUROS	80
6.2	PRODUÇÃO CIENTÍFICA	81
7	REFERÊNCIAS.....	87

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
BESS	Battery Energy Storage Systems
DOD	Depth of Discharge
EPRI	Electrical Power System Research Institute
GD	Geração Distribuída
GMDH	Group Method of Data Handling
IESO	Independent Electricity System Operator
PSB	Polysulfide Bromine Flow Battery
SEUMRE	Space Exploration and Region Elimination,
VRFB	Vanadium Redox-Flow Batteries

LISTA DE VARIÁVEIS

C^{DOP}	Custos das perdas e da operação diários
C_{loss_i}	Custos das perdas na hora i
C_{DN_i}	Custo da energia na hora i
P_i^{Loss}	Perdas de potência na hora i
P_i^{DN}	Potência na subestação na hora i
C_{DN24}	Custo de oportunidade por uso da bateria
E_{24}^{BESS}	Energia armazenada ao fim do dia
P_i^L	Potência da carga na hora i
P_i^{DG}	Potência injetada pela geração distribuída
P_i^{Loss}	Perdas de potência no sistema
P_i^{BESS}	Potência absorvida/injetada do armazenador
SOC_i^{ESS}	SOC da bateria na hora i
E_i^{BESS}	Energia armazenada durante a hora i
CE^{BESS}	Capacidade de armazenamento de energia máxima da bateria
$\eta_{d,c}$	Eficiência de carga/descarga
CP^{BESS}	Máxima capacidade de potência da bateria
T^{BESS}	Duração máxima da descarga da bateria em horas
$\hat{E}(F)$	Valor esperado
$F(x)$	Função de teste
x_i	Estado do sistema
N	Número de cenários
$\hat{V}(F)$	Variância amostral
β	Coefficiente de variação
Fit	Função de aptidão
C_0^{YOP}	Valor presente do custo de operação anual
C_0^{BESS}	Valor presente do custo do custo associado ao uso da bateria
C^{YOP}	Custo de operação anual
$C_j^{DOP^*}$	Aproximação da rede neural ao custo de operação diário
C_0^{AOM}	Valor presente do custo de operação e manutenção do armazenador
C^{INV}	Custo inicial de inversão do armazenador
C_0^{Re}	Valor presente do custo de mudança da tecnologia
C_{re}	Valor inicial do custo de mudança
Ds	Taxa de desconto
NRE	Número de mudanças
T	Período de estudo
Lf	Vida útil do armazenador em anos
Des	Desgaste da bateria
LC	Número de ciclos de falha
a_n	Coefficientes de ajuste do ciclo de bateria
$FDOD$	Profundidade de descarga parcial do armazenador
C^{AOM}	Custo de operação e manutenção anual

1. INTRODUÇÃO

Dentro do contexto do setor elétrico, tem-se observado um crescimento das redes elétricas inteligentes em virtude das pesquisas e projetos desenvolvidos a nível mundial. Estas redes inteligentes são caracterizadas por uma integração de tecnologias de medição e controle para gerenciamento da energia que é ofertada e demandada. Nesta concepção, a participação do consumidor como um agente gerador é considerada na Geração Distribuída (GD) fortemente promovida no uso de fontes de tipo renováveis como a solar e a eólica. Com a GD, o consumidor fornece energia para atender sua demanda e pode oferecer o excedente para a rede.

O uso de fontes renováveis na rede inteligente, favorece a redução de gases de efeito estufa. No entanto, estas tecnologias são caracterizadas por um comportamento variável. São comuns os casos onde a energia fornecida pela GD ou é maior que a demanda ou é insuficiente para atender a mesma. Tais variações podem refletir na confiabilidade da rede de distribuição que cada vez mais poderá ser dependente destes tipos de recursos para sua geração. Além disto, a presença da GD na rede inteligente traz consigo fluxos reversos. Os fluxos reversos podem aumentar as perdas de energia do sistema, quando a geração excede a carga, tendo um sistema menos eficiente em termo de custos. Assim, o crescente aumento de geração distribuída no sistema de distribuição no mundo faz da geração intermitente um problema que precisa ser solucionado pelo gerenciamento da energia no sistema com o uso de elementos de suporte. Somente com geração distribuída é difícil manter a energia do sistema de acordo com a demanda desejada.

Por estes motivos a implementação de mecanismos de suporte como os armazenadores de energia (*Energy Storage Systems*, ESS), permitem uma melhor confiabilidade e qualidade da energia com redução das perdas do sistema. Também, possibilitam ações de resposta à demanda e de gerenciamento da energia. No entanto, para lograr estes objetivos é fundamental o gerenciamento adequado dos armazenadores para reduzir o impacto nas perdas e na qualidade da tensão do sistema. Procura-se o carregamento dos armazenadores nos momentos em que existe uma alta produção pela GD e uma baixa demanda. A descarga do armazenador é importante quando a GD é insuficiente para atender à demanda.

Um planejamento adequado do uso dos armazenadores considera tanto os custos da tecnologia como o impacto no sistema. Os custos da tecnologia consideram tempo de vida, custo de investimento e custos de manutenção. A finalidade é que os benefícios econômicos

pelo uso da bateria na rede compensem os custos próprios da tecnologia para garantir sua viabilidade.

1.1 MOTIVAÇÃO

Existem diferentes formas de armazenar energia, dependendo das aplicações no sistema elétrico. Os armazenadores de energia, por enquanto, apresentam custos elevados sobretudo para aplicações nos sistemas de distribuição. Porém, o potencial deste tipo de tecnologia já tem mostrado avanços com projetos nos Estados Unidos, Alemanha, Japão, Reino Unido e Austrália (LUO et al., 2015).

Dentro dos tipos de armazenadores, os sistemas de armazenamento por baterias (*Battery Energy Storage Systems*, BESS) possuem capacidades de armazenamento e descarga por períodos longos de tempo, assim como rápida resposta para a operação (LUO et al., 2015). Estes motivos dão preferência às BESS para a operação na rede de distribuição. Além disto, o custo das baterias tem se reduzido com o passar dos anos (IRENA, 2017). Para garantir a viabilidade econômica das baterias, é importante contar com ferramentas de decisão que permitam a integração destas tecnologias no sistema de distribuição. A integração deve considerar tanto aspectos técnicos como econômicos.

Dada a diversidade de tecnologias de construção das baterias, é fundamental comparar e selecionar a melhor alternativa para ser instalada no sistema de distribuição. Fatores como custos fixos e variáveis dos armazenadores, tempo de vida e desempenho no sistema são determinantes na seleção do tipo de bateria mais adequado. Como a instalação do armazenador é planejada em longo prazo é importante verificar a barra de alocação que garante o melhor desempenho durante o tempo de uso. Além disso deve-se prever o gerenciamento do armazenador, indicando o melhor benefício econômico no sistema. Neste caso, a operação do armazenador está sujeita ao custo de oportunidade da venda da energia reservada ao fim do dia.

Uma abordagem probabilística dos dados permite determinar casos críticos e riscos associado ao uso do armazenador, dando um maior suporte à tomada de decisão. Este tratamento dos dados, ao ser modelado por redes neurais, permite acelerar os processos de seleção ótima da resposta. A rede neural garante uma aproximação considerável dos resultados esperados.

Considerando os fatos anteriores, a motivação desta tese se dá na determinação de um método para seleção de armazenadores de energia em sistemas de distribuição com geração distribuída considerando aproximação da operação por redes neurais.

1.2 JUSTIFICATIVA

Esta tese se justifica dada a necessidade de contar com um método que permita selecionar o tipo adequado de bateria a ser empregado em suportes a sistemas de distribuição com geração distribuída. O Método determina a melhor barra para ser alocada no sistema e a estratégia de gerenciamento da energia de modo que seja garantida a redução dos custos, e impacto das perdas durante seu tempo de vida. Assim se garante a viabilidade técnica e econômica dos armazenadores de energia. O método foca na criação de uma base de dados para determinar casos críticos na seleção da bateria durante sua operação diária e a estimativa destes resultados por meio de redes neurais para aceleração da determinação da solução ótima.

Já existem modelos que abordam o assunto dos armazenadores de energia, porém, eles não incluem todas as características propostas. Pode ter casos de trabalhos que abordam o gerenciamento da energia por parte do armazenador, entretanto não avaliam os diferentes tipos possíveis (CAO et al., 2016; CARPINELLI et al., 2013, 2016; CHAKRABORTY et al., 2016; MOEINI et al., 2016; QIN et al., 2016; XIAO et al., 2016). Têm estudos que avaliam diferentes armazenadores, mas não determinam casos críticos (CAO et al., 2016; ELNOZAHY et al., 2015; WILSON et al., 2016). A maioria dos trabalhos não consideram fatores determinantes como a influência da profundidade de descarga dentro do ciclo de vida das baterias (ATWA et al., 2010; ELNOZAHY et al., 2015; WILSON et al., 2016). A influência da profundidade de descarga dentro do ciclo de vida do armazenador é determinada no modelo de Xiao et al. (2016), porém apenas é focado nas baterias de lítio-íon sem comparar diferentes tecnologias. Podem-se ter casos onde o armazenador é gerenciado, mas sua alocação no sistema é predeterminada, assim não sendo avaliada (CARPINELLI et al., 2016; CHAKRABORTY et al., 2016; VERGARA et al., 2017). Em comparação, este trabalho permite determinar a barra e a capacidade por tecnologia. Alguns trabalhos estudam incentivos econômicos que não abordam características técnicas do sistema como nível de tensão ou impacto dos fluxos reversos (CHEN et al., 2016; GHOLIAN et al., 2016; KHANI et al., 2017; MOHSENIAN et al., 2010; SOROUDI et al., 2016).

A metodologia proposta contribui em projetos com baterias analisando em conjunto os seguintes aspectos: seleção do tipo de armazenador (determinando também sua alocação), operação do armazenador (avaliando o impacto das perdas, níveis de tensão e carregamento) avaliação de custos em sistemas de distribuição com baterias (considerando influência do desgaste e custos de oportunidade), avaliação de riscos (análise probabilística da base de dados). A vantagem da proposta é a facilidade para adequação a diferentes tipos de armazenadores por contar com uma metodologia heurística baseada em algoritmo genético e a aceleração da tomada decisão pelo uso da base de dados representativa da operação e da relação entrada/saída. Assim, caso seja interessante adicionar mais características no sistema ou comparar mais tipos além dos tratados no trabalho, é possível orientar o modelo para tratar estes assuntos.

1.3 OBJETIVOS DO TRABALHO

1.3.1 Objetivo Geral

Este trabalho propõe implementar uma metodologia para determinar o tipo, capacidade e alocação na rede dos armazenadores de energia visando redução de custos e perdas em sistemas de distribuição com geração distribuída, considerando o desgaste pelo uso de baterias. O desgaste está associado à profundidade de descarga da bateria e permite determinar seu tempo de vida.

1.3.2 Objetivos específicos

Os objetivos específicos desta proposta de tese são:

- Contar com uma ferramenta para comparar diferentes tipos de baterias considerando seu impacto técnico no regime permanente, seus custos associados e seu desgaste operativo.
- Gerenciamento do sistema de armazenamento para redução de perdas, determinando o desgaste e impacto nas perdas e níveis de tensão.
- Analisar as perdas e níveis de tensão presentes em sistemas de distribuição com armazenadores de energia, determinando fatores e riscos associados a prejuízo econômico e problemas na tensão.

- Desenvolver um modelo para aproximar a operação diária ótima da bateria a uma relação entrada-saída de modo que seja possível acelerar o processo de seleção ótima.

1.4 CONTRIBUÇÕES INOVADORAS

Com a metodologia proposta, este trabalho apresenta um modelo que considera em conjunto os seguintes aspectos inovadores:

- Determinação do tipo de armazenador baseado na curva de operação, ciclo de vida e tipos diversos de carregamento ao longo da vida útil.
- Gerenciamento do sistema de armazenamento considerando a influência do comportamento variável da geração solar e/ou eólica e dos preços.
- Uso de uma base de dados para determinação de casos críticos e riscos associados a alternativas de seleção de armazenadores de energia.
- Uso de uma rede neural para aproximação da operação diária do armazenador e seu impacto nos custos, perdas, níveis de tensão e ciclo de vida.
- Aplicação de um método heurístico para seleção, dimensionamento e alocação de armazenadores de energia acelerado pelo uso de uma relação entrada-saída.

1.5 ORGANIZAÇÃO DOS CAPÍTULOS

Este trabalho está dividido da seguinte forma:

Capítulo 2: Apresenta uma revisão bibliográfica sobre o tema do trabalho. A revisão bibliográfica considera as abordagens econômicas, técnicas e técnico-econômicas que se empregam na análise do uso de armazenadores em sistemas de energia.

Capítulo 3: Apresenta uma descrição das baterias determinando suas características principais, vantagens e desvantagens. A descrição considera as baterias tradicionais, as baterias de fluxo, e as baterias em desenvolvimento.

Capítulo 4: Faz uma descrição da metodologia proposta. A metodologia proposta se classifica em 4 processos. O primeiro processo está focado na criação de uma base de dados representativa das opções de seleção da bateria, utilizando uma simulação de Monte Carlo. O segundo processo, o qual está inserido dentro da simulação de Monte Carlo, determina a operação ótima da bateria para cada dia usando um modelo de otimização não linear. O terceiro

processo, determina a solução da resposta baseada num algoritmo genético. Finalmente o quarto processo, o qual está inserido dentro do algoritmo genético, determina a operação da bateria para cada dia usando uma rede neural. A rede neural aproxima os resultados da operação ótima do armazenador com relação ao modelo de otimização não linear (segundo processo).

Capítulo 5: Mostra o estudo do caso com os resultados obtidos no sistema teste. Neste estudo de caso, se determinam as opções de seleção da bateria que podem apresentar problemas em termos de prejuízo econômico e tensões foras dos limites. É calculada uma probabilidade de ocorrência dos casos menos desejáveis. Após a análise de casos críticos, é feita uma análise do desempenho da bateria, em termos de custos e benefícios obtidos na operação diária. Posteriormente, é avaliado o algoritmo genético na seleção do melhor projeto com baterias. Finalmente, são comparados dados obtidos pela rede neural com os obtidos pelo modelo de otimização não linear, considerando a melhor resposta.

Capítulo 6: Mostra as conclusões do trabalho, possíveis futuros estudos e a produção científica do autor durante o desenvolvimento da tese.

2 REVISÃO DE LITERATURA

O estudo de armazenadores de energia em sistemas de distribuição tem-se orientado de diversas formas. Estas abordagens podem ser de tipo econômico, técnico e técnico-econômico. As abordagens econômicas procuram que a inclusão dos armazenadores de energia na rede seja viável economicamente. As abordagens de tipo técnico observam o impacto do uso dos armazenadores na confiabilidade, nível de tensão e perdas de energia no sistema de distribuição. Finalmente, as abordagens técnico-econômicas, consideram tanto os custos como o impacto do uso dos armazenadores de energia. Estas abordagens técnico-econômicas empregam normalmente modelos de otimização na rede.

Na continuação será elaborada uma descrição dividida por cada tipo de abordagem.

2.1 ABORDAGEM ECONÔMICA

Mohsenian et al. (2010) analisam o uso dos armazenadores de energia, como mecanismo de suporte para obter uma redução nos preços de energia. A formulação do problema, realiza cenários de controle horário dos preços de energia. Nesse trabalho, é empregado um modelo estocástico onde se aplica uma limitação nos preços de energia conforme o nível de carga. A limitação garante o melhor comportamento de consumo no sistema durante cada hora atendendo a tarifa variável durante o dia. O modelo é orientado no controle da demanda do sistema. A operação do armazenador é considerada como uma carga negativa para os momentos de descarga.

No trabalho de Gast et al. (2014) é empregado um modelo para determinação da operação ótima de armazenadores de energia. Considera-se, a natureza estocástica das fontes de geração eólica. A modelagem é orientada visando a redução dos custos de energia no sistema. As características físicas da rede não são estudadas em termos de localização do armazenador e da GD no sistema, nem as perdas e níveis de tensão.

El Nozahy et al. (2015) apresentam uma metodologia estocástica para determinar a operação de armazenadores de energia em instalações residenciais. O trabalho emprega exclusivamente fontes solares e veículos elétricos ligados à rede. Compara-se diferentes tipos de baterias, mas apenas perante uma perspectiva de custos. Tem-se também uma análise baseada em cenários avaliando o desempenho do transformador e a demanda final do sistema para a determinação da capacidade e ciclo de operação das baterias.

Soares et al. (2015) apresentam um modelo para determinação dos custos no sistema de distribuição com uma alta penetração de fontes de geração distribuída. Neste caso se determinam os custos de fontes como solar, eólica, biomassa, veículo elétrico ligado à rede e baterias. O modelo baseado em cenários não determina a forma de operação do armazenador sem empregar o gerenciamento da energia.

Carpinelli et al. (2016) utilizam uma abordagem probabilística para determinação da capacidade de sistemas armazenadores de energia com baterias (*Battery Energy Storage System*, BESS) considerando a resposta de demanda e cenários com mecanismos de preços de tipo de “tempo de uso” (*time of use*). A aplicação do armazenador não avalia o uso de fontes renováveis.

Os estudos apresentados nesta seção abordaram a viabilidade do uso de armazenadores de energia em sistemas de distribuição desde o ponto de vista econômico. Nesses trabalhos se emprega uma simplificação do sistema ao desconsiderar a alocação do armazenador no sistema e/ou outros parâmetros técnicos como nível de tensão ou perdas e utilizam-se metodologias de predição para tratar as características estocásticas da geração distribuída. Nesse sentido, esta proposta de tese apresenta um modelo que avalia o impacto técnico do armazenador no sistema, fazendo uma análise do fluxo de carga, determinando perdas e níveis de tensão considerando o comportamento diário no sistema. Da mesma forma por estarem as publicações citadas focadas em calcular custos de projetos com armazenadores, o horizonte de planejamento se estende para vários anos. A proposta desta tese também considera custos ao longo dos anos, partindo de uma aproximação da operação diária por meio de uma rede neural. Porém, diferencia-se dos demais ao analisar o impacto técnico no curto prazo contemplando a influência da localização do armazenador nos custos e desempenho diário no sistema.

2.2 ABORDAGEM TÉCNICA

Shigematsu et al. (2002), analisam o impacto das baterias de fluxo de vanádio na qualidade da energia em sistemas com geração eólica. O armazenador estudado serve como compensador de distúrbios na tensão como *sags* para flutuações nas turbinas eólicas. A aplicação do armazenador garante tanto uma melhoria na qualidade da energia como na confiabilidade do sistema.

Em seu trabalho, Miltra (2010) descreve uma abordagem analítica para determinar a capacidade em termos de potência e energia de uma unidade armazenadora de energia com o

fim de manter a confiabilidade do sistema elétrico. Para a abordagem analítica o método considera-se o evento da falha da unidade de produção primária, falha em atendimento das cargas críticas, tempo máximo de suporte do armazenador num caso de contingência, tempo (aleatório) de duração da contingência e a função de densidade probabilística. O mesmo autor apresenta um modelo mais detalhado para aplicação em microrredes isoladas com fontes de geração intermitentes usando uma simulação de Monte Carlo sequencial para verificação da confiabilidade do sistema (MILTRA, 2012).

Seo et al. (2011) analisam o uso de armazenadores de energia para mitigar flutuações em sistemas de energia com participação de fontes solares. O suporte permite gerar a maior quantidade de energia possível sob diferentes condições climáticas, através do gerenciamento da carga e descarga do armazenador. As diferentes condições climáticas são representadas por níveis de irradiação. O armazenador é controlado segundo a potência do gerador solar e as condições de qualidade de energia do sistema. A análise deste impacto é feita empregando uma simulação dinâmica do sistema verificando a operação dos conversores.

No trabalho de Díaz-Gonzales et al. (2013) se emprega um modelo de otimização para determinar a melhor estratégia de operação de um sistema armazenador de energia em regime transitório. O armazenador é usado para suporte à energia eólica, suavizando sua curva de injeção de potência. Segundo as simulações empregadas, o estado de carregamento necessário do armazenador para garantir a operação ótima do sistema deve estar entre 89% a 93%.

Quesada et al. (2013) determinam uma estratégia de controle para os inversores empregados em baterias visando uma adequada resposta dinâmica do sistema em termos de estabilidade do sistema. As fontes de geração solares são suportadas pelo armazenador fazendo controle primário de frequência, permitindo um despacho independente de injeções ativas e reativa por parte do armazenador.

Jamian et al. (2014) estudam a alocação ótima de baterias em sistemas de distribuição para pontos de carregamento de veículos elétricos. O estudo realiza uma metodologia de otimização heurística baseada na colônia de formigas para determinar a barra e tamanho do armazenador tendo como objetivo a redução das perdas de potência do sistema. A comparação do método heurístico com o método analítico mostra resultados similares e o uso de armazenadores apresentou uma contribuição na redução das perdas do sistema levando em conta a instalação de unidades de geração distribuída. O tipo de unidade de geração distribuída não foi especificado, mas modelado como um nó tipo PV (tensão constante).

Aghamohammadi e Abdolahinia (2014) aplicam um método para determinação da capacidade ótima de baterias para controle primário de frequência em microrredes elétricas. O sistema conta com uma fonte de geração solar com resposta baixa para controle na frequência. A rápida resposta dinâmica da bateria estudada permite o balanço da geração com a demanda de forma adequada. Na formulação do problema é empregado um controlador para o inversor usado na bateria considerando suas limitações no estado de carga. Além disto, a abordagem tenta aproveitar as características de sobrecarregamento do armazenador para responder rapidamente a desbalanços de energia no sistema e assim apresentar um sistema mais robusto baseado em cenários de isolamento.

Marra et al. (2014) propõem uma estratégia descentralizada de armazenamento de energia para suportar o controle de tensão em alimentadores residenciais de baixa tensão com alta capacidade de geração solar instalada. Com o uso do armazenador é possível prevenir situações de sobretensões durante períodos de alta penetração de fontes intermitentes. Neste caso, é explorada uma alternativa ao método tradicional de operação onde o armazenador está em modo de carregamento nos momentos em que a geração da GD é maior que a demanda. A estratégia proposta é testada num sistema real localizado na Bélgica com simulações baseadas em perfis de carga e geração anuais quantificando a capacidade de energia e potência do armazenador.

Zhao et al. (2015) apresentam um modelo de controle ótimo da potência ativa de um sistema de geração eólico avaliando o uso de armazenadores de energia ao curto e longo prazo. O trabalho emprega um modelo distribuído de controle previsível onde a adição de sistemas armazenadores de energia leva a uma redução da carga contida nas turbinas eólicas melhorando a eficiência do sistema. As aplicações deste modelo permitem empregar o armazenador para operação em tempo real em atendimento às necessidades dos consumidores.

Reihani e Ghorbani (2016) aplicam uma metodologia de gerenciamento de baterias usando um algoritmo de predição série-paralelo para redução de picos e suavização da carga. Neste caso, é feito um teste no sistema real da ilha de Maui no Havaí, considerando uma alta participação de fontes de geração solar. O algoritmo avalia o impacto em dois níveis, tanto na distribuição como na transmissão e emprega ferramentas de predição do comportamento da demanda final do sistema.

Os trabalhos anteriores apresentaram as diferentes aplicações que têm sido estudadas dos armazenadores de energia em sistemas de distribuição. O impacto deles demonstra a capacidade do armazenador para atender problemas de confiabilidade do sistema, como de

melhoria da qualidade de energia em relação ao nível de tensão e perdas. Assim, para horizontes de planejamento de curto prazo, o interesse dos estudos é mais por controlar os inversores usados nos armazenadores e por determinar o modo de carregamento/descarga do armazenador sob as restrições técnicas do sistema focadas no regime transitório. Por serem problemas de operação do sistema, estes estudos não consideram avaliações econômicas de custos associados ao uso de armazenadores. A implementação de custos é mais comum para horizontes de tempo maiores, ou para análise de preços que consideram o despacho da energia conforme projeções e medições preestabelecidas. Esta tese se diferencia desses trabalhos ao abordar um problema não só de operação, mas também de planejamento avaliando tanto custos como características técnicas do sistema. Deve-se salientar que a contribuição do trabalho será realizada para estudos em regime permanente, por tanto, a análise da configuração dos inversores ou outros assuntos relacionados ao regime transitório não serão abordados. A consideração técnica dentro da proposta está relacionada a operação do armazenador (carregamento e descarga), seu impacto nas perdas e níveis de tensão, alocação do armazenador e restrições elétricas do sistema. Ao explorar uma abordagem em regime permanente é possível planejar o sistema para quadros de tempo de curto, médio e longo prazo, considerando custos de energia.

2.3 ABORDAGEM TÉCNICO-ECONÔMICA

Atna et al. (2010) realizam um modelo de planejamento do sistema avaliando a alocação de diferentes tipos de baterias. O objetivo do modelo é a redução dos custos de energia no sistema considerando as restrições elétricas apresentadas sob uma forte participação de energia eólica. São considerados diferentes tipos de baterias e o modelo desconsidera as variações da profundidade de descarga no cálculo do tempo de vida da mesma, utilizando um valor constante. O gerenciamento do armazenador é focado em compensar os excessos de geração eólica, mas não em atender os excessos de demanda, apresentando menor regulação da carga final do sistema.

Carpinelli et al. (2013) abordam a operação do armazenador considerando as características estocásticas da GD. É utilizado um algoritmo genético para otimizar o sistema, usando uma aproximação por meio de um fluxo de carga linearizado. O trabalho emprega um algoritmo genético para verificar a alocação ótima do armazenador levando em conta limites de tensão e redução das perdas de energia.

Awad et al. (2014) empregam um modelo de otimização de armazenadores de energia avaliando além das perdas, a confiabilidade do sistema, utilizando como critério a energia não suprida. O armazenador analisado é a bateria (analisa só um tipo) e sua operação é orientada por horários de picos de demanda, mais focadas em fontes como solar, desconsiderando outras fontes como a eólica onde pode-se apresentar geração em horas da noite.

Jayakesara et al. (2014) empregam um modelo para gerenciamento de energia por parte de baterias em suporte a um sistema com alta penetração de fontes solares. O algoritmo de solução implementado é uma combinação entre o método de pontos interiores e a busca padrão. O modelo é aplicado para redução das perdas e melhoria no nível de tensão. A alocação das baterias é aleatória sem determinar sua melhor alocação no sistema e seu tempo de vida é fixado e independente da profundidade das descargas.

Sheng et al. (2015) empregam uma análise multiobjetivo para alocação ótima de armazenadores de energia em sistemas de distribuição com geração distribuída. Esse modelo considera tanto a energia solar como a eólica como fontes de geração distribuída. A alocação ótima do armazenador é focada no ponto de vista da confiabilidade do sistema, usando como critério a energia não suprida. Os tipos de armazenadores não são comparados. O tempo de vida do armazenador se considera como linear e é fixado. O trabalho mostra a contribuição do armazenador no melhoramento da confiabilidade do sistema.

Lu et al. (2016) aplicam um modelo de otimização multiobjetivo de dois níveis para determinar a operação ótima de um sistema de distribuição ligado à microrredes. O objetivo deste modelo é a redução das perdas e melhoria do nível de tensão, sujeito ao uso de energia solar, eólica e baterias, como tipo de armazenador. O modelo não determina a alocação ótima do armazenador e não considera diferentes tipos de baterias levando em conta um tempo de vida independente da profundidade de descarga.

Xiao et al. (2016) empregam um fluxo de carga linearizado e um algoritmo genético para analisar a viabilidade das baterias. O objetivo do trabalho é a alocação ótima de baterias visando reduzir custos de energia e perdas. É um dos poucos trabalhos que consideram o tempo de vida do armazenador como não linear e dependente da profundidade de descarga do armazenador durante seus ciclos de carregamento e descarga. A análise feita se limita para as baterias de lítio sem comparar este efeito em outros tipos de baterias.

Qiu et al. (2016) consideram o uso de baterias de Fluxo (VRFB) e de ácido em conjunto para operar no sistema, avaliando os resultados em termos de eficiência e perdas avaliando uma

microrrede independente. Neste trabalho o uso das baterias demonstrou ter potencial para redução nos custos de energia e perdas do sistema, melhorando a qualidade da energia.

Vergara et al. (2017) utilizam um modelo de programação linear inteira-mista para o gerenciamento ótimo de energia em microrredes desbalanceadas considerando tanto unidades de geração trifásicas, geração fotovoltaica monofásica e armazenadores monofásicos, como resposta em demanda. O trabalho analisa o custo de operação sem quantificar a redução das perdas, nem dos fluxos reversos e sem comparar tipos de armazenadores, tomando como base o modelo das baterias de ácido. A posição do armazenador é preestabelecida no sistema analisando suas capacidades.

Gao et al. (2017) obtêm um modelo para fluxo ótimo de potência em redes ativas considerando o estado de carregamento dos armazenadores de energia. Para este caso a fonte de geração distribuída analisada é de tipo eólica. O armazenador tem uma capacidade máxima fixa e sua alocação na rede é preestabelecida.

Os trabalhos indicados anteriormente têm mais relação com a metodologia proposta dado que consideram tanto as características técnicas como econômicas, analisando a operação e planejamento do uso do armazenador em regime permanente. Os estudos citados abordam assuntos como alocação, minimização de perdas, avaliação dos custos do armazenador e seleção do tipo baseados em modelos de otimização heurísticos. Neste caso, apresentaram bons resultados aplicando algoritmos genéticos para alocação do armazenador. Por estes motivos o projeto de pesquisa proposto considera também esta abordagem. O diferencial dado do modelo empregado está focado na seleção do tipo do armazenador, sujeita a sua alocação, custos e tempo de vida. O cálculo do tempo de vida considera a influência da profundidade de descarga no desgaste das baterias. Essa influência é um fator pouco considerado nos estudos citados e que pode impactar significativamente na tomada de decisão.

Deve-se salientar que no desenvolvimento desta tese foi possível realizar um modelo abordando as características mencionadas, sendo possível a seleção da bateria considerando as características econômicas e técnicas do sistema aplicando um algoritmo genético para seleção do armazenador junto com um modelo de otimização não linear para a otimização da operação da bateria durante o ano (SEPULVEDA et al., 2018). No entanto, o modelo desenvolvido em (SEPULVEDA et al., 2018) não considerava o fato dos preços da energia estarem relacionados ao comportamento diário da demanda e da geração renovável, ao utilizar uma curva de preços padrão durante todo o ano de estudo e não abordou a análise de riscos associados as opções de seleção da bateria, por ter empregado uma curva determinística para a operação diária da

bateria. Esta tese, considera estes assuntos ao utilizar uma simulação de Monte Carlo para gerar uma base de dados baseada em dados reais, de geração, carga e preços os quais estão relacionados para cada dia. A base de dados permite a identificação de casos críticos e riscos associados a prejuízos econômicos e problemas na tensão. Acrescentou-se um modelo de entrada/saída para aproximar os resultados da operação diária da bateria aplicando redes neurais, o que permite acelerar o processo de tomada de seleção, em comparação com (SEPULVEDA et al., 2018).

A abordagem entrada/saída para aproximação da operação diária da bateria é também proposta por Hao Xiao et al. (2018), utilizando um modelo de dois níveis. O nível superior determina as opções de capacidade da bateria e o nível inferior a operação ótima do sistema. As incertezas no sistema de distribuição são consideradas pela criação de diferentes cenários probabilísticos, utilizando uma distribuição uniforme. Os cenários aplicam curvas sintéticas para representar a carga, GD e preços da energia. A modelagem entrada/saída é determinada pelo método de exploração e eliminação de região (*Space Exploration and Region Elimination – SEUMRE*). O modelo consegue acelerar o processo de tomada de decisão determinando a capacidade e operação da bateria. A tese proposta se diferencia do trabalho citado ao considerar, além do carregamento/descarga e tamanho da bateria, a alocação na rede e a influência do desgaste no tempo de vida do armazenador, junto com a aplicação de curvas tomadas de dados reais e o uso de uma rede neural para a modelagem da relação entrada/saída.

2.4 RESUMO DO CAPÍTULO

Este capítulo fez uma descrição dos estudos realizados nos armazenadores de energia em redes de distribuição com geração distribuída. Três focos foram abordados. Os estudos de abordagem econômica analisam o benefício econômico dos armazenadores obtido por: redução de perdas no sistema, ajuste da curva de demanda, redução de picos de carga, e suporte à geração distribuída. Procura-se a determinação da capacidade e/ou forma de operação diária da bateria considerando venda e fornecimento de energia. Estes estudos também avaliam o retorno de investimento dos projetos, analisando o planejamento em longo prazo (anos).

A abordagem técnica estuda o impacto técnico dos armazenadores de energia nos sistemas de distribuição. Demonstra-se o uso dos armazenadores para suporte tanto às fontes solares, quanto às eólicas. O suporte dos armazenadores no regime transitório se dá na redução

de flutuações de tensão e no controle de tensão e de frequência. Além disto, é comprovado que a alocação do armazenador na rede permite reduzir as perdas no sistema.

O estudo técnico econômico procura determinar tanto a capacidade como a operação do armazenador de modo que se tenha um benefício econômico e técnico do projeto. Estes estudos focam em análise no regime permanente para observar impactos em prazos curto (dias), médio (semanas) e longo (anos). Destes estudos se observa diferentes focos, sejam para determinar capacidades e localização na rede do armazenador como para determinar estratégias de carregamento e descarga ao longo do dia. Um limitante determinado nos estudos é a falta de comparação dos tipos, junto com a consideração do desgaste nos casos das baterias.


Finalmente mostra-se um estudo realizado em etapas iniciais da tese, onde se conseguiu considerar o desgaste da bateria para seleção ótima dos equipamentos comparando tipos. Se apresentaram as limitantes em termos de esforço computacional, e a falta de dados reais que associem as curvas de preço, demanda e geração para cada dia. Estes fatores foram adicionados para a versão final desta tese, junto com a análise de casos críticos.

3 SISTEMAS DE ARMAZENAMENTO POR BATERIAS (BESS)

Existem diferentes tipos de armazenadores de energia, os quais dependendo de suas características podem ter diversas aplicações nos sistemas de distribuição de energia. Uma das principais características é o tempo de atuação e a quantidade de energia que é possível armazenar por tempo por dispositivo. Conhecendo estes parâmetros, o armazenador pode ser orientado a trabalhar para operações com respostas em milissegundos, segundos ou horas.

A bateria é uma das tecnologias de armazenamento mais usadas na indústria e no cotidiano. Um sistema de armazenamento por baterias também conhecido como *Battery Energy Storage System* (BESS) consiste num número de células eletroquímicas ligadas em série e/ou em paralelo, as quais produzem eletricidade numa tensão desejada por uma reação eletroquímica. Cada célula possui dois eletrodos (conhecidos como ânodo e cátodo) com um eletrólito que pode estar num estado sólido, líquido ou viscoso (WAGHORNE, 2001; SONG et al., 1999). Uma célula pode bidirecionalmente converter a energia entre elétrica e química. Durante a descarga, a reação eletroquímica ocorre no ânodo e cátodo simultaneamente. No circuito externo, os elétrons vêm dos ânodos e são coletados dos cátodos. Durante a carga, a reação reversa ocorre e a bateria é recarregada por meio de uma tensão externa nos dois eletrodos, como se observa na Figura 1 (LUO et al., 2015).

Figura 1 – Diagrama de uma BESS.



Fonte: Adaptado de Luo et al. (2015).

As baterias podem ser usadas amplamente em diferentes aplicações relacionadas à qualidade de energia, gerenciamento da energia e sistemas de transporte. A construção de uma BESS leva um período relativamente curto, sendo de aproximadamente um ano (CHEN et al., 2009; SMITH et al., 2008). A localização para instalação pode ser flexível, sendo possível dentro de prédios ou perto dos pontos onde é necessária sua aplicação. O uso fácil das baterias de ácido assim como seu baixo custo levam a preferência deste tipo de sistema de armazenamento em redes de distribuição. Atualmente as principais barreiras para sua implementação em grande escala são em razão de seus baixos tempos de ciclo e altos custos de manutenção. Além disto, deve-se ter cuidado com os dejetos tóxicos que possam surgir pela sua elaboração, troca ou retirada, dependendo do tipo de material empregado para sua construção (LUO et al., 2015). Por estes motivos muitos tipos de baterias não podem ser completamente descarregados devido a seu ciclo de vida ser dependente da Profundidade de Descarga conhecida também como *Depth of Discharge* (DOD) (DÍAZ-GONZÁLEZ et al., 2012). As típicas formas de comparar cada classe de bateria utilizam os seguintes critérios: possível profundidade de descarregamento da bateria, custo, número de ciclos de carga/descarga toleráveis pela bateria, eficiência, auto descarregamento, desenvolvimento da tecnologia e densidade de energia (ALOTTO et al., 2014; COPPEZ et al., 2010).

Os tipos das baterias dependem principalmente dos componentes empregados para sua fabricação, onde seus requerimentos químicos resultaram em diferentes características de carregamento e descarga, assim como tempo de vida e custos de fabricação e manutenção. A continuação apresenta os principais tipos de bateria que tem possibilidade ou já são empregados em sistemas de distribuição como suporte de energia.

3.1 BATERIAS DE CHUMBO-ÁCIDO

O tipo de bateria mais usado normalmente é a de chumbo-ácido (CHEN et al., 2009; IBRAHIM et al., 2008). Para este tipo de bateria o cátodo está feito de PbO_2 o ânodo de Pb , e o eletrólito de ácido sulfúrico. Este tipo de bateria tem um tempo de resposta rápido, a mesma possui pequenas taxas de auto descargas (<0,3%), relativamente altos ciclos de eficiência (63 a 90%) e baixos custos de capital com preços da ordem dos 50 até o 600 \$/kWh (CHEN et al., 2009; BEAUDIN et al., 2010; HADJIPASCHALIS et al., 2009; KONDOH et al., 2000). Estas baterias podem ser usadas em dispositivos estacionários como plantas de *backup* para dados, sistemas de comunicação e aplicações em gerenciamento de energia. Também, têm sido

desenvolvidas como fontes de energia para veículos híbridos ou elétricos. No entanto, existem ainda poucas instalações no mundo em grande escala, devido a seu relativamente baixo ciclo de carregamento (acima dos 2000) (CHEN et al., 2009; FARRET et al., 2006; BAKER, 2008). Além disto, podem não trabalhar adequadamente a baixas temperaturas pois é necessário um sistema de gerenciamento que incrementa seus custos (LUO et al., 2015).

Atualmente as pesquisas e desenvolvimento em baterias de chumbo-ácido estão focados em: melhoria dos materiais para seu funcionamento, garantindo ciclos de vida maiores e profundidade de descarga maiores, implementação de tecnologia para aplicações em sistemas de geração distribuída com fontes como solar e eólica. Alguns projetos em desenvolvimento são a *Ecoul UltraBattery* e *Dry Cell* (RASTLER, 2010; LUO et al., 2015). Por outro lado, tem-se já projetos que vão das capacidades de 1 MW aos 35 MW em lugares como Berlim, Califórnia, Porto Rico, Alasca e Havaí (CHEN et al., 2009; DÍAZ-GONZÁLEZ et al., 2012; ZHANG et al., 2008; LUO et al., 2015; HODSON, 2013).

3.2 BATERIAS DE LÍTIO-ÍON

Neste tipo de baterias, o cátodo está feito de um óxido metálico de lítio, tal como $LiCoO_2$ e $LiCoO_2$, e o ânodo está feito de carvão de grafite. O eletrólito é normalmente um líquido orgânico não aquoso dissolvido em sais de lítio, como o $LiClO_4$ (DÍAZ-GONZÁLEZ et al., 2012). A bateria de lítio-íon é considerada um bom candidato para aplicações onde o tempo de resposta é importante (CHEN et al., 2009; LUO et al., 2015; HADJIPASCHALIS et al., 2009). Essas baterias têm também uma alta eficiência de ciclo, acima de 97% (CHEN et al., 2009; LUO et al., 2015). O principal assunto a melhorar é a profundidade de descarga (DOD) que pode afetar o tempo de vida destas baterias e normalmente é requerido de um computador para gerenciar sua operação, incrementando seus custos de uso.

As investigações mais recentes incluem: incremento da capacidade de energia usando materiais de nanoescala, crescimento da energia específica da bateria por desenvolvimento de materiais avançados para os eletrodos e eletrólitos. Várias companhias têm experiência usando estas baterias em mercados de energia em grande escala, em lugares como Nova Iorque, Laurel Mountain e Reino Unido com capacidades que vão desde os 2 MWh até os 10 MWh, em aplicações relacionadas desde controle de frequência e suporte a fontes eólicas de geração (TAYLOR et al., 2012; LUO et al., 2015; SUBBURAJ et al., 2014). Uma capacidade de 20 MWh é planejada em Tohoku pela Toshiba, para um projeto focado no suporte à fontes

renováveis de energia na rede. Adicionalmente a isto, as baterias de lítio são aplicadas em veículos elétricos e híbridos com capacidades de até 50 kWh.

3.3 BATERIAS DE SULFETO DE SÓDIO

As baterias de Sulfeto de Sódio (NaS) usam sódio e sulfeto derretidos como os eletrodos, e beta-alumina como o eletrólito sólido. A reação requer uma temperatura de 574 a 624 K para assegurar que os eletrodos fiquem em estado líquido, levando a uma alta reatividade (TAYLOR et al., 2012). Uma propriedade desejável deste tipo de bateria é uma taxa muito baixa de autodescarga diária (quase zero) e maiores capacidades em comparação com outros tipos (DÍAZ-GONZÁLEZ et al., 2012; LUO et al., 2015; KAWAKAMI et al., 2010). A bateria usa materiais não tóxicos e econômicos levando a uma alta reciclabilidade (99%) (CHEN et al., 2009; DÍAZ-GONZÁLEZ et al., 2012). No entanto, suas limitações estão dadas no alto custo anual de operação (80 \$/kW/ano) e um sistema adicional requerido para assegurar sua temperatura de operação (LUO et al., 2015).

A bateria NaS é considerada uma das melhores candidatas em sistemas de potência de grande porte. As investigações e desenvolvimento estão focados principalmente em melhorar os índices de desempenho das células e reduzir suas restrições por operação a altas temperaturas. Um exemplo destas investigações se encontra no trabalho da Sumitomo Electric Industries em conjunto com a Universidade de Tóquio, os quais tem uma bateria que trabalha a 330 K (LUO et al., 2015). Outros trabalhos avaliam a operação conjunta com fontes eólicas (ZHAO et al., 2014; TEWARI et al., 2013). Embora ainda estejam em testes, alguns projetos encontram-se em lugares como Japão, Estados Unidos, França, Alemanha e Emirados Árabes Unidos com capacidades que podem ir desde os 0,05 MW até os 34 MW.

3.4 BATERIAS DE NÍQUEL-CÁDMIO (NICD)

As baterias de NiCd usam hidróxido de níquel e cádmio metálico com dois eletrodos e uma solução alcalina aquosa como eletrólito. Esta bateria tem normalmente alta confiabilidade e baixos requerimentos de manutenção. O problema pelo uso deste tipo de bateria é que o cádmio e níquel são metais pesados tóxicos, resultando em problemas no meio ambiente (LUO et al., 2015; LACERDA et al., 2009). Até hoje, são pouco usados em sistemas de potência de grande porte, como exemplo disto teve-se um projeto em Alasca nos Estados Unidos, usada

para reserva de giro, fornecimento de energia e compensação a sistemas eletricamente isolados com capacidades de 27 MW por 15 minutos ou 40 MW por 7 minutos, com eficiências de 72 a 78% (LUO et al., 2015; DIVYA KC, 2009). No entanto, na renovação das instalações da cidade este projeto foi descontinuado.

3.5 BATERIAS EM DESENVOLVIMENTO

A bateria de Hidreto Metálico de Níquel (NiMH) é similar à de NiCd mas emprega uma fusão de metais com hidrogênio para o eletrodo ao invés do cádmio, tendo melhores características elétricas do que a bateria de NiCd, sendo menos prejudicial ao meio ambiente. Estas baterias tem um ciclo de vida maior em comparação as baterias de Lítio-íon (ZHU et al., 2013; FETCENKO et al., 2007; LUO et al., 2015).

As baterias de NiMH têm uma proeminente aplicação para produtos portáteis como o HEVs e EVs e aplicações industriais de suporte a energia como as UPS (ZHU et al., 2013; FETCENKO et al., 2007; YING et al., 2006). No entanto, a principal barreira para sua aplicação é sua alta taxa de auto descarga, perdendo de 5 a 20% de sua capacidade dentro das primeiras 24 horas após estar totalmente carregada (ZHU et al., 2013; FETCENKO et al., 2007; LUO et al., 2015). São também sensíveis a altas profundidades de descarga com detrimento de seu desempenho.


As baterias de tecnologia de cloreto de níquel de sódio (Também conhecida como baterias ZEBRA) são similares as baterias de NaS. Estas baterias tem uma alta temperatura de operação (523 a 623 K) (CHEN et al., 2009; LUO et al., 2015; DUSTMANN, 2004; O'SULLIVAN et al., 2006). As vantagens destas baterias são a boa capacidade de injeção de potência, a falta de necessidade de manutenção da célula, muito pouco auto descargas e relativamente altos ciclos de vida. Esta bateria tem sido usada em demonstrações com veículos elétricos (LUO et al., 2015).

Recentemente um novo empreendimento FIAMM da *Energy Storage Solutions*, começou a produzir baterias de Sódio com Níquel (nomeadas de SoNick) para aplicações estacionárias de armazenamento de energia (LUO et al., 2015). No entanto, este tipo de bateria requer de 12 a 15 horas para aquecimento após estar em estado solidificado (LUO et al., 2015), e poucas empresas tem-se envolvido no desenvolvimento desta tecnologia, limitando seu potencial (CHEN et al., 2009).

3.6 BATERIAS DE FLUXO

As baterias de fluxo armazenam energia em dois pares de redox solúvel contidas em tanques líquidos externos de eletrólitos. Estes eletrólitos podem ser extraídos desde o tanque para as pilhas de célula que consiste em dois compartimentos de eletrólitos de fluxo separados por membranas eletivas de íons. A operação é baseada na reação de redução–oxidação da solução dos eletrólitos. Durante a fase de carga um eletrólito é oxidado no ânodo e outro eletrólito é reduzido no cátodo e a energia elétrica é convertida pela energia química do eletrólito. Este processo é revertido durante a fase de descarga. As baterias de fluxo podem ser classificadas nas categorias de baterias de fluxo redox e baterias de fluxo híbridas, dependendo dos componentes que podem ser dissolvidos no eletrólito. A Figura 2 mostra o diagrama de um sistema de bateria de fluxo redox de vanádio.

Figura 2 – Diagrama de Uma Bateria de Fluxo Redox de Vanádio.



Fonte: Adaptado de Luo et al. (2015).

Uma importante vantagem das baterias de fluxo é que a potência do seu sistema é independente de sua capacidade de armazenamento. A potência do seu sistema é determinada pelo tamanho dos eletrodos e números de células na pilha, no entanto sua capacidade de armazenamento é determinada pela concentração e quantidades de eletrólitos (LUO et al., 2015; YANG et al., 2011; EYER et al., 2005). Também, possuem uma taxa de autodescarga baixa devido aos eletrólitos estarem colocados em tanques selados (CHEN et al., 2009; DÍAZ-

GONZÁLEZ et al., 2012). Alguns problemas destas baterias são o baixo desempenho resultante pela não uniforme queda de pressão e as limitações de transferência da massa de reação, relativos a altos custos de produção e sistemas mais complexos de operação quando comparados com os das baterias tradicionais (NGUYEN et al., 2010; TAYLOR, 2012).

Projetos com baterias de fluxo tem alcançado níveis desde os kW até MW, mas não há muitas comercialmente disponíveis na atualidade (CHEN et al., 2009; WEBER et al., 2011; MODIBA P, 2010). As pesquisas realizadas tratam sobre: eletrodos de baixo custo, eficientes e confiáveis, gerenciamento de energia e potência de sistemas de baterias de fluxo de grande porte.

3.7 BATERIAS DE FLUXO DE VANÁDIO

A Baterias de Fluxo de Vanádio também conhecida como *Vanadium Redox Flow Battery* (VRFB) é um dos mais maduros sistemas de baterias de fluxo (CHEN et al., 2009; DIVYA KC, 2009). A VRFB armazena energia usando pares de vanádio redox em dois tanques de eletrólitos. Estas baterias exploram o vanádio em quatro estados de oxidação os quais a fazem ter somente elementos ativos tanto em ânodo como em cátodo (YANG et al., 2011).

As VRFB têm respostas rápidas (menores a 0,001 s) e podem operar por 10000 até 16000 ciclos (ZHOU et al., 2011; GONZALES et al., 2004). Elas têm relativamente altas eficiências, acima do 85% (YANG et al., 2011; GONZALES et al., 2004). Provedores podem empregar VRFB para fornecer energia continuamente durante um dia (duração de descarga maior a 24 horas) (CHEN et al., 2009; BARTON et al., 2004). Embora estas baterias procurem expandir sua abrangência de aplicações pelo crescimento de seu tamanho físico, há alguns problemas técnicos que precisam ser solucionados, como a baixa estabilidade nos eletrólitos. Além disso possuem relativamente altos custos de operação que precisam ser reduzidos (TAYLOR, 2012).

As VRFB podem ser usadas num número grande de aplicações, principalmente envolvendo melhora da qualidade da energia usada para aplicações estacionárias e dispositivos UPS, melhora do nível de carga e segurança energética e suporte a natureza intermitente das fontes renováveis de geração (LUO et al., 2015). Alguns projetos foram desenvolvidos em países como Itália, Austrália, Irlanda, Japão, e Estados Unidos com capacidades que vão desde os 5 kW até os 2 MW.

3.8 BATERIAS DE FLUXO DE BROMETO DE ZINCO

As Baterias de Fluxo de Brometo de Zinco também conhecidas como *Zinc Bromine Flow Battery* (ZnBr) fazem parte da categoria das baterias de fluxo híbridas. Nesta bateria dois eletrólitos de soluções aquosas contêm os componentes reativos, os quais são baseados em elementos de Zinco e Brometo, armazenados em dois tanques externos. Durante as fases de carga e descarga, estas duas soluções de eletrólitos fluem através da pilha da célula que consiste em eletrodos compostos de carvão plástico com compartimentos. Assim, a reação eletroquímica reversível ocorre nestas células eletrolíticas.

As ZnBr têm uma alta capacidade de descarga e uma boa reversibilidade (WEBER et al., 2011; NGUYEN et al., 2010). Os tamanhos dos módulos variam dos 3 kW até os 500 kW, com tempos de vida estimados de 10 a 20 anos e durações de descarga maiores a 10 horas (CHEN et al., 2009; BREKKEN et al., 2010; LUO et al., 2015). A desvantagens das ZnBr são: corrosão do material, ciclos de baixa eficiência (ao redor de 65 a 75%) comparados com os das baterias tradicionais que podem limitar suas aplicações (CHEN et al., 2009; LUO et al., 2015; ARAI et al., 2008). Além disso, estas baterias normalmente operam numa abrangência limitada de temperatura (NGUYEN et al., 2010; TONG, 2010). Aplicações em sistemas de potência deste tipo de baterias estão na fase inicial de demonstração e comercialização. *ZBB Energy Corporation* e *Premium Power Corporation* tem desenvolvido esta tecnologia para fins comerciais com capacidades desde os 50 kWh até os 2 MW (BEAUDIN et al., 2010). Na Austrália também se tem comercializado ZnBr com capacidade de até 8 kWh de energia (LUO et al., 2015). A maioria de aplicações e projetos encontram-se nos Estados Unidos para aplicações que incluem suporte a rede e confiabilidade (RASTLER, 2011).

3.9 BATERIAS DE FLUXO DE BROMETO DE POLISSULFETO

As Baterias de Fluxo de Brometo de Polissulfeto conhecidas também como *Polysulfide Bromine Flow Battery* (PSB) usam brometo de sódio e polissulfeto de sódio como eletrólitos de solução salgada. As principais vantagens do PSB incluem a viabilidade econômica e tempo de resposta curto (20 ms). Este tipo de baterias têm uma ampla abrangência de potenciais áreas de aplicação, especialmente para controle nos sistemas de potência e controle da tensão devido a suas características de resposta rápida. Como seus componentes construtivos são feitos durante reações químicas, pode-se apresentar problemas ambientais pelo seu uso.

Vários sistemas de PSB têm mostrado viabilidade em diferentes capacidades. No Reino Unido, por exemplo, tem-se um sistema com eficiência de 75% desenvolvido para capacidades de até 100 kW (MODIBA P, 2010). Outro projeto feito no Reino Unido tem uma capacidade de até 15 MW. Além disto, nos Estados Unidos tem-se um sistema com 12 MW de capacidade usado no suporte à geração de tipo eólica (CHEN et al., 2009). No entanto devido à limitações financeiras estes projetos ficaram incompletos (LUO et al., 2015; MODIBA P, 2010; BAXTER, 2006), pois suas aplicações ainda estão em fase de desenvolvimento.

3.10 RESUMO DO CAPÍTULO

Este capítulo fez uma descrição sobre as baterias, seu modo de funcionamento e seus tipos disponíveis no mercado. Primeiro tem-se uma descrição das baterias tradicionais as quais tem um funcionamento pela separação de dois eletrodos num meio eletrolítico. Entre estas apresentam-se as baterias de chumbo-ácido, lítio-íon, NaS, NiCd entre outras. Fatores que indicam as vantagens e desvantagens de cada tipo são: tempo de resposta, eficiência do ciclo, taxas de auto descarga, confiabilidade, impacto da profundidade de descarga, custos de manutenção, e impacto ambiental entre outros. O desenvolvimento destas tecnologias tem-se mostrado ao redor do mundo com projetos em Estados Unidos, Japão, Austrália, Europa Emirados Árabes e Brasil entre outros.

Apresentou-se também, as baterias de fluxo as quais armazenam energia em dois pares de redox solúvel contidas em tanques líquidos externos de eletrólitos. Estas baterias possuem uma taxa de auto-descarga baixa devido aos eletrólitos estarem colocados em tanques selados. Também, garantem que o impacto da profundidade de descarga não vai influir no ciclo de vida do equipamento. Uma limitante destes tipos de baterias são os altos custos de operação e, em alguns casos, os problemas ambientais presentes pela composição de seus materiais. Mostra-se um desenvolvimento destas tecnologias na Europa, Estados Unidos, Japão e Austrália.

4 METODOLOGIA PROPOSTA

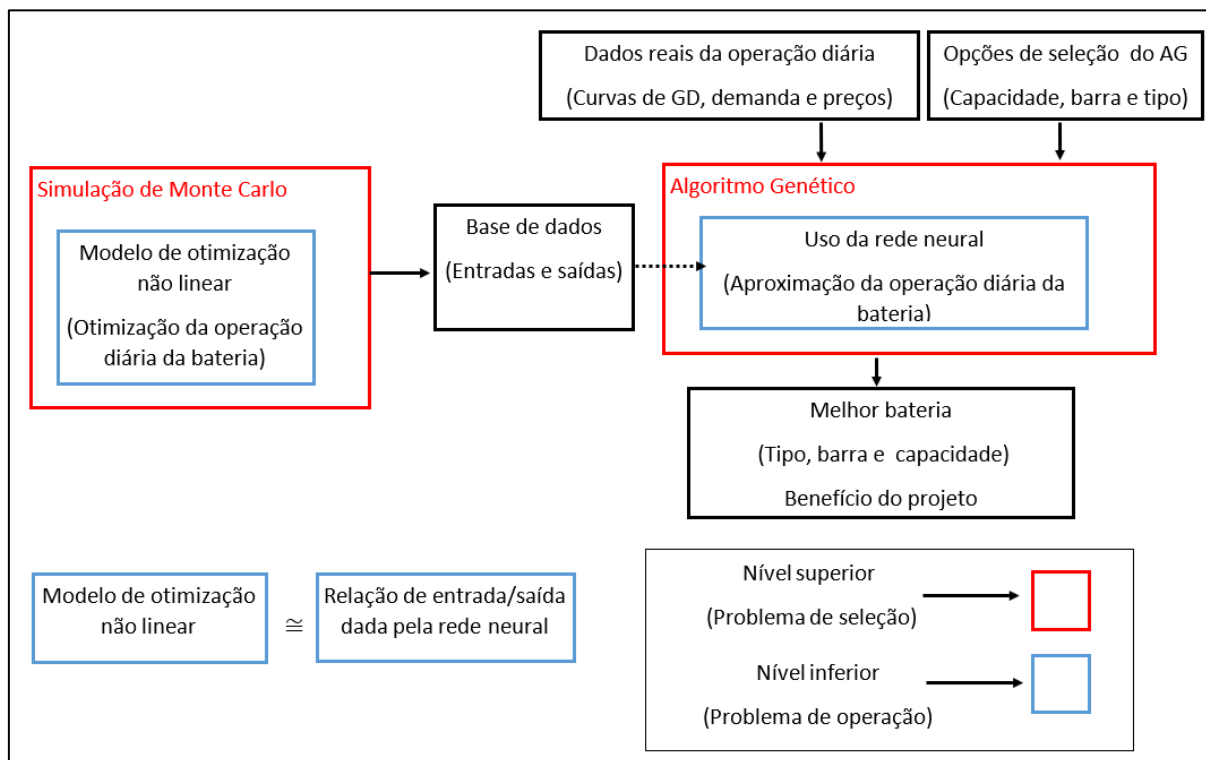
A tese proposta trata tanto o problema de seleção como o problema de operação da bateria. Supondo a compra da bateria com capacidade, tipo e barra determinados durante um horizonte de planejamento, o problema de seleção analisa o benefício econômico e técnico obtido no longo prazo. Nesta tese, o longo prazo considera a sequência de dias que forma o ano com base em dados reais. Já o problema de operação determina, dada a bateria com capacidade, tipo e barra de alocação especificados, sua estratégia de carga e descarga. A estratégia de operação está sujeita as condições de operação do dia em termos de demanda, preços e fornecimento da GD. Assim, tem-se dois níveis principais de solução (superior), o nível de seleção e o nível de operação (inferior).

No problema de seleção são empregados algoritmos genéticos (AG) para avaliar as diferentes alternativas de compra da bateria tendo como entradas o tipo, capacidade, e a alocação no sistema. No problema de operação é empregado um método de otimização não linear para determinar o regime de operação da bateria, permitindo avaliar o desempenho obtido pelas entradas do AG no horizonte de longo prazo.

Como o processo de otimização é não linear, considerando as características do sistema de distribuição e fluxo de carga, que tornam lenta a resolução do problema de operação, propôs-se uma aproximação dos resultados por meio de uma relação entrada saída mediante redes neurais. Assim, para determinação da solução do problema de operação, ao invés de empregar um método de otimização não linear, é utilizada a rede neural como avaliadora do desempenho da operação diária, em termos de custos, níveis de tensão e desgaste da bateria.

Para gerar a base de dados da rede neural é necessário saber, dada as opções de seleção que existem da bateria (tipo, barra, capacidade), e dada as curvas de geração, demanda e preços do sistema elétrico, as variáveis relativas aos custos, níveis de tensão e perdas na rede e o desgaste do armazenador pela sua operação. Visto que, analisar todas as possíveis formas de operação diárias para cada entrada implicaria uma quantidade elevada de dados, para reduzir este tamanho é aplicada a simulação de Monte Carlo. A simulação de Monte Carlo permite determinar uma amostra representativa dos dados de modo que não é afetada a qualidade dos resultados obtidos nas redes neurais modeladas. A base de dados permite também, determinar casos críticos em termos de prejuízo econômico e níveis de tensão. A descrição do modelo se mostra na Figura 3.

Figura 3 – Representação do método proposto.



Fonte: Autor.

A Figura 3 mostra a divisão do método em quatro processos principais. Dois processos são de nível superior (simulação de Monte Carlo e algoritmo genético) e dois deles são de nível inferior (a otimização não linear da operação da bateria e uso da rede neural). Considerando isto, a ordem dos processos do método proposto é descrita a seguir.

Simulação de Monte Carlo: determina a base de dados que relaciona as entradas com as saídas.

Otimização não linear da operação da bateria: define a estratégia de carga e descarga da bateria, considerando os dados da operação do sistema, baseada nas curvas diárias de geração, demanda e preços.

Algoritmo Genético: define a capacidade, tipo e barra de alocação da bateria que apresenta o melhor benefício no horizonte de planejamento.

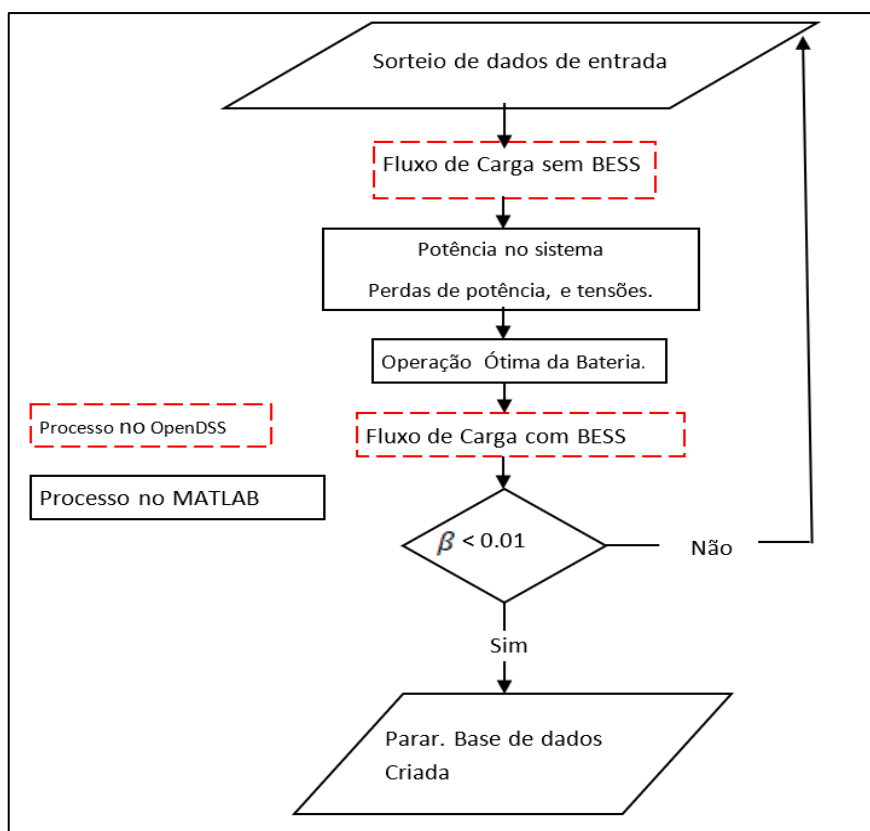
Desenvolvimento e uso da rede neural: partindo da base de dados, se determinam os casos críticos da seleção da bateria em termos de prejuízos econômicos e níveis de tensão. Após a filtragem de dados é gerada a rede neural. O uso da rede neural aproxima os resultados obtidos da operação diária do armazenador com base no seu tipo, capacidade e barra de localização.

Desta forma, para cada curva de preço, GD e demanda são obtidos os custos, perdas e níveis de tensão do sistema, e o desgaste da bateria.

4.1 SIMULACAO DE MONTE CARLO

A determinação do desempenho final da bateria ao longo do tempo de planejamento é condicionada às características de seleção da bateria e as curvas de operação do sistema diário. O desempenho do projeto está quantificado pelos custos, perdas, níveis de tensão do sistema e o desgaste da bateria. Analisar os 365 dias do ano para o grupo de alternativas de seleção da bateria incrementa o tempo de solução do problema. No entanto, a simulação de Monte Carlo permite reduzir o tamanho da base de dados ao determinar uma amostra significativa. A Figura 4 mostra o fluxograma da simulação de Monte Carlo considerando a operação ótima da bateria (processos de nível inferior).

Figura 4 – Simulação de Monte Carlo.



Fonte: Autor.

Na Figura 4 se observa que o começo do método é dado pelo sorteio inicial dos dados de entrada. Neste caso, os dados de entrada são as possíveis opções de capacidade, tipo e alocação na rede da bateria e as curvas de preço, demanda e GD que influenciam na determinação do desempenho diário. Todas as entradas são sorteadas com distribuição probabilística uniforme e inteira. Partindo destas entradas é calculado o fluxo de carga inicial no OpenDSS, onde é possível determinar o estado do sistema sem a bateria em termos de níveis de tensão, perdas, custos e injeção de potências. Com estes parâmetros, se determina a operação ótima do armazenador considerando um modelo de otimização não linear que será descrito na seção 4.2. A otimização não linear é um processo de nível inferior, que permite parametrizar o estado de carga e descarga da bateria no OpenDSS. Após a parametrização, é realizado o fluxo de carga com a bateria inserida no sistema para determinar o desempenho diário do armazenador. Este processo é repetido até obter um número significativo dos dados garantindo por um baixo valor do coeficiente de variação β .

A determinação do tamanho da população suficiente para garantir a amostra representativa dos dados é descrita a seguir. Durante cada iteração é calculado a estimativa do valor esperado $\hat{E}(F)$ do custo total do sistema $F(x)$ (função de teste) para o estado do sistema x_i (Dados de entrada sorteados) com base no número de cenários N (DA SILVA et al., 2007; PEREIRA et al., 1992):

$$\hat{E}(F) = \frac{1}{N} \sum_{i=1}^N F(x_i) \quad (1)$$

partindo-se deste valor calcula-se a variância amostral $\hat{V}(F)$ por meio de (PEREIRA et al., 1992):

$$\hat{V}(F) = \frac{1}{N-1} \sum_{i=1}^N [F(x_i) - \hat{E}(F)]^2 \quad (2)$$

Na equação (2) se observa que a incerteza na estimativa do valor esperado, a qual é medida pela amplitude da variância, é inversamente proporcional ao tamanho da amostra. Desta forma, o critério de parada da simulação é baseado no coeficiente de variação β determinado por (PEREIRA et al., 1992):

$$\beta = \frac{\sigma(\hat{E}(F))}{\hat{E}(F)} = \sqrt{\frac{V(\hat{E}(F))}{\hat{E}(F)^2}} \quad (3)$$

sendo que um valor baixo de β garante um maior intervalo de confiança e por tanto uma melhor representação dos dados. Partindo da equação anterior, tem-se que N é (PEREIRA et al., 1992):

$$N = \frac{\hat{V}(F)}{\beta \hat{E}(F)^2} \quad (4)$$

Nesta forma é possível identificar um valor aproximado do número de iterações necessárias para chegar ao valor esperado conforme o nível de confiança estabelecido. Assim, são realizados os sorteios das entradas até cumprir o critério de parada para a criação da base de dados.

4.2 DETERMINAÇÃO DA OPERAÇÃO ÓTIMA DO ARMAZENADOR

Para determinar o modo de operação do armazenador, primeiro é calculado o fluxo de carga no sistema no OpenDSS, determinando o valor final da carga e o valor da geração obtida por hora. Neste modelo de mercado, a distribuidora é a proprietária da bateria e gerencia a operação da GD instalada da rede. Assim, a oferta da GD pela distribuidora se dá por meio de uma cooperativa de gerações onde o consumidor paga o serviço diretamente a esta cooperativa (ANEEL, 2016).

Dado que a distribuidora é a proprietária da bateria, o lucro obtido da venda de energia aos consumidores, é interpretado como uma redução do custo da energia que é injetada da subestação. Assim, o objetivo do modelo é a redução de perdas e custos operativos C^{DOP} representados por:

$$\min \left[\sum_{i=1}^{24} C_{loss_i} P_i^{Loss} \Delta t_i + \sum_{i=1}^{24} C_{DN_i} P_i^{DN} \Delta t_i - C_{DN24} E_{24}^{BESS} \right] \quad (5)$$

sendo C_{loss_i} o custo das perdas (% associado a tarifa), C_{DN_i} o custo da energia na hora i , P_i^{Loss} as perdas de potência na hora i , e P_i^{DN} a potência na subestação. Além disto, no modelo é avaliada a capacidade da bateria para ofertar energia ao dia seguinte, considerando a reserva de energia no último horário do dia. Esta capacidade de venda de energia é determinada pelo preço estimado do dia seguinte C_{DN24} e a energia armazenada ao fim do dia E_{24}^{BESS} . Neste trabalho propôs-se o valor do preço do dia seguinte pela seguinte equação:

$$C_{DN24} = \frac{\max(C_{loss_i} + C_{DN_i}) - \min(C_{loss_i} + C_{DN_i})}{2} \quad (6)$$

A formulação em (6) foi determinada após comparar os resultados obtidos com o preço máximo e o preço mínimo do dia. Ao usar o preço máximo se cria uma expectativa muito alta

para venda no dia seguinte, causando uma baixa reserva de energia ao fim do dia. Analogamente usar o preço mínimo estabelece uma expectativa baixa de retorno, causando um incremento da reserva ao fim do dia. A formulação de (6) mostrou um resultado menos tendencioso ao estabelecer um ponto médio entre estes dois limites.

A restrição do balanço de potência é dada por (XIAO et al., 2016):

$$P_i^{DN} = P_i^L - P_i^{DG} \pm P_i^{BESS} + P_i^{Loss} \quad i = 1 \dots 24 \quad (7)$$

onde P_i^{DN} é a potência na subestação, P_i^L é a potência da carga na hora i , P_i^{DG} é a potência injetada pela geração distribuída, e P_i^{Loss} são as perdas de potência no sistema determinadas pelo OpenDSS. A potência absorvida/injetada do armazenador é P_i^{BESS} sendo que valores positivos significam carregamento (incremento da carga) e valores negativos significam descarga. A bateria é restrita operativamente por:

$$0,2 < SOC_i^{BESS} < 0,9 \quad i = 1 \dots 24 \quad (8)$$

$$SOC_i^{BESS} = \frac{E_i^{BESS}}{CE^{BESS}} \quad (9)$$

$$P_i^{BESS} \leq CP^{BESS} \eta_{d,c} \quad (10)$$

a restrição (4) garante que o estado de carga ou SOC (*State of Charge*) da bateria não supere 90% ou seja inferior a 20% de modo que a vida útil da bateria seja prolongada (ATWA et al. 2010), onde E_i^{BESS} é a energia armazenada durante a hora i e CE^{BESS} é a capacidade de armazenamento de energia máxima da bateria. A potência de injeção/absorção da bateria é limitada pela eficiência de carga/descarga $\eta_{d,c}$ e a máxima capacidade de potência da bateria CP^{BESS} .

As baterias possuem uma capacidade de armazenamento e descarga por períodos longos de tempo, assim como uma rápida resposta para a operação (LUO et al., 2015).

A capacidade de energia total dos armazenadores que podem ser descarregadas ou carregadas CP^{BESS} é dividida para cada armazenador usando a seguinte equação (SEPULVEDA et al., 2018):

$$CP^{BESS} = \frac{CE^{BESS}}{T^{BESS}} \quad (11)$$

tal que T^{BESS} é a duração máxima em horas em que o armazenador pode estar em descarga. O tempo de vida do armazenador será considerado na Seção 4.4.

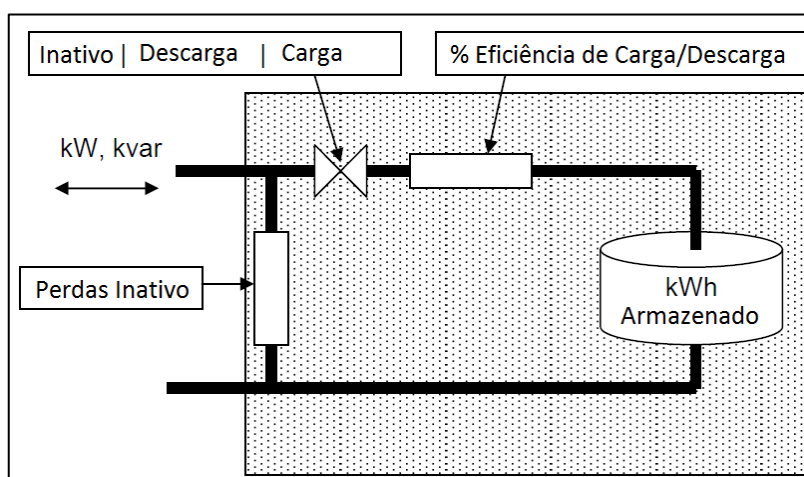
Após determinar o valor de P_i^{BESS} que minimiza a função objetivo de (5) é realizada a parametrização da curva de operação diária da bateria no OpenDSS para o cálculo do fluxo de

carga, que permite determinar os valores diários das perdas, custos, e níveis de tensão no sistema.

4.2.1 Conceitos para parametrizar a bateria no OpenDSS

Para realizar o fluxo de potência foi empregado o software OpenDSS da *Electric Power System Research (EPRI)* por ser um programa recomendado pela Agência Nacional de Energia Elétrica (ANEEL) para análise dos sistemas de distribuição (ANEEL, 2014). Neste software, um elemento armazenador como a bateria é modelado como um gerador que pode ser despachado para produzir energia (estado de descarga) ou consumir energia (estado de carga). Considera-se na operação as capacidades de injeção de potência e de armazenamento de energia da bateria. A bateria pode atuar independentemente ou ser controlada por um elemento controlador de armazenador (DUGAN, 2012). O modelo usa um fluxo de potência conforme os parâmetros do sistema para computar com o estado escolhido de controle do armazenador, como se observa na Figura 5.

Figura 5 – Conceito do Armazenador no OpenDSS.



Fonte: (DUGAN, 2012).

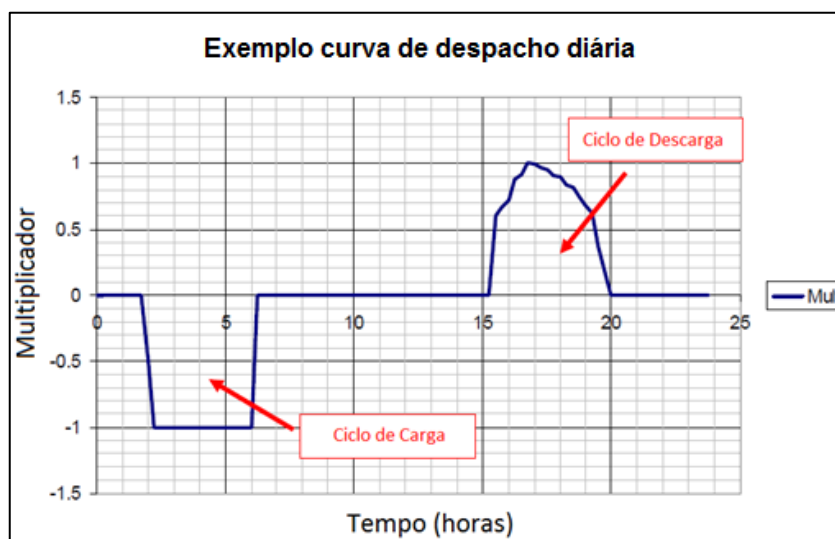
A Figura 5 apresenta três possíveis estados da bateria: carga, descarga e inativo. Deve-se salientar que só pode existir um estado de descarga se o nível de carregamento parametrizado é maior que o nível de energia reservado. Além disto, o OpenDSS permite a simulação em diferentes horizontes de estudo como diário, anual ou transitório. Nestes casos, dependendo do tempo de estudo o armazenador pode ser parametrizado por minutos ou horas de operação. A bateria tem como parâmetros: capacidade de armazenamento, eficiência, capacidade de

descarga, eficiência de carga e descarga, taxa de carregamento e descarga, perdas em estado inativo, injeção ativa ou reativa, nível de tensão e fator de potência (DUGAN, 2012).

Um fator importante é o reconhecimento das perdas, as quais são associadas tanto às eficiências de carga e descarga como as perdas em estado inativo. As perdas em estado inativo representam a energia requerida pelos controles internos em ordem de manter a temperatura adequada do armazenador. As perdas são modeladas como uma impedância constante em paralelo com o sistema de potência e com valor de 1%. Nos estados de carga e descarga o armazenador é normalmente modelado como um modelo PQ constante, considerado no presente trabalho. Deve-se salientar que o OpenDSS também permite uma modelagem de impedância constante.

Uma forma de estabelecer os estados de carga e descarga do armazenador durante cada hora, é configurando seu estado para trabalhar conforme uma curva de operação. Desta forma, é possível estabelecer a quantidade de energia que pode ser fornecida ou absorvida durante o dia (DUGAN, 2012). A Figura 6 mostra um exemplo destas curvas empregadas no software, onde o valor negativo indica o ciclo de carga e o positivo o ciclo de descarga. A operação da bateria no trabalho proposto se determina pela configuração da curva de operação da Figura 6. A curva será diferente para cada dia conforme as curvas de preços, demanda e geração presentes no sistema (DUGAN, 2012).

Figura 6 – Exemplo de curva de operação do armazenador no OpenDSS.

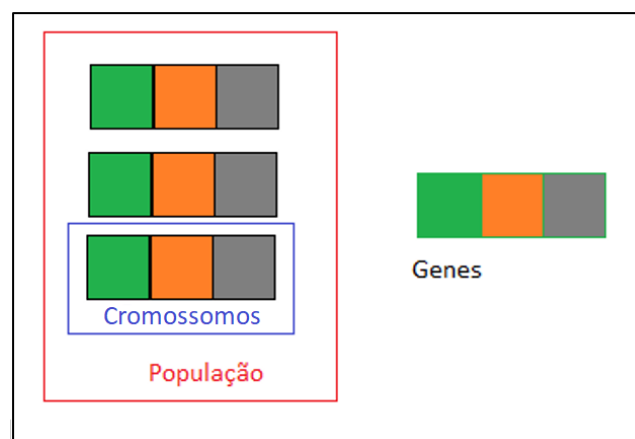


Fonte: (DUGAN, 2012).

4.3 ALGORITMO GENÉTICO

O algoritmo genético é um algoritmo de busca heurística baseado em conceitos evolutivos como seleção natural e genética, que explora um processo de busca inteligente para resolução de problemas. A metodologia funciona inicialmente com a criação de soluções randômicas formadas por um grupo de indivíduos (População). Neste modelo o indivíduo está codificado por um vetor de componentes que definem as opções de decisão. Supondo que o indivíduo fosse um cromossomo e cada componente um gene, a solução é um cromossomo formado por um grupo de genes (DAVIS L, 1991). A Figura 7 mostra esta representação.

Figura 7 – Representação do grupo de soluções.




Fonte: Autor.

Na Figura 7 se pode observar a população (retângulo em vermelho) formada por um grupo de cromossomos (retângulo em azul). Os cromossomos estão conformados por genes representados nos retângulos de cor verde, laranja e cinza, respectivamente. Para este modelo os genes representam, a capacidade da bateria, a barra de localização e o tipo respectivamente. A cada indivíduo é atribuído um valor de aptidão, que vai determinar quão competente é para se reproduzir em gerações futuras. Existem 3 etapas que determinam solução do problema, seleção, cruzamento e mutação (DAVIS L, 1991).

Na seleção o indivíduo mais apto passa seus genes para a geração seguinte. No cruzamento dois indivíduos são selecionados da população por um operador de seleção (neste modelo o torneio binário) e são cruzados selecionando aleatoriamente parte dos genes de ambos os indivíduos. A descendência criada passa a ser parte da população da seguinte geração. A Figura 8 mostra o processo de seleção (DAVIS L, 1991).


Figura 8 – Obtenção da descendência de dois indivíduos aptos.



Fonte: Autor.

Na mutação são introduzidas modificações aleatórias onde, com uma baixa probabilidade, uma parte dos genes do indivíduo é modificada. A Figura 9 representa isto.

Figura 9 – Mutação.



Fonte: Autor.

Assim, para a implementação do algoritmo genético, os resultados obtidos na rede neural (nível inferior) são avaliados de modo a calcular a função de aptidão, cujo objetivo é maximizar o lucro do projeto com o armazenador. Este lucro é quantificado como o benefício obtido pelo uso do armazenador na redução do custo do sistema inicial (sem bateria e com GD). Por exemplo, supondo que o custo sem a bateria tem um valor de 5, e com o uso da bateria o custo final foi de 3, o benefício obtido (pela redução do custo) foi de $5-3=2$. Desconta-se deste benefício os custos da compra, manutenção e substituição do sistema de armazenamento. A função de aptidão é dada por:

$$Fit = \max (C_0^{In} - C_0^{YOP} - C_0^{BESS} - Pen) \quad (12)$$

em que C_0^{In} , e C_0^{YOP} são os valores presentes dos custos de operação anual sem e o armazenador com o uso da bateria respectivamente. O valor presente do custo da bateria é C_0^{BESS} . A variável Pen penaliza se o sistema resultante excede os limites de tensão permitidos na operação do sistema ou se os custos das perdas do sistema são incrementados após colocar a bateria. Para o

modelo proposto os limites de tensão são determinados na faixa de 0,95 até 1,05 conforme (XIAO et al., 2016). O custo de operação anual do sistema com a bateria é dado por:

$$C^{YOP} = \sum_{j=1}^{365} C_j^{DOP*} \quad (13)$$

sendo C_j^{DOP*} a aproximação da rede neural ao custo de operação diário otimizado em (5). Desta forma, a rede neural é utilizada como avaliador do algoritmo genético ao invés do modelo de otimização não linear, reduzindo o esforço computacional.

O custo associado à compra, manutenção, operação e substituição do armazenador é representado por:

$$C_0^{BESS} = C_0^{AOM} + C^{INV} + C_0^{Subs} \quad (14)$$

no qual C_0^{BESS} é o valor presente do custo do armazenador, C_0^{AOM} é o valor presente do custo de operação e manutenção do armazenador, C^{INV} o custo inicial de investimento do armazenador, e C_0^{Subs} o valor presente do custo de substituição da tecnologia que dependerá da vida útil do mesmo (SEPULVEDA et al., 2018). Assim, dependendo do tipo de armazenador o valor de C_0^{Subs} é:

$$C_0^{Re} = \sum_N^{NRE} \frac{C_{Subs}}{(1 + Ds)^{N*Lf}} \quad N = 1,2,3 \dots NRE \quad (15)$$

em que C_{Subs} é o valor inicial do custo de substituição, Ds a taxa de desconto, e NRE o número de substituições do armazenador empregando (SEPULVEDA et al., 2018):

$$NRE = \frac{T}{Lf} \quad (16)$$

sendo T é o período de estudo e Lf é a vida útil do armazenador em anos.

No caso das baterias, a vida útil dependerá de fatores como tipo, ciclos de operação e profundidade de descarga (LUO et al., 2015). A vida útil da bateria é determinada por (MANWELL et al., 1998):

$$Lf = \frac{1}{Des} \quad (17)$$

em que Des é o desgaste da bateria, associado aos ciclos de operação da bateria. O uso da bateria em dependência da variabilidade da geração renovável e dos preços, faz com que os ciclos de operação diária sejam irregulares, (diferentes picos e diferentes taxas de carregamento/descarga durante o dia). Considerando isto, é utilizado o método *rainflow counting technique* (NIESLONY, 2003; RYCHLIK I, 1987) para contagem dos ciclos de

descarga parciais. Existe também uma relação entre o número de ciclos utilizados da vida útil LC e a profundidade de descarga, que é dado por (MANWELL et al., 1998; XIAO, 2016):

$$LC = a_1 + a_2 * e^{a_3 * FDOD} + a_4 * e^{a_5 * FDOD} \quad (18)$$

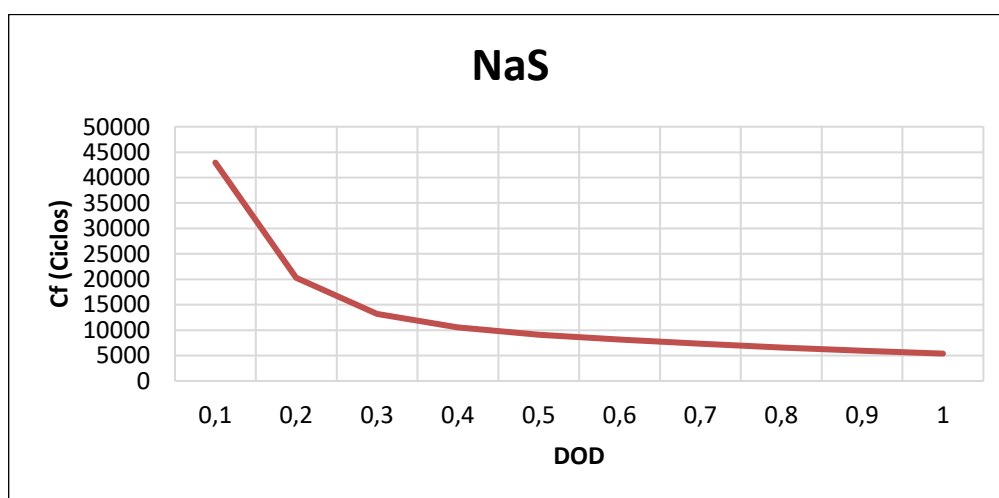
na qual a_n são os coeficientes determinados por um método de ajuste de curvas dadas por fabricantes para cada tipo de bateria e $FDOD$ é a profundidade de descarga parcial do armazenador (determinada pelo *rainflow counting technique*) (RYCHLIK, 1987). A maneira de exemplo, supondo que existem N_{ck} ciclos até 15 profundidades de descarga fracionais variando entre 0,1 a 0,8 (10% até 80%), e que para conjunto de descargas diário existe um número de ciclos utilizados da vida útil LC , tem-se (MANWELL et al., 1998; XIAO, 2016):

$$Des = \sum_{k=1}^{15} N_{ck} \frac{1}{(LC)} \quad (19)$$

se para o anterior $Des = 0,25$ significa que ao final do ano, 1/4 da vida da bateria foi usada, pelo que seriam necessários 4 anos para mudar o equipamento. Assim, quando o valor do desgaste é igual a 1, interpretasse que a bateria tem se utilizado completamente (gasto todos os ciclos de operação) e deve ser trocada.

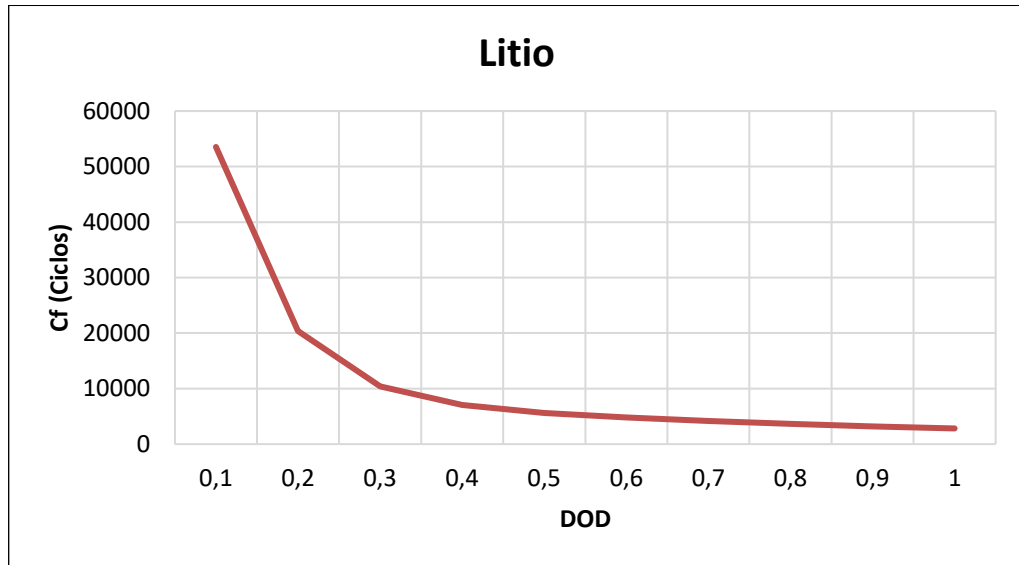
Deve-se salientar que alguns tipos de bateria como as de fluxo (VRFB) têm um ciclo de vida fixo, independente do DOD (IRENA, 2015). Para uma melhor observação, as Figuras 10, 11, 12 e 13 mostram as curvas de ciclo de vida para os tipos de bateria empregados no modelo.

Figura 10 – Curva de Ciclo de Vida da Bateria de NaS.



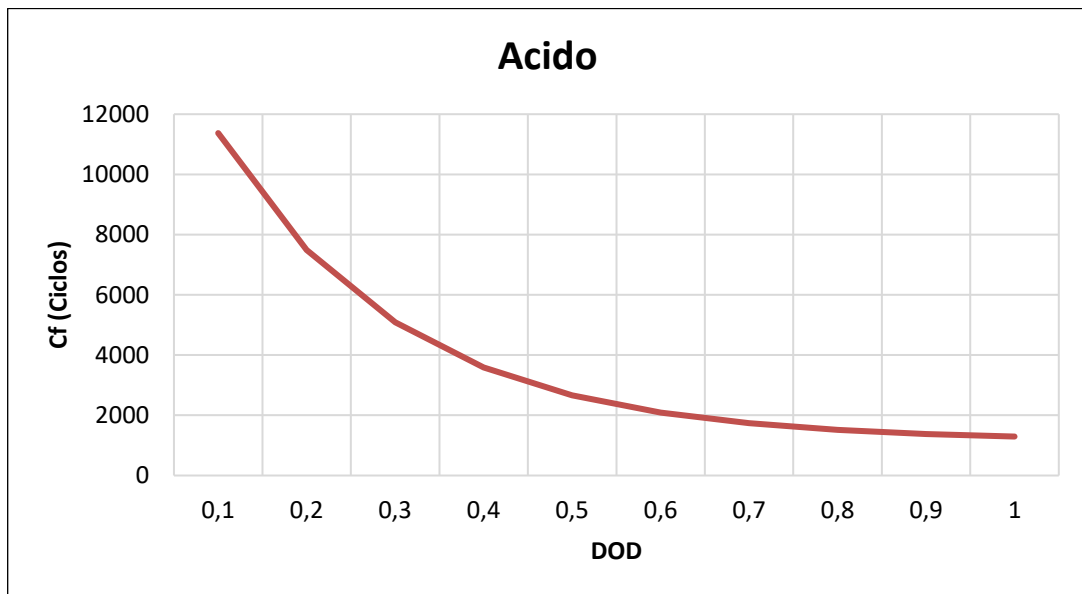
Fonte: (Blonbou, et al., 2013).

Figura 11—Curva de Ciclo de Vida da Bateria de Lítio.



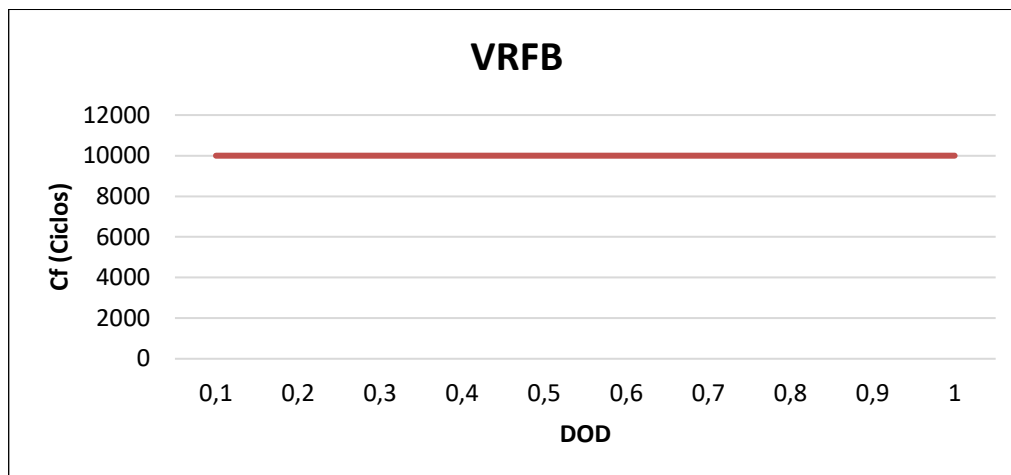
Fonte: (Millner et al., 2010).

Figura 12—Curva de Ciclo de Vida da Bateria de Chumbo-Ácido.



Fonte: (Drouilhet et al., 1997).

Figura 13—Curva de Ciclo de Vida da Bateria VRFB.



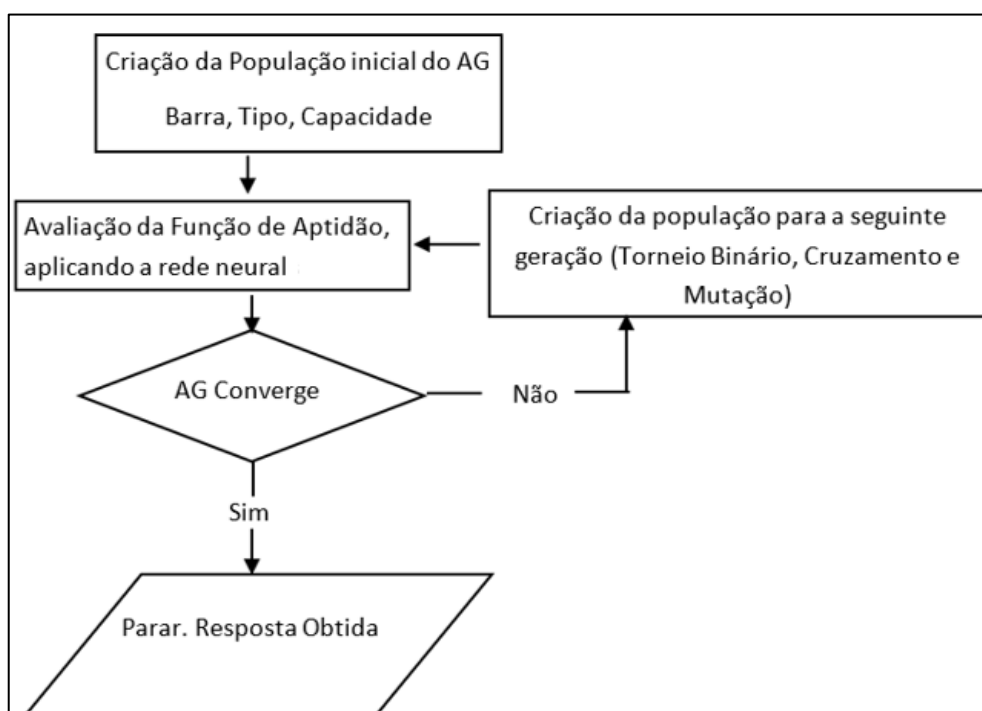
Fonte: (IRENA, 2015).

O valor presente do Custo de operação e manutenção AOM é dado por:

$$C_0^{AOM} = \frac{C^{AOM}}{Ds} * \left(1 - \frac{1}{(1 + Ds)^T} \right) \quad (20)$$

no qual C^{AOM} é o custo de operação e manutenção anual, Ds a taxa de desconto e T o período de estudo. Determinada a formulação da função da aptidão a Figura 14 mostra o processo do algoritmo genético do método proposto.

Figura 14 – Determinação da resposta pelo AG.



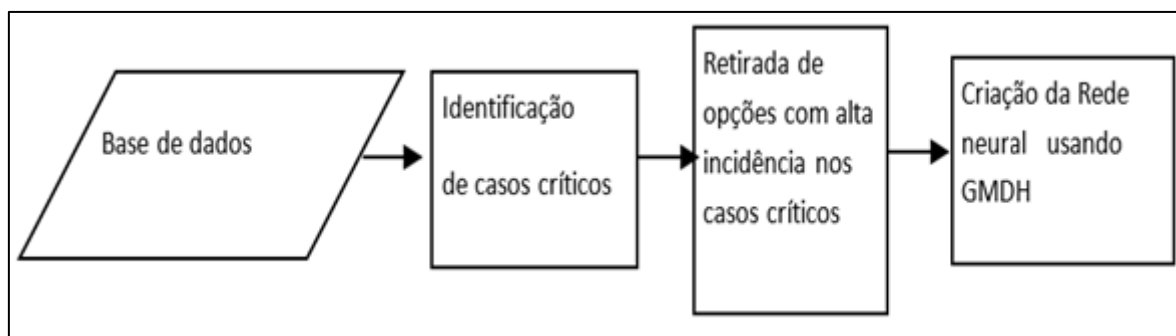
Fonte: Autor.

Na Figura 14 o algoritmo genético empregado utiliza uma representação inteira dos cromossomos. Cada cromossomo indica a capacidade, o número da barra e o tipo de armazenador. Cada população passa por um processo de seleção usando um torneio binário, um cruzamento e uma mutação. A função de aptidão é determinada com base na avaliação do desempenho diário da bateria com base na rede neural (nível inferior). O algoritmo genético tem dois critérios de parada. O primeiro é determinado pela melhoria da função de aptidão a cada geração. Se a função de aptidão não mostra uma melhoria, significa que se mantém fixa dentro de um mesmo valor para um determinado número de gerações, assim o algoritmo chega numa convergência. Por outro lado, se durante este processo a função de aptidão permanece mudando a cada geração, o algoritmo genético determina como critério de parada um máximo número de gerações. Quando o primeiro desses critérios for alcançado, o algoritmo termina sua execução e a população final com o melhor resultado é apresentada.

4.4 DESENVOLVIMENTO DA REDE NEURAL

O processo de desenvolvimento da rede neural está mostrado na Figura 15.

Figura 15 – Desenvolvimento da rede neural.



Fonte: Autor.

Inicialmente, da base de dados do processo de Monte Carlo, são identificados os casos críticos da operação do sistema. Estes casos críticos definem-se para uma opção de seleção da bateria, em termos de capacidade, tipo ou localização, podem-se apresentar problemas na tensão ou de prejuízo econômico, (incremento dos custos após a inserção do armazenador na rede). Com essa identificação é possível determinar a probabilidade de ocorrência de problemas para o conjunto de entradas, e filtrar aquelas entradas que tem uma alta incidência nestes problemas.


Desta forma para gerar a rede neural, são retirados da base de dados as opções de entrada com alta incidência nos casos críticos. Da base de dados resultante, gera-se a rede neural.

A relação entrada/saída da rede neural é modelada empregando a abordagem *Group Method of Data Handling* (GMDH). Este modelo utiliza um treinamento supervisionado, onde se realiza uma aproximação polinomial das entradas com as saídas. Para cada neurônio a saída Y_{ij} é expressa em função de suas entradas pela seguinte equação (DA SILVA, 2007; BUENO, 2011):

$$Y_{ij} = A_{ij} + B_{ij}x_i + C_{ij}x_j + D_{ij}x_i^2 + E_{ij}x_j^2 + F_{ij}x_ix_j \quad (21)$$

sendo x_i e x_j as entradas, e A , B , C , D , E e F são os coeficientes polinomiais equivalentes aos pesos da rede. O modelo do neurônio se mostra na Figura 16.


Figura 16 – Modelo do Neurônio.



Fonte: (Da Silva et al., 2007).

Para o treinamento, partindo de cada entrada são construídas as camadas da rede uma por vez. Em cada nova camada, os neurônios são formados pela combinação das variáveis de entrada por pares. A Figura 17 mostra a formação da primeira camada com base nas entradas.

Figura 17 – Formação da primeira camada para a rede de 4 entradas.




Fonte: Autor.

A Figura 17 mostra a criação da primeira camada formada por 4 entradas. Observa-se que para cada neurônio da primeira camada, só existem duas entradas associadas (representadas pelas setas). A função de cada saída Y_{ij} é resolvida usando os mínimos quadrados para determinar os valores dos coeficientes polinomiais da rede (A_{ij} , B_{ij} , C_{ij} , etc.). A qualidade de cada neurônio Y_{ij} é avaliada calculando um índice r_{ij} associado ao erro quadrático médio ou à variância dos erros (valor normalizado) (DA SILVA, 2007; BUENO, 2011):

$$r_{ij} = \frac{\sum_{m=1}^{N_{test}} (y_{ij,m} - z_m)^2}{\sum_{m=1}^{N_{test}} (y_{ij,m})^2} \quad (22)$$

sendo z_m o valor a aproximar pela rede neural, m a m -ésima camada e N_{test} o número total de camadas a testar. Fazendo uma categorização dos valores mínimos e máximos do r_{ij} , é excluído um grupo de neurônios que não apresenta uma boa aproximação dos resultados. Assim, supondo que na Figura 17 os neurônios Y_{14} e Y_{34} tiveram os piores desempenhos, para a criação da seguinte camada só serão considerados os neurônios restantes. A Figura 18 representa a criação da seguinte camada.


Figura 18 – Formação da segunda camada para a rede de 4 entradas.



Fonte: Autor.

A figura 18 mostra a redução da primeira camada pela exclusão dos neurônios com desempenhos baixos. Na criação das camadas seguintes aplica-se o mesmo procedimento. Desta forma, a seleção de estradas relevantes é uma característica importante deste modelo que evita o sobre dimensionamento da rede. Finalmente o processo de criação de camadas é repetido até que o valor do melhor índice r não apresente uma melhoria comparado com o valor da camada anterior. Por exemplo, se para a camada n o índice foi 0,8 e para a camada $n+1$ 4 o índice foi de 0,9, deve-se criar outra camada. Conseqüentemente, se para a camada $n+1$ o índice foi de 0,9, mas para a camada $n+2$ o índice foi 0,7, o processo deve parar na camada $n+1$, determinando o tamanho final da rede. Na camada final escolhe-se a saída com melhor índice r_{ij} como a saída final da rede. A figura 19 mostra a melhor saída na rede com 3 camadas (DA SILVA, 2007; BUENO, 2011).

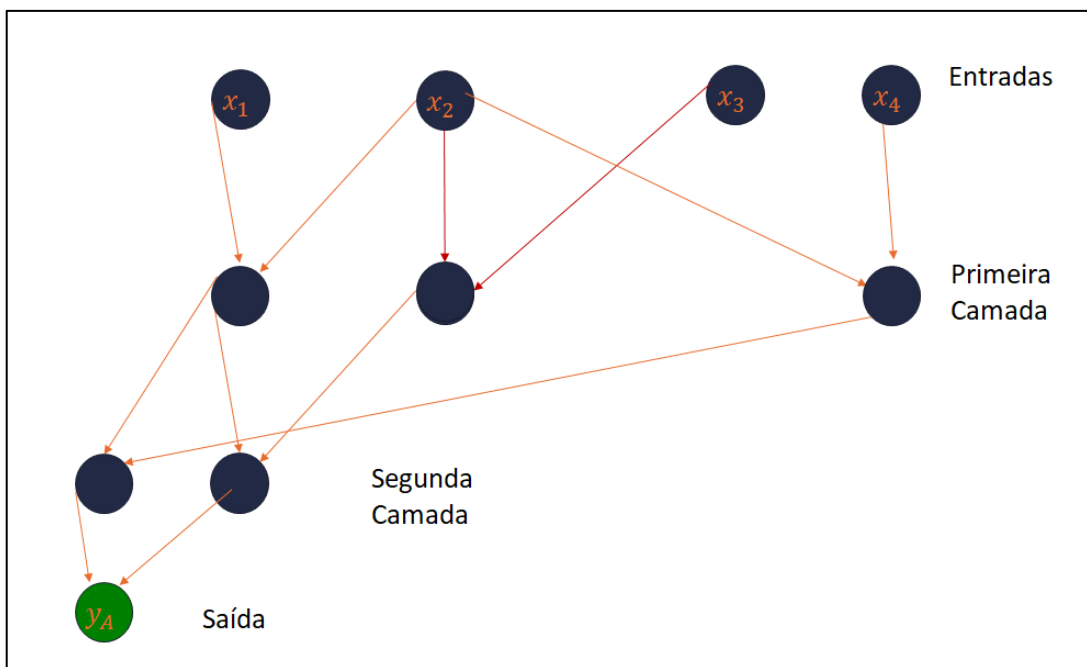
Figura 19 – Escolha da melhor saída na rede de 4 entradas.



Fonte: Autor.

Da Figura 19 observa-se que o neurônio y_A teve o melhor índice r_{ij} na camada. Desta forma a rede neural determina y_A como a saída e exclui todos os caminhos que não chegam nessa saída. A Figura 20 mostra a formação final da rede.

Figura 20 – Formação da rede neural com 4 entradas.

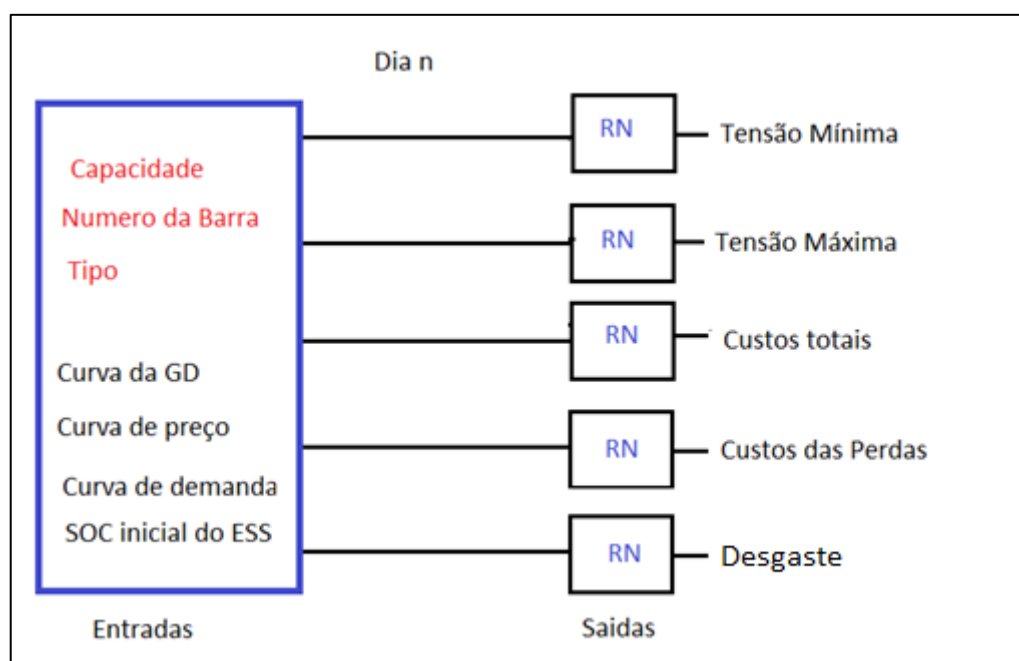


Fonte: Autor

A Figura 20, comprova a redução do tamanho da rede pela exclusão de caminhos com desempenho baixo. Assim para as 4 entradas, as ativações dos neurônios formam um único valor de saída.

Para o desenvolvimento do modelo proposto, foi considerada a operação em paralelo de 5 redes neurais. Neste caso, têm-se um grupo de opções de saída para o conjunto de variáveis de entrada, como mostra a Figura 21.

Figura 21 – Relação das variáveis de entrada e de saída.

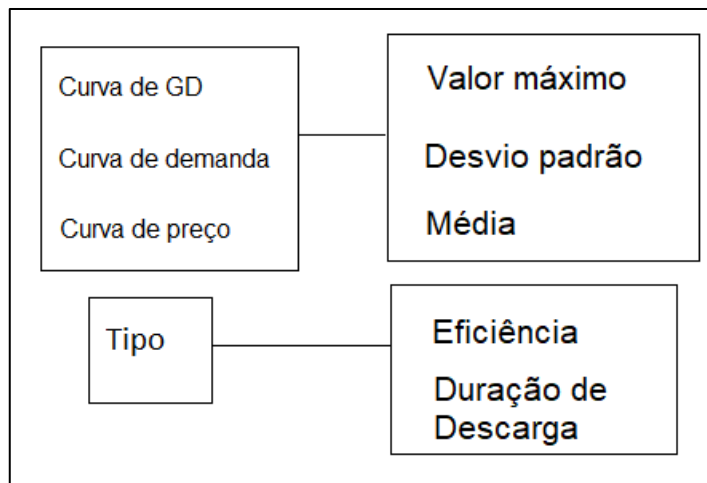


Fonte: Autor.

Na relação da Figura 21 pode-se observar as variáveis de decisão do algoritmo genético (Capacidade, Alocação da Barra, Tipo) e as características que determinam o comportamento diário do sistema (geração, preço e demanda). Além disto, o SOC inicial do BESS é determinado para quantificar a reserva que se terá para o dia seguinte. Partindo destas entradas, é possível determinar: tensão mínima, a tensão máxima, custos totais (tanto das perdas como da operação) e desgaste da bateria (fator determinante para calcular seu tempo de vida). Assim, para avaliar o desempenho anual do projeto com a bateria, considera-se a simulação da sequência dos dias tomados das curvas reais. Deve-se salientar que não é necessário a entrada de todos os valores horários (24 pontos) das curvas do sistema para a aplicação da rede neural. Basta apenas contar com as características mais representativas destas curvas em termos de desvio padrão, média e valor máximo para reduzir o número de neurônios requeridos na

implementação. A Figura 22 mostra as características tomadas para a criação das redes que determinam os custos totais e custos das perdas.

Figura 22 – Características associadas as entradas, para criação da rede neural.



Fonte: Autor.

Como se pode constatar na Figura 11, as saídas da rede neural dependem unicamente dos valores máximos, o desvio padrão e a média das curvas de operação diária sem a bateria. O tipo da bateria é categorizado em sua eficiência e duração de descarga.

4.5 RESUMO DO CAPÍTULO

Este capítulo fez uma descrição da metodologia proposta. Neste caso, apresentou-se 4 processos principais que compõem a metodologia. Inicialmente, foi ressaltada a resolução do problema de seleção e de operação da bateria em dois níveis. O nível superior encarregado da seleção da bateria em termos de capacidade, localização no sistema e tipo de tecnologia. No nível inferior de otimização considerasse a operação diária da bateria, sujeita as condições de demanda, geração distribuída e custos da energia no sistema. Todo procedimento de nível inferior está inserido dentro do nível superior.

Apresenta-se a simulação de Monte Carlo, processo de nível superior utilizado para gerar uma base de dados representativa das entradas. Esta base de dados permite determinar a relação entre as possíveis alternativas de seleção da bateria e seu desempenho diário, em termos de custos, níveis de tensão no sistema e desgaste do armazenador. A avaliação do desempenho diário é dada no nível inferior por um modelo de otimização não linear proposto. Neste modelo,

a formulação da função objetivo está orientada na redução dos custos na subestação pelo uso da bateria.

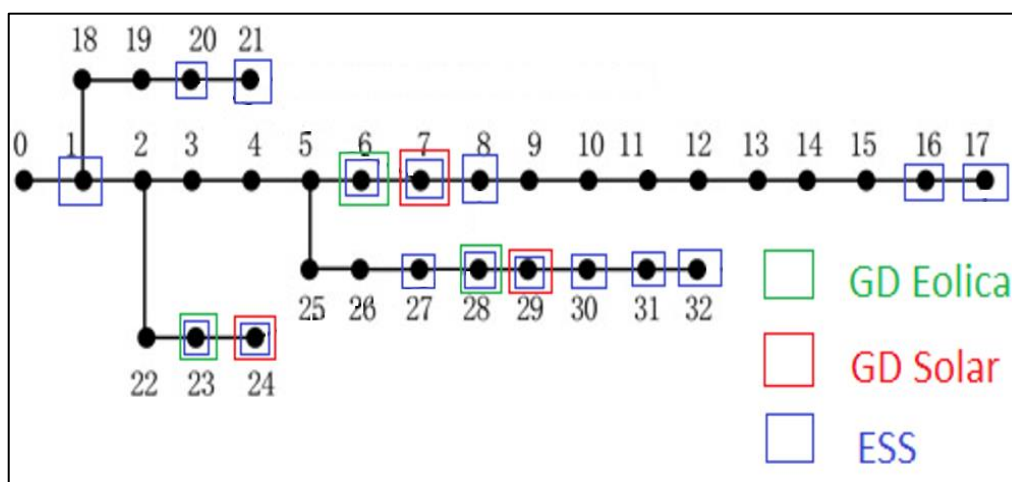
Analogamente, no nível superior utiliza-se o algoritmo genético que permite determinar a melhor resposta da metodologia proposta. Neste caso, as entradas são o tipo, barra e capacidade da bateria, e se avalia o desempenho do projeto de forma diária. O desempenho diário considera as curvas de geração, demanda e preços do sistema, tomando dados reais. Para determinar o sucesso de cada geração determinasse uma função de aptidão baseada no benefício econômico obtido pelo projeto com baterias. Esta função de aptidão penaliza casos de problemas no nível de tensão e perdas. Além disto, considera-se os custos próprios de cada bateria em termos de manutenção, substituição e investimento. Para comparar os tipos de baterias, formula-se a relação entre o ciclo de vida da bateria com a profundidade de descarga. Assim, para analisar os casos em termos do tempo de vida útil, se toma uma sequência de anos. A representação dos anos em termos de preços, demanda e geração no sistema, se toma como a repetição do ano base, que considera os dados reais. Esta representação repetitiva pode ser modificada caso existam mais dados disponíveis para representar futuros anos, afetando o modelo apenas no tamanho da amostragem.

Finalmente, se apresenta o desenvolvimento da rede neural, a qual avalia o desempenho da bateria selecionada no algoritmo genético. Esta avaliação do desempenho é um processo de nível inferior, e considera a relação entre as entradas e as saídas. A rede neural é gerada pela amostra de dados da simulação de Monte Carlo.

5 ESTUDO DO CASO

Para validação, o modelo proposto foi testado no sistema de 33 barras de (XIAO et al., 2016), as curvas de geração, carga, demanda e preços da energia foram tomadas dos dados reais presentes no sistema de distribuição canadense IESO (IESO, 2018) e normalizadas para se adaptar no sistema teste. A carga nominal do sistema testado foi de 2043,25 kW. Foram instaladas 3 fontes solares e 3 fontes eólicas com capacidades de 320 kW cada uma. O modelo permite localizar a barra em qualquer nó do sistema. No entanto, para reduzir o tamanho da amostragem no estudo do caso, somente foram consideradas 17 opções de localização conforme a Figura 23.

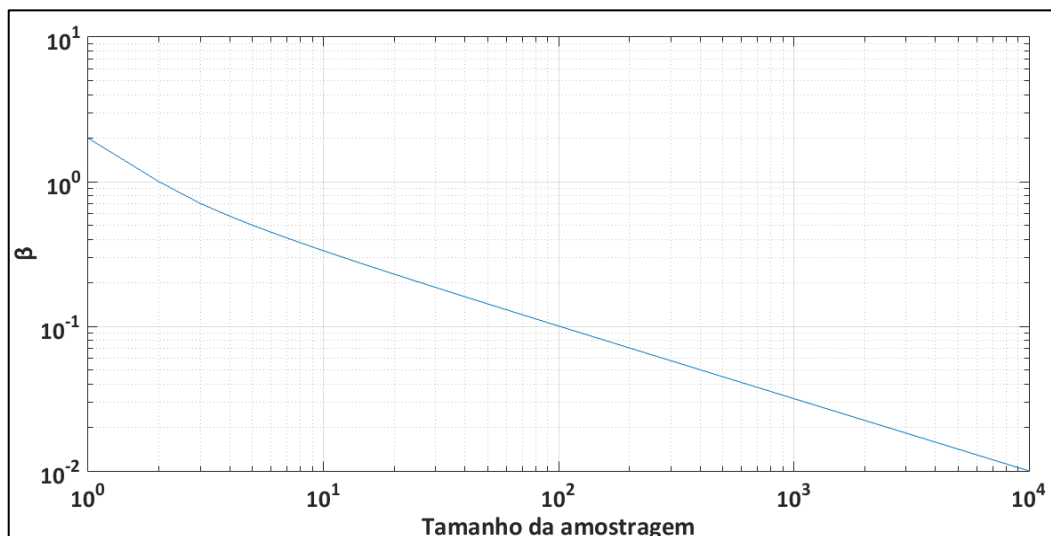
Figura 23 – Sistema Teste.



Fonte: (Xiao et al., 2016)

Na Figura 23 as possíveis localizações da bateria encontram-se perto da geração distribuída e nos pontos extremos da rede. Para a criação da base de dados da rede neural, foi realizada uma simulação de Monte Carlo considerando uma amostra de 10002 dados, obtendo um valor de β de 0,01. A Figura 24 mostra esta relação.

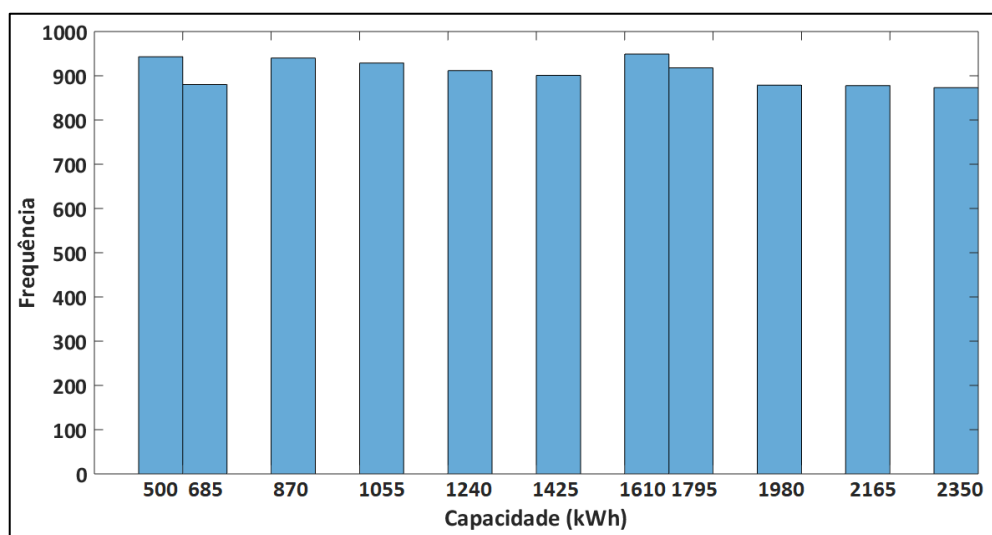
Figura 24 – Determinação do tamanho da população.



Fonte: Autor.

A simulação de Monte Carlo é baseada em sorteios com distribuição probabilística predefinida. Dada a necessidade de entradas com valores inteiros e positivos foi selecionada a distribuição probabilística uniforme. Desta forma, foram realizados 10002 sorteios chegando num valor do beta do 0,01, o qual garante uma boa aproximação do valor esperado. As possíveis entradas para as capacidades da bateria mostram-se na Figura 25.


Figura 25 – Histograma de capacidades de entrada.



Fonte: Autor

Neste caso, tem-se uma variação das capacidades de energia de 500 kWh até 2350 kWh com um passo de 185 kWh totalizando 12 possíveis opções. A distribuição das possíveis barras se apresenta na Figura 26.

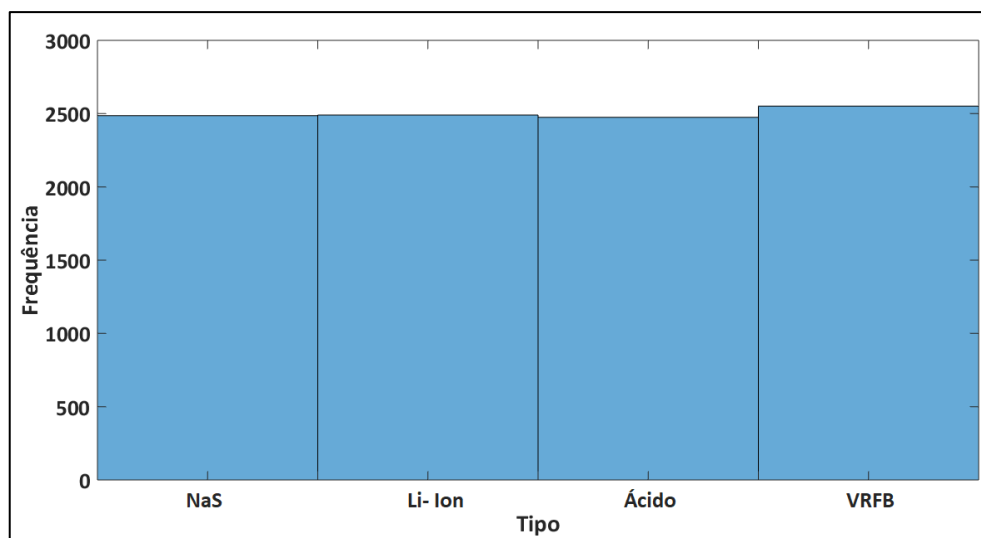
Figura 26 – Histograma de Barras de entrada (Armazenador).



Fonte: Autor.

Os tipos de bateria analisados foram indicados por índices de 1 até 4, representados na seguinte ordem: NaS, Li-íon, Ácido, VRFB. A Figura 27 mostra a distribuição destas entradas.

Figura 27 – Histograma de Tipos (Armazenador).



Fonte: Autor.

Por outro lado, a Tabela 1 mostra as características de cada tipo de bateria.


Tabela 1 – Características de cada tipo de bateria.

Parâmetro	NaS	Lítio-íon	Ácido	VRFB
t_{dn} (h)	8	8	10	12
C^{INV} (\$/kWh)	300	600	200	600
C_0^{Re} (\$/kWh)	300	600	200	600
C_0^{AOM} (\$/kWh)	80	8	50	70
η (%)	85	85	85	82
a_1	-1,28E+01	-1,27E+01	1,16E+03	1,00E+04
a_2	1,07E+05	1,46E+05	-4,28E+03	0,00E+00
a_3	-1,28E+01	-1,27E+01	-7,96E+01	0,00E+00
a_4	1,48E+04	1,01E+04	-1,65E+04	0,00E+00
a_5	-1,01E+00	1,27E+00	4,80E+00	0,00E+00

Fonte: Beaudin et al. (2010), Blonbou, et al. (2013), Drouilhet et al. (1997), IRENA, (2015), Luo et al. (2015), Millner et al. (2010).

Outro ponto a considerar é o estado inicial do SOC da bateria, já que é dependente do estado final do dia anterior. Assim, dado os sorteios se determina para diferentes casos de SOC inicial, o SOC final obtido. A Figura 28 mostra a distribuição do SOC inicial.

Figura 28 – Histograma do SOC inicial.




Fonte: Autor.

Finalmente, para representar o comportamento variável do dia, foram realizados sorteios considerando as 365 possíveis opções da operação diária que representam o ano. Neste caso, cada dia tem em conjunto uma curva de carga, de geração e de preços que estão associadas e baseadas nos dados reais. Para o sorteio foi necessário somente escolher o número indicativo

do dia e utilizar as curvas referenciadas para esse dia. Deste modo o sorteio do dia se representa na Figura 29.


Figura 29 – Histograma da referência do dia de entrada.



Fonte: Autor.

As figuras anteriores demonstraram a distribuição uniforme dos dados de entradas de modo que é possível criar a base de dados representativa da operação ótima diária da bateria. Para mostrar o impacto do modelo de otimização na operação da bateria, a Figura 26 mostra a configuração do preço durante o primeiro dia do ano.


Figura 30 – Preços no dia 1.



Fonte: Autor.

A curva de preço mostra um comportamento quase fixo durante as primeiras horas que muda para valores altos após as 17 horas. Considerando o anterior, foi tomado como exemplo uma bateria localizada na barra 30 com capacidade de energia de 2385 kWh e do tipo 2 (Lítio-ion). O impacto no custo total se mostra na Figura 31.


Figura 31 – Comparação de custos.



Fonte: Autor.


A figura 31 mostra a redução dos custos de acordo com os picos nos preços e as necessidades de demanda. Desta forma, a bateria traz um benefício a rede. As Figuras 32 e 33 mostram o comportamento da bateria de acordo com o impacto de preço em termos da injeção de potência e o SOC. Valores positivos indicam carga, e valores negativos descarga.

Figura 32 – SOC da Bateria.



Fonte: Autor.


Figura 33 – Injeção da bateria.



Fonte: Autor.


Um fato interessante foi que o SOC final chegou ao valor mínimo no fim do dia. O anterior deve-se a configuração dos preços que são elevados no fim do dia, conforme a Figura 27. A modo de verificar este comportamento foi criada uma curva de preços, com valores baixos para o fim do dia. As Figuras 34 e 35 mostram estes preços e o SOC da bateria respectivamente.

Figura 34 – Preços reduzidos ao fim do dia.



Fonte: Autor.

Figura 35 – SOC da bateria para os preços reduzidos ao final do dia.

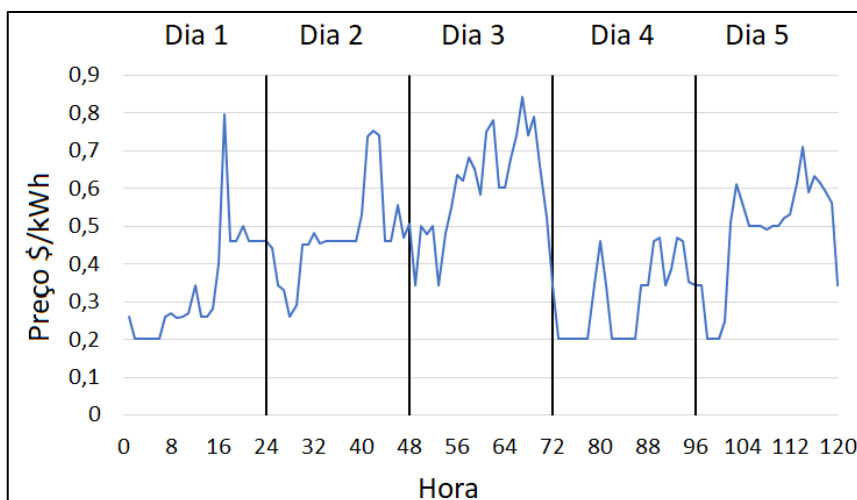


Fonte: Autor

Neste caso, se observa que o SOC da bateria aumenta ao final do dia visto a redução do preço da energia, sendo mais favorável o carregamento para o aproveitamento da energia na venda no dia seguinte.


As curvas de preços e de custos de operação do sistema com a bateria para os primeiros 5 dias se apresentam na Figura 36 e Figura 37. Nota-se nessas figuras que os preços para o início do dia tendem a ser baixos, e os preços ao redor das últimas horas do dia tendem a ser elevados. Assim a tendência da bateria será de descarregar ao fim do dia dados os preços elevados e custo do dia seguinte baixo, o que garante o carregamento. Também, se pode observar uma redução dos custos pelo uso da bateria para cada dia.

Figura 36 – Preços para os primeiros 5 dias.



Fonte: Autor.


Figura 37 – Custos de operação para os primeiros 5 dias.



Fonte: Autor.

A Figura 38 mostra as diferenças entre o custo total do sistema sem a bateria e o custo total obtido com o uso da bateria, para os dias analisados.


Figura 38 – Custos de operação para a primeira semana.



Fonte: Autor.


Na Figura 38 se observa que para os horários onde os preços são maiores, conforme a Figura 27, a bateria tende a proporcionar benefícios no sistema. Também, para o começo dos dias a bateria apresenta um prejuízo justificada pela compra de energia em horários de carga. As figuras 39 e 40 mostram o comportamento do sistema em relação ao custo das perdas.

Figura 39 – Custos das perdas dos primeiros 5 dias.



Fonte: Autor.

Figura 40 – Custos das perdas dos primeiros 5 dias.



Fonte: Autor.

A Figura 39 e Figura 40, mostram uma redução dos custos das perdas, pelo uso da bateria na maioria do dia. Também, ao igual que no caso do custo total, o custo das perdas é reduzido para os horários de preços mais altos. Desta forma, o carregamento da bateria está impactando negativamente nos custos das perdas considerando a capacidade alta da bateria no exemplo tomado. A Tabela 2 resume os custos obtidos para os primeiros 5 dias.

Tabela 2 – Comparação das respostas.

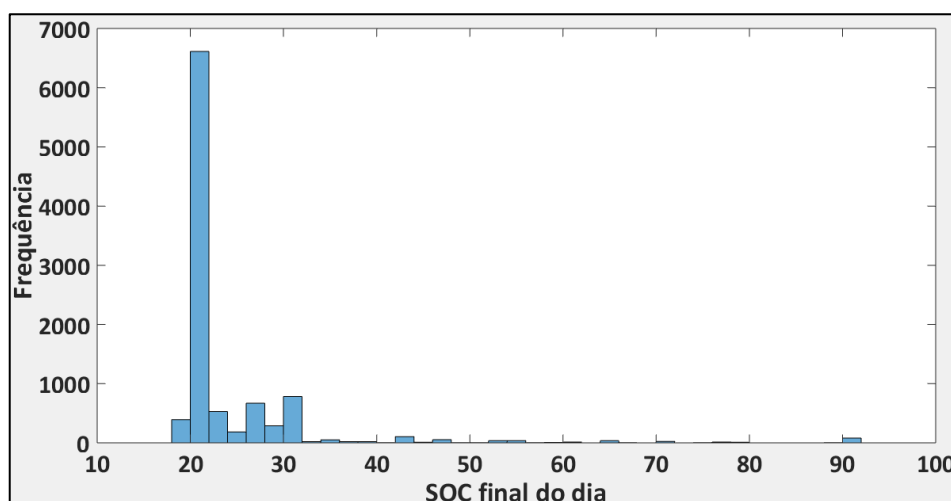
	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Total	Benefício (%)
Custo Totais sem Bateria (\$)	8170	13528	20927	5438	10869	58932	
Custo Totais com Bateria (\$)	7707	13013	20500	4883	10363	56466	4,2%
Custos das Perdas sem Bateria (\$)	5,25	10,05	19,72	2,73	6,56	44,31	
Custos das Perdas com Bateria (\$)	4,92	10,09	19,29	2,74	6,61	43,65	1,5%

Fonte: Autor.

Na Tabela 2 se observa a redução dos custos totais pelo uso das baterias em todos os dias, obtendo um benefício total de 4,2%. Já para os custos das perdas, se observa que nos dias 2, 4 e 5 teve-se um prejuízo pelo uso da bateria, porém, ao considerar o conjunto dos 5 dias, se obteve um benefício total de 1,5%. Esta presença de dias com prejuízos torna importante a determinação dos casos críticos e o uso de penalizações na seleção do armazenador.

Considerando os comportamentos diários, se analisam as saídas obtidas para determinar comportamentos críticos e riscos. A Figura 41 mostra as saídas do SOC obtidas.

Figura 41 – Histograma SOC ao final do dia.




Fonte: Autor.

Segundo a Figura 41, devido a configuração dos preços do sistema estudado, apresentar preços altos finalizando o dia na maioria dos casos, há uma alta probabilidade de que o SOC do final do dia seja menor a 30%. Pode-se afirmar que independentemente do SOC inicial a bateria vai ter uma operação que ao final do dia manterá o SOC até máximo 30%. Este dado será


importante na realização da sequência dos dados anuais para a rede neural. Analisando agora as tensões, as Figuras 42 e 43 mostram as tensões máximas e mínimas obtidas nas simulações.

Figura 42 – Histograma tensão máxima.



Fonte: Autor.

Figura 43 – Histograma tensão mínima.




Fonte: Autor.

Das figuras anteriores se pode observar que a tensão máxima respeita o máximo permitido em todos os casos, mas para a tensão mínima existe um grupo de casos onde a tensão é menor do que a permitida apresentando casos críticos. Neste caso foram obtidos 77 casos com tensão crítica, obtendo assim uma probabilidade de 0,77% de falha para a inserção da bateria. Para identificar se existe alguma tendência na obtenção destes casos críticos foram identificadas as entradas para as quais se obteve estes valores e as características que mais poderiam impactar

neste caso. Pelo tanto, foi determinado que a localização da bateria é um fator determinante nos casos críticos, como mostra a Figura 44.

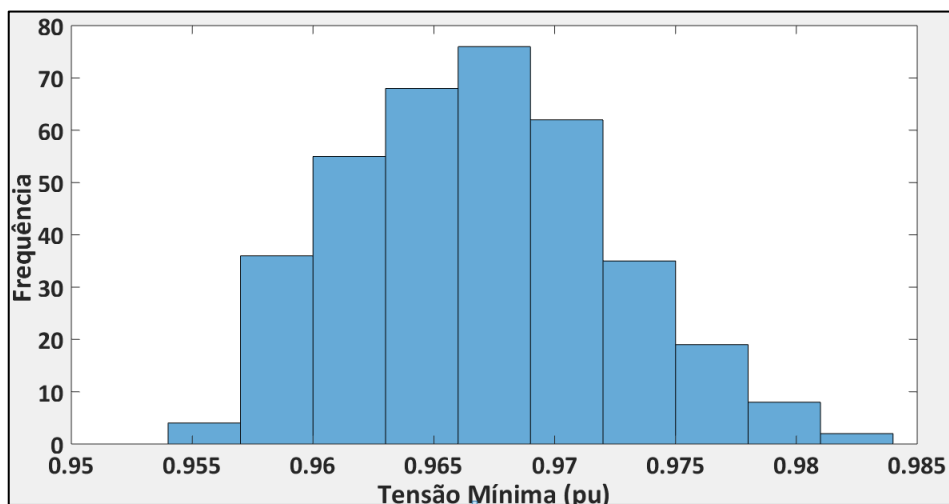
Figura 44 – Histograma das barras de alocação da bateria associadas a tensão.



Fonte: Autor

Da figura anterior, claramente se pode observar que a localização da bateria nas barras 16 ou 17 impacta negativamente o sistema no caso da tensão mínima. Observando a topologia da rede esta tendência pode estar associada as opções estarem localizadas em pontos extremos da rede. Quando a bateria encontra-se sobrecarregando as barras tem-se presença de queda da tensão. A Figura 45 mostra a tensão mínima sem a bateria para comprovar que o problema da tensão é consequência do uso da bateria nos casos críticos.


Figura 45 – Histograma das barras no caso sem bateria.



Fonte: Autor.


Da Figura 45 se pode determinar que sem a bateria não existem casos críticos na tensão no sistema testado. Pelo tanto, a alocação inadequada da bateria na rede é a causa principal dos problemas de tensão. A Figura 46 e a Figura 47 mostram os resultados obtidos com os custos totais e com os custos das perdas. Valores positivos da diferença indicam que se teve um benefício pelo uso da bateria.

Figura 46 – Comparação custos totais ESS VS Caso sem Bateria.



Fonte: Autor.

Figura 47 – Comparação custos das perdas ESS VS Caso sem Bateria.



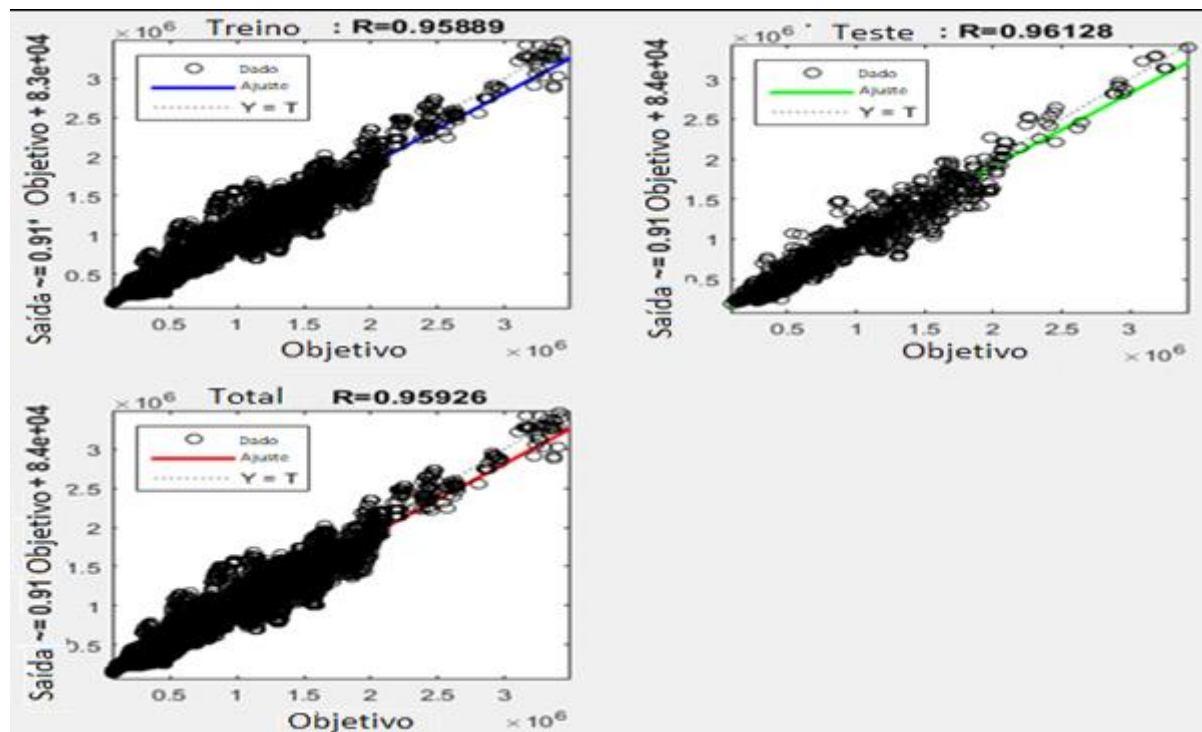
Fonte: Autor.

Na Figura 46 teve-se casos críticos relacionados aos custos totais com uma probabilidade de 0,05% de ocorrência. Observa-se também lucros elevados nos pontos extremos da figura, porém, tem baixa probabilidade de ocorrência. A Figura 41 apresenta

maiores casos onde os custos das perdas não são reduzidos pelo uso da bateria. Este risco tem 16,10% de probabilidade de ocorrência. Tentou-se identificar se para estes casos críticos existe alguma opção de seleção que marque esta tendência (como as barras para nas tensões). Como os histogramas das entradas mostraram distribuições similares, é a combinação de características (barra, tipo, dia e/ou capacidade) o que causa os prejuízos nos custos das perdas. A penalização incluída na formulação do algoritmo genético ajuda a filtrar estes casos críticos. Considerando os resultados da base de dados se desenvolveu a rede neural do tipo *Group Method of Data Handling* utilizando o toolbox do Yarpiz (HERIS SM, 2015) para o Matlab. Cinco redes neurais foram unidas em paralelo para determinar, com base nas entradas, as 5 saídas que são: custos totais, custos das perdas, tensões máximas, tensões máximas e desgaste operativo.

Para analisar a precisão das redes neurais em se adaptar aos resultados da otimização diária, foi considerada a correlação entre os dados originais e da rede neural. A Figura 48 mostra os resultados considerando os custos totais.

Figura 48 – Correlação de dados com a rede neural. Custos totais.




Fonte: Autor.

A Figura 48 mostra que os dados obtidos pela rede neural são similares aos desejados com uma alta correlação. Teve-se, uma correlação de 0,988 para todos os dados considerados,

de 0,987 para os dados testados e de 0,988 para os dados utilizados no treinamento. A Figura 49 mostra esta comparação em detalhe para o conjunto total de dados.

Figura 49 – Aproximação dos resultados. Custos totais.



Fonte: Autor.

A Figura 49 mostra pouca diferença entre os dados obtidos pela rede e os da base de dados, sendo possível implementar a rede para a simulação da operação diária durante o ano de estudo. Resultados similares obteve-se com as outras variáveis de saída. Estes casos são mostrados no Apêndice.

Após pôr em prática a rede neural foi possível selecionar a melhor alternativa considerando a curva anual dos dados reais utilizando o algoritmo genético. Para testar os resultados do algoritmo genético se utilizaram diferentes tamanhos de populações e taxas de mutação. Além disto se considerou uma taxa de desconto de 8% para os investimentos (DAZA, 2018). Os resultados dos testes do algoritmo genético se mostram na Tabela 3.

Tabela 3 – Resultados do Algoritmo Genético.

Parâmetro	Caso 1	Caso 2	Caso 3	Caso 4
Taxa de elitismo (%)	40	10	10	10
Número de indivíduos	1000	200	500	1000
Benefício (\$)	272.922	272.922	272.922	272.922
Capacidade (kWh)	500	500	500	500
Barra	27	20	30	28
Tipo	Li Ion	Li Ion	Li Ion	Li Ion
Número de gerações	29	32	31	29
Tempo (s)	1.562	201	649	1.568
Vida Útil (Anos)	11,079	11,079	11,079	11,079

Fonte: Autor.

A Tabela 3 mostra que independente da taxa de elitismo ou o número de gerações, o algoritmo genético tem uma convergência determinada pelo valor do benefício do projeto de 272.922 \$ em aproximadamente 11 anos. Assim, a bateria a selecionar deve ser do tipo Lítio-íon e ter uma capacidade de 500 kWh. A localização da bateria influi menos na determinação do benefício para o caso estudado. Analisando o esforço computacional, os testes foram realizados num computador com processador Intel® Core™2 QUAD com 2,83 GHz, memória de 4 GB de RAM e sistema operacional Windows 10. Da tabela 3 se observa que o Caso 4 apresentou o maior tempo de simulação, com 1568 segundos. Este tempo se deve a consideração de um tamanho da população grande e uma taxa de elitismo baixa, o que garante diversidade nas gerações. No entanto este tempo de simulação é muito menor ao tempo de solução empregando um fluxo de carga. Analisar o fluxo de carga usando o modelo de otimização não linear leva em torno de 365 segundo para cada caso. Desta forma, o estudo de 1000 casos em 29 gerações (considerando o estudo anual pela rede neural) equivale a analisar somente 4 casos se for usado o fluxo de carga. Em resumo, o que poderia levar dias para ser resolvido pelo fluxo de carga otimizado, é reduzido consideravelmente pelo uso da rede neural no algoritmo genético.

As tabelas a seguir mostra os resultados obtidos para um ano de operação, considerando as respostas dos 4 casos. Compara-se o fluxo de carga otimizado com a rede neural.

Tabela 4 – Comparação das respostas. Caso 1.

Caso 1	Rede Neural	Fluxo de Carga	Erro
Custo das perdas (\$)	2.519	2.561	1,63%
Custo total (\$)	3.244.195	3.317.478	2,21%
Tensão mínima (pu)	0,952	0,955	0,28%
Tensão máxima (pu)	1,001	1,014	1,26%
Tempo de Vida (Anos)	11,079	11,433	4,20%

Fonte: Autor.

Tabela 5 – Comparação das respostas. Caso 2.

Caso 2	Rede Neural	Fluxo de Carga	Erro
Custo das perdas (\$)	2519	2603	3,23%
Custo total (\$)	3244195	3318416	2,24%
Tensão mínima (pu)	0,954	0,954	0,03%
Tensão máxima (pu)	1,001	1,014	1,27%
Tempo de Vida (Anos)	11,079	11,433	3,09%

Fonte: Autor.

Tabela 6 – Comparação das respostas. Caso 3.

Caso 3	Rede Neural	Fluxo de Carga	Erro
Custo das perdas (\$)	2519	2553	1,34%
Custo total (\$)	3244195	3317292	2,20%
Tensão mínima (pu)	0,955	0,955	0,04%
Tensão máxima (pu)	1,001	1,014	1,28%
Tempo de Vida (Anos)	11,079	11,888	6,80%

Fonte: Autor.

Tabela 7 – Comparação das respostas. Caso 4.

Caso 4	Rede Neural	Fluxo de Carga	Erro
Custo das perdas (\$)	2519	2558	1,51%
Custo total (\$)	3244195	3317404	2,21%
Tensão mínima (pu)	0,952	0,955	0,35%
Tensão máxima (pu)	1,001	1,014	1,30%
Tempo de Vida (Anos)	11,079	11,554	4,11%

Fonte: Autor.

As tabelas anteriores mostram uma boa aproximação dos resultados obtidos na rede neural com os obtidos pelo fluxo de carga otimizado ao longo do ano. Assim, o Caso 3 apresentou os menores erros no cálculo dos custos totais e dos custos das perdas com valores de 2,2% e 1,34% respectivamente. O Caso 2 apresentou o menor erro nas tensões mínimas e no

tempo de vida da bateria com valores de 0,03% e 3,09%. Finalmente o caso 1 apresentou o menor erro na tensão máxima com valor de 1,26%. Em geral, o cálculo das tensões mínimas foram os que apresentaram menores erros, e o cálculo do tempo de vida foi o que apresentou o maior erro com valor de 6,8%. Observa-se também que a vantagem da seleção da tecnologia é determinada pela capacidade e tipo, dado que mudar a alocação da barra influencia mais que tudo no custo das perdas, que é uma parcela menos significativa quando comparada com o custo total. Mostra-se assim também a flexibilidade do método que permite analisar diferentes soluções em pouco tempo de processamento.

5.1 RESUMO DO CAPÍTULO

Este capítulo apresentou o estudo de caso da metodologia proposta. O estudo de caso considerou um sistema de distribuição de 33 barras, com 3 fontes de geração solar e 3 fontes de geração eólica. Teve-se uma alta penetração de fontes renováveis no sistema. O método permite alocar a bateria em qualquer barra do sistema, mas para reduzir o tamanho da base de dados se consideraram apenas 17 barras. Isto apenas com fines demonstrativos do método.

O estudo dos casos críticos mostrou que nas barras 16 e 17 tem-se uma alta incidência em problemas de tensão, conforme os limites estabelecidos. A eliminação destas barras como opções de entrada dentro do algoritmo genético e na rede neural, permite reduzir o esforço computacional. Além disto, foram determinada uma probabilidade de prejuízos nos custos totais de 0,06% e nos custos das perdas de 16,10%. Demonstra-se, pelo resultado probabilístico, que a bateria consegue reduzir os custos do projeto na maioria dos casos.

O estudo do comportamento diário, mostra uma tendência na redução dos custos totais, considerando a operação diária da bateria. O estudo diário mostrou que para preços elevados ao fim do dia, a bateria tende a descarregar mantendo um baixo nível de reserva. Caso os preços fossem elevados para estes horários, a bateria tende a aumentar sua reserva.

O algoritmo genético mostrou diferentes resultados conforme o número de indivíduos e a taxa de mutação utilizada. Neste caso tem-se uma tendência do valor de capacidade de 500 kWh e da tecnologia de Lítio-íon como resposta final. Este valor conseguiu um benefício aproximado de \$ 272.922 considerando ainda os custos próprios de investimento da tecnologia de armazenamento durante 11 anos. A influência da alocação da bateria nas barras foi pouca quando comparados os custos totais do projeto. Esta influência de alocação impacta majoritariamente nos problemas das tensões. Considera-se que o método de seleção heurístico

para determinação da melhor resposta foi adequado, levando em conta poucos tempos de processamento.

Finalmente mostrou-se a aproximação da rede neural com os dados obtidos pelo modelo de otimização não linear e fluxo de carga. Os dados obtidos para o ano de estudo, mostraram uma boa aproximação dos resultados. O maior erro foi de 6,8%, presente no valor da vida útil da bateria, valor que pode ser melhorado em estudos futuros.

6 CONCLUSÕES

Este trabalho permitiu desenvolver um modelo para seleção ótima de armazenadores de energia em sistemas de distribuição com geração distribuída considerando uma aproximação da operação ótima diária por meio de uma relação de tipo entrada/saída. O modelo mostrou uma adequada operação da bateria na redução dos custos totais e das perdas, mantendo os níveis de tensão dentro do regulamentado. Além disto, a criação da base de dados partindo da simulação de Monte Carlo permitiu identificar valores de probabilidade de risco de prejuízo nos custos totais do projeto. Outro fator determinado foi o risco de apresentar tensões mínimas fora dos limites, o qual embora seja baixo, caso não seja avaliado pelo planejador pode apresentar um problema na rede. Assim, foi constatado que o caso crítico da tensão mínima persistia exclusivamente na seleção das barras 16 e 17. Com este resultado, foi possível descartar estas opções para a implementação da heurística de seleção de alternativas. A rede neural por sua parte, mostrou uma boa aproximação dos resultados originais, o que permitiu avaliar a operação ótima durante o ano de forma rápida. O resultado do algoritmo genético permitiu determinar o tipo adequado da bateria para o estudo do caso considerando diferentes números de indivíduos e taxas de elitismo. Se determinou assim, que a bateria do tipo Lítio-íon com capacidade de 500 kWh consegue obter os melhores benefícios na rede estudada durante um tempo de 11 anos. Esta bateria está sujeita a seus custos de investimento e de manutenção, seu desgaste e seus tempos máximos de descarga. Determinou-se também que para o estudo de caso o impacto da alocação da bateria é um fator que influencia mais nos comportamentos críticos da tensão, do que nos custos totais. Isto se deve ao custo associado às perdas, que representa apenas uma pequena porcentagem do custo total.

6.1 ESTUDOS FUTUROS

Como perspectivas futuras tem-se a avaliação de outros modelos de negócios para o uso do armazenador. Neste caso pode-se planejar uma perspectiva onde a bateria pertence ao consumidor e seu objetivo está focado na obtenção do lucro pela venda de energia. Outra alternativa é o benefício econômico dado por contratos de capacidade, onde tem-se um pagamento fixo garantido numa base de energia de reserva por dia. Finalmente, poderia se observar o caso de uma empresa independente de serviços intermediários como dona da bateria, analisando seu desempenho a tanto para o consumidor como para a distribuidora, sendo

interessante a resolução dos conflitos de interesse entre ambas as partes. Outras possibilidades incluem: Reconfiguração, atendimento ilhado, impacto dos indicadores de confiabilidade DEC, FEC e ENS entre outros.

6.2 PRODUÇÃO CIENTÍFICA

Os seguintes trabalhos foram realizados durante o desenvolvimento da tese:

1 Artigo publicado em revista internacional Qualis A2:

RANGEL, C. A. S.; CANHA L.; SPERANDIO, M. e SEVERIANO, R. "Methodology for ESS-type selection and optimal energy management in distribution system with DG considering reverse flow limitations and cost penalties," in *IET Generation, Transmission & Distribution*, vol. 12, no. 5, pp. 1164-1170, 13 3 2018.

2 Artigos publicados em congressos nacionais:

RANGEL, C. A. S.; PAGNOSSIN, R.; CANHA, L. e SPERANDIO, M. "Estudo de Impacto dos Armazenadores de energia nas perdas dos Sistemas de distribuição com Geração Distribuída". In: VI Simpósio Brasileiro de Sistemas Elétricos, 2015, Natal, 2016.

RANGEL, C. A. S.; CANHA, L.; SPERANDIO, M. e SCHMITZ, W. I. "Modelo de gerenciamento de Armazenadores de Energia em Sistemas de Distribuição com Geração Distribuída." In: X CBPE Congresso Brasileiro de Planejamento Energético, 2016, Gramado-RS. X CBPE Congresso Brasileiro de Planejamento Energético, 2016.

1 Capítulo de livro em fase de avaliação:

Handbook of Optimizations in Electric Power Distribution Systems. Energy Storage System Siting and Sizing for Renewable Support. SPRINGER.

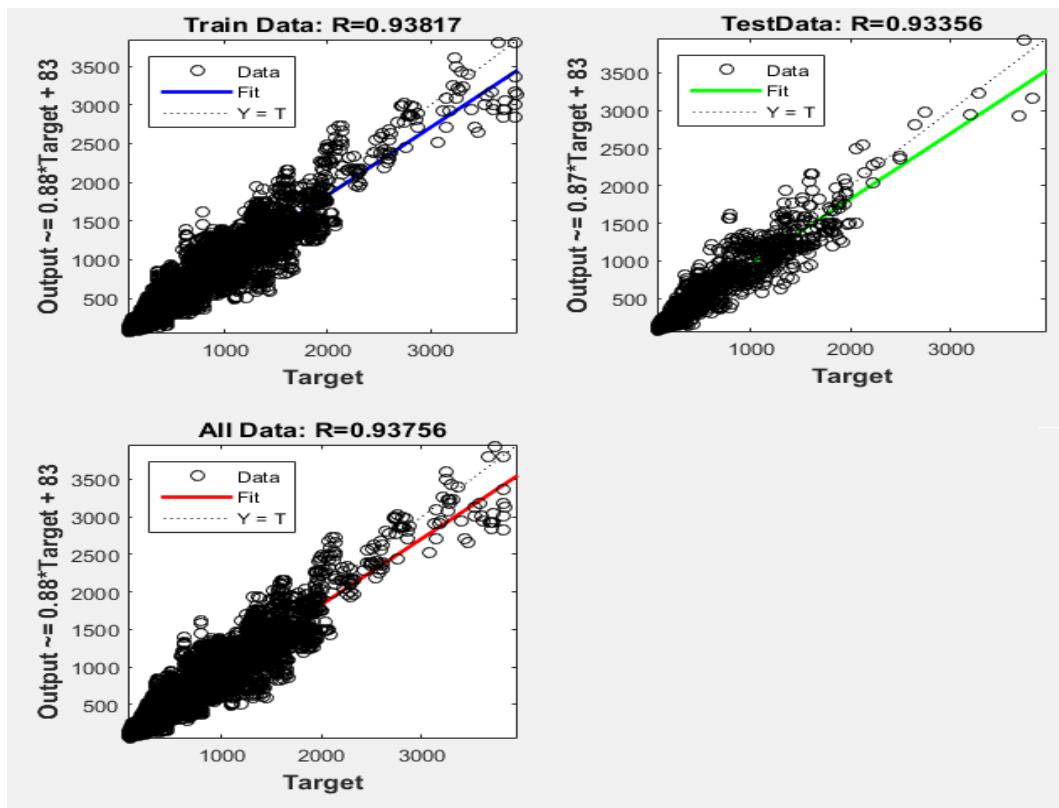
1 Artigo aceito em congresso internacional:

Profit Study of the Combined Operation of a Wind Farm and a Battery Storage System in the MIBEL electricity Market no Innovative Smart Grid Technologies Latin America, 2019. Gramado RS, Brazil.

7 APÊNDICE

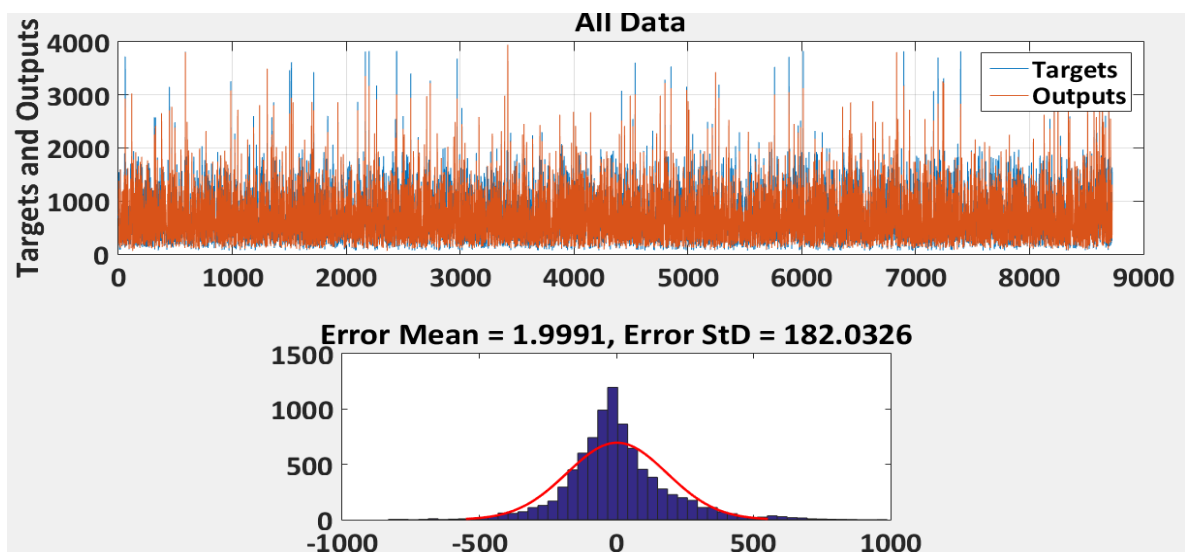
Neste apêndice apresentam-se os resultados obtidos das redes neurais usadas no modelo.

Figura 50 – Correlação de dados com a rede neural. Custos das perdas.



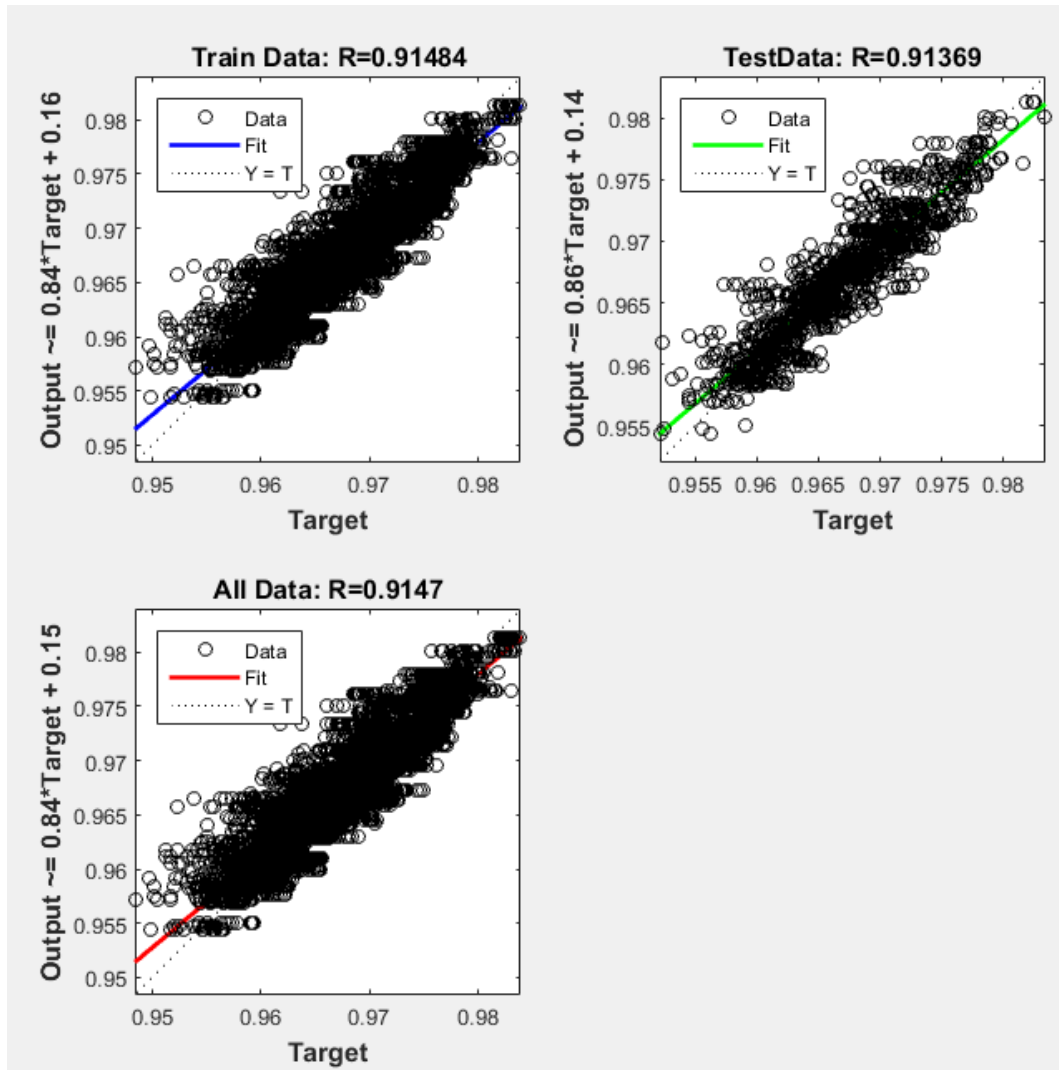
Fonte: Autor.

Figura 51 – Aproximação dos resultados. Custos das perdas.



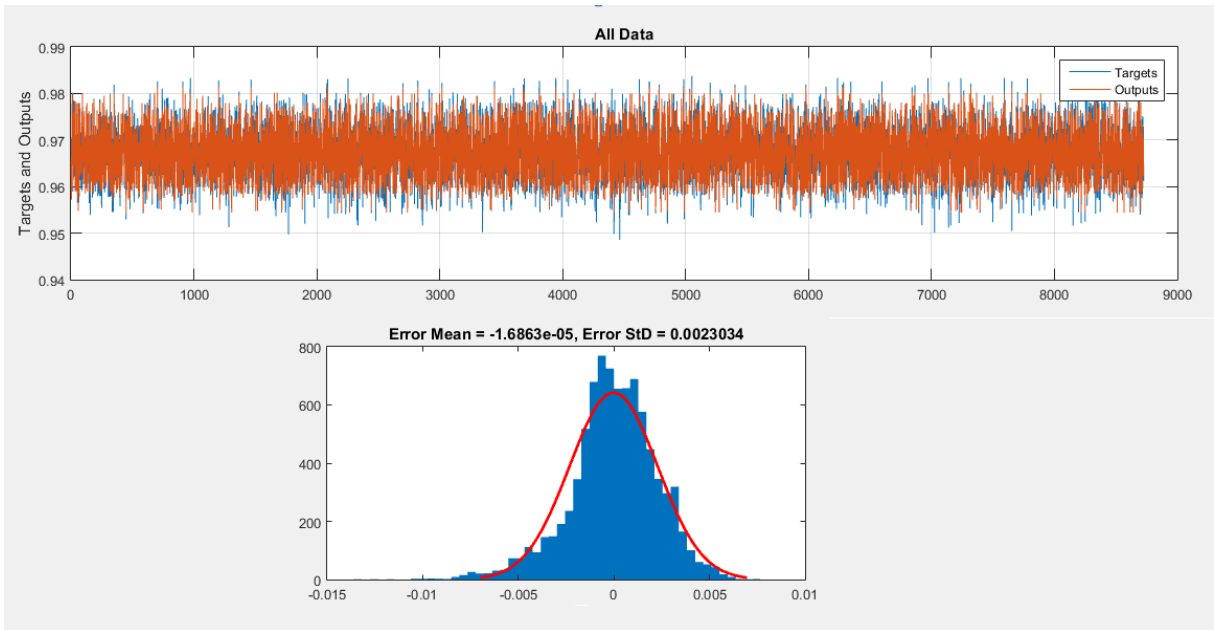
Fonte: Autor.

Figura 52 – Correlação de dados com a rede neural. Tensão mínima.



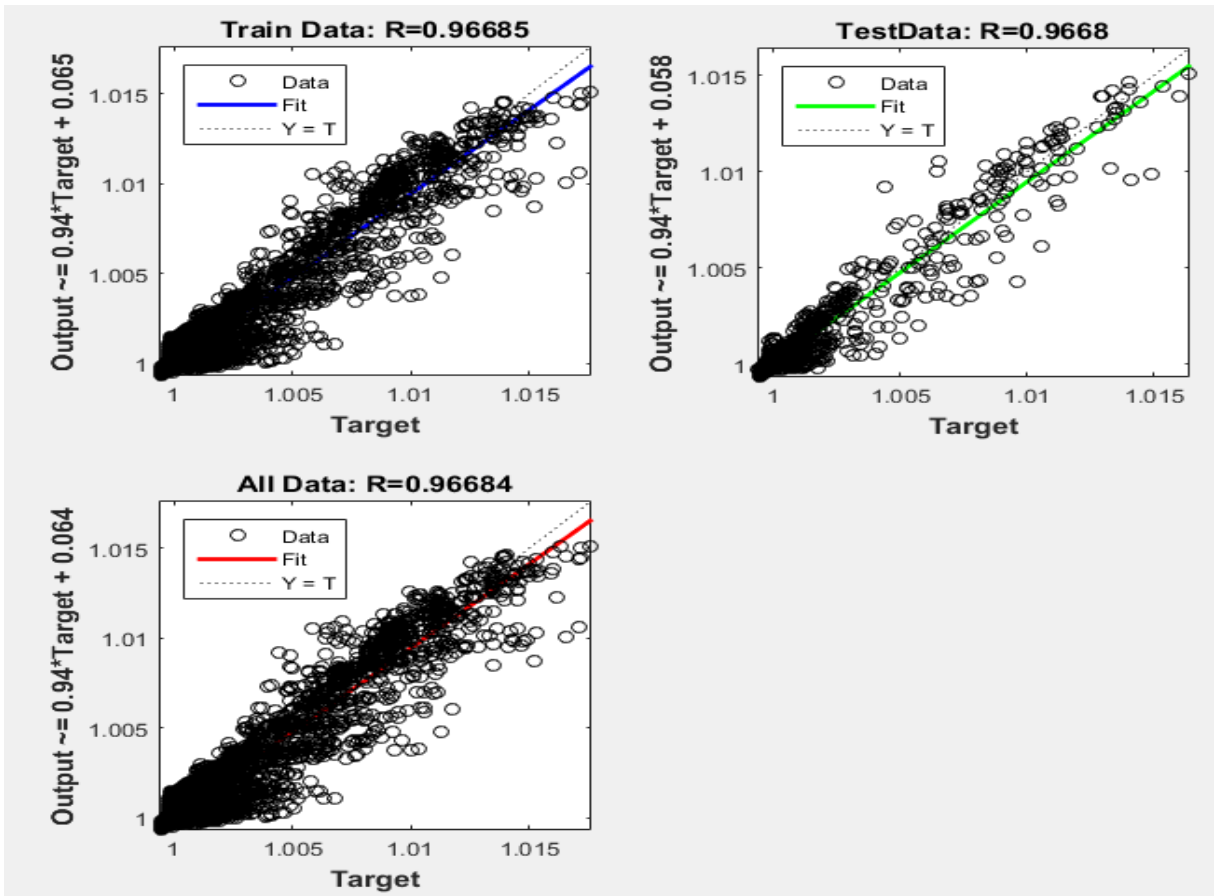
Fonte: Autor.

Figura 53 – Aproximação dos resultados. Tensão mínima.




Fonte: Autor.

Figura 54 – Correlação de dados com a rede neural. Tensão máxima.



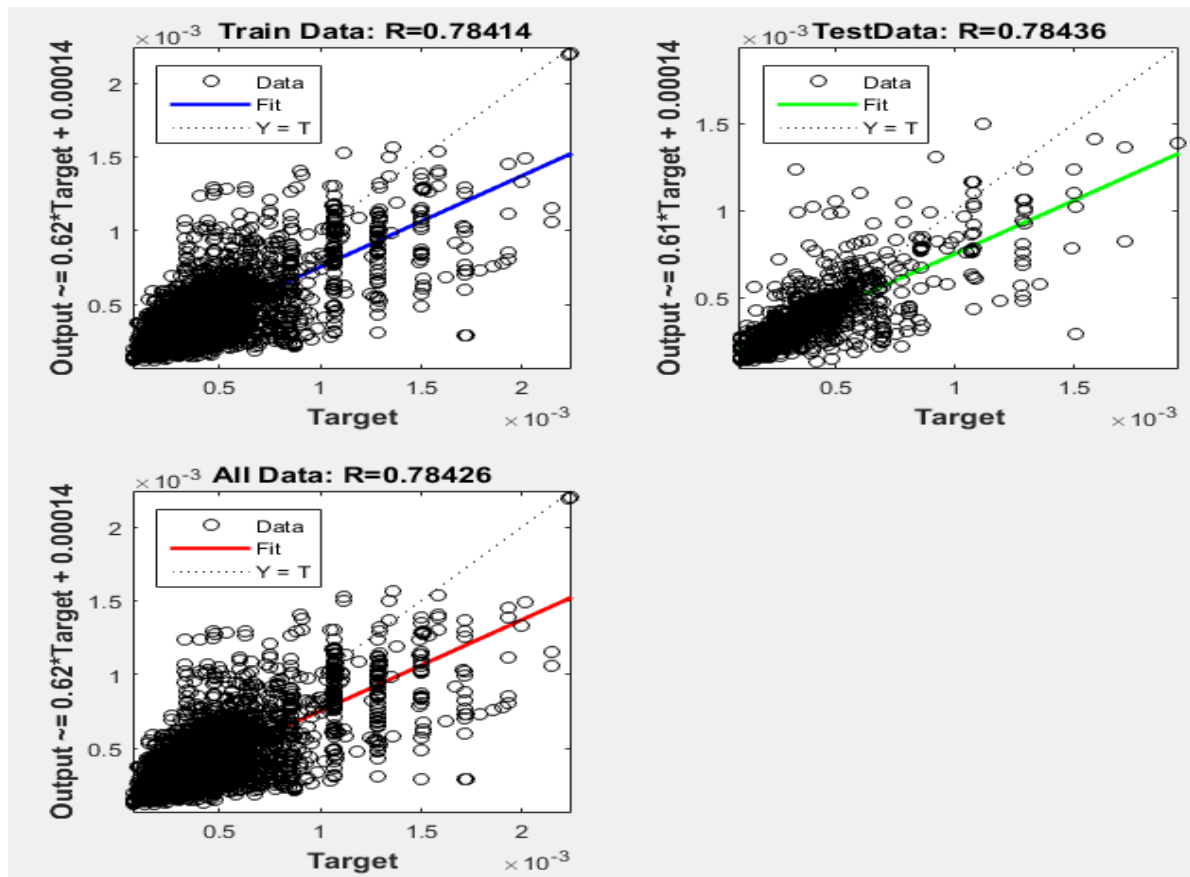
Fonte: Autor.

Figura 55 – Aproximação dos resultados. Tensão máxima.




Fonte: Autor.

Figura 56 – Correlação de dados com a rede neural. Desgaste da Bateria.



Fonte: Autor.

Figura 57 – Aproximação dos resultados. Desgaste da Bateria.



Fonte: Autor.

8 REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA DO Brasil – ANEEL. Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST. 2016.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA DO Brasil – ANEEL. Aprimoramento da metodologia de cálculo de perdas na distribuição regulamentada no Módulo 7 – Cálculo de Perdas na Distribuição do PRODIST. **Nota Técnica n° 0057/2014-SRD/ANEEL**. 2014.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA DO Brasil – ANEEL. Cadernos Temáticos. **Micro e Minigeração Distribuída. Sistema de Compensação de Energia Elétrica**. Brasília, DF, Brasil: Centro de Documentação–Cedoc, 2014.

AGHAMOHAMMADI, M. R.; ABDOLAHINIA, H. A new approach for optimal sizing of battery energy storage system for primary frequency control of islanded microgrid. **International Journal of Electrical Power & Energy Systems**, vol. 54, p. 325-333, 2014.

ALOTTO, P.; GUARNIERI, M.; MORO, F. Redox flow batteries for the storage of renewable energy: A review. **Renewable and Sustainable Energy Reviews**, v. 29, p. 325- 335, 2014.

ARAI, J., et al. Power electronics and its applications to renewable energy in Japan. **IEEE Circuits and Systems Magazine**, vol. 8, no 3, 2008.

ATWA, Y.; EL-SAADANY, E. F. Optimal allocation of ESS in distribution systems with a high penetration of wind energy. **IEEE Transactions on Power Systems**, vol. 25, no 4, p. 1815-1822, 2010.

ATZENI, I., et al. Demand-side management via distributed energy generation and storage optimization. **IEEE Transactions on Smart Grid**, vol. 4, no 2, p. 866-876, 2013.

AWAD, A.; EL-FOULY, T.; SALAMA, M. Optimal ESS allocation and load shedding for improving distribution system reliability. **IEEE Transactions on Smart Grid**, vol. 5, no 5, p. 2339-2349, 2014.

BAKER, J. New technology and possible advances in energy storage. **Energy Policy**, vol. 36, no 12, p. 4368-4373, 2008.

BARAN, Mesut E.; WU, Felix F. Network reconfiguration in distribution systems for loss reduction and load balancing. **IEEE Transactions on Power delivery**, v. 4, n. 2, p. 1401-1407, 1989.

BARTON, J. P.; INFIELD, D. G. Energy storage and its use with intermittent renewable energy. **IEEE transactions on energy conversion**, vol. 19, no 2, p. 441-448, 2004.

BAXTER R. Energy storage: a nontechnical guide. PennWell Books; 2006.

BEAUDIN, M., et al. Energy storage for mitigating the variability of renewable electricity sources: An updated review. **Energy for Sustainable Development**. 14, no 4, p. 302-314, 2010.

BUENO, Elaine Inacio. Group Method of Data Handling (GMDH) e Redes Neurais na Monitoração e Detecção de Falhas em sensores de centrais nucleares. 2011. Tese de Doutorado. Universidade de São Paulo.

BREKKEN, T., et al.. Optimal energy storage sizing and control for wind power applications. **IEEE Transactions on Sustainable Energy**, vol. 2, no 1, p. 69-77, 2011.

CAO, M. et al. Research on configuration strategy for regional energy storage system based on three typical filtering methods. **Trans. Distrib. IET Gener**, vol. 10, no 10, pp. 2360–2366, 2016.

CARPINELLI, G., et al. Optimal integration of distributed energy storage devices in smart grids. **IEEE Transactions on Smart Grid**, vol. 4, no 2, p. 985-995, 2013.

CARPINELLI, G.; MOTTOLA, Fabio; PROTO, Daniela. Probabilistic sizing of battery energy storage when time-of-use pricing is applied. **Electric Power Systems Research**, vol. 141, p. 73-83, 2016.

CHAKRABORTY, S., et al. Determination methodology for optimizing the energy storage size for power system. **IET Gener. Transm. Distrib**, vol 3, no 11 p. 987–999, 2009.

CHEN, H., et al. Progress in electrical energy storage system: A critical review. **Progress in Natural Science**, vol. 19, no 3, p. 291-312, 2009.

CHEN, H., et al. Economic dispatch of wind integrated power systems with energy storage considering composite operating costs. **IET Gener. Transm. Distrib**, vol. 10, no 5, p. 1294–1303, 2016.

COPPEZ, G.; CHOWDHURY, S.; CHOWDHURY, S. P. **Impacts of energy storage in distributed power generation: a review**. In: Power System Technology (POWERCON), 2010 International Conference on. IEEE, p. 1-7, 2010.

DA SILVA, A. M. Leite et al.. Composite reliability assessment based on Monte Carlo simulation and artificial neural networks. **IEEE Transactions on Power Systems**, v. 22, n. 3, p. 1202-1209, 2007.

DA SILVA, B. F. G. Estudo de soluções alternativas de armazenamento de energia para diferentes horizontes temporais. Tese de Doutorado. Universidade do Porto, 2008.

DAVIS, L. Handbook of genetic algorithms. 1991.

DAZA, Eric Fernando Boeck et al. Determinação de arranjos regulatórios e econômicos para viabilizar investimentos em sistemas de armazenamento de energia em redes de distribuição de energia elétrica. 2018. Tese de Doutorado. Universidade Federal de Santa Maria.

DÍAZ-GONZÁLEZ, F., et al. A review of energy storage technologies for wind power applications. **Renewable and sustainable energy reviews**, vol. 16, no 4, p. 2154-2171, 2012.

DÍAZ-GONZÁLEZ, F., et al. Energy management of flywheel-based energy storage device for wind power smoothing. **Applied energy**, vol. 110, p. 207-219, 2013.

DIVYA, K. C.; ØSTERGAARD, J. Battery energy storage technology for power systems—An overview. **Electric Power Systems Research**, vol. 79, no 4, p. 511-520, 2009.

DROUILHET, S., et al. **A battery life prediction method for hybrid power applications**. In: 35th Aerospace Sciences Meeting and Exhibit. p. 948, 1997.

Dugan, R. C. **Reference guide: The open distribution system simulator (OpenDSS)**. Electric Power Research Institute, Inc, 2012.

DUSTMANN, C. H. Advances in ZEBRA batteries. **Journal of Power Sources**, vol. 127, no 1, p. 85-92, 2004.

ELNOZAHY, M. S.; ABDEL-GALIL, Tarek K.; SALAMA, M. M. A. Probabilistic ESS sizing and scheduling for improved integration of PHEVs and PV systems in residential distribution systems. **Electric Power Systems Research**, vol. 125, p. 55-66, 2015.

EYER, J.; IANNUCCI, J.; BUTLER, P. C. Estimating electricity storage power rating and discharge duration for utility transmission and distribution deferral: a study for the DOE energy storage program. Sandia National Laboratories Technical report, 2005.

FARRET, F. A., et al. **Integration of alternative sources of energy**. John Wiley & Sons, 2006.

FETCENKO, M. A., et al. Recent advances in NiMH battery technology. **Journal of Power Sources**, vol. 165, no 2, p. 544-551, 2007.

GAO, H., et al. Cutting planes based relaxed optimal power flow in active distribution systems. **Electric Power Systems Research**, vol. 143, p. 272-280, 2017.

GAST, N.; TOMOZEI, D.; LE BOUDEC, J. Optimal generation and storage scheduling in the presence of renewable forecast uncertainties. **IEEE Transactions on Smart Grid**, vol. 5, no 3, p. 1328-1339, 2014.

GHOLIAN, A.; MOHSENIAN-RAD, H.; HUA, Y. Optimal industrial load control in smart grid. **IEEE Transactions on Smart Grid**, vol. 7, no 5, p. 2305-2316, 2016.

GONZALEZ, A., et al. Study of electricity storage technologies and their potential to address wind energy intermittency in Ireland. **Sustainable Energy Ireland**, 2004.

HADJIPASCHALIS, I.; POULLIKKAS, A.; EFTHIMIOU, V. Overview of current and future energy storage technologies for electric power applications. **Renewable and sustainable energy reviews**, vol. 13, no 6, p. 1513-1522, 2009.

HERIS, S. M. K. Implementation of group method of data handling in Matlab, Yarpiz. 2015.

HILL, C. A., et al. Battery energy storage for enabling integration of distributed solar power generation. **IEEE Transactions on Smart Grid**, vol. 3, no 2, p. 850-857, 2012.

HODSON H. Texas-sized battery aims to green up the grid. **New Sci**;217(February):20. 2013

IBRAHIM, H.; ILINCA, A.; PERRON, J. Energy storage systems—characteristics and comparisons. **Renewable and sustainable energy reviews**, vol. 12, no 5, p. 1221-1250, 2008.

INTERNATIONAL RENEWABLE ENERGY AGENCY – IRENA. Battery Storage for Renewables: Market Status and Technology Outlook. Jan. 2015.

INTERNATIONAL RENEWABLE ENERGY AGENCY – IRENA Electricity Storage and Renewables: Costs and Markets to 2030. Out. 2017.

IESO. INDEPENDENT ELECTRICITY SYSTEM OPERATOR. **Power data. Data Directory**. Disponível em: <http://www.ieso.ca/en/Power-Data/Data-Directory>. Acesso em: 1 de Novembro de 2018.

JAMIAN, J. J., et al. Simulation study on optimal placement and sizing of Battery Switching Station units using Artificial Bee Colony algorithm. **International Journal of Electrical Power & Energy Systems**, vol. 55, p. 592-601, 2014.

JAYASEKARA, N.; WOLFS, P.; MASOUM, M. A. An optimal management strategy for distributed storages in distribution networks with high penetrations of PV. **Electric Power Systems Research**, vol. 116, p. 147-157, 2014.

KHANI, H.; ZADEH, M.D.; VARMA, R.: Optimal Scheduling of Independently Operated, Locally Controlled Energy Storage Systems as Dispatchable Assets in a Competitive Electricity Market. **IET Gener. Transm. Distrib**, 2017.

KAWAKAMI, N., et al. **Development and field experiences of stabilization system using 34MW NAS batteries for a 51MW wind farm**. In: Industrial Electronics (ISIE), 2010 IEEE International Symposium on. IEEE, p. 2371-2376, 2010.

KONDOH, J., et al. Electrical energy storage systems for energy networks. **Energy Conversion and Management**, vol. 41, no 17, p. 1863-1874, 2000.

LACERDA, V., et al. Separation of Cd and Ni from Ni–Cd batteries by an environmentally safe methodology employing aqueous two-phase systems. **Journal of Power Sources**, vol. 193, no 2, p. 908-913, 2009.

LUO, X., et al. Overview of current development in electrical energy storage technologies and the application potential in power system operation. **Applied Energy**, vol. 137, p. 511-536, 2015.

LV, T.; AI, Q.; ZHAO, Y. A bi-level multi-objective optimal operation of grid-connected microgrids. **Electric Power Systems Research**, vol. 131, p. 60-70, 2016.

MANWELL, J. F., et al. **Hybrid2—a hybrid system simulation model—theory manual**. Renewable Energy Research Laboratory, University of Massachusetts, 2006.

MARRA, F., et al. A decentralized storage strategy for residential feeders with photovoltaics. **IEEE Transactions on Smart Grid**, vol. 5, no 2, p. 974-981, 2014.

MATHWORKS INC. **MATLAB. User’s Guide**. Natick, MA, vol. 5, p. 333, 1998.

MILLNER, Alan. **Modeling lithium ion battery degradation in electric vehicles**. In: 2010 IEEE Conference on Innovative Technologies for an Efficient and Reliable Electricity Supply. IEEE, 2010. p. 349-356.

MODIBA P. **Electrolytes for redox flow battery systems**. Ph.D. thesis. Department of Chemistry and Polymer Science. the University of Stellenbosch, December 2010.

MOEINI, A.; KAMWA, I.; DE MONTIGNY, M. Power factor-based scheduling of distributed battery energy storage units optimally allocated in bulk power systems for mitigating marginal losses **IET Gener. Transm. Distrib**, vol. 10, no 5, p. 1304–1311, 2016.

MOHSENIAN-RAD, Amir-Hamed, et al. Autonomous demand-side management based on game-theoretic energy consumption scheduling for the future smart grid. **IEEE Transactions on Smart Grid**, vol. 1, no 3, p. 320-331, 2010.

NIESLONY, Adam. **Rainflow counting algorithm**. File Exchange-MATLAB Central, <http://www.mathworks.com/matlabcentral/fileexchange/3026-rainflow-counting-algorithm>, 2003.

NGUYEN, T.; SAVINELL, R. F. Flow batteries. **The Electrochemical Society Interface**, vol. 19, no 3, p. 54-56, 2010.

O'SULLIVAN, T. M.; BINGHAM, C. M.; CLARK, R. E. **Zebra battery technologies for all electric smart car**. In: Power Electronics, Electrical Drives, Automation and Motion, 2006. SPEEDAM 2006. International Symposium on. IEEE, p. 243, 2006.

PEREIRA, M. V. F. et al. Combining analytical models and Monte-Carlo techniques in probabilistic power system analysis. **IEEE Transactions on Power Systems**, v. 7, n. 1, p. 265-272, 1992.

PIRES, V, et al. Power converter interfaces for electrochemical energy storage systems – A review. **Energy Conversion and Management**, v. 86, p 453-475, 2014.

QIN, M., et al. Optimal planning and operation of energy storage systems in radial networks for wind power integration with reserve support. **IET Gener. Transm. Distrib**, vol. 10, no 8, p. 2019–2025, 2016.

QIU, X.; NGUYEN, T.; CROW, M. Heterogeneous energy storage optimization for microgrids. **IEEE Transactions on Smart Grid**, vol. 7, no 3, p. 1453-1461, 2016.

QUESADA, J., et al. Control of inverters in a low voltage microgrid with distributed battery energy storage. Part I: Primary control. **Electric Power Systems Research**, vol. 114, p. 126-135, 2014.

RASTLER D. Electric energy storage applications in the electric enterprise: overview of applications and U.S. demonstration activities. Electric Power Research Institute (EPRI). EDF energy storage work shop. October 2011.

RASTLER, D. **Electricity Energy Storage Technology Options: A White Paper Primer on Applications. Costs and Benefits**: Electric Power Research Institute, 2010.

REIHANI, E.; GHORBANI, R. Load commitment of distribution grid with high penetration of photovoltaics (PV) using hybrid series-parallel prediction algorithm and storage. **Electric Power Systems Research**, vol. 131, p. 224-230, 2016.

SEO, H. R., et al. Power quality enhancement of renewable energy source power network using SMES system. **Physica C: Superconductivity and its applications**, vol. 471, no 21, p. 1409-1412, 2011.

SEPULVEDA, C. A et al. Methodology for ESS-type selection and optimal energy management in distribution system with DG considering reverse flow limitations and cost penalties. **IET Generation, Transmission & Distribution**, v. 12, n. 5, p. 1164-1170, 2018.

SHENG, W., et al. Research and practice on typical modes and optimal allocation method for PV-Wind-ES in microgrid. **Electric Power Systems Research**, vol. 120, p. 242-255, 2015.

SHIGEMATSU, T., et al. **Applications of a vanadium redox-flow battery to maintain power quality**. In: Transmission and Distribution Conference and Exhibition 2002: Asia Pacific. IEEE/PES. IEEE, p. 1065-1070, 2002.

SMITH, S. C.; SEN, P. K.; KROPOSKI, B. **Advancement of energy storage devices and applications in electrical power system**. In: Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century, 2008 IEEE. IEEE, p. 1-8, 2008.

SOARES, T., et al. Cost allocation model for distribution networks considering high penetration of distributed energy resources. **Electric Power Systems Research**. 124, p. 120-132, 2015.

SONG, J. Y.; WANG, Y. Y.; WAN, C. Cv. Review of gel-type polymer electrolytes for lithium-ion batteries. **Journal of Power Sources**, vol. 77, no 2, p. 183-197, 1999.

SOROUDI, A., SIANO, P., KEANE, A.: Optimal DR and ESS scheduling for distribution losses payments minimization under electricity price uncertainty. **IEEE Trans. Smart Grid**, vol. 7, no 1, p. 261-272, 2016.

SUBBURAJ, A., et al. Analysis and review of grid connected battery in wind applications. **Em Green Technologies Conference (GreenTech), 2014 Sixth Annual IEEE**. IEEE, p. 1-6, 2014.

TAYLOR E. **Flow battery structures to improve performance and reduce manufacturing cost**. The 2012 DOE Energy Storage Program Peer Review and Update Meeting; 2012

TAYLOR, P., et al. **Pathways for energy storage in the UK**. Report for the center for low carbon futures, York, 2012.

TEWARI, S.; MOHAN, Ned. Value of NAS energy storage toward integrating wind: Results from the wind to battery project. **IEEE Transactions on Power Systems**, vol. 28, no 1, p. 532-541, 2013.

TONG, W. Wind power generation and wind turbine design. WIT press, p. 678-82, 2010.

VERGARA, P., et al.. Security-constrained optimal energy management system for three-phase residential microgrids. **Electric Power Systems Research**, vol. 146, p. 371-382, 2017.

WAGHORNE, W. E. Viscosities of electrolyte solutions. **Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences**, vol. 359, no 1785, p. 1529-1543, 2001.

WEBER, Adam Z., et al. Redox flow batteries: a review. **Journal of Applied Electrochemistry**, vol. 41, no 10, p. 1137, 2011.

WILSON, A., et al. Comparison of two energy storage options for optimum balancing of wind farm power outputs. **IET Gener. Transm. Distrib.**, vol. 10, no 3, p. 832–839, 2016.

XIAO, J., et al. Determination of the optimal installation site and capacity of battery energy storage system in distribution network integrated with distributed generation. **IET Generation, Transmission & Distribution**, vol. 10, no 3, p. 601-607, 2016.

XIAO, Hao et al. Bi-level planning for integrated energy systems incorporating demand response and energy storage under uncertain environments using novel metamodel. **CSEE Journal of Power and Energy Systems**, v. 4, n. 2, p. 155-167, 2018.

YANG, Z., et al. Electrochemical energy storage for green grid. **Chemical reviews**, vol. 111, no 5, p. 3577-3613, 2011.

YING, T.-K., et al. Studies on rechargeable NiMH batteries. **International Journal of Hydrogen Energy**, vol. 31, no 4, p. 525-530, 2006.

ZHAO, H., et al. Optimal active power control of a wind farm equipped with energy storage system based on distributed model predictive control. **IET Generation, Transmission & Distribution**, vol. 10, no 3, p. 669-677, 2016.

ZHAO, H., et al. Review of energy storage system for wind power integration support. **Applied Energy**, vol. 137, p. 545-553, 2015.

ZHU, W. H., et al. Energy efficiency and capacity retention of Ni–MH batteries for storage applications. **Applied Energy**, vol. 106, p. 307-313, 2013.