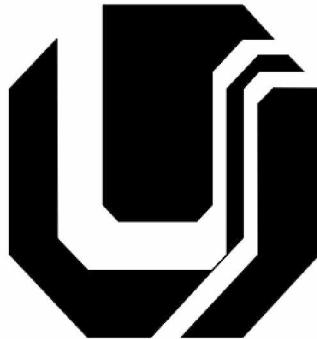


UNIVERSIDADE FEDERAL DE UBERLÂNDIA
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA



**RECONFIGURAÇÃO OTIMIZADA DE REDES DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA COM
PENETRAÇÃO FOTOVOLTAICA, COM A UTILIZAÇÃO
DE ARMAZENADORES DE ENERGIA E COM O
AUXÍLIO DE INTELIGÊNCIA ARTIFICIAL**

RAUL VITOR ARANTES MONTEIRO

PROF. PhD. GERALDO CAIXETA GUIMARÃES
ORIENTADOR

UBERLÂNDIA-MG

Setembro, 2017

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA

**RECONFIGURAÇÃO OTIMIZADA DE REDES DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA COM
PENETRAÇÃO FOTOVOLTAICA, COM A UTILIZAÇÃO
DE ARMAZENADORES DE ENERGIA E COM O
AUXÍLIO DE INTELIGÊNCIA ARTIFICIAL**

RAUL VITOR ARANTES MONTEIRO

Tese submetida à Universidade Federal de Uberlândia
como parte dos requisitos para a obtenção do título de
Doutor em Ciências.

Banca Examinadora:

Geraldo Caixeta Guimarães, PhD. – UFU (Orientador)
Adélio José de Moraes, Dr. – UFU
Keiji Yamanaka, Dr. UFU
Bismarck Castillo Carvalho, Dr. – UFMT
Márcio Augusto Tamashiro, Dr. – IFTO

UBERLÂNDIA-MG

Setembro, 2017

M775r

Monteiro, Raul Vitor Arantes.

Reconfiguração otimizada de redes de distribuição de energia elétrica com penetração fotovoltaica, com a utilização de armazenadores de energia e com o auxílio de inteligência artificial./ Raul Vitor Arantes Monteiro, 2017.

186 fls.

Orientador: Prof. PhD. Geraldo Caixeta Guimarães

Tese (Doutorado em Ciências) – Univ. Federal de Uberlândia,
Programa de pós-graduação em Engenharia Elétrica – Área de
Concentração: Dinâmica de Sistemas Elétricos. Uberlândia, 2017.

1.Penetração fotovoltaica. 2.Redes neurais artificiais. 3.Baterias de chumbo-ácido. 4.Armazenadores de energia. 5.Otimização por enxame de partícula. 1.Título.

CDU 621.3

**RECONFIGURAÇÃO OTIMIZADA DE REDES DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA COM
PENETRAÇÃO FOTOVOLTAICA, COM A UTILIZAÇÃO
DE ARMAZENADORES DE ENERGIA E COM O
AUXÍLIO DE INTELIGÊNCIA ARTIFICIAL**

RAUL VITOR ARANTES MONTEIRO

“Esta tese foi julgada adequada para a obtenção do título de Doutor em Ciências, área de concentração em *Dinâmica de Sistemas Elétricos*, e aprovada pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia”

Prof. Geraldo Caixeta Guimarães, Ph.D.
Orientador

Prof. Alexandre Cardoso, Dr.
Coordenador do Curso de Pós-Graduação

“Este trabalho é o resultado de 30 anos de exemplo e amor, concedidos a mim pelos meus pais, Raul Domingos Valle Monteiro (*in memoriam*) e Simone de Fátima Arantes. Como forma de agradecê-los, dedico este trabalho àquelas que os ensinaram a me ensinar.”

Dedico esta tese, portanto, às minhas avós Benedita e Lenice, por serem exemplos de honestidade, perseverança e amor. Por sempre terem me apoiado e acreditado em mim.

Agradecimentos

- Agradeço a minha esposa Paula Dornelles Martins Monteiro, por ter aberto mão de muitas coisas para poder me acompanhar nesta jornada.
- Ao meu orientador, professor Dr. Geraldo Caixeta Guimarães, por ter me aberto a oportunidade de participar do programa de Pós-Graduação da UFU. Por ter me apoiado e ajudado durante todo o processo de doutoramento. Por ter sido paciente e compreensível.
- A minha mãe por ter sempre se preocupado comigo e desejado o melhor para mim.
- As minhas irmãs Elisa e Maria, pelo amor e carinho que sempre tiveram comigo.
- Aos professores Dr. Fabrício Moura e Dra. Madeleine Albertini.
- Aos colegas do núcleo de Dinâmica de Sistemas Elétricos da UFU: Leonardo Rosenthal, Thales Lima, André Roger, Jaqueline, Roberta Amaral, Antônio Manoel e Seluyvi.
- Ao meu amigo Thiago Vieira, que sem sua insistência no primeiro momento eu não teria ingressado no programa de doutorado. Agradeço também por todo o suporte dado a mim e a minha esposa quando mudamos para Uberlândia e por toda a amizade que sempre teve comigo.
- Ao professor Dr. Márcio Augusto Tamashiro, pela amizade e pelo aceite em fazer parte da minha banca de doutorado.
- Ao professor Dr. Keiji Yamanaka, por ter aceitado fazer parte da minha banca de doutorado e pelos ensinamentos sobre Inteligência Artificial.
- Ao professor Dr. Adélio de Moraes, pelas contribuições e por ter aceitado fazer parte da minha banca de doutorado.
- Ao professor e amigo Dr. Bismarck Castillo Carvalho, por ter sido meu orientador de mestrado, da vida e por fazer parte da minha banca de doutorado.
- A Coordenação de Aperfeiçoamento de Pessoal do Ensino Superior - CAPES pelo auxílio financeiro por meio de uma bolsa de estudos no Brasil e no exterior.
- Ao meu amigo Daniel Caixeta, que com certeza sua amizade foi mais valiosa do que qualquer conquista que tive em Uberlândia.
- Aos meus amigos Cazeca, Nícolas Borges, Augusto (xexa) e José Neto.
- Ao meu amigo André Luis Amorim da Fonseca, que sempre me apoiou e me incentivou.

Resumo

Monteiro, R. V. A., Reconfiguração otimizada de redes de distribuição de energia elétrica com penetração fotovoltaica, com a utilização de armazenadores de energia e com o auxílio de inteligência artificial, FEELT-UFU, 186 p. 2017.

Este trabalho apresenta um estudo realizado sobre a reconfiguração de um sistema de distribuição de energia elétrica, com o objetivo de mitigar suas perdas técnicas, ou seja, perdas por efeito Joule. Foram considerados os efeitos da introdução de geração distribuída por meio de placas fotovoltaicas e, também, o uso de armazenadores de energia objetivando a redução das perdas técnicas. Para alcançar este objetivo, de maneira a disponibilizar ao final da pesquisa uma ferramenta útil e aplicável, utilizaram-se recursos oriundos de técnicas de inteligência artificial, tais como as Redes Neurais Artificiais e a Otimização por Enxame de Partículas. As Redes Neurais Artificiais foram empregadas de modo a fazer uma estimativa da potência gerada pelas placas fotovoltaicas. Foram obtidos e tratados dados climáticos com projeção de um horizonte definido os quais permitiram realizar estimativa do potencial de geração de energia elétrica. Através do estudo das revisões bibliográficas e simulações, foi escolhida a arquitetura de rede NARX. Foi feito também um estudo de dimensionamento a longo prazo de armazenadores de energia para a minimização das perdas técnicas em redes de distribuição. Foram feitas análises combinatórias para a reconfiguração da rede de distribuição com testes de factibilidades, de acordo com a teoria dos grafos. O fluxo de carga foi implementado por meio do método de Newton-Raphson trifásico. Por meio da Otimização por Enxame de Partículas Binário (BPSO) foram testadas as configurações otimizadas de rede para a minimização de perdas técnicas. A linguagem de programação utilizada, para o desenvolvimento de todos os algoritmos propostos, foi a disponível no software MATLAB®. A topologia de rede analisada, é a do sistema do IEEE 37 barras (modificado).

Palavras-chave: Penetração Fotovoltaica, Redes Neurais Artificiais, Armazenadores de Energia, Baterias de chumbo-ácido, Otimização por Enxame de Partícula.

Abstract

Monteiro, R. V. A., *Optimized reconfiguration of electric distribution networks with photovoltaic penetration, with the use of energy storage and with the aid of artificial intelligence*, FEELT-UFU, 186 p. 2017.

This work presents a study about the reconfiguration of electrical distribution systems, with aim to minimize its technical losses, or be it, Joule effect losses. The effect of Photovoltaics penetration and energy storage were considered herein. To achieve this objective, in a way to at the end of this research left available a useful and applicable tool, resources from Artificial Intelligence techniques were used, such as Artificial Neural Networks and Particle Swarm Optimization. The Artificial Neural Networks were used to estimate the generated power by means of Photovoltaics. Weather data were obtained and standardized with the projection for a defined horizon which allowed the estimation of the potential generated power. By means of bibliographic studies e simulation, the NARX architecture was chosen. A battery energy storage long-term scale study was performed to minimize technical losses on distribution grids. Combinatory analysis were performed to reconfigure the distribution grid with factbility tests, according to graph theory. The power flow was implemented by means of the three-phase Newton-Raphson method. With Particle Swarm Optimization, the optimized configurations of the grid were tested for the network losses minimization. The computer language used, for all of the proposed algorithms, was the available on MATLAB® software. The grid topology analyzed is that from IEEE 37 buses (modified).

Keywords: Photovoltaic Penetration, Artificial Neural Networks, Energy Storages, Lead-acid Batteries, Particle Swarm Optimization.

Listas de Figuras

Figura 1 - Uso da energia solar por Arquimedes para incendiar navios.....	32
Figura 2 - Uma fornalha de Lavoisier.	33
Figura 3 - Amostra do refletor cônico truncado de Augustin Mouchot.	33
Figura 4 - Concentrador de prato parabólico alinhado a uma impressora.....	34
Figura 5 - Concentrador cilíndrico parabólico de Ericsson, 1883	35
Figura 6 - Patente de Aubrey Eneas de seu gerador solar.	36
Figura 7 - O arranjo solar térmico de Shuman e Vernon.....	36
Figura 8 - Comparativo entre 2013 e 2014 de armazenamento de energia.	38
Figura 9 - Impedância equivalente.	41
Figura 10 - Ramo trifásico.....	43
Figura 11. Modelo não-linear de um neurônio.	53
Figura 12 - Função Degrau. Onde $net = uk$	55
Figura 13 - Função Linear. Onde $net = uk$	56
Figura 14 - Função Logística. Onde $net = uk$	57
Figura 15 - Função Tangente Hiperbólica. Onde $net = uk$	57
Figura 16 - Rede alimentada adiante ou acíclica com uma única camada de neurônios.	58
Figura 17 - Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída.....	58
Figura 18 - Rede recorrente sem laços de auto-alimentação e sem neurônios ocultos. .	59
Figura 19 - Rede recorrente com neurônios ocultos.....	59
Figura 20 - Modelo de uma rede NARX.	61
Figura 21 - Algoritmo de treinamento para Scaled Conjugat Gradient.....	64
Figura 22 - Diagrama do espaço de busca do PSO clássico.....	70
Figura 23 - Fluxograma do PSO clássico	71
Figura 24 - Configuração inicial do sistema utilizado como exemplo.	73
Figura 25 - Aplicação do operador de deslocamento SO.	73
Figura 26 - Configuração final do sistema utilizado como exemplo.....	74
Figura 27 - Esquema armazenador hidroelétrico bombeado.	83
Figura 28 - Esquema CAES.	85
Figura 29 - Reator com Pebble Beds.	86
Figura 30 - Sistema flywheel.....	87
Figura 31 - Sistema SMES.	88
Figura 32 - Estrutura de um supercapacitor.....	90
Figura 33 - Sistema de uma bateria eletroquímica.	92
Figura 34 - Atlas solarimétrico de Minas Gerais - Radiação média diária anual.....	96
Figura 35 - Irradiância, temperatura da célula e potência gerada.....	96
Figura 36 - Curva corrente por tensão de uma fotocélula com diferentes irradiações. .	98

Figura 37 - Curva de corrente por tensão de uma fotocélula com diferentes temperaturas.....	99
Figura 38 - Regressão linear para os algoritmos de treinamento.	103
Figura 39 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento BFG.	104
Figura 40 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento BR.	104
Figura 41 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento CGB.....	105
Figura 42 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento CGP.	105
Figura 43 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento RP.....	105
Figura 44 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento SCG.	106
Figura 45 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento LM.	106
Figura 46 - Potência ativa medida e estimada (W) para os 3 dias de irradiância intermitente. Algoritmo BR.....	107
Figura 47 - Potência ativa medida e estimada (W) para os 3 dias de irradiância intermitente. Algoritmo LM.	107
Figura 48 - MAPEs e RMSEs obtidos por algoritmo de treinamento.	108
Figura 49 - Demanda de potência ativa x Geração fotovoltaica de potência ativa.	109
Figura 50 - Relação entre DoD(%) e o numero máximo de ciclos que uma bateria de chumbo-ácido pode realizar.....	116
Figura 51- Fluxograma do algoritmo proposto.	119
Figura 52 - Diagrama do sistema do AEE conectado à rede de distribuição de média tensão.....	121
Figura 53 - SoC(%). (a) Projeção a longo prazo para 5 anos. (b) Projeção a curto prazo.	123
Figura 54 - SoC(%). Projeção a longo prazo para 10 anos.....	123
Figura 55 - Comportamento da energia nos AEEs para a projeção a longo prazo de 10 anos.....	124
Figura 56 - Comportamento da energia nos AEEs para a projeção a longo prazo de 5 anos.....	124
Figura 57 - Comportamento da energia nos AEEs para a projeção a curto prazo.....	125
Figura 58 - DoD(%) e SoH(%) dos AEEs para a projeção a longo prazo de 10 anos..	125
Figura 59- DoD(%) e SoH(%) dos AEEs para a projeção a longo prazo de 5 anos....	126
Figura 60 - DoD(%) e SoH(%) dos AEEs para a projeção a curto prazo.....	126
Figura 61 - RNAs utilizadas para a previsão de dados.....	130
Figura 62 - Regiões de concentração de carga do sistema IEEE 37 barras modificado.	131
Figura 63 - Crescimento de demanda e GD previstos ao longo de 10 anos.....	135
Figura 64 - Perfil de demanda e geração fotovoltaica durante 1 dia.....	135

Figura 65 - Perfil de demanda trifásico	137
Figura 66 - Custos das perdas ativas	137
Figura 67 - Perfil diário da bateria, perfil de perdas com e sem Baterias para 6 dias de análises.	138
Figura 68 - Sistema IEEE 37 barras modificado.	142
Figura 69 - Convergência do BPSO para 10 partículas e 100 iterações.	145
Figura 70 - Convergência do BPSO para 20 partículas e 100 iterações.	145
Figura 71 - Convergência do BPSO para 30 partículas e 100 iterações.	146
Figura 72 - Convergência do BPSO para 40 partículas e 100 iterações.	146
Figura 73 - Convergência do BPSO para 50 partículas e 100 iterações.	147
Figura 74 - Convergência do BPSO para 60 partículas e 100 iterações.	147
Figura 75 - Convergência do BPSO para 70 partículas e 100 iterações.	148
Figura 76 - Convergência do BPSO para 80 partículas e 100 iterações.	148
Figura 77 - Convergência do BPSO para 90 partículas e 100 iterações.	149
Figura 78 - Convergência do BPSO para 100 partículas e 100 iterações.	149
Figura A.1 - Exemplo de um diagrama representando um grafo G.	171
Figura A. 2 - Representação de um sistema elétrico malhado.....	172
Figura A. 3 - Matriz a para o caso de todas as linhas ativas	174
Figura A. 4 - Matriz a para o caso das linhas 2 e 6 inativas ou abertas.	174
Figura AN 1 - Interface construída.....	178
Figura AN 2 - Regressão linear entre potências medidas e previstas.....	180
Figura AN 3 - Comparaçāo gráfica entre potências medidas e previstas.....	180
Figura AN 4 - Gráficos gerados a partir do botão exportar gráficos.....	181

Listas de Tabelas

Tabela 1 - Tensões nominais padronizadas do sistema de distribuição brasileiro	31
Tabela 2 - Níveis de tensão para conexão de centrais de geração distribuída.....	31
Tabela 3 - Empreendimentos em operação no Brasil.....	37
Tabela 4 - Situação dos reservatórios do Sistema Elétrico Brasileiro.....	38
Tabela 5 - Usinas do Tipo Solar Fotovoltaica na cidade de Uberlândia/MG.....	39
Tabela 6 - Características elétricas da placa solar	97
Tabela 7 - Síntese dos dados analisados de acordo com os algoritmos de treinamento	102
Tabela 8 - Parâmetros utilizados nas simulações.	120
Tabela 9 - Resultados das simulações a longo prazo para duas projeções de tempo diferentes comparativamente ao dimensionamento a curto prazo.....	121
Tabela 10 - Dados horários diurnos de 1 dia simulado - dia 15	129
Tabela 11 - Dados horários noturnos de 1 dia simulado - dia 15	130
Tabela 12 - Fatores de carga e custos de perdas por potência ativa	136
Tabela 13 - Resultado do primeiro ano para os 4 casos simulados.	138
Tabela 14 - Valores de perdas técnicas com bes, encontradas em 1 dia de simulação para o período noturno. casos 1 e 2.	138
Tabela 15 - Valores simulados para 1 dia no período diurno durante 10 anos.....	139
Tabela 16 - Valores percentuais de aumento de perdas técnicas anuais em relação ao primeiro ano.....	139
Tabela 17 - Valores anuais previstos de perdas técnicas com e sem BES e sua diferença.	140
Tabela 18 - Tecnologias de armazenadores de energia.	141
Tabela 19 - Trechos e numeração atribuída.....	150
Tabela 20 - Número de partículas, trechos abertos e perdas em pu.	151
Tabela 21 - Perdas sem e com AEE para a melhor configuração encontrada no processo de otimização	151
 Tabela A. 1 - Um grafo G, figura A. 1, e uma de suas representações em diagrama... Tabela A. 2 - Exemplos de caminho, cadeia, ciclo e seus respectivos pares de vértices.	171 172
Tabela A. 3 - Conectividade das barras do sistema representado na figura A. 2.	173
 Tabela ANB 1 - Dados de carga do sistema teste IEEE 37 barras.	182
Tabela ANB 2 - Impedâncias próprias utilizadas nas simulações. Sistema IEEE 37 barras modificado.	182
Tabela ANB 3 - Impedâncias mútuas utilizadas nas simulações. Sistema IEEE 37 barras modificado.	183

Tabela ANB 4 - Admitâncias próprias utilizadas nas simulações. Sistema IEEE 37 barras modificado.....	184
Tabela ANB 5 - Admitâncias mútuas utilizadas nas simulações. Sistema IEEE 37 barras modificado.....	185

Listas de Abreviaturas

a.C.	Antes de Cristo
AEE	Armazenadores de Energia Elétrica
AG	Algoritmo Genético
ANEEL	Agência Nacional de Energia Elétrica
ARIMA	<i>Auto Regressive Integrated Moving Average</i>
AVR	<i>Automatic Voltage Regulator</i>
BES	<i>Battery Energy Storage</i>
BFGS	Broyden-Fletcher-Goldfarb-Shannon
BPSO	<i>Binary Particle Swarm Optimization</i>
BR	Bayesian Regularization
BS	Bobina Supercondutora
CA	Corrente Alternada
CAES	<i>Compressed Air Energy Storage</i>
CC	Corrente Contínua
CGB	Conjugate Gradient with Powell/Beale Restarts
DoD	<i>Depth of Discharge</i>
FACTS	<i>Flexible Alternating-Current Transmission Systems</i>
FPO	Fluxo de Potência Ótimo
Gbest	<i>Global Best Position</i>
GD	Geração Distribuída
GUI	<i>Graphical User Interface</i>
HVDC	<i>High-Voltage Direct-Current</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
INPE	Instituto Nacional de Pesquisas Espaciais
LM	Levenberg-Marquardt
MAPE	<i>Mean Absolute Percentage Error</i>
MATLAB	<i>Matrix Laboratory</i>
MPC	<i>Model Predictive Control</i>
NA	Normalmente Aberta
NARX	<i>Nonlinear Autoregressive with eXogeneous inputs</i>

NF	Normalmente Fechada
OCV	<i>Open Circuit Voltage</i>
ONS	Operador Nacional do Sistema
Pbest	<i>Particular Best Position</i>
PC	<i>Personal Computer</i>
PHS	<i>Pumped Hydroelectric Storage</i>
PRODIST	Procedimentos de Distribuição
PSO	<i>Particle Swarm Optimization</i>
PV	<i>Photovoltaic</i>
RAM	<i>Random Access Memory</i>
RMSE	<i>Root Mean Square Error</i>
RNA	Rede Neural Artificial
RP	Resilient Backpropagation
SCG	Scaled Conjugate Gradient
SD	Steepest Descent
SDR	Sistema de Distribuição Radial
SEPTA	Southeastern Pennsylvania Transportaion Authority's
SMES	<i>Super Conducting Energy Storage</i>
SO	<i>Shift Operator</i>
SoC	<i>State of Charge</i>
SoH	<i>State of Health</i>
SOM	<i>Self-Organize Mapping Network</i>
SOS	<i>Shift Operator Set</i>
SSS	<i>Sequence Switch States</i>
UPFC	<i>Unified Power Factor Controller</i>
VLSI	<i>Very Large Scale Integration</i>
VVC	Volt/VAR

Sumário

CAPÍTULO 1	20
<i>Introdução</i>	20
1.1 Justificativa.....	20
1.2 Motivações.....	23
1.3 Objetivos gerais	24
1.3.1 <i>Objetivos específicos</i>	24
CAPÍTULO 2	26
<i>Aspectos Gerais Sobre Energia Elétrica</i>	26
2.1 Considerações Iniciais	26
2.2 A Geração Distribuída	26
2.2.1 <i>Evolução Histórica da Geração Distribuída</i>	27
2.2.2 <i>Aspectos Técnicos da Geração Distribuída</i>	28
2.3 Um Histórico da Utilização da Energia Solar.....	32
2.3.1 <i>Estrutura Energética no Brasil</i>	37
2.4. Fluxo de potência trifásico.....	40
2.4.1 <i>Método de fluxo de potência Newton - Raphson trifásico</i>	41
CAPÍTULO 3	48
<i>Inteligência Artificial</i>	48
3.1 Introdução	48
3.2 <i>Motivação e Estado da Arte</i>	48
3.3 <i>Redes neurais artificiais (RNA)</i>	51
3.3.1 <i>O Neurônio</i>	53
3.3.2 <i>Funções de Ativação</i>	55
3.3.3 <i>Arquitetura de redes</i>	57
3.3.3.1 <i>Redes Recorrentes</i>	60
3.3.3.2 <i>A Rede NARX</i>	60
3.3.5 <i>Algoritmos de treinamento</i>	61
3.4 Otimização por Enxame de Partículas (PSO)	64
3.4.1 <i>Motivação e Estado da Arte</i>	65

3.4.2 <i>PSO Clássico</i>	68
3.4.3 <i>PSO binário (BPSO)</i>	71
3.4.3.1 <i>Operador de deslocamento</i>	72
3.4.3.2 <i>Conjunto de operadores de deslocamento</i>	74
3.4.4 <i>BPSO modificado</i>	74
Capítulo 4	77
<i>Armazenadores de Energia</i>	77
4.1 Introdução	77
4.1.1 <i>Armazenadores de energia elétrica</i>	77
4.2 Motivação e estado da arte	80
4.3 Classificação	82
4.3.1 <i>Tipos de sistemas armazenadores de energia</i>	82
4.3.1.1 <i>Armazenador hidroelétrico bombeado</i>	83
4.3.1.2 <i>Armazenador de energia a ar comprimido</i>	84
4.3.1.3 <i>Armazenador de energia de roda livre</i>	86
4.3.1.4 <i>Armazenador de energia supercondutor magnético</i>	88
4.3.1.5 <i>Capacitores (Supercapacitores)</i>	89
4.3.1.6 <i>Baterias eletroquímicas</i>	91
4.3.1.6.1 <i>Baterias de chumbo-ácido</i>	92
CAPÍTULO 5	94
<i>Resultados</i>	94
5.1 Introdução	94
5.2 Análise do desempenho de algoritmos de treinamento da RNA para a estimação de geração fotovoltaica	94
5.2.1 <i>Dados solares da região de coleta de dados</i>	95
5.2.1.1 <i>O efeito da irradiação na fotocélula</i>	97
5.2.1.2 <i>O efeito da temperatura na fotocélula</i>	98
5.2.2 <i>Estrutura da RNA</i>	99
5.2.2.1 <i>Preparação da rede e índices de desempenho</i>	99
5.2.3 <i>Resultados e discussões</i>	101
5.2.4 <i>Conclusão parcial</i>	108
5.3 Proposta de dimensionamento a longo prazo de armazenadores de energia do tipo chumbo-ácido.....	109
5.3.1 <i>Características e parâmetros da bateria</i>	110

5.3.1.1 <i>Estado de carga (State of Charge - SoC)</i>	110
5.3.1.2 <i>Profundidade de descarga (Depth of Discharge - DoD)</i>	111
5.3.1.3 <i>Estado de vida útil (State of Health - SoH)</i>	111
5.3.2 Proposta de dimensionamento da capacidade de armazenamento de baterias	112
5.3.2.1 <i>Potência da Bateria</i>	112
5.3.2.2 <i>Dimensionamento a longo prazo considerando aumento de demanda e geração não constantes</i>	113
5.3.2.2.1 <i>Regressão Polinomial</i>	113
5.3.2.2.3 <i>Dimensionamento a longo prazo considerando aumento de demanda e geração constante - Método direto</i>	114
5.3.2.4 <i>Previsão de vida útil da bateria</i>	115
5.3.2.4.1 <i>Regressão não linear logarítmica</i>	117
5.3.2.5 <i>Algoritmo de dimensionamento proposto para cálculo da vida útil das baterias</i>	118
5.3.3 <i>Resultados e discussões</i>	120
5.3.4 <i>Conclusão Parcial</i>	126
5.4 Análise a longo prazo da minimização de perdas por potência ativa, utilizando RNA e armazenadores de energia do tipo chumbo-ácido.....	127
5.4.1. <i>Redes neurais artificiais utilizadas</i>	128
5.4.2 <i>Estudos de caso</i>	131
5.4.3 <i>Modelo matemático com demanda variável</i>	133
5.4.3 <i>Resultados</i>	134
5.4.4 <i>Conclusão parcial</i>	141
5.5 Reconfiguração otimizada por BPSO	142
5.5.1 <i>Conclusão parcial</i>	152
CAPÍTULO 6	153
<i>Considerações Finais</i>	153
6.1 <i>Sugestões para trabalhos futuros</i>	155
Referências	156
APÊNDICE A	170
A.1 Representação por grafos	170
A.1.1 <i>Teoria dos grafos</i>	170
A.1.2 <i>Técnica para verificação da radialidade do SDR</i>	172
APÊNDICE B	176

<i>ARTIGOS PUBLICADOS RELATIVOS AO TEMA DA TESE</i>	176
<i>ANEXO A</i>	178
<i>ANEXO B</i>	182

CAPÍTULO 1

Introdução

1.1 Justificativa

O desenvolvimento da humanidade está intimamente ligado ao uso da energia em suas diversas formas. Consolidar este avanço significa, entre outros fatores, garantir que as fontes de energia estejam disponíveis em níveis suficientes e, de igual forma, acessíveis para garantir a demanda energética que sustenta a sociedade moderna. Torna-se cada vez mais necessário, portanto, que novas tecnologias para geração de eletricidade sejam aplicadas em consonância à preservação dos recursos naturais, permitindo assim o desenvolvimento sustentável de futuras gerações.

O nível de consumo de energia elétrica de um país é um dos indicadores do quanto esse país está se desenvolvendo economicamente. Um país que tem um alto e crescente consumo de energia elétrica se traduz em fortes investimentos nos setores de produção devido ao aumento do seu parque industrial e também no setor residencial, uma vez que provê a sua população maiores condições de acesso a bens de consumo como, por exemplo, eletrodomésticos e eletroeletrônicos.

Além dos programas de conservação de energia elétrica vigentes no Brasil para a diminuição da demanda de potência ativa e do consumo de energia elétrica, investimentos na geração de energia elétrica vêm sendo feitos e previstos para suportar e garantir essa expansão econômica no tocante ao consumo de energia elétrica.

Até o ano de 2016, as hidroelétricas eram responsáveis por 68,1% da geração de energia elétrica no Brasil e este panorama não tende a diminuir muito nos próximos 5 anos. Em segundo lugar pode-se destacar a geração de energia elétrica por meio das

termoelétricas sendo responsáveis por 23,9%. Já a geração através da energia solar é inexpressiva no Brasil tendo aproximadamente 0,0% de contribuição quando comparada aos outros tipos de geração (EPE, 2016).

Os impactos ambientais ocasionados pelos tipos de geração de energia elétrica supracitados, em consonância com a crescente preocupação com a conservação do meio ambiente, intensificam a necessidade da utilização, cada vez mais, de fontes alternativas de energia elétrica, empregando-se para tal finalidade energias primárias consideradas do tipo renováveis.

Neste contexto tem-se como grande expectativa o crescimento da geração de energia elétrica por meio da energia eletromagnética advinda da irradiação solar e que pode ser aproveitada por placas fotovoltaicas para a geração de energia elétrica para diversos tipos de utilização, sejam eles para alimentar equipamentos elétricos de uma residência ou recarregar automóveis elétricos, por exemplo.

Uma das maneiras de se utilizar a energia solar para gerar energia elétrica é por meio da geração distribuída (GD). Geração distribuída nada mais é do que uma expressão utilizada para identificar a geração de energia elétrica junto ou próximo a um consumidor, independente de potência, tecnologia e fonte de energia (INEE, 2017).

O Brasil é um país de clima predominantemente tropical com um grande potencial energético para a geração de energia elétrica por meio da energia solar. Avaliando somente as regiões Centro-Oeste e Sudeste, em média o período de insolação diária é de 7 a 8 horas diárias com uma irradiação solar anual média de 16 a 18 (MJ/m².dia) (ANEEL, 2005).

A geração de energia elétrica por placas fotovoltaicas, em determinados casos, se torna uma alternativa viável quando se analisa comunidades distantes e com difícil acesso a linhas e redes de distribuição de energia elétrica.

Pode-se citar, como destaque da utilização de energia no caso supracitado, o programa do Governo Federal “Luz para Todos” que proved acesso à energia elétrica a muitas famílias brasileiras, por meio de sistemas fotovoltaicos (CUNHA, 2013).

Em 2012 a ANEEL – Agência Nacional de Energia elétrica, aprovou a Resolução Normativa – REN 482/2012, que estabelece as condições gerais para o acesso da micro e minigeração aos sistemas de distribuição de energia elétrica em, baixa tensão, advindas de fontes renováveis de energia (CUNHA, 2013). Prevê-se dessa maneira um grande aumento na geração de energia elétrica através de placas fotovoltaicas e também o aumento da procura dessa tecnologia e desenvolvimento.

Os impactos da inserção de geradores distribuídos à rede de distribuição elétrica, contudo necessitam ser melhor estudados. Alguns efeitos poderão ser sentidos somente com o aumento do número de consumidores com geração própria.

Uma vez que em determinadas épocas do ano, como por exemplo, no período seco no Brasil, há um aumento de demanda de potência ativa e do consumo de energia elétrica devido, na maioria das vezes, ao aumento da utilização de condicionadores de ar, as concessionárias e permissionárias de energia elétrica poderão utilizar como recurso a energia elétrica fornecida pelas micro e minigerações.

Entretanto, o perfil de carga de consumidores residenciais se comporta de uma maneira específica (JARDINI et. al., 2000). Durante o dia, período em que a fotovoltaica é maior devido a insolação, são as horas do dia em que maior parte dos consumidores estão fora de suas residências trabalhando ou exercendo suas atividades diárias, aproveitando esse período para obterem créditos com a energia gerada ao invés de utilizá-la. Com isso há um aumento considerável de potência na rede de distribuição fazendo com que isso cause uma variação no nível de tensão da rede, sendo caracterizado neste caso um aumento de tensão (DESCHEEMAEKER, 2014). O mesmo pode-se dizer da ocorrência do contrário, ou seja, do aumento da demanda da rede devido a esses consumidores estarem retornando para suas residências e aumentarem a demanda de potência ativa nos horários de pico ocasionando uma redução de tensão (DESCHEEMAEKER, 2014).

Assim, a injeção de potência ativa nas redes ocasiona aumento de perdas técnicas, tornando-se imprescindível o estudo desses fatores, de forma a desenvolver meios que possam verificá-los e minimizá-los.

Uma das maneiras de se fazer isso, atualmente, é utilizando dispositivos armazenadores de energia elétrica, facilitando assim o controle das variáveis presentes na inserção da GD.

Armazenadores de energia elétrica (AEE) utilizam o processo de conversão de energia elétrica de um sistema de potência para uma forma de energia que possa ser armazenada (CHEN et. al, 2009).

Dentro desse cenário, a análise, desenvolvimento e a compreensão de meios para controlar e manter a correta operação de redes de distribuição de energia elétrica se tornam imprescindível.

1.2 Motivações

As redes de distribuição são tradicionalmente passivas, ou seja, projetadas para um fluxo de potência unidirecional desde a subestação até os consumidores finais, não sendo concebidas para suportar a inserção de unidades de geração, ou geração distribuída. Neste sentido, vários estudos têm indicado que esta integração pode resultar em problemas técnicos e operacionais para a rede. Tal fato aponta para a necessidade de se entender como se daria esta interconexão, atentando-se para a escolha da melhor barra de conexão, além de se determinar o modo de operação dos geradores a fim de minimizar os possíveis impactos para a qualidade da energia elétrica e estabilidade do sistema. Adicionalmente, maior atenção deve ser dispensada à natureza intermitente da geração de energia pelos sistemas fotovoltaicos, pois estes dependem da irradiação solar, que condiciona a confiabilidade no fornecimento de energia. Esta condição obriga às aplicações autônomas a recorrerem a equipamentos armazenadores de energia, normalmente baterias.

A conexão desta nova fonte de energia, PV (*Photovoltaic – PV*), aos sistemas de potência consiste num importante desafio para a engenharia. Um gerador baseado na energia solar não responde às variações das condições do sistema elétrico da mesma forma que um gerador síncrono convencional. Mesmo na ausência de transitórios eletromagnéticos, a fonte solar tem características exclusivas, tais como resposta de alta velocidade (baixa inércia) e taxas elevadas da rampa de potência. A instalação em larga escala das fontes fotovoltaicas requer meios mais confiáveis para interconexão com a rede de energia elétrica principal. Têm-se, então, o que passou a ser definido como "Penetração Fotovoltaica".

A penetração fotovoltaica indica, em dados genéricos, a relação entre a quantidade de potência ativa injetada por geração fotovoltaica distribuída e o nível de demanda de potência ativa de uma determinada rede de distribuição de energia elétrica.

Diversos estudos, como em (DEGEFA et. al., 2015), (SOARES et. al., 2015), tratam dos problemas associados a alta penetração da geração distribuída em sistemas de distribuição. Dentre os casos que vem sendo analisados, em trabalhos relacionados ao tópico abordado aqui, destacam-se como consequências as variações de tensão, variações de frequência e redução de perdas técnicas.

Além das técnicas determinísticas aplicadas à resolução da problemática descrita aqui, métodos heurísticos vêm ganhando ampla divulgação e utilização, por apresentarem bons resultados. Dentre estes destaca-se o algoritmo de enxame de partículas, ou *Particle Swarm Optimization*, que além de bons resultados tem apresentado eficiência e simplicidade em sua implementação (EBERHART e SHI, 2004).

Neste sentido é que se insere a contribuição deste trabalho. É apresentado o desenvolvimento de uma ferramenta computacional voltada para a análise da redução de perdas por potência ativa de um sistema de distribuição por meio de análise trifásica. Nesta análise, é considerada a influência da penetração fotovoltaica e de armazenadores de energia introduzidos no sistema. Com o intuito de produzir uma ferramenta eficiente e prática, se fez a utilização de redes neurais artificiais para a estimativa do nível de potência ativa gerada por placas fotovoltaicas e o uso do algoritmo de enxame de partículas binário para a reconfiguração ótima do sistema trifásico. Foi desenvolvido um equacionamento matemático para o dimensionamento a longo prazo, de armazenadores de energia de chumbo-ácido. Complementarmente, uma análise da redução de perdas técnicas a longo prazo utilizando AEE também foi realizada.

1.3 Objetivos gerais

Nesta pesquisa, propõe-se a reconfiguração otimizada de redes de distribuição de energia elétrica com penetração fotovoltaica, com a utilização de armazenadores de energia, e com o auxílio de inteligência artificial.

1.3.1 *Objetivos específicos*

Esta pesquisa tem como objetivos específicos:

- Fazer uma revisão bibliográfica sobre o assunto;
- Analisar o perfil de demanda residencial com penetração fotovoltaica;
- Analisar dados climáticos para um período desejado para uma estimativa de geração fotovoltaica;
- Fazer a estimativa de geração fotovoltaica nesta rede de distribuição utilizando-se, para tanto, de redes neurais artificiais;

- Fazer um estudo e uma proposta de dimensionamento a longo prazo de armazenadores de energia do tipo bateria de chumbo-ácido, com o intuito de minimizar perdas técnicas em redes de distribuição;
- De posse de todas as informações anteriores, utilizar o algoritmo de enxame de partículas binário (BPSO) para o estudo trifásico de reconfiguração ótima da rede de distribuição de acordo com os limites impostos pelas condições anteriores, afim de se obter uma melhor configuração da rede para a minimização de perdas técnicas na mesma;
- Implementar um método de verificação de soluções factíveis por meio da teoria dos grafos e o estudo trifásico de fluxo de potência por meio do método de Newton – Rapshon.

CAPÍTULO 2

Aspectos Gerais Sobre Energia Elétrica

2.1 Considerações Iniciais

Em diversos países do mundo a geração distribuída representa uma alternativa bastante interessante frente às tradicionais soluções de produção centralizada de energia elétrica, com destaque para os sistemas de conversão fotovoltaicos, que agridem ao meio ambiente de forma mínima e cujas perspectivas de crescimento tem se mostrado bastante promissoras. Assim, nota-se cada vez mais a importância do desenvolvimento de pesquisas e tecnologias que levem a uma utilização mais eficiente da energia proveniente do sol e assegurem a estabilidade da conexão desta fonte à rede elétrica de potência.

2.2 A Geração Distribuída

Nesta seção é apresentada uma revisão e contextualização da geração distribuída bem como o seu papel na história do desenvolvimento e evolução das redes de distribuição de energia elétrica.

2.2.1 Evolução Histórica da Geração Distribuída

Apesar de fazer referência a uma tecnologia relativamente recente, a primeira concepção da operação de uma unidade de geração distribuída ocorreu ainda no século XIX. Em 1882, Thomas A. Edison desenvolveu e instalou uma central de geração que fornecia energia para lâmpadas incandescentes de cerca de 60 clientes em uma área de aproximadamente 1,0 km² (DIAS, BOROTONI e HADDAD, 2005). Essencialmente, esse é o conceito mais simples de GD, sendo representado por uma fonte produtora localizada próxima à carga.

A produção de energia elétrica no local de consumo, motivada principalmente pela falta de grandes redes de transporte e tecnologia de geração, quer fosse destinada à indústria, ao comércio, às residências ou à agricultura, foi a prática até meados do século XX (SANTOS e SANTOS, 2008). No entanto, o aumento da demanda por energia elétrica desencadeou a altos valores de corrente a ele associados, causando quedas de tensão nas linhas caso os geradores estivessem localizados distantes das cargas. Como consequência, a exigência de se manter a geração próxima à demanda tornou-se cada vez mais necessária, pois, frequentemente, não havia disponibilidade de locais para níveis maiores de produção (SEVERINO, 2008).

Notou-se então a necessidade de realizar a transmissão de energia elétrica em maiores níveis de tensão e por longas distâncias, onde seria possível a geração em maior escala. Paralelo a isso, o avanço na compreensão dos fenômenos elétricos e magnéticos e o desenvolvimento de equipamentos como geradores e transformadores permitiram que o uso da corrente alternada logo conquistasse seu espaço, possibilitando o atendimento de cargas distantes do ponto de geração. Assim, foi consagrado o modelo de grandes centrais de geração com extensas linhas de transmissão.

Esse modo organizacional adotado para o sistema elétrico ao longo de quase toda sua história é o que se conhece por geração centralizada de energia elétrica, ou simplesmente “geração centralizada”, “geração central”, “geração convencional” ou “geração tradicional”, expressões estas encontradas na literatura.

De outro lado, o crescimento populacional e o desenvolvimento tecnológico contínuo exigiram cada vez mais energia. Neste modelo centralizado, quando a demanda total se aproximava dos limites do sistema, tornava-se necessária a construção de novas unidades de geração de grande porte, bem como o aumento da capacidade de

transmissão e distribuição. Os motivos que justificavam tal estrutura dos setores elétricos de diversos países são (RODRIGUES, 2006), (RODRIGUEZ, 2002):

- Contínua busca por economias de escala, com a consequente redução dos custos unitários de investimento e de produção;
- Conveniente minimização dos impactos e dos riscos ambientais para os centros mais densamente povoados;
- Influência de empreendedores de grandes obras, principalmente no que tange ao setor público, dando suporte às soluções então propostas;
- Alta confiabilidade dos sistemas de transmissão de energia em alta e extra alta tensão.

Ao longo da década de 70, o paradigma da geração centralizada começou a ser questionado devido ao surgimento de novas tecnologias, que reduziram o custo da energia gerada, aliado à dificuldade de financiamento de grandes centrais de geração e aos problemas (DIAS, BOROTNI e HADDAD, 2005). Já na década de 80, a tendência de crescimento de usinas geradoras foi revertida a partir do momento em que turbinas a gás de menor porte, produzidas em larga escala, chegaram ao mercado. Prova disso é que o porte médio de uma nova usina de geração elétrica nos EUA caiu de 600 MW, em meados da década de 80, para 100 MW, em 1992, e para 21 MW, em 1998 (DUNN e FLAVIN, 2000).

Desta forma, as contínuas inovações tecnológicas no setor elétrico, associadas à desregulamentação dos mercados, possibilitaram o surgimento de novos agentes que têm contribuído para a valorização da geração distribuída: os produtores independentes e os autoprodutores de energia, vendendo ou não excedentes para a rede. Como consequência, tem-se possibilitado a expansão da malha energética de vários países ao mesmo tempo em que suas barreiras financeiras e ambientais são contornadas.

2.2.2 Aspectos Técnicos da Geração Distribuída

Nas últimas décadas, a desregulamentação da indústria de energia elétrica tem levado a mudanças profundas em suas configurações de mercado. Neste sentido, o alvo principal tem sido buscar um ambiente competitivo, inovador e voltado para os consumidores. Tal contexto enfatiza, portanto, a confiabilidade, o aumento na eficiência

energética, a preservação ambiental e a prestação de serviços que atendam a outras necessidades da comunidade em geral.

As melhorias tecnológicas ocorridas na produção em menor escala, considerando fontes tradicionais como a térmica e a hídrica, além de meios alternativos como a eólica e fotovoltaica, têm proporcionado um recurso concreto para o suprimento da crescente demanda por energia elétrica, efetuando-se a geração próxima aos pontos de consumo final. Estes sistemas de geração distribuída configuraram um modelo complementar ou alternativo ao das grandes centrais de potência no suprimento de energia elétrica.

Existem diversas definições relacionadas ao conceito de geração distribuída, como é enunciado em (EL-KJATTAN e SALAMA, 2004). Segundo (ACKERMANN, ANDERSSON e SODER, 2001), por exemplo, a geração distribuída pode ser definida como uma fonte de geração conectada diretamente na rede de distribuição ou ao consumidor. A potência instalada, nesta definição, não é considerada relevante para sua caracterização. Essa mesma referência divide a geração distribuída em função da potência em micro (até 5 kW), pequena (de 5 kW a 5 MW), média (de 5 MW a 50 MW) e grande (de 50 MW a 300 MW), valores que consideram a realidade americana.

De acordo com (SEVERINO, 2008) as GDs são caracterizadas como usinas de pequeno porte ou pequenas o suficiente para serem conectadas ao sistema de distribuição ao invés da rede de transmissão. Porém, esse conceito pode variar bastante entre países, podendo ser despachada segundo as mesmas regras de uma geração centralizada. O autor dita ainda que em alguns locais uma central de GD não deve exceder o tamanho de 10 MW, enquanto que em outros, esse valor deve ser menor que 30 MW ou até mesmo de 300 MW, desde que atenda a outras exigências.

As fontes (LORA e HADDAD, 2006) e (TRIGOSO et. al., 2008) ditam que a localização da geração distribuída é definida como conectada diretamente à rede de distribuição ou no lado do consumidor. Considera-se ainda o caso em que a GD pode ser conectada diretamente à rede de transmissão, situação essa em que a unidade de produção estiver diretamente ligada a uma indústria. Trigoso et. al. (2008), sugere ainda as seguintes distinções:

- Micro GD: Sistemas com potência inferior a 10 kW.
- Pequena GD: sistemas com potência entre 10 e 500 kW.

- Média GD: sistemas com potência entre 500 kW e 5 MW.
- Grande GD: Sistemas com potência entre 5 e 100 MW.

Outras definições, independentes da capacidade instalada, têm sido adotadas, de acordo com (MALFA, 2002). Segundo o CIGRE, geração distribuída é a geração que não é planejada de modo centralizado, nem despachada de forma centralizada, não havendo, portanto, um órgão que comande as ações das unidades de geração descentralizada. Para o *Institute of Electrical and Electronics Engineers* (IEEE), geração descentralizada é uma central de geração pequena o suficiente para estar conectada à rede de distribuição e próxima do consumidor.

Já (TURKSON e WOHLGEMUTH, 2001) ditam que a GD é definida como o uso integrado ou isolado de recursos modulares de pequeno porte por concessionárias, consumidores e terceiros em aplicações que beneficiam o sistema elétrico e/ou consumidores específicos. A referência (WILLIS e SCOTT, 2000) define geração distribuída como um caso particular de produção de energia elétrica, aplicada diretamente ao sistema de distribuição, com potências na faixa de 10 kW a 250 kW.

Para o caso do Brasil, segundo (SERVERINO, 2008), a geração distribuída é considerada como uma fonte de energia elétrica alimentando uma instalação isolada ou conectada diretamente à rede de distribuição, ou ainda no lado do consumidor conectado à rede transmissão, desde que ela não possa ser considerada pertencente à geração centralizada. Esta definição é também registrada através do decreto 5.163/2004 (BRASIL, 2004), que considera geração distribuída como aquela conectada diretamente no sistema de distribuição, de acordo com as seguintes condições:

- Hidrelétricas com capacidade inferior a 30MW;
- Termelétrica, inclusive cogeração, com eficiência energética superior a 75%;
- Para os casos de empreendimentos termelétricos que utilizem biomassa ou resíduos de processo como combustível não estarão limitados ao percentual de eficiência energética das termelétricas.

A ANEEL, através de seus Procedimentos de Distribuição (PRODIST), estabelece GD como “centrais geradoras de energia elétrica, de qualquer potência, com instalações conectadas diretamente no sistema elétrico de distribuição ou através de

instalações de consumidores, podendo operar em paralelo ou de forma isolada e despachadas – ou não – pelo ONS” (ANEEL, 2011). Esse mesmo órgão determina a relação entre as faixas de potência da unidade de GD e os níveis de tensão considerados, de acordo com a tabela 1 e tabela 2 (ANEEL, 2012).

Tabela 1 - Tensões nominais padronizadas do sistema de distribuição brasileiro

Classificação do Nível de Tensão	Tipo do Sistema	Tensão Nominal (V)
Baixa Tensão	Monofásico	254 / 127
		440 / 220
	Trifásico	220 / 127
		380 / 220
Média Tensão	Trifásico	13800
		34500
Alta Tensão	Trifásico	69000
		138000

Fonte: (O autor) a partir de (ANEEL, 2012)

Tabela 2 - Níveis de tensão para conexão de centrais de geração distribuída

Potência Instalada	Níveis de Tensão de Conexão
Menor que 10 kW	Baixa Tensão (Monofásico)
de 10 a 75 kW	Baixa Tensão (Trifásico)
de 76 a 150 kW	Baixa Tensão (Trifásico)/Média Tensão
de 151 a 500 kW	Baixa Tensão (Trifásico)/Média Tensão
de 501 kW a 10 MW	Média Tensão/Alta tensão
de 11 a 30 MW	Média Tensão/Alta tensão
Maior que 30 MW	Alta Tensão

Fonte: (O autor) a partir de (ANEEL, 2012)

Como pode ser visto, não é uma tarefa simples um acordo na definição do que constitui de fato a GD e de como ela difere da geração convencional ou centralizada. A única conclusão, em geral, é que esse tipo de geração está conectado à rede distribuição ou sub-transmissão da concessionária de energia.

Na bibliografia há também propostas de definição da GD em função de parâmetros técnicos tais como níveis de tensão, capacidade de geração, tecnologia empregada, modo de operação, área de atendimento dos consumidores, etc. No entanto, fatores limitadores como dificuldades operativas, de planejamento, regulatórias e outros empecilhos acabam impedindo que seja adotada uma definição mais simplista e restritiva.

2.3 Um Histórico da Utilização da Energia Solar

O uso da energia solar data de tempos remotos. Há registros do século I que Herão de Alexandria já utilizava o calor do Sol para bombear água. Esses coletores solares foram construídos no ano de 212 a.C., com o crédito atribuído a Arquimedes. Além de tê-los construído, é creditada a ele a façanha de ter incendiado a frota romana, durante o cerco de Siracusa (214-212 a.C.) com um conjunto de espelhos parabólicos dirigidos aos cascos dos navios, que eram imbebidos em piche para impermeabilização, e suas velas. Apesar do mito não ser completamente confirmado modernamente, foi referenciado durante toda a história, como na coletânea *Vitellonis Thuringopoloni opticae libri decem*, do matemático polonês Witelo (1230-1314), em que descreve que a arma consistia de 24 espelhos que convergiam para um único ponto (THURINGNOPOLIS, 1572), além de contar com várias obras de arte, como na figura 1.



Figura 1 - Uso da energia solar por Arquimedes para incendiar navios.
Fonte: (THURINGNOPOLIS, 1572).

Já no século XVII eram desenvolvidas as fornalhas solares, utilizadas para fundir metais, como ferro e cobre (LODI, 2011). A fornalha de Lavosier, uma das primeiras aplicada em larga escala, foi desenvolvida em 1774. Esta fornalha possuía uma lente de 1,32 m e outra de 0,2 m construída antes da primeira e era capaz de atingir altas temperaturas de até 1750°C (KALOGIROU, 2013). A fornalha de Lavosier pode ser vista na figura 2.

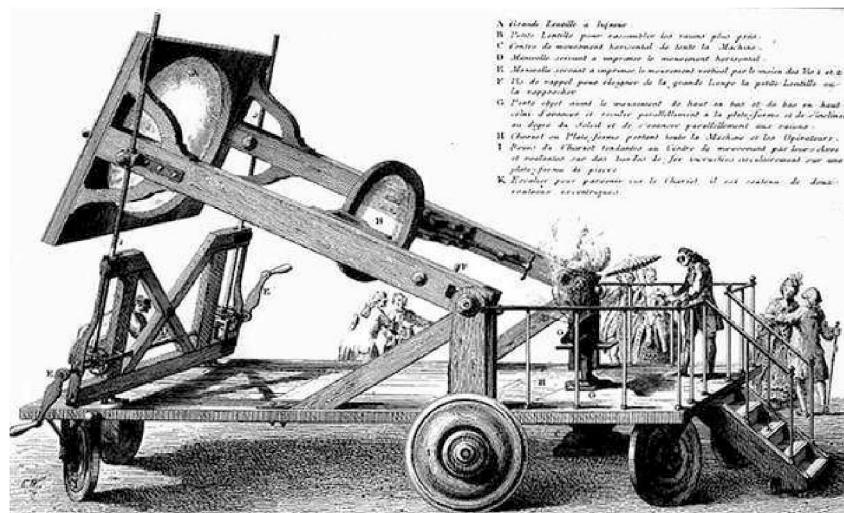


Figura 2 - Uma fornalha de Lavoisier.
Fonte: (Autor desconhecido, 2015).

No século XIX surgiu a percepção da criação de vapor a baixa pressão utilizando a radiação solar. Augustin Mouchot, com o apoio de Napoleão III, apresentou as primeiras máquinas a vapor operadas via Sol entre 1866 e 1872. Seu trabalho foi exibido em Tours e testado na Argélia como bombeamento de água (USP, 2015). Sua máquina a vapor consistia em um espelho refletor côncico truncado, figura 3, com uma caldeira estacionária em seu foco. Sua máquina chegava a produzir 0,5 HP em um dia ensolarado (FILHO, 2014).

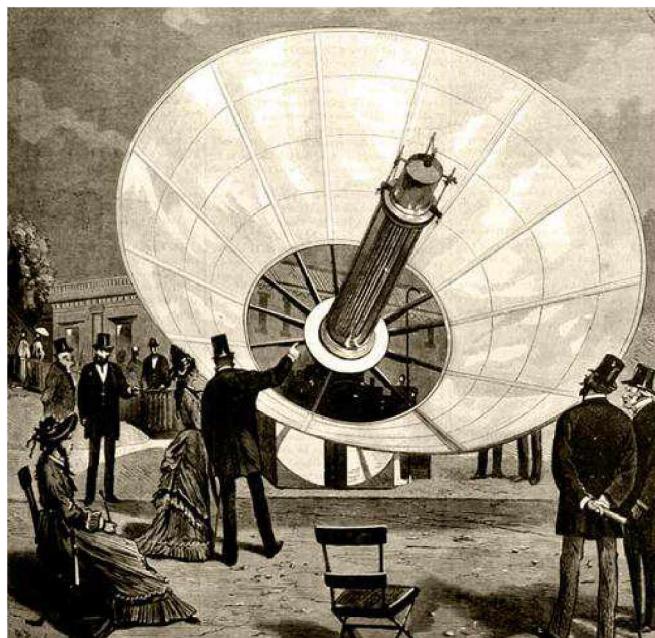


Figura 3 - Amostra do refletor cônicamente truncado de Augustin Mouchot.
Fonte: (MOUCHOT, 1872).

Em 1878, William Adams observou que a invenção de Mouchot seria impraticável utilizando apenas um espelho cônico e propôs a utilização de vários espelhos pequenos dispostos em semicírculos a fim de cada espelho refletir a radiação solar na caldeira. William estimou que 72 espelhos seriam suficientes para que a temperatura da caldeira subisse para 650°C, sendo determinante para a melhora da tecnologia (FILHO, 2014).

Em 1882, Abel Pifre construiu o primeiro concentrador solar de prato parabólico. Pifre trabalhou como assistente de Mouchot e adicionou ao seu trabalho uma impressora que chegava a produzir 500 cópias por hora. O modelo foi apresentado na exposição internacional de Paris, mas foi considerado muito caro para ser utilizado em larga escala. A figura 4 ilustra a ousada idéia de Pifre (FILHO, 2014).

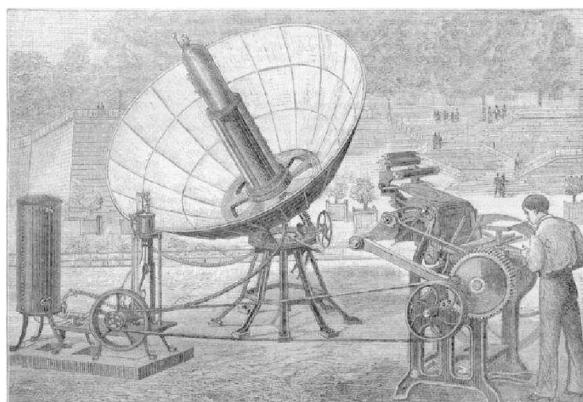


Figura 4 - Concentrador de prato parabólico alinhado a uma impressora.
Fonte: (Nature, vol 26, 1882).

De acordo com o jornal da época (Nature, vol 26, 1882):

"Uma prensa de impressão funcionou por meio de calor solar foi exibida no jardim de Tuileries em Paris na *fête*. [...] O gerador solar foi idealizado pelo M. Abel Pifre, que melhorou alguns pontos na invenção original de M. Mouchot. [...] O vapor da caldeira foi posicionado em seu foco [dos espelhos] e operou uma prensa de Marioni (na direita da imagem). Apesar do Sol não estar muito ardente e a radiação ser encoberta por frequentes nuvens, a prensa funcionou regularmente das 13 horas até as 17 horas e 30 minutos, imprimindo em média 500 cópias em uma hora de um jornal especialmente arranjado para a ocasião, o Jornal Soleil".

Ao mesmo tempo, nos Estados Unidos da América, o engenheiro e Capitão John Ericsson havia construído oito modelos de engenhos solares em 1875, mas nenhum para utilização prática. Finalmente, em 1883, conseguiu construir a segunda máquina solar da época em tamanho, diferenciando-se das outras por contar com um formato cilíndrico, o receptor na linha focal poderia ser um pequeno cano de cobre funcionando como caldeira. A máquina de Ericsson continha um coletor retangular de 11 por 16 pés que movimentava um pistão de 6 polegadas de calibre e 8 de percurso. Seu engenho operava a vapor ou a ar e, de acordo com o próprio Ericsson, conseguia gerar 1 CV por pés de coletor e era utilizado para bombear água (USP, 2015). Seu sistema pode ser visto na figura 5. Após várias melhorias em seu sistema, Ericsson desejava vê-lo comercializado, mas seu trabalho não foi levado adiante após sua morte, em 1889.

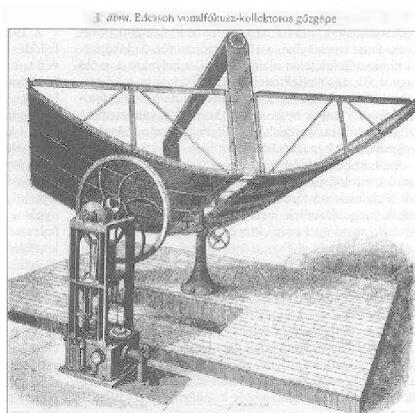


Figura 5 - Concentrador cilíndrico parabólico de Ericsson, 1883
Fonte: (UJFALUDI, 2016).

No início do século XX, os concentradores solares apresentaram continuidade em seu desenvolvimento. Aubrey Eneas, em 1901, instalou com sucesso um coletor solar para bombeamento de água em uma fazenda na Califórnia. Com 1788 espelhos alinhados como um prato parabólico, os raios de sol eram concentrados em uma caldeira no foco da estrutura. O vapor gerado operaria uma bomba centrífuga. Seu esboço de patente pode ser vista na figura 6 (FILHO, 2014).

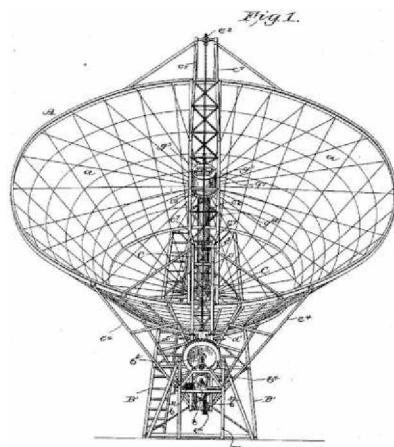


Figura 6 - Patente de Aubrey Eneas de seu gerador solar.
Fonte: (SOLAR MOTOR COMPANY, 1901).

Já em 1904, Henry E. Willsie desenvolveu o conceito de armazenamento térmico. Com o calor gerado pelos coletores, o vapor era armazenado em um recipiente isolado e a geração de movimento era feita por dióxido de enxofre que esquentava com o calor do vapor armazenado e era expelido por um exaustor para movimentar um pistão. Quando o dióxido de enxofre esfriava, retornava ao recipiente com vapor. Com essa modificação foi possível armazenar calor para ser utilizado a noite e em dias nublados (FILHO, 2014), (CANIVAN, 2012).

Em 1912, Frank Shuman e Charles Vernon Boys utilizaram o sistema de geração com refletores para bombear água do rio Nilo, onde o campo de captação se estendia por 1200m². Foi a maior construção do tipo na época. Foram utilizados cilindros parabólicos de 62 m de comprimento e 4,5 m de largura e era capaz de operar uma bomba de 75kW (LODI, 2011), (FILHO, 2014). O sistema de Shuman e Vernon pode ser visto na figura 7, assim como seu esboço e o detalhe de um cilindro.

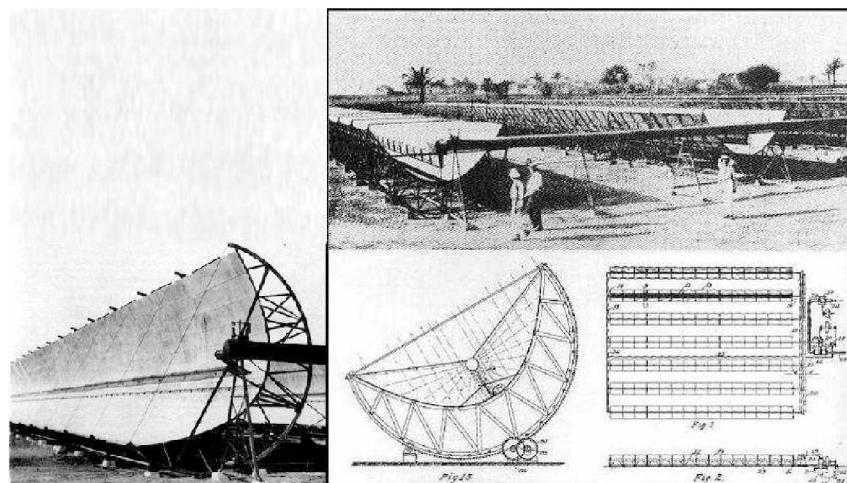


Figura 7 - O arranjo solar térmico de Shuman e Vernon.
Fonte: (WORDPRESS, 2010).

Apesar do grande sucesso, a planta foi desativada em 1915 devido a Primeira Grande Guerra e, quando esta foi findada, grandes descobertas de campos petrolíferos no Oriente Médio e na Venezuela alavancaram o setor deixando a geração termal solar em segundo plano (LODI, 2011), praticamente paralisando novos avanços significativos para a tecnologia.

2.3.1 Estrutura Energética no Brasil

O Brasil possuía, no ano de 2017, 4.710 empreendimentos de geração de energia elétrica em operação, com uma potência instalada de 153.814.820 kW. Desse número de empreendimentos, apenas 53 são do tipo fotovoltaico, com uma potência outorgada de 176.248 kW, fazendo parte de apenas 0,11% da energia produzida no Brasil. A tabela 3 apresenta os empreendimentos em operação no Brasil pelo tipo de geração (ANEEL, 2017).

Tabela 3 - Empreendimentos em operação no Brasil.
Fonte: (ANEEL, 2016).

Tipo	Qtd.	Potência Outorgada (kW)	Potência Fiscalizada (kW)	%
Central Geradora Hidrelétrica	616	557.628	560.084	0,36
Central Geradora Eólica	459	11.266.239	11.180.343	7,27
Pequena Central Hidrelétrica	433	4.979.583	4.963.967	3,23
Central Geradora Solar Fotovoltaica	53	176.248	176.248	0,11
Usina Hidrelétrica	219	101.169.128	93.858.334	61,02
Usina Térmica	2.928	42.481.848	41.085.844	26,71
Usina Termouclear	2	1.990.000	1.990.000	1,29
Total	4.710	161.620.674	153.841.820	100

Vê-se que o Brasil tem a maioria de sua matriz energética baseada em fontes renováveis, com um total de 71,99%, porém, grande parte provém de energia de usinas hidrelétricas, ficando o sistema condicionado aos reservatórios. Com essa dependência de água, períodos de seca prolongados afetam gravemente o sistema, forçando racionamentos e o aumento do preço da energia elétrica (ANEEL, 2017).

Os dados do dia 26 de Janeiro de 2016 do Operador Nacional do Sistema são apresentados na tabela 4, com os níveis dos principais reservatórios. Pode-se notar que as Regiões Sudeste e Centro-Oeste estão com os reservatórios baixos devido à seca que assola a região. É um fato preocupante, já que as duas regiões têm a capacidade de armazenamento de 70% de toda matriz hidrelétrica do país. No ano de 2017 a situação já havia mudado e os reservatórios se estabilizado em níveis adequados. Porém, o ocorrido em 2016 pode voltar a acontecer.

Observando a figura 8, da energia armazenada nas Regiões Sudeste e Centro-Oeste entre 2013 e 2014, vê-se que o armazenamento de energia nos reservatórios chega a ser 60% menor que o mesmo período em 2013. Além de notar que a diferença aumenta com o passar dos anos.

Tabela 4 - Situação dos reservatórios do Sistema Elétrico Brasileiro.
Fonte: (ONS, 2016).

Região	Bacia	Reservatório	Situação	
SE/CO	Rio Paranaíba	Emborcação	13,32%	
		Nova Ponte	10,50%	
		Itumbiara	11,27%	
		São Simão	54,39%	
	Rio Grande	Furnas	10,35%	
		Mascarenhas de Moraes	12,58%	
		Marimbondo	12,37%	
		Água Vermelha	16,63%	
	Rio Paraná	Ilha / 3 Irmãos	0%	
		Jurumirim	20,65%	
		Chavantes	18,28%	
S	Rio Paranapanema	Capivara	23,04%	
		S. Santiago	66,47%	
		G. B. Munhoz	54,72%	
	Rio Iguaçú	Segredo	100,42%	
		Rio Jacuí	Passo Real	61,94%
NE	Rio São Francisco	Rio Uruguai	Passo Fundo	92,76%
		Sobradinho	19,68%	
		Três Marias	10,23%	
N	Rio Tocantins	Itaparica	19,55%	
		Serra da Mesa	26,19%	
		Tucuruí	33,53%	

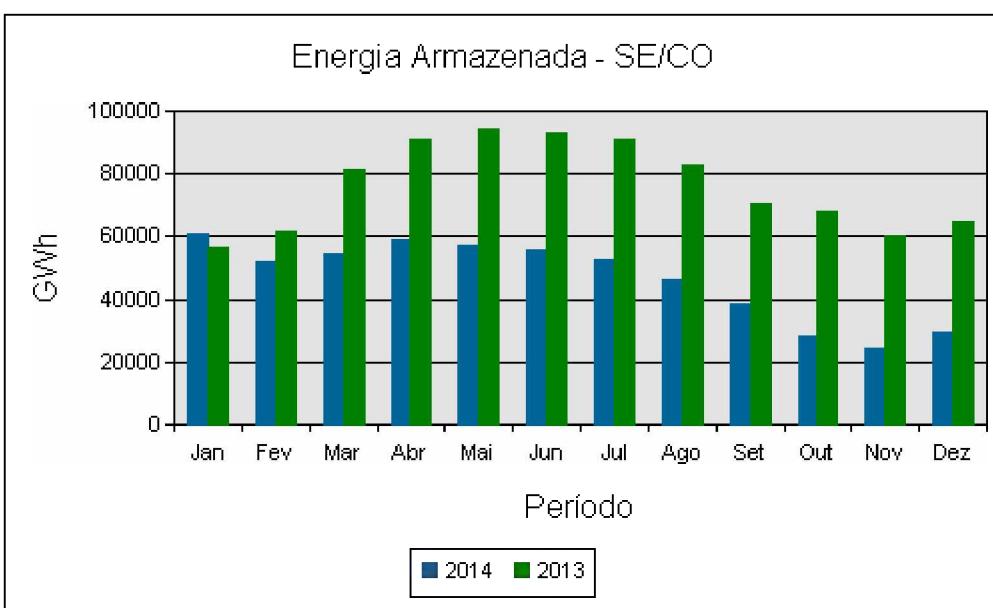


Figura 8 - Comparativo entre 2013 e 2014 de armazenamento de energia.

Fonte: (ONS, 2015).

2.3.2 A Energia Fotovoltaica no Brasil

Como visto, as fontes fotovoltaicas no Brasil compreendem 0,11% do total de potência instalada no País. Este valor é inexpressivo em comparação a outras fontes instaladas no País, porém, vem crescendo com a entrada do capital privado no mercado (ANEEL, 2017).

Dos empreendimentos em construção atuais, os de natureza fotovoltaica representam 9,55%. Com previsão de construção de 67 centrais ainda não iniciadas com possibilidade de gerar potência de 1.711.093 kW (ANEEL, 2017).

Em outubro de 2011 existiam apenas 6 usinas fotovoltaicas em operação no Brasil gerando 1.087,44 kW; em novembro de 2012 o número cresceu para 10 usinas com 2.578,06 kW; em fevereiro de 2013 contava com 11, gerando 7.578,06 kW; em dezembro de 2014, 289 usinas com 18.985,03 kW. Em setembro de 2017, eram 53 gerando 176.248 kW, um aumento de 16.207,60% em 6 anos (ANEEL, 2017).

A maioria das novas conexões são de uso particular em baixa tensão com conexão à rede elétrica, destacando-se a importância de novas pesquisas no campo de sistemas fotovoltaicos conectados à rede elétrica como geração independente.

2.3.3 A Energia Fotovoltaica em Uberlândia/MG

Na cidade de Uberlândia, Minas Gerais, é notável o número de pequenas centrais fotovoltaicas espalhadas. As primeiras usinas fotovoltaicas da região conectadas a rede se instalaram em 2013, com a instalação da usina da PGM, mantida pela PGM Suporte em Tecnologia Ltda. Seguindo a tendência, com a Resolução Normativa nº 482/2012 da ANEEL entrando em vigor e a tecnologia se espalhando, outras empresas iniciaram, também, a sua própria geração fotovoltaica.

A tabela 5 mostra a única usina do tipo solar fotovoltaica encontrada no Banco de dados da ANEEL no ano de 2017.

Tabela 5 - Usinas do Tipo Solar Fotovoltaica na cidade de Uberlândia/MG.
Fonte: ANEEL, 2017.

Usina	Potência Instalada (kW)	Proprietário
ALGAR TECH	655	100% para Algar Tecnologia e Consultoria S.A

2.4. Fluxo de potência trifásico

Os elementos convencionais de um sistema elétrico de potência são: geradores, transformadores, linhas de transmissão, cabos, cargas, bancos de capacitores, indutores não-lineares, proteções e equipamentos de controle. Esses elementos são criteriosamente interconectados para permitir que a geração de energia elétrica seja suficiente para suprir a demanda a qualquer tempo. O objetivo operacional é transmitir eletricidade para os centros de carga a um custo mínimo de produção, máxima confiabilidade e mínimas perdas na transmissão.

Para os diversos propósitos práticos, a rede elétrica de potência pode ser dividida em quatro subsistemas, chamados, geração, transmissão, distribuição e utilização. A rede de transmissão opera em altos níveis de tensão, tipicamente entre 132-700 kV. Nos sistemas de distribuição, a média tensão está tipicamente entre 13,8 - 69 kV e, em baixa tensão, para atender os consumidores residenciais e comerciais, tipicamente entre 127-380V.

Geradores síncronos trifásicos são utilizados para produzir a maior parte da energia elétrica consumida em todo o mundo e, exceto por uma pequena porcentagem de energia elétrica que é transmitida em corrente contínua (CC), que utilizam o chamado *high-voltage direct-current* (HVDC) ou corrente contínua em alta tensão, toda a eletricidade é entregue aos pontos de consumo utilizando corrente alternada (CA) através de cabos e linhas de transmissão trifásicas.

O estudo de fluxo de potência em linhas de transmissão longas, frequentemente são realizados considerando as linhas como sendo monofásicas, devido ao suposto balanceamento existente entre as fases das mesmas. Porém, essa suposição não pode ser levada em consideração para os sistemas de distribuição em baixa tensão, onde os pontos de carga podem ser altamente desbalanceados devido à grande quantidade de cargas monofásicas individuais existentes em tal sistema.

A ferramenta aplicada para a análise do estado de operação de um sistema de distribuição trifásico com um considerável desbalanceamento geométrico ou de carga é conhecido como fluxo de potência trifásico. Nesta análise, todas as operações são analisadas por fase, e todos os componentes da planta de potência são modelados sendo referenciados a cada fase do sistema.

Neste trabalho, o fluxo de potência trifásico foi feito com a utilização do método Newtom - Raphson. Toda a teoria foi feita por meio do método proposto por (ACHA et. al., 2004).

2.4.1 Método de fluxo de potência Newton - Raphson trifásico

Para se utilizar o método de Newton - Raphson trifásico, primeiramente é necessário se estabelecerem algumas relações entre corrente e tensão de barra injetadas, figura 9.

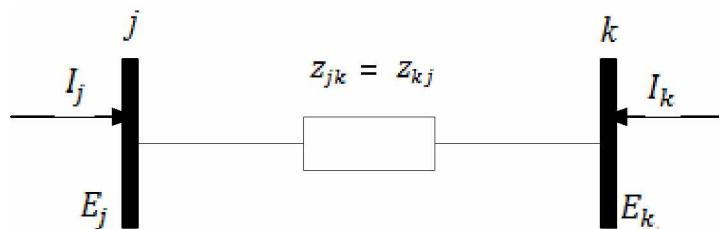


Figura 9 - Impedância equivalente.
Fonte: Modificado (ACHA et. al., 2004).

De acordo com a figura 9, a corrente complexa injetada na barra j , denominada I_j , pode ser expressa em termos de tensão complexa E_k e E_j , (1):

$$I_j = \frac{1}{Z_{jk}}(E_j - E_k) = y_{jk}(E_j - E_k) \quad (1)$$

Similarmente para a barra k , (2):

$$I_k = \frac{1}{Z_{kj}}(E_k - E_j) = y_{kj}(E_k - E_j) \quad (2)$$

onde as admitâncias de barra e as tensões podem ser expressas de forma explícita por (3) e (4):

$$Y_{im} = G_{im} + jB_{im} \quad (3)$$

$$E_i = V_i e^{j\theta_i} = V_i(\cos\theta_i + j\sin\theta_i) \quad (4)$$

onde $i = j, k$, e $m = k, j$.

As expressões de potência complexa injetada na barra, bem a expressão geral de potência ativa e reativa transmitidas, podem ser encontradas em (MONTICELLI, 1983).

Na teoria do fluxo de potência convencional cada barra é descrita pela dupla combinação entre quatro variáveis: P, Q, V e θ (ângulo de fase).

Uma vez que há somente duas equações por barra, outras duas variáveis precisam ser especificadas em cada barra no intuito de se ter um problema solucionável. As barras são classificadas de acordo com as variáveis especificadas, sendo:

- Barra de carga PQ: sem conexão de gerador na barra, consequentemente as variáveis P_G e Q_G possuem valor zero. Além disso, as potências ativas e reativas drenadas pelas cargas P_C e Q_C são conhecidas. Nesse tipo de barra as potências ativa e reativa da rede são especificadas e V e θ computados.
- Barras de geração PV: uma fonte é conectada a barra e a magnitude de tensão nodal V é constante. Isso seria o correspondente a ajustar a corrente de excitação de campo do gerador enquanto o mesmo absorve ou gera potência reativa. A potência ativa gerada P_G também é especificada. As outras duas variáveis θ e Q_G são calculadas. A operação com tensão constante só é possível se o limite de potência reativa do gerador não ultrapassa os limites $Q_{G\ min} < Q_G < Q_{G\ máx}$.
- Barra de referência (*slack* ou *swing*): uma das barras geradoras são escolhidas como a barra de referência ou *slack*, onde a magnitude de tensão nodal V_{slack} e o ângulo de fase θ , são especificados. Existe somente uma barra de referência no sistema de potência e a função desta é produzir potência o suficiente para atender cargas não atendidas e suprir as perdas do sistema. O ângulo de tensão de fase θ_{slack} é determinado como referência em relação a todos os demais ângulos de tensão do sistema que por sua vez são determinados em relação ao ângulo de referência. Este ângulo é fixado em zero.

Para o fluxo trifásico, tem-se a injeção de correntes e tensões injetadas nas barras nas três fases, figura 10:

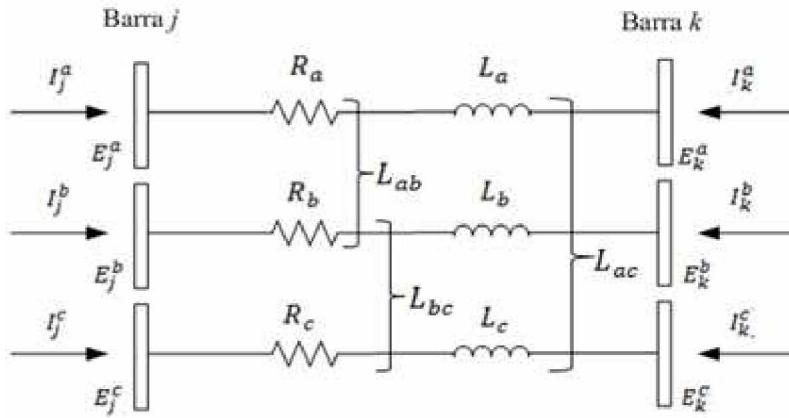


Figura 10 - Ramo trifásico.

As tensões são relacionadas pela matriz admintância de transferência do ramo (5):

$$\begin{bmatrix} I_j^{abc} \\ I_k^{abc} \end{bmatrix} = \begin{bmatrix} Y_{jj}^{abc} & Y_{jk}^{abc} \\ Y_{kj}^{abc} & Y_{kk}^{abc} \end{bmatrix} \begin{bmatrix} E_j^{abc} \\ E_k^{abc} \end{bmatrix} \quad (5)$$

onde:

$$Y_{jj}^{abc} = G_{jj}^{abc} + jB_{jj}^{abc} = \begin{bmatrix} R_{jk}^{aa-g} + j\omega L_{jk}^{aa-g} & R_{jk}^{ab-g} + j\omega L_{jk}^{ab-g} & R_{jk}^{ac-g} + j\omega L_{jk}^{ac-g} \\ R_{jk}^{ba-g} + j\omega L_{jk}^{ba-g} & R_{jk}^{bb-g} + j\omega L_{jk}^{bb-g} & R_{jk}^{bc-g} + j\omega L_{jk}^{bc-g} \\ R_{jk}^{ca-g} + j\omega L_{jk}^{ca-g} & R_{jk}^{cb-g} + j\omega L_{jk}^{cb-g} & R_{jk}^{cc-g} + j\omega L_{jk}^{cc-g} \end{bmatrix}^{-1} \quad (6)$$

$$Y_{jj}^{abc} = Y_{kk}^{abc} = -Y_{jk}^{abc} = -Y_{kj}^{abc}$$

$$\begin{aligned} E_j^{abc} &= [E_j^a \ E_j^b \ E_j^c]^t = [V_j^a e^{\theta_j^a} \ V_j^b e^{\theta_j^b} \ V_j^c e^{\theta_j^c}]^t, \\ E_k^{abc} &= [E_k^a \ E_k^b \ E_k^c]^t = [V_k^a e^{\theta_k^a} \ V_k^b e^{\theta_k^b} \ V_k^c e^{\theta_k^c}]^t, \\ I_j^{abc} &= [I_j^a \ I_j^b \ I_j^c]^t, \\ I_k^{abc} &= [I_k^a \ I_k^b \ I_k^c]^t, \end{aligned} \quad (7)$$

sendo a matriz transposta ou vetor indicado por 't'. As impedâncias trifásicas das barras j e k levam em consideração a contribuição dos condutores de terra 'g'.

As expressões para potência ativa e reativa injetadas nas barras trifásicas j e k da figura 10, podem ser obtidas por meio da expressão complexa, (8):

$$\begin{bmatrix} S_j^{abc} \\ S_k^{abc} \end{bmatrix} = \begin{bmatrix} P_j^{abc} + jQ_j^{abc} \\ P_k^{abc} + jQ_k^{abc} \end{bmatrix} = \begin{bmatrix} E_j^{abc} I_j^{abc*} \\ E_k^{abc} I_k^{abc*} \end{bmatrix} \quad (8)$$

Resolvendo (8), as expressões para as potências ativa e reativa injetadas na barra k nas fases a, b e c , são (9) e (10):

$$P_k^\rho = V_k^\rho \left\{ \sum_{i=j,k} \sum_{j=a,b,c} V_i^j [G_{ki}^{\rho j} \cos(\theta_k^\rho - \theta_i^j) + B_{ki}^{\rho j} \sin(\theta_k^\rho - \theta_i^j)] \right\}, \quad (9)$$

$$Q_k^\rho = V_k^\rho \left\{ \sum_{i=j,k} \sum_{j=a,b,c} V_i^j [G_{ki}^{\rho j} \sin(\theta_k^\rho - \theta_i^j) - B_{ki}^{\rho j} \cos(\theta_k^\rho - \theta_i^j)] \right\}, \quad (10)$$

onde os subscritos ρ é utilizado para denotar as fases a, b e c .

As expressões para calcular as potências ativa e reativa da barra j são as mesmas em (9) e (10), porém com o subscrito k trocado por j .

As expressões (9) e (10) podem ser linearizadas em torno de um ponto de operação base, segundo a teoria básica de Newton - Raphson (MONTICELLI, 1983) para o caso de fluxo de potência de sequência positiva. Na aplicação trifásica, variáveis de estado e potências incompatíveis se tornam vetores 3×1 , e termos individuais Jacobianos se tornam matrizes de ordem 3×3 . A equação linearizada resultante, adequada para soluções iterativas, se torna (11):

$$\begin{bmatrix} \Delta P_\ell^\rho \\ \Delta Q_\ell^\rho \end{bmatrix}^{(i)} = \begin{bmatrix} \frac{\partial P_\ell^\rho}{\partial \theta_u^\rho} & \frac{\partial P_\ell^\rho}{\partial V_u^\rho} V_u^\rho \\ \frac{\partial Q_\ell^\rho}{\partial \theta_u^\rho} & \frac{\partial Q_\ell^\rho}{\partial V_u^\rho} V_u^\rho \end{bmatrix}^{(i)} \begin{bmatrix} \Delta \theta_u^\rho \\ \Delta V_u^\rho \end{bmatrix}^{(i)} \quad (11)$$

onde, $\ell = j, k, u = j, k$, e (i) é o número de iterações.

Os termos do vetor são descritos em (12)-(15):

$$\Delta P_\ell^\rho = [\Delta P_j^a \Delta P_j^b \Delta P_j^c \Delta P_k^a \Delta P_k^b \Delta P_k^c]^t, \quad (12)$$

$$\Delta Q_\ell^\rho = [\Delta Q_j^a \Delta Q_j^b \Delta Q_j^c \Delta Q_k^a \Delta Q_k^b \Delta Q_k^c]^t, \quad (13)$$

$$\Delta\theta_u^\rho = [\Delta\theta_j^a \Delta\theta_j^b \Delta\theta_j^c \Delta\theta_k^a \Delta\theta_k^b \Delta\theta_k^c]^t, \quad (14)$$

$$\frac{\Delta V_u^\rho}{V_u^\rho} = \left[\frac{\Delta V_j^a}{V_j^a} \frac{\Delta V_j^b}{V_j^b} \frac{\Delta V_j^c}{V_j^c} \frac{\Delta V_k^a}{V_k^a} \frac{\Delta V_k^b}{V_k^b} \frac{\Delta V_k^c}{V_k^c} \right]^t \quad (15)$$

Os termos Jacobianos são, (16)-(18):

$$\frac{\partial P_\ell^\rho}{\partial \theta_u^\rho} = \begin{bmatrix} \frac{\partial P_\ell^a}{\partial \theta_u^a} & \frac{\partial P_\ell^a}{\partial \theta_u^b} & \frac{\partial P_\ell^a}{\partial \theta_u^c} \\ \frac{\partial P_\ell^b}{\partial \theta_u^a} & \frac{\partial P_\ell^b}{\partial \theta_u^b} & \frac{\partial P_\ell^b}{\partial \theta_u^c} \\ \frac{\partial P_\ell^c}{\partial \theta_u^a} & \frac{\partial P_\ell^c}{\partial \theta_u^b} & \frac{\partial P_\ell^c}{\partial \theta_u^c} \end{bmatrix}, \quad (16)$$

$$\frac{\partial P_\ell^\rho}{\partial V_u^\rho} V_u^\rho = \begin{bmatrix} \frac{\partial P_\ell^a}{\partial V_u^a} V_u^a & \frac{\partial P_\ell^a}{\partial V_u^b} V_u^b & \frac{\partial P_\ell^a}{\partial V_u^c} V_u^c \\ \frac{\partial P_\ell^b}{\partial V_u^a} V_u^a & \frac{\partial P_\ell^b}{\partial V_u^b} V_u^b & \frac{\partial P_\ell^b}{\partial V_u^c} V_u^c \\ \frac{\partial P_\ell^c}{\partial V_u^a} V_u^a & \frac{\partial P_\ell^c}{\partial V_u^b} V_u^b & \frac{\partial P_\ell^c}{\partial V_u^c} V_u^c \end{bmatrix} \quad (17)$$

$$\frac{\partial Q_\ell^\rho}{\partial \theta_u^\rho} = \begin{bmatrix} \frac{\partial Q_\ell^a}{\partial \theta_u^a} & \frac{\partial Q_\ell^a}{\partial \theta_u^b} & \frac{\partial Q_\ell^a}{\partial \theta_u^c} \\ \frac{\partial Q_\ell^b}{\partial \theta_u^a} & \frac{\partial Q_\ell^b}{\partial \theta_u^b} & \frac{\partial Q_\ell^b}{\partial \theta_u^c} \\ \frac{\partial Q_\ell^c}{\partial \theta_u^a} & \frac{\partial Q_\ell^c}{\partial \theta_u^b} & \frac{\partial Q_\ell^c}{\partial \theta_u^c} \end{bmatrix}, \quad (18)$$

$$\frac{\partial Q_\ell^\rho}{\partial V_u^\rho} V_u^\rho = \begin{bmatrix} \frac{\partial Q_\ell^a}{\partial V_u^a} V_u^a & \frac{\partial Q_\ell^a}{\partial V_u^b} V_u^b & \frac{\partial Q_\ell^a}{\partial V_u^c} V_u^c \\ \frac{\partial Q_\ell^b}{\partial V_u^a} V_u^a & \frac{\partial Q_\ell^b}{\partial V_u^b} V_u^b & \frac{\partial Q_\ell^b}{\partial V_u^c} V_u^c \\ \frac{\partial Q_\ell^c}{\partial V_u^a} V_u^a & \frac{\partial Q_\ell^c}{\partial V_u^b} V_u^b & \frac{\partial Q_\ell^c}{\partial V_u^c} V_u^c \end{bmatrix} \quad (19)$$

Pode-se notar que a expressão linearizada (8) se aplica somente em redes trifásicas entre as barras j e k . No entanto, o resultado pode ser estendido para casos

práticos, envolvendo n_i linhas e n_b barras genéricas $\ell = 1, \dots, j, k, \dots, n_b - 1$, e $u = 1, \dots, j, k, \dots, n_b - 1$. Deve-se notar que somente $n_b - 1$ barras são consideradas, uma vez que a barra de referências (*slack*) não é representada explicitamente no sistema linearizados de equações.

Considerando o ℓ th elemento conectado às barras j e k , em (8) para cada próprio e mútuo, os termos Jacobianos são dados em (20) - (32), com o auxílio dos sobrescritos $\rho 1$ e $\rho 2$, utilizados para denotar a , b , e c , respectivamente.

Para $j = k$ e $\rho 1 = \rho 2$:

$$\frac{\partial P_{k,l}^{\rho 1}}{\partial \theta_{k,l}^{\rho 1}} = -Q_k^{\rho 1 \text{ cal}} - (V_k^{\rho 1})^2 B_{kk}^{\rho 1 \rho 1}, \quad (20)$$

$$\frac{\partial P_{k,l}^{\rho 1}}{\partial V_{k,l}^{\rho 1}} V_{k,l}^{\rho 1} = P_k^{\rho 1 \text{ cal}} + (V_k^{\rho 1})^2 G_{kk}^{\rho 1 \rho 1}, \quad (21)$$

$$\frac{\partial Q_{k,l}^{\rho 1}}{\partial \theta_{k,l}^{\rho 1}} = P_k^{\rho 1 \text{ cal}} - (V_k^{\rho 1})^2 G_{kk}^{\rho 1 \rho 1}, \quad (22)$$

$$\frac{\partial Q_{k,l}^{\rho 1}}{\partial V_{k,l}^{\rho 1}} V_{k,l}^{\rho 1} = Q_k^{\rho 1 \text{ cal}} - (V_k^{\rho 1})^2 B_{kk}^{\rho 1 \rho 1}, \quad (23)$$

Para $k = m$, e $\rho 1 \neq \rho 2$:

$$\frac{\partial P_{j,l}^{\rho 1}}{\partial \theta_{j,l}^{\rho 2}} = V_j^{\rho 1} V_j^{\rho 2} [G_{jj}^{\rho 1 \rho 2} \sin(\theta_j^{\rho 1} - \theta_j^{\rho 2}) - B_{jj}^{\rho 1 \rho 2} \cos(\theta_j^{\rho 1} - \theta_j^{\rho 2})] \quad (24)$$

$$\frac{\partial P_{j,l}^{\rho 1}}{\partial V_{j,l}^{\rho 2}} V_{j,l}^{\rho 2} = V_j^{\rho 1} V_j^{\rho 2} [G_{jj}^{\rho 1 \rho 2} \cos(\theta_j^{\rho 1} - \theta_j^{\rho 2}) + B_{jj}^{\rho 1 \rho 2} \sin(\theta_j^{\rho 1} - \theta_j^{\rho 2})] \quad (25)$$

$$\frac{\partial Q_{j,l}^{\rho 1}}{\partial \theta_{j,l}^{\rho 2}} = -V_j^{\rho 1} V_j^{\rho 2} [G_{jj}^{\rho 1 \rho 2} \cos(\theta_j^{\rho 1} - \theta_j^{\rho 2}) + B_{jj}^{\rho 1 \rho 2} \sin(\theta_j^{\rho 1} - \theta_j^{\rho 2})] \quad (26)$$

$$\frac{\partial Q_{j,l}^{\rho 1}}{\partial V_{j,l}^{\rho 2}} V_{j,l}^{\rho 2} = V_j^{\rho 1} V_j^{\rho 2} [G_{jj}^{\rho 1 \rho 2} \sin(\theta_j^{\rho 1} - \theta_j^{\rho 2}) - B_{jj}^{\rho 1 \rho 2} \cos(\theta_j^{\rho 1} - \theta_j^{\rho 2})] \quad (27)$$

Para $k \neq m$:

$$\frac{\partial P_{j,l}^{\rho 1}}{\partial \theta_{k,l}^{\rho 2}} = V_j^{\rho 1} V_k^{\rho 2} [G_{jk}^{\rho 1 \rho 2} \sin(\theta_j^{\rho 1} - \theta_k^{\rho 2}) - B_{jk}^{\rho 1 \rho 2} \cos(\theta_j^{\rho 1} - \theta_k^{\rho 2})] \quad (28)$$

$$\frac{\partial P_{j,l}^{\rho 1}}{\partial V_{k,l}^{\rho 2}} V_{k,l}^{\rho 2} = V_j^{\rho 1} V_k^{\rho 2} [G_{jk}^{\rho 1 \rho 2} \cos(\theta_j^{\rho 1} - \theta_k^{\rho 2}) + B_{jk}^{\rho 1 \rho 2} \sin(\theta_j^{\rho 1} - \theta_k^{\rho 2})] \quad (29)$$

$$\frac{\partial Q_{j,l}^{\rho 1}}{\partial \theta_{k,l}^{\rho 2}} = -V_j^{\rho 1} V_k^{\rho 2} [G_{jk}^{\rho 1 \rho 2} \cos(\theta_j^{\rho 1} - \theta_k^{\rho 2}) + B_{jk}^{\rho 1 \rho 2} \sin(\theta_j^{\rho 1} - \theta_k^{\rho 2})] \quad (30)$$

$$\frac{\partial Q_{j,l}^{\rho 1}}{\partial V_{k,l}^{\rho 2}} V_{k,l}^{\rho 2} = V_j^{\rho 1} V_k^{\rho 2} [G_{jk}^{\rho 1 \rho 2} \sin(\theta_j^{\rho 1} - \theta_k^{\rho 2}) - B_{jk}^{\rho 1 \rho 2} \cos(\theta_j^{\rho 1} - \theta_k^{\rho 2})] \quad (31)$$

A solução iterativa das equações trifásicas utilizando o método de Newton - Raphson, requerem as mesmas considerações feitas na análise monofásica em consideração a inicialização das variáveis de estado e verificação dos limites de potência ativa gerado. No entanto, os ângulos iniciais das fases a , b e c devem ser inicializados com os valores 0 , $-2\pi/3$ e $2\pi/3$, respectivamente.

CAPÍTULO 3

Inteligência Artificial

3.1 Introdução

A inteligência artificial busca, através de técnicas inspiradas na natureza, o desenvolvimento de sistemas inteligentes que imitem aspectos do comportamento dos seres vivos, tais como: aprendizado, percepção, raciocínio (redes neurais artificiais).

Este capítulo tem por objetivo apresentar os conceitos fundamentais das ferramentas utilizadas nesta pesquisa voltadas à inteligência artificial.

3.2 Motivação e Estado da Arte

No últimos anos, as redes neurais artificiais vem ganhando destaque e espaço em pesquisas nas mais diversas áreas da engenharia, principalmente, no que tange à previsão temporal de dados e reconhecimento de padrões. Dentre os trabalhos publicados na última década, podem ser destacados os a seguir.

Em 2004, Wahab apresenta um trabalho que utiliza uma técnica baseada em RNA para a previsão da tensão de ruptura de óleo de transformadores. As variáveis de entrada para o treinamento da rede são o tempo de serviço do transformador, acidez total e teor de água. É proposta uma RNA multicamadas e seus resultados são comparados com a técnica de regressão polinomial. Os resultados demonstram que a técnica proposta é efetiva e justifica sua precisão.

Tzeng e Ho (2006) propõe a utilização de técnicas envolvendo RNA's para a redução de perdas técnicas em sistemas de distribuição de energia elétrica por meio da reconfiguração do mesmo. Primeiramente os autores classificam os consumidores por

meio da rede de mapeamento auto - organizável (*self-organize mapping Network - SOM*) e utilizando a rede *Back-Propagation* calculam as perdas por meio do chaveamento dos trechos da rede de distribuição. Os autores concluem que a proposta apresentada obteve resultados superiores a outros métodos heurísticos.

Os autores Catalão et. al. (2007), apresentam um estudo sobre a previsão a curto - prazo de custos da eletricidade, por meio de uma rede neural de três camadas do tipo *feedforward* treinada pelo algoritmo Levenberg-Marquardt. Essa técnica é comparada com a técnica ARIMA (*auto regressive integrated moving average*) e se mostra eficiente no que tange à precisão dos resultados e na facilidade com que podem ser obtidos. Os autores utilizam o *toolbox* do MATLAB para a realização desse trabalho.

Hang, Huiming e Jie (2008) utilizam a classificação de rede Kohonen para o aumento da precisão de treino de uma rede neural artificial do tipo *Back - Propagation*. Dessa maneira, com o objetivo de calcular perdas em sistemas de potência, o método utilizado demonstrou uma melhora na precisão devido à utilização do método de classificação de Kohonen.

Mellit e Pavan (2010), utilizam RNA do tipo *Multilayer Perceptron - MLP*, para a previsão com 24 horas de antecedência de irradiação solar. Os dados foram coletados na cidade de Triste na Itália, sendo utilizados para o treinamento da rede neural. Além dos dados de irradiação solar foram utilizados também os dados de temperatura ambiental. Os resultados demonstram que o modelo obteve um bom desempenho apresentando dados de coeficiente de correlação de 98-99% para dias ensolarados e 94-96% para dias nublados.

Outro estudo que pode ser citado, é o realizado por Zhang, Xu e Zhou (2010). Nesta pesquisa, os autores utilizam uma RNA para a previsão de carga em uma rede inteligente (*smart grid*). A RNA aplicada é utilizada para a previsão de cargas baseada em uma situação prática na província de Ontário no Canadá. A técnica utilizada é a *Back - Propagation* e é feita uma comparação entre os algoritmos de treinamento Levenberg-Marquardt e o Bayesian Regularization. Os resultados demonstram que o algoritmo de treinamento Bayesian Regularization apresentou a melhor performance na previsão de cargas feita pela RNA.

Forounzanfar et. al. (2010), apresentam um estudo sobre os algoritmos de treinamento utilizados em uma RNA com arquitetura *Feed - Forward* para a estimação da pressão sanguínea oscilométrica. Os algoritmos comparados foram o *Steep Descent* e suas variações (*resilient propagation*, com taxa de aprendizagem variável e com taxa de

aprendizagem e momentum variáveis); *quasi-Newton* e suas variações (*Broyden-Fletcher-Goldfarb-Shanno*, *one step secant*, *Levenberg-Marquardt*); e *conjugate gradient* e suas variações (*Fletcher-Reeves update*, *Polake-Ribiére update*, *Powell-Beale restart*, *scaled conjugate gradient*). Este trabalho se torna interessante do ponto de vista de se ter uma visão mais apurada sobre a eficiência dos algoritmos de treinamento apresentados. De todos os algoritmos de treinamento verificados, o que apresentou melhor desempenho em estimação de erro e treinamento foi o *resilient propagation*.

Naing e Srinivasan (2010), utilizam uma RNA de arquitetura *Back - Propagation* com múltiplas camadas ocultas para a previsão de radiação solar. Os resultados obtidos da RNA são comparados com os resultados obtidos por meio de métodos matemáticos como o método de Meinel e da ASHRAE. Os resultados obtidos por meio da RNA apresentaram menores erros do que os encontrados pelos métodos matemáticos. As índices estatísticos utilizados para essa constatação foram o RMSE (*Root Mean Square Error* - Erro médio quadrático) e o MAPE (*Mean Absolute Percentage Error* - Erro médio percentual absoluto). Os dados para as previsões foram coletados em Singapura.

Para a previsão da radiação global diária, Behrang et. al. (2010), fazem comparações de duas arquiteturas de RNA (*Multi-Layer Perceptron* e *Radial-Basis Function*) com diferentes métodos convencionais de previsão propostos por diferentes autores (Modelo Angstrom, Lewis, Swartman e Ogunlade, Abdalla, Akinoglu e Ecevit, Bahel et. al., Almorox e Hontoria e Bakirik). Ao todo seis combinações de variáveis de entrada foram utilizadas como, por exemplo, a combinação entre o dia do ano, a média diária de temperatura e a umidade relativa do ar. Obteve como resultado que o método mais eficiente e preciso para a previsão proposta foi o resultante da RNA com arquitetura *Multi-Layer Perceptron*.

Celik (2011), utiliza uma RNA com regressão generalizada para a previsão da corrente de operação de um módulo fotovoltaico. Os dados de entrada utilizados para o treinamento da rede e para a previsão foram a temperatura ambiental, a temperatura da célula e a irradiação solar. Os resultados obtidos foram comparados com os obtidos através de um método matemático, que pode ser encontrado no artigo, que utiliza 5 parâmetros para o cálculo para encontrar a corrente de operação do módulo. Ao final dos testes, a autora conclui que a RNA apresentou resultados de previsão mais precisos do que os resultantes do método matemático.

Marques e Coimbra (2011), desenvolveram uma técnica por meio do chamado GHAMMA TEST combinado com algoritmos genéticos que analisam a melhor combinação e relevância entre 11 variáveis de entrada de uma RNA para a previsão de irradiação solar direta e global. No geral, o método demonstra um bom aumento na precisão de previsão para o horizonte determinado, porém, menos acentuada no verão do que em meses de inverno.

Em 2012, Biserica et. al., propõem um estimador de pseudomedidas utilizando RNA com o objetivo de melhorar os resultados do estimador de parâmetros de uma rede de distribuição. A arquitetura de RNA utilizada foi a *feedforward* utilizando o algoritmo Resilient Backpropagation para o treinamento da rede. Os dados fornecidos pela RNA são utilizados como dados de entrada para o estimador de estado de uma rede de distribuição de energia elétrica.

Kaushika, Tomar e Kaushik (2014), apresentam um modelo de RNA utilizado para a estimação de radiação solar global, difusa e direta considerando superfícies inclinadas e horizontais. Para tanto, utilizam como arquitetura de rede a *feedforward* com duas camadas e utilizando a função de ativação sigmóide. Como dados de entrada os autores utilizaram a latitude, longitude, altitude, hora local, mês do ano, média horária de umidade relativa, precipitação média horária mensal e a duração média de luz solar por hora.

O trabalho publicado por Khwaja et. al. (2015), apresenta um estudo sobre previsão de carga, aperfeiçoada, a curto prazo utilizando uma RNA com a técnica *bagged*. A técnica *bagged* é utilizada para melhorar o desempenho de aprendizagem dos algoritmos da máquina. Especialmente, esta técnica pode ser utilizada para melhorar uma estimação instável, isto é, uma estimação onde a cada momento um modelo treinado pode levar a resultados diversos. Resultados comparados a dados reais demonstram que a técnica proposta aumentou a eficiência da previsão de carga quando comparada a outras técnicas existentes, como a RNA convencional.

3.3 Redes neurais artificiais (RNA)

O uso de redes neurais artificiais vem sendo motivado pelo fato desta, conseguir reproduzir certas funções do cérebro humano, como a capacidade de obter conhecimento e a capacidade de reconhecer padrões do ambiente ao qual está sendo utilizada e tomar suas próprias decisões através de um processo de treinamento. As

redes neurais são compostas por diversas unidades computacionais paralelas, interconectadas parcial ou totalmente. Cada uma dessas unidades, recebe o nome de *neurônio artificial*, que efetuam um certo número de operações e transmitem seus resultados aos neurônios vizinhos com os quais possui conexão. Os neurônios são elementos processadores interligados, trabalhando em paralelo para desempenhar uma determinada tarefa. Os modelos de RNA's constituem uma importante técnica estatística não linear capaz de resolver uma gama de problemas de grande complexidade. Segundo HAYKIN (2001)::

"Uma rede neural é um processador maciçamente paralelo distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1- O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;

2- Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido."

A rede neural se torna uma ferramenta confiável uma vez que possui uma estrutura maciçamente paralela e distribuída, e por ter habilidade de aprender e, portanto, de generalizar. Segundo HAYKIN (2001), a generalização se refere ao fato de a rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem). Estas duas capacidades de processamento de informação tornam possível para as redes neurais resolver problemas complexos de grande escala que são atualmente intratáveis.

O uso de redes neurais oferece as seguintes propriedades úteis e capacidades:

- 1- Não-linearidade;
- 2 - Mapeamento de Entrada - Saída;
- 3 - Adaptabilidade;
- 4 - Resposta a Evidências;
- 5 - Informação Contextual;

- 6 - Tolerância a Falhas;
- 7 - Implementação em VLSI (*very - large - scale - integration*);
- 8 - Uniformidade de Análise e Projeto;
- 9 - Analogia Neurobiológica.

O processo de aprendizagem é realizado através de um algoritmo de aprendizagem cujo objetivo é mudar os pesos sinápticos de forma que a rede neural artificial se adapte e alcance o objetivo desejado (MÜLLER, 2008).

3.3.1 O Neurônio

Segundo HAYKIN (2001), um neurônio é definido como:

"Um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural."

Nesta perspectiva, a Figura 11 mostra a descrição funcional do k-ésimo neurônio de uma rede, ou seja, descreve o que se encontra no interior de um neurônio.

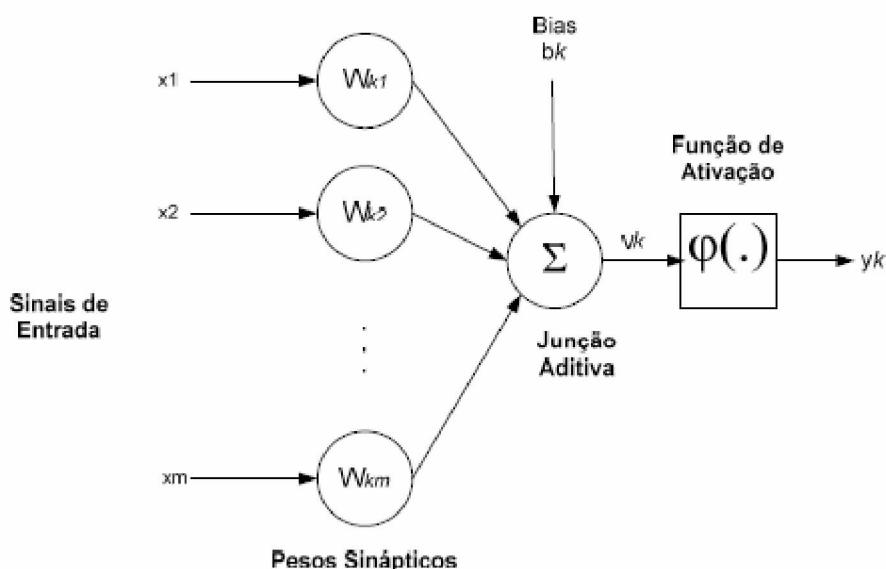


Figura 11. Modelo não-linear de um neurônio.

Fonte: (MÜLLER, 2008).

x_m representa o e-mésimo conjunto das entradas.

w_{km} representa o-mésimo peso sináptico (força de interação entre neurônios). É importante notar a maneira como são escritos os índices. O primeiro índice se refere ao neurônio em questão e o segundo se refere ao terminal de entrada ao qual o peso se refere.

v_k representa a combinação linear dos pesos. Corresponde à soma ponderada da entrada pelos pesos.

φ é a função de ativação que restringe a amplitude de saída de um neurônio. Ela também é conhecida como “*função restritiva*” já que limita o intervalo permissível de amplitude do sinal de saída a um valor finito.

y_k é a saída do k-ésimo neurônio que depende do nível de ativação aplicado ao neurônio pela função de ativação.

$b_k (\theta_k)$ é conhecido como termo *bias* ou polarizador. Indica o ponto em que a função se encontra em cima do eixo e, portanto, define o domínio dos valores de saída.

Para cada sinal de entrada, x , existe um peso associado, w , para fortalecer ou enfraquecer o sinal de entrada. A RNA calcula os sinais de entrada e usa uma função de ativação (função de transferência) $\varphi(v_k)$ para calcular a saída y , de acordo com a entrada da rede. A força do sinal de saída é ainda influenciada por um valor limitador, $b(\theta)$, também conhecido como *bias*.

Em termos matemáticos, pode-se descrever o k-ésimo neurônio escrevendo o seguinte par de neurônios, pelas equações (32) e (33):

$$u_k = \sum_{p=1}^m w_{kp} x_p + \theta_k \quad (32)$$

$$y_k = \varphi(u_k + \theta_k) \quad (33)$$

Onde θ_k é o termo polarizador que como já descrito define o domínio dos valores de saída através de uma *transformação afim* que ele aplica ao sinal de saída. Esta transformação é matematicamente descrita como (34):

$$v_k = u_k + \theta_k \quad (34)$$

O termo v_k é conhecido como *campo local induzido*, e dependendo do valor do polarizador, positivo ou negativo, a saída do combinador linear u_k será modificada.

O termo polarizador é um parâmetro externo do k-ésimo neurônio, logo, podemos considerar sua presença na equação que descreve a saída do neurônio, e por isso, pode-se descrever a saída sendo função do *campo local induzido* (35):

$$y_k = \varphi(v_k) \quad (35)$$

Logo, pode-se dizer que a função de ativação do neurônio é descrita em termos do *campo local induzido*.

3.3.2 Funções de Ativação

Como descrito anteriormente, em um neurônio, existe uma função de ativação, que restringe a amplitude do sinal de saída. Esta função pode ser definida de diferentes maneiras sendo as mais comuns, descritas abaixo:

1 – *Função Degrau*. Para este tipo de função de ativação, temos

$$\varphi(v) = \begin{cases} \gamma_1, & \text{se } v \geq \theta \\ \gamma_2, & \text{se } v < \theta \end{cases}$$

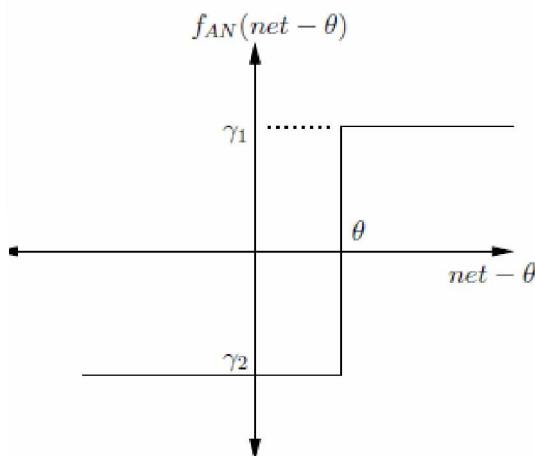


Figura 12 - Função Degrau. Onde $net = v_k$.
Fonte: (ENGELBRECHT, 2007).

Esta função também é conhecida em outras literaturas como *função de Heaviside*.

2 – *Função Linear*. Esta função é geralmente utilizada como a função de ativação da camada de saída, pois diferentemente das outras funções, esta tem a vantagem de os neurônios de saída assumirem qualquer valor (no intervalo de -1 a 1), além disso, é mais fácil para se analisar a diferença entre as respostas geradas e os valores desejados devido ao seu formato linear mostrado na Figura 13.

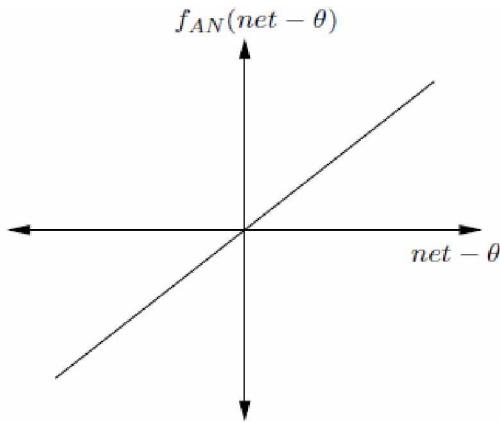


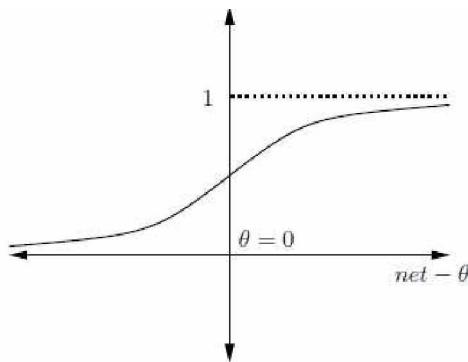
Figura 13 - Função Linear. Onde $\text{net} = \mathbf{v}_k$.
Fonte: (ENGELBRECHT, 2007).

3 – *Função Sigmóide*. A função sigmoide, cujo gráfico tem a forma de s, é de longe a forma mais comum de função de ativação utilizada na construção de redes neurais artificiais. Ela é definida como uma função estritamente crescente que exibe um balanceamento adequado entre comportamento linear e não-linear. Um exemplo de função sigmóide é a *função logística*, definida por:

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (36)$$

Onde a é conhecido como *parâmetro de inclinação*.

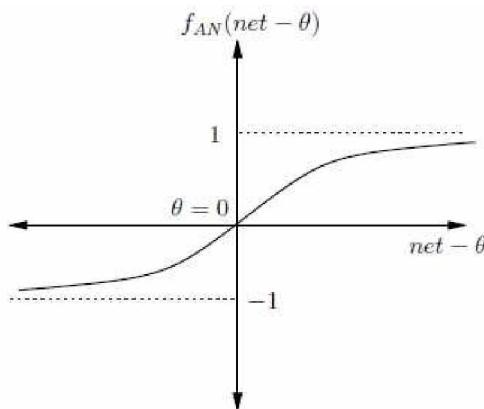
O gráfico da função logística é mostrado na Figura 14.

Figura 14 - Função Logística. Onde $net = v_k$.

Fonte: (ENGELBRECHT, 2007).

4 – Função Tangente Hiperbólica. Até agora, foram demonstradas funções que se estendem no intervalo de 0 a +1. Algumas vezes é desejável que a função de ativação se estenda de -1 a +1, ou seja, que tenha uma forma anti-simétrica em relação à origem. Uma função sigmoide que corresponde à estas características, é denominada como Tangente Hiperbólica.

Com seu gráfico demonstrado de acordo com a Figura 15.

Figura 15 - Função Tangente Hiperbólica. Onde $net = v_k$.

Fonte: (ENGELBRECHT, 2007)

3.3.3 Arquitetura de redes

A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. A maneira como estes algoritmos estão estruturados são chamadas de "arquitetura de redes". Em geral, podem-se citar três classes de arquiteturas de rede fundamentalmente diferente (HAYKIN, 2001):

- 1 - Redes alimentadas adiante com camada única:

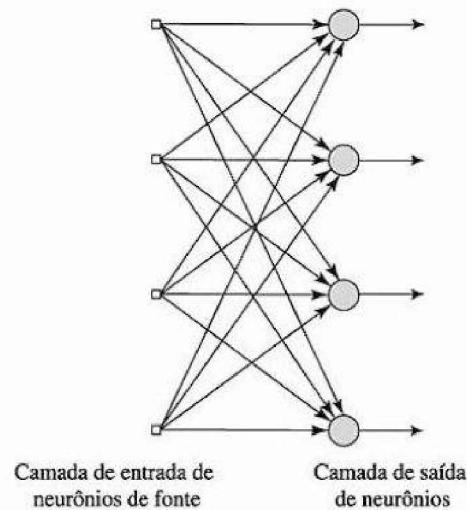


Figura 16 - Rede alimentada adiante ou acíclica com uma única camada de neurônios.
Fonte: (HAYKIN, 2001).

2 - Redes alimentadas diretamente com múltiplas camadas:

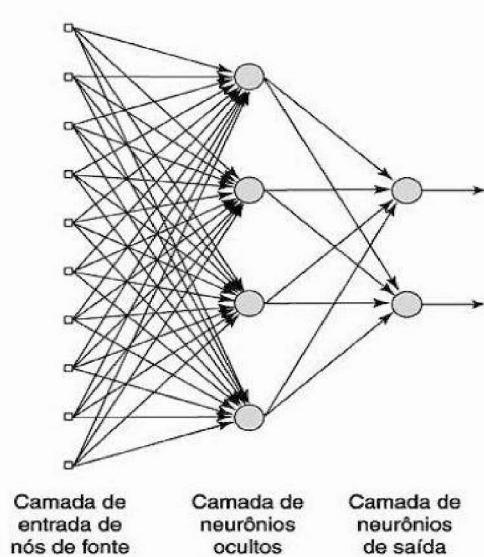


Figura 17 - Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída.
Fonte: (HAYKIN, 2001).

3 - Redes recorrentes

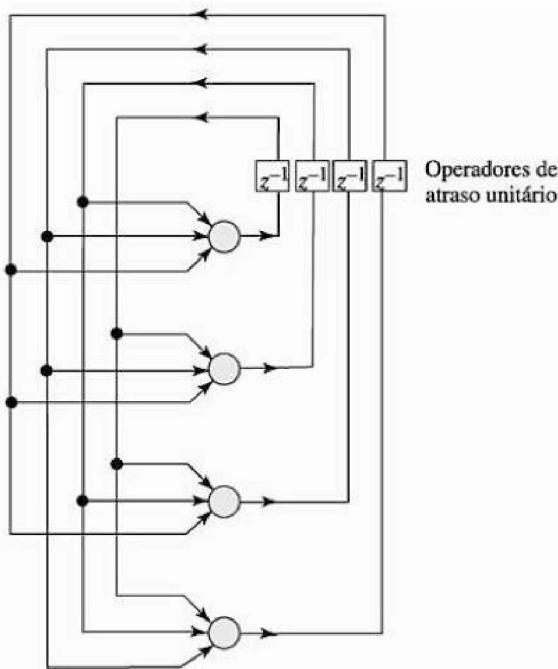


Figura 18 - Rede recorrente sem laços de auto-alimentação e sem neurônios ocultos.
Fonte: (HAYKIN, 2001).

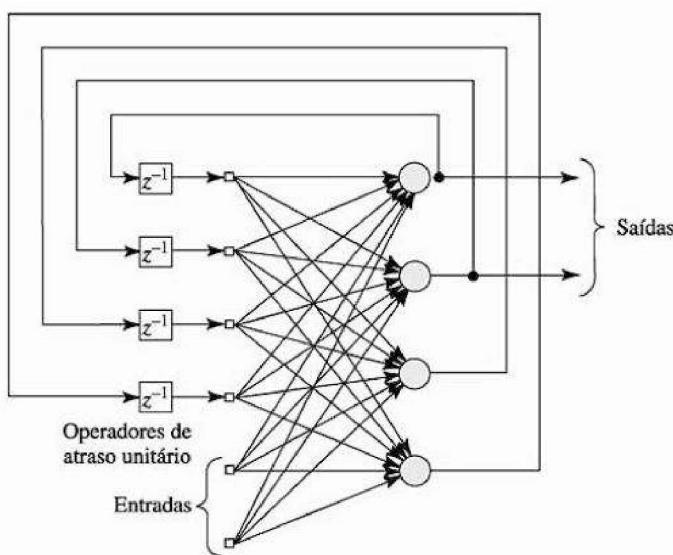


Figura 19 - Rede recorrente com neurônios ocultos.
Fonte: (HAYKIN, 2001).

Neste trabalho, será dada maior ênfase na arquitetura conhecida como *redes recorrentes*, devido ao seu desempenho quando utilizada para a previsão de dados temporais. Estudos relacionados a eficiência e precisão na previsão de dados temporais por meio da rede NARX (“*Nonlinear Autoregressive with exogenous inputs*” ou “auto-regressivo não linear com entradas exógenas”) podem ser vistos em (MONTEIRO et. al., 2016) e (HAYES e PRODANOVIC, 2016).

3.3.3.1 Redes Recorrentes

As *redes neurais recorrentes* são estruturas de processamento capazes de representar uma grande variedade de comportamentos dinâmicos.

Diferentemente das outras arquiteturas, as redes recorrentes possuem realimentações e que devido a essa característica, é possível se ter a criação de representações internas e dispositivos de memória capazes de processar e armazenar informações temporais e sinais sequenciais.

Basicamente, existem dois usos funcionais para as redes recorrentes:

- *Memórias associativas*
- *Redes para mapeamento de entrada-saída*

Qualquer que seja seu uso, uma questão de particular interesse no uso das redes recorrentes se deve ao fato de sua *estabilidade*.

Quando se utiliza as redes para o mapeamento, o espaço de entrada é mapeado em um espaço de saída. Neste tipo de aplicação (que será aplicada ao exemplo deste documento), uma rede recorrente responde a um sinal de entrada aplicado externamente. Com este tipo de aplicação essas redes recebem o nome de *redes recorrentes dirigidas dinamicamente*. Além disso, aplicando-se realimentações a estas redes, faz com que elas adquiram representações de *estados*, o que as torna dispositivos apropriados para aplicações tão diversas como previsão não-linear e modelagem, que é o caso em questão neste documento.

3.3.3.2 A Rede NARX

Dentro do grupo das *redes recorrentes dirigidas dinamicamente*, existe um modelo específico, que terá um foco maior neste trabalho, visto que, será este, o modelo de rede utilizado para parte do desenvolvimento dessa pesquisa. Esta rede é conhecida como NARX.

Em uma rede NARX as respostas são atrasadas de uma unidade de tempo e, posteriormente, reapresentadas às entradas, produzindo uma melhor resposta de generalização da rede.

Seus dados são organizados considerando um atraso de (p) amostras para as entradas, que são deslocadas dentro do vetor de entrada. Da mesma forma, as saídas

recorrentes são atrasadas de (q) amostras, e realocadas no sentido decrescente. A topologia desta RNA é mostrada na Figura 20.

A rede neural NARX pode ser expressa por (37):

$$y_{t+1} = f(u_t, u_{t-1}, \dots, u_{t-n}, y_t, y_{t-1}, \dots, y_{t-n}) \quad (37)$$

onde o próximo valor do sinal de saída, y_{t+1} , é regredida utilizando os valores anteriores medidos y_t, y_{t-1} , e sinais de entradas u_t, u_{t-1} . A função f representa a rede neural, onde os pesos de cada conexão na rede são treinados pelos algoritmos de treinamentos.

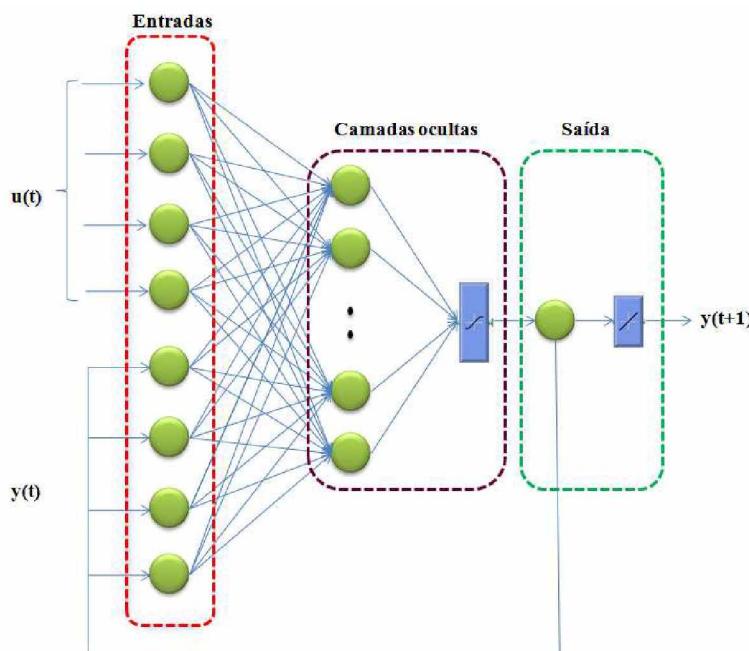


Figura 20 - Modelo de uma rede NARX.
Fonte: (O autor, 2016).

Assim, pode-se dizer que esta topologia apresenta uma memória, pois utiliza valores passados, que são atualizados a cada instante, sendo capaz de produzir respostas atuais e também futuras.

3.3.5 Algoritmos de treinamento

A preparação da rede necessita de um algoritmo de treinamento para a aprendizagem da rede neural artificial. O aprendizado consiste do ajuste dos pesos e limiares da rede neural até que um certo critério seja satisfeito.

Neste trabalho foram comparados 7 algoritmos de treinamento disponibilizados na toolbox do MATLAB, os quais são:

1. *BFGS Quasi-Newton (BFG)*;
2. *Bayesian Regularization (BR)*;
3. *Conjugate Gradient with Powell/Beale Restarts (CGB)*;
4. *Polak-Ribiére Conjugate Gradient (CGP)*;
5. *Resilient Backpropagation (RP)*;
6. *Scaled Conjugate Gradient (SCG)*;
7. *Levenberg-Marquardt (LM)*.

Os demais algoritmos de treinamento disponibilizados pela *toolbox* do MATLAB não são comentados por não terem apresentado bons resultados para a proposta feita neste trabalho. A seguir, são apresentadas as descrições resumidas desses algoritmos.

- *BFGS Quasi-Newton (BFG)*

O método Quasi-Newton é baseado na série de Taylor de segunda ordem. O procedimento iterativo é obtido através de (38) (FOROUZANFAR et. al., 2010):

$$\Delta w_i = -A_i^{-1}g_i \quad (38)$$

Sendo, A_i a matriz Hessiana da função de desempenho e g_i o vetor de gradientes da iteração i.

O método Broyden-Fletcher-Goldfarb-Shannon (BFGS), atualiza o método Quasi-Newton. A decomposição deste método pode ser vista em (JOO e LIU, 2009).

- *Bayesian Regularization (BR)*

O método Bayesian Regularization altera a função de desempenho de erro anexando um desvio padrão dos pesos e os limiares (LI e WANG, 2009) e pode ser expressado por (39):

$$F = \beta E_D + \alpha E_w \quad (39)$$

Onde α e β são parâmetros de regularização.

Usando (39) para minimizar a performance de erro, habilita a rede a ter menores pesos e limites. Isso equivale a reduzir o tamanho da rede de forma que a mesma responda suavemente reduzindo o "overfitting".

- *Conjugate Gradient with Powell/Beale Restarts (CGB)*

O método Conjugate Gradient with Powell/Beale Restarts é utilizado para verificar a ortogonalidade entre os vetores gradientes atual e o anterior a cada iteração do algoritmo de treinamento Conjugate Gradient (CG). A ortogonalidade é verificada de acordo com (40) (FOROUZANFAR et. al., 2010). O algoritmo (CG) é derivado do algoritmo Steepest Descent (SD) que é baseado na série de Taylor de primeira ordem. Uma descrição completa desses dois algoritmos pode ser vista em (JANG, SUN e MIZUTANI, 1997).

$$|g_{i-1}^T g_{i-1}| \geq 0.2 \|g_i\|^2 \quad (40)$$

Sendo, g_i o vetor de gradientes e T o transposto da matriz desse vetor de gradientes.

- *Polak-Ribiére Conjugate Gradient (CPG)*

O algoritmo Polak-Ribiére Conjugate Gradient atualiza um parâmetro, também, do algoritmo Conjugate Gradient, β_i , como o produto escalar da mudança anterior no vetor gradiente com o gradiente atual, dividido pelo quadrado do gradiente anterior, expressado por (41) (FOROUZANFAR et. al., 2010):

$$\beta_i = \frac{\Delta g_{i-1}^T g_i}{\Delta g_{i-1}^T g_{i-1}} \quad (41)$$

Sendo, g_i o vetor de gradientes e T o transposto da matriz desse vetor de gradientes.

- *Resilient Backpropagation (RP)*

Para o algoritmo de treinamento Resilient Backpropagation, uma descrição completa é dada em (RIEDMILLER e BRAUN, 1993).

- *Scaled Conjugate Gradient (SCG)*

O algoritmo para treinamento Scaled Conjugate Gradient é apresentado na Figura 21.

Algoritmo de treinamento de rede neural "Scaled Conjugate Gradient"

Inicialize o peso do vetor, $w(0)$;
Defina direção inicial do vetor como
 $p(0) = -\epsilon'(w(0)) = \theta - Hw(0)$
para $t = 1, \dots, \eta_\omega$, faça
Calcule o tamanho do passo,
 $\eta(t) = -\frac{\epsilon'(w(t))^T p(t)}{p(t)^T H p(t)}$
Calcule um novo peso para o vetor,
 $w(t+1) = w(t) + \eta(t)p(t)$
Calcule fatores de escala,
 $\beta = \frac{\epsilon'(w(t+1))^T \epsilon'(w(t+1))}{\epsilon'(w(t+1))^T \epsilon'(w(t))}$
Calcule uma nova direção para o vetor,
 $p(t+1) = -E(w(t+1)) + \beta(t)p(t)$
Fim
Retorne o peso do vetor, $w(t+1)$;

Figura 21 - Algoritmo de treinamento para Scaled Conjugate Gradient.

Fonte: (ENGELBRECHT, 2007).

- *Levenberg-Marquardt (LM)*

Para o método de Levenberg-Marquardt, as mudanças nos pesos (v_i) podem ser obtidas resolvendo-se (42) (LERA e PINZOLAS, 1998):

$$\sum_{j=1}^n \alpha_{ij} v_i = -\frac{1}{2} \frac{\partial E}{\partial v_i} \quad (42)$$

Sendo "n" o número de pesos adaptáveis da rede, "E" o erro médio quadrático da rede e α uma matriz cujos elementos são dados por (43) (LERA e PINZOLAS, 1998):

$$\alpha_{ij} = (1 + \lambda \delta_{ij}) \sum_{k=1}^N \left[\frac{\partial y(x_k)}{\partial w_i} \frac{\partial y(x_k)}{\partial w_j} \right] \quad (43)$$

O algoritmo de treinamento LM, assim como os demais, é utilizado para ajustar os pesos para que a rede neural produza a requerida saída para a dada entrada (MELLIT e PAVAN, 2010).

3.4 Otimização por Enxame de Partículas (PSO)

Desenvolvido por Kennedy e Eberhart (1995), o *Particle Swarm Optimization* (PSO) ou Otimização por Enxame de Partículas é um método de otimização estocástico¹

¹ Em teoria probabilística, o **padrão estocástico** é aquele cujo estado é indeterminado, com origem em eventos aleatórios.

que leva em consideração o comportamento social de um bando de pássaros (ENGELBRECHT, 2007). O PSO utiliza um procedimento de busca onde cada indivíduo é denominado partícula e essas partículas fazem parte de um enxame. Cada partícula do enxame representa um candidato a solução de otimização de um determinado problema. Nos algoritmos de PSO, as partículas se deslocam através de um espaço de busca multidimensional, ajustando sua posição de acordo com as experiências obtidas por elas e por seus vizinhos. Uma partícula, portanto, faz uso da melhor posição encontrada por ela e a melhor posição encontrada pelas partículas vizinhas, para depois se posicionar em direção a uma solução ótima. Este processo é análogo ao processo de revoada de pássaros, por exemplo, onde cada um dos indivíduos voam em direção ao ótimo, enquanto continuam procurando uma área menor em volta da melhor solução de um problema.

3.4.1 Motivação e Estado da Arte

Em problemas de reconfiguração de redes, em que a complexidade da solução é uma função do número de chaves, o elevado número de variáveis pode levar a uma explosão combinatória, dificultando a utilização de programação matemática para redes de distribuição de grande porte.

Neste cenário, surgem as técnicas heurísticas - conjuntos de regras e métodos que conduzem à solução relativamente rápida de problemas, mas não asseguram que esta seja a melhor (SARFI, SALAMA e CHIKHANI, 1994). Com isso, obtêm-se ganhos em termos de eficiência computacional em detrimento da precisão das respostas encontradas.

A inteligência artificial ou metaheurística busca, através de técnicas inspiradas na natureza, o desenvolvimento de sistemas inteligentes que imitem aspectos do comportamento dos seres vivos.

Nesta categoria são apresentados os trabalhos oriundos da técnica heurística de otimização por enxame de partículas, ou do inglês *Particle Swarm Optimization* (PSO).

Em 2000, Yoshida et. al. apresentam a utilização do PSO para o controle de tensão e potência reativa. O método proposto expande o PSO original para resolver um problema de otimização não-linear integrador misto e determina o controle *on-line* da estratégia intitulada Volt/VAR (VVC), com variáveis de controles contínuas e discretas

como um regulador de tensão automático (AVR) controlando valores de geradores, taps de transformadores, e o número de dispositivos compensadores de reativo.

Zhao, Guo e Cao (2004), trazem uma proposta de solução do FPO utilizando o PSO. O principal objetivo do trabalho foi o de verificar a viabilidade da utilização do PSO considerando um problema composto por diversas funções objetivo. Para isso, se fez necessário a incorporação de uma função penalidade multi-estágio no intuito de melhorar a convergência e precisão da resposta do algoritmo. O PSO proposto foi comparado com uma abordagem feita por programação linear e por outra feita por algoritmos genéticos (AG). O sistema teste escolhido foi o sistema do IEEE 30 barras. Os resultados dos testes identificaram que o PSO proposto foi capaz de obter soluções de maior qualidade para o problema do FPO proposto.

Em 2005, Esmin, Lambert-Torres e Souza, propuseram um PSO híbrido para o estudo de minimização de perdas em um sistema IEEE 118 barras. A proposta consistia na utilização de uma técnica denominada de vetor tangente, que identifica a área crítica do sistema por meio de análises de variações de tensão. Identificada esta área, o PSO calcula a quantidade de reativo necessário em cada barra do sistema para que se restabeleçam os níveis adequados das tensões elétricas.

No ano de 2006, Jeyadevi e Baskar, trazem uma descrição da aplicação do PSO para a resolução do FPO em sistemas de transmissão CA flexíveis (FACTS). Um dispositivo de controle unificado de fluxo de potência (UPFC) é utilizado como um comutador de fases e compensador série para a regulação dos ângulos e magnitudes de tensão. O PSO juntamente com o fluxo de potência PQ, determina a melhor solução para minimizar as perdas e manter o fluxo de potência dentro de suas restrições de segurança. O algoritmo foi testado em um sistema IEEE 30 barras.

El-Dib et. al. (2007), propõem uma técnica para encontrar a alocação e dimensionamentos ótimos de compensadores *shunt* em sistemas de transmissão. O objetivo da formulação é o de melhorar a estabilidade de tensão do sistema enquanto se mantém níveis de tensão aceitáveis. O problema pode ser formulado como um problema de otimização de integrador não linear. O PSO é utilizado para a resolução desse problema. São apresentados estudos de caso nos sistemas Ward-Hale de 6 barras, IEEE 14 e 30 barras. Uma comparação com AG é feita e a qualidade das respostas obtidas por meio do PSO fica comprovada.

Nouri e Jadid (2008), comparam dois esquemas de alocação de perdas baseados no princípio da troca bilateral equivalente e a matrix de rede Z-bus. Vários testes são

feitos como o incremento de carga, para a avaliação dos métodos citados. Para a resolução do FPO o PSO é utilizado. O sistema teste foi o IEEE 14 barras modificado (aumento dos parâmetros de resistência elétrica em 50%; taps dos transformadores em 1.0 e 0.3 p.u; a conexão de um gerador de 100 MW na barra 8 e a omissão da susceptância *shunt* da barra 9).

Abdelaziz et. al. (2009), introduzem o PSO como solução do FPO para a reconfiguração de redes de distribuição para a redução de perdas técnicas (perdas nas linhas por potência ativa (W). O PSO proposto neste trabalho trás algumas modificações como o decréscimo da inércia que decresce linearmente durante a simulação. Essa modificação possibilitou o PSO de explorar uma grande área no começo da simulação. Nos testes realizados foram feitas mudanças na quantidade de partículas da população e número de iterações. O método proposto é simulado nos sistemas do IEEE 32 e 69 barras.

Em 2010, Arya, Titare e Kothari, apresentam uma abordagem do monitoramento de variáveis de controle de potência reativa para estabilidade de tensão utilizando o PSO. O PSO foi utilizado devido ao fato de encontrar a solução ótima global e, também, porque a sua programação além de muito simples é eficiente computacionalmente. O algoritmo implementado foi testado nos sistemas chamados pelos autores de padrões 6 barras e 7 linhas e 25 barras e 35 linhas.

Ainda em 2010, Leeton et. al., descrevem um FPO baseado no PSO em que as perdas de potência ativa de uma linha de transmissão foram a função objetivo. Neste trabalho, para minimização global de perdas por potência ativa, quatro variáveis de decisão são analisadas: potência gerada por planta; magnitude de tensão especificada na subestação; posição de tap de transformadores sob carga; e injeção de reativo por compensadores. O algoritmo criado para a formulação do FPO foi testado e comparado com o método quasi-Newton (BFGS) e com um método de FPO baseado em algoritmo genético (AG). Foi comprovado que o método que utilizou o PSO obteve as melhores soluções dentre todos os métodos testados. Os testes foram feitos nos sistemas IEEE 6 e 30 barras.

Gomez-Gonzales, López e Jurado (2012), introduzem um método híbrido que emprega PSO discreto com a técnica denominada "pulo do sapo" (do inglês - *jumping frog* - técnica inspirada no comportamento de sapos procurando por alimento) e FPO para a alocação e dimensionamento ótimos de geradores distribuídos (GDs). As restrições técnicas principais são impostas por empresas de distribuição de energia

elétrica. Uma comparação do método proposto é feita com outros métodos como o PSO discreto e o AG. O algoritmo proposto alcançou melhores soluções do que os demais. Os testes foram realizados no sistema IEEE 30 barras.

Tandon e Saxena (2014), apresentam uma modificação feita no algoritmo de enxame de partículas binário (BPSO) (do inglês - *Binary Particle Swarm Optimization*) resultando no *Selective Particle Swarm Optimization* (SPSO). O algoritmo é utilizado para a reconfiguração de redes de distribuição com configuração radial com o objetivo de minimizar as perdas técnicas. Nesta simulação foi utilizado o sistema do IEEE 69 barras. Foi observado que o algoritmo modificado obteve um melhor desempenho do que o BPSO.

Hazra et. al. (2015), propõem um FPO considerando armazenadores de energia do tipo bateria eletroquímica. O PSO é utilizado para a resolução do problema de FPO que leva em consideração os custos de geração e das baterias alocadas na rede, como função objetivo. Para essa pesquisa foi utilizada a configuração do sistema do IEEE de 30 barras. As simulações demonstraram que a alocação das baterias na rede resultaram em redução dos custos de geração para a distribuidoras de energia elétrica.

Todos os trabalhos supracitados consideraram os sistemas testes equilibrados e, portanto, utilizaram seus equivalentes monofásicos para os cálculos das simulações.

3.4.2 PSO Clássico

Em um bando de pássaros ou em um enxame de abelhas, os indivíduos pertencentes a estes seguem um princípio básico de comportamento: alcançar o sucesso em uma tarefa de acordo com as experiências imediatas dos indivíduos vizinhos e participes do grupo ao qual pertencem e também de acordo com as experiências adquiridas por si. É esse comportamento coletivo e individual que faz o algoritmo de PSO descobrir soluções ótimas em um espaço de busca.

O algoritmo de PSO, representa um enxame onde cada partícula corresponde a uma potencial solução para um problema descrito. Fazendo-se uma analogia com a programação evolucionária, cada enxame é similar a uma população e cada partícula a um indivíduo (ENGELBRECHT, 2007).

Seja $x(i)$ uma partícula em um espaço de busca no tempo t . A posição da partícula é alterada adicionando-se a velocidade $V_i(k)$ em sua posição atual. Essa situação pode ser representada por (44):

$$x_i^{k+1} = x_i^k + V_i^{k+1} \quad (44)$$

A velocidade então, é o que guia o processo de otimização por enxame de partículas e reflete ambas as experiências de aprendizagem individual e coletiva das mesmas.

Portanto, no processo de aprendizagem, as posições que as partículas procuram seguir, podem ser classificadas como: a melhor posição encontrada por ela mesma no instante (t), a qual se denomina *pbest* (*particular best position*); e a melhor posição encontrada por toda a população, levando em consideração todas as posições individuais de cada partícula, denominada *gbest* (*global best position*). Ao fim do processo feito pelo algoritmo, a melhor solução ou as melhores soluções (*fitness*), de acordo com uma função objetivo, são apresentadas como resultado.

Para N partículas, tem-se a modelagem matemática para o PSO (45):

$$V_i^{k+1} = w_i \cdot V_i^k + C_1 \cdot rand_1 \cdot (pbest_i - x_i^k) + C_2 \cdot rand_2 \cdot (gbest - x_i^k) \quad (45)$$

sendo:

V_i^k a velocidade corrente da partícula i na interação k ;

V_i^{k+1} a velocidade modificada da partícula i ;

$rand$ corresponde a um número aleatório entre 0 e 1;

x_i^k é a posição corrente da partícula i na iteração k ;

$pbest_i$ é o melhor valor da partícula i ;

$gbest$ é o melhor valor do enxame;

w_i é uma função ponderação (ponderação inercial) da velocidade da partícula i ;

C_1 e C_2 são coeficientes de ponderação.

A figura 22 ilustra o diagrama do espaço de busca do PSO clássico.

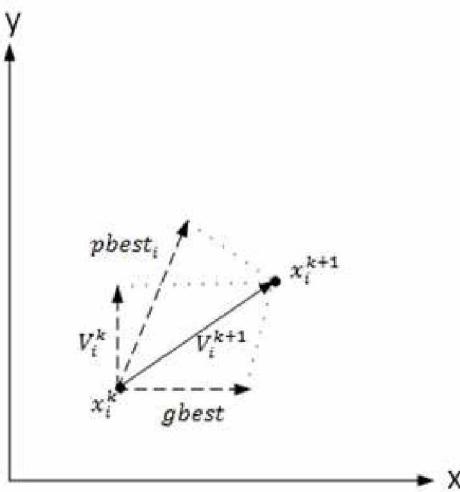


Figura 22 - Diagrama do espaço de busca do PSO clássico.

Fonte: (O autor, 2016).

Segundo Eberhart e Shi (2004), o procedimento para a implementação do algoritmo PSO segue as seguintes etapas:

- 1) Inicialize a população (enxame) de partículas com posições e velocidades aleatórias na dimensão d no espaço de busca do problema;
- 2) Para cada partícula, avalie a função *fitness* de otimização desejada;
- 3) Compare a avaliação da etapa 2 com o $pbest$ de cada partícula. Se o valor corrente for melhor do que o valor anterior, atualize o $pbest$ corrente como o novo $pbest$, e a localização do $pbest$ passa a ser igual a localização atual;
- 4) Compare a avaliação de cada $pbest$ com o prévio melhor valor de avaliação da população. Se o valor atual é melhor que o $gbest$ anterior, atualize o valor de $gbest$;
- 5) Modifique a velocidade e a posição de cada partícula de acordo com (45) e (44), respectivamente;
- 6) Repita o processo a partir da etapa 2 até que um critério de parada seja satisfeito, geralmente um número máximo de iterações, de modo que esse número seja adequado para garantir uma função *fitness* de boa qualidade.

Para simplificar o processo supracitado, faz-se uso do fluxograma da figura 23.

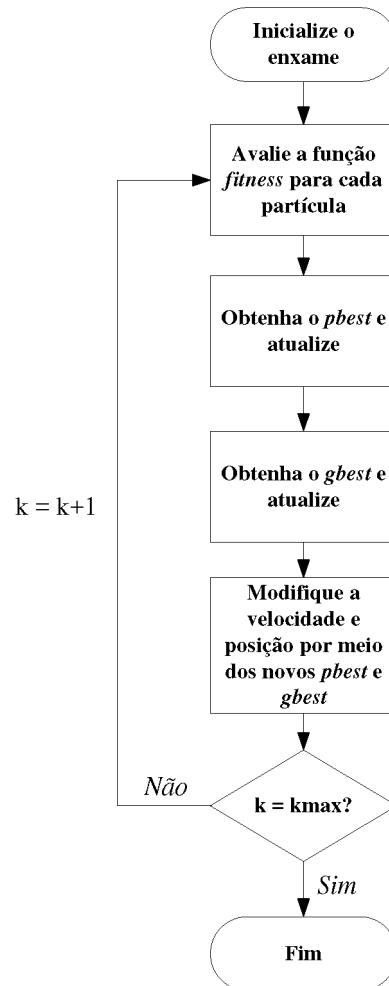


Figura 23 - Fluxograma do PSO clássico

Fonte: (O autor, 2016).

Nota-se pelo fluxograma da figura 23, que o algoritmo PSO é simples, o que resulta num esforço computacional e tempo de execução menores do que outros algoritmos, como por exemplo, o algoritmo genético.

3.4.3 PSO binário (BPSO)

O PSO clássico é projetado para funções de otimização contínuas e não para funções discretas de otimização. Dessa maneira, Kennedy e Eberhart (1997), propuseram uma versão binária para o PSO denominada *Binary Particle Swarm Optimization* - Otimização por enxame de partículas binário.

Em sistemas de distribuição de energia elétrica, a reconfiguração dos alimentadores é realizada por meio de aberturas e fechamentos de equipamentos de comutação. A mudança de posição dessas chaves pode reduzir as perdas nas linhas ou

operar o sistema com maior segurança, por meio de métodos de contingência, por exemplo. A estrutura resultante desses chaveamentos, deve, obrigatoriamente, obedecer a estrutura radial de um sistema de distribuição. Para essa reconfiguração, o PSO pode ser utilizado para que se encontrem topologias ótimas para os sistemas em estudos.

O objetivo primário da reconfiguração de sistemas de distribuição é o de minimizar as perdas técnicas totais nas linhas durante a sua operação normal, tornando o sistema mais econômico. Esse problema pode ser formulado por (46):

$$P_{perdas} = \sum_{i=1}^n I_i^2 \cdot z_i \quad (46)$$

Sendo P_{perdas} as perdas técnicas totais do sistema de distribuição, n o número total de zonas do sistema, I_i o valor eficaz de corrente da i -th zona e z_i a impedância da i -th zona.

Para resolver esse problema específico Wu, Tsai e Hsu (2007), propõem um BPSO modificado, que é o método utilizado neste trabalho. Este método define o operador de deslocamento (SO - *Shift Operator*) e o conjunto de operadores de deslocamento (SOS -*Shift Operator Set*).

O problema da reconfiguração de um sistema de distribuição, pode ser tratado como uma otimização de permutação combinacional de '1' e '0', onde uma chave normalmente fechada (NF) corresponde ao '1' e uma normalmente aberta (NA) ao '0'.

3.4.3.1 Operador de deslocamento

Suponha que um sistema de distribuição normal tenha ' m ' chaves seccionadoras NF e ' n ' NA. O status da combinação de chaves Na + NF é $[S_1, S_2, \dots, S_s]$ e será chamado de sequência de estados das chaves ou SSS (*Sequence Switch States*). Como exemplo, uma partícula ou indivíduo pode ser representado por uma sequência de zeros e uns. Para um sistema contendo em sua configuração 9 chaves, figura 24, tem-se (47):

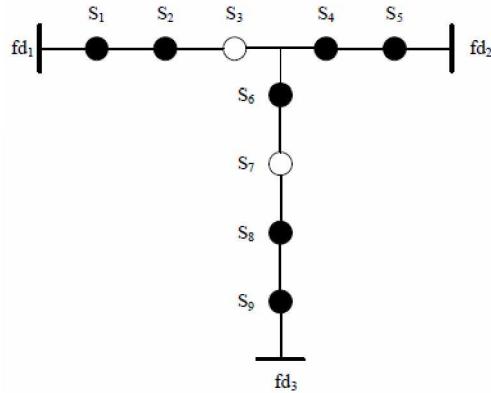


Figura 24 - Configuração inicial do sistema utilizado como exemplo.

Fonte: (Wu, Tsai e Hsu. 2007).

$$SSS = x_i^k = [1 \ 1 \ 0 \ 1 \ 1 \ 1 \ 0 \ 1 \ 1] \quad (47)$$

O SO é definido como um vetor de 3 dimensões, o qual armazena as seguintes informações:

- Qual bit da solução será deslocado;
 - Em qual direção esse bit será deslocado (direita ou esquerda);
 - Quantas posições o bit será deslocado de acordo com a direção atribuída.

A nova permutação no SSS é definida por $SSS' = SSS \leftrightarrow SO$. O símbolo \leftrightarrow indica que o operador de deslocamento foi aplicado ao vetor SSS.

Como exemplo, a figura 25 ilustra a aplicação do SO no SSS resultando em SSS':

$$\text{sss} \cdots \begin{matrix} 1 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \end{matrix} \xrightarrow{\quad \text{SO}(3, \mathbf{d}, 1) \quad} \begin{matrix} 1 & 1 & \boxed{1} & 0 & 1 & 1 & 0 & 1 & 1 \end{matrix} \xrightarrow{\quad} \text{sss}'$$

Figura 25 - Aplicação do operador de deslocamento SO.
Fonte: Modificado (Wu, Tsai e Hsu. 2007).

No exemplo anterior, de acordo com o SO resultante, o bit 3 foi deslocado para a direita, representado pela letra 'D', 1 posição. Nesta operação, para que fosse mantida a radialidade do sistema, somente duas chaves puderam permanecer abertas. Portanto, a chave correspondente a posição 3 passou do estado NA (0) para o NF (1), conforme figura 25. A configuração do sistema passa a ser a apresentada na figura 26.

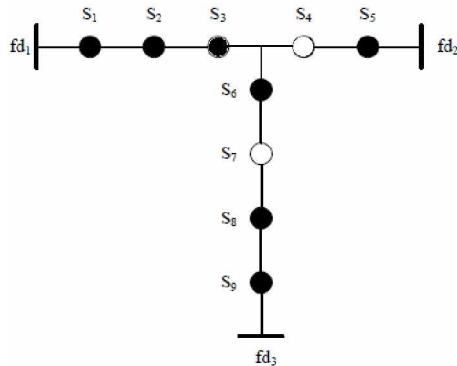


Figura 26 - Configuração final do sistema utilizado como exemplo.

Fonte: Modificado (Wu, Tsai e Hsu, 2007).

3.4.3.2 Conjunto de operadores de deslocamento

O operador de deslocamento pode conter mais de uma operação, ou seja, pode existir um conjunto de operações a serem realizadas em um mesmo passo. Por exemplo, imagine dois operadores SO_1 e SO_2 . Por meio da fusão entre os dois operadores pode-se obter o operador de deslocamento resultante SOS, sendo $SOS = \{SO_1, SO_2\} = SSS_1 \ominus SSS_2$. Onde SSS_1 e SSS_2 são duas partículas ou soluções (diferentes sequências de chaves NA e NF). O SOS é, na verdade, encontrado comparando-se as posições das chaves NA uma por uma. O operador \ominus é utilizado para indicar a obtenção dos operadores de deslocamento de SSS_1 e SSS_2 . O SOS é exemplificado detalhadamente na próxima seção.

3.4.4 BPSO modificado

Com as definições dos operadores necessários para o desenvolvimento do algoritmo modificado dadas, o BPSO pode ser definido para a resolução de problemas de reconfiguração de topologias de sistemas de distribuição de energia elétrica. As equações do PSO clássico (44) e (45) passam a ser (48) e (49) (WU, TSAI e HSU, 2007):

$$x_i^{k+1} = x_i \langle + \rangle V_i^{k+1} \quad (48)$$

$$V_i^{k+1} = (w \otimes V_i) \oplus (\text{rand}() \times (pbest \ominus x_{id})) \oplus (\text{rand}() \times (gbest \ominus x_{id})) \quad (49)$$

Em (49), w é o operador de inércia. Neste processo este operador preserva a sua função sendo utilizado também para ajustes nas áreas de busca. Sua abordagem neste modelo de PSO consiste no incremento ou decremento do passo a ser realizado no operador de deslocamento a cada iteração. Sendo assim, \otimes aplica o valor de w calculado à dimensão do operador que compreende o passo do deslocamento.

A composição do coeficiente $rand()$ com o símbolo $\langle \times \rangle$, executa uma operação cuja ação é escolher randomicamente um operador de deslocamento entre os operadores agrupados em $(pbest \ominus x_{id})$ e $(gbest \ominus x_{id})$.

Para que se fixem esses conceitos, o exemplo utilizado em Wu, Tsai e Hsu (2007), é apresentado.

Novamente toma-se o exemplo de um sistema de distribuição contendo 9 chaves seccionadoras, sendo exigido 2 NA e 7 NF, garantindo assim sua radialidade. Supondo um conjunto 'n' de soluções e que na iteração k se tem a seguinte partícula x_i , $pbest$ e $gbest$, representando diferentes SSSs:

$$x_i = [1 \ 1 \ 0 \ 1 \ 1 \ 1 \ 0 \ 1 \ 1]$$

$$pbest = [1 \ 0 \ 1 \ 1 \ 1 \ 1 \ 1 \ 0 \ 1]$$

$$gbest = [1 \ 1 \ 1 \ 0 \ 1 \ 0 \ 1 \ 1 \ 1]$$

Os SOS podem ser encontrados por meio das operações $(pbest \ominus x_{id})$ e $(gbest \ominus x_{id})$:

$$(pbest \ominus x_{id}) = \{(3, E, 1), (7, D, 1)\}$$

$$(gbest \ominus x_{id}) = \{(3, D, 1), (7, E, 1)\}$$

$$w = 2$$

Aleatoriamente se escolhem 1 operador de cada porção do equacionamento aplicando a inércia w aleatoriamente também, obtendo-se:

$$(w \otimes V_i) = \{(3, D, 2), (7, D, 2)\}$$

$$rand() \langle \times \rangle (pbest \ominus x_{id}) = \{(3, E, 1)\}$$

$$rand() \langle \times \rangle (gbest \ominus x_{id}) = \{(7, E, 1)\}$$

Dessa maneira, V_i^{k+1} contém quatro operadores SOs, (3, E, 1), (3, D, 2), (7, E, 1) e (7, D, 2).

Quando um SOS contém mais de um SO com o mesmo bit de referência, esses SOs precisam ser fundidos para depois serem utilizados como operadores de deslocamento. Isso ocorre, por exemplo com os bits 3 e 7 do exemplo dado. Percebe-se que mudar-se-ia o bit 3 duas posições para a direita no primeiro passo e uma para a esquerda no segundo passo, resultando na verdade em apenas uma mudança de posição para a direita. O mesmo raciocínio pode ser aplicado ao bit 7. Assim, os operadores finais resultam em (3, D, 1) e (7, D, 1). Finalmente, a nova sequência de bits (SSS) após todos os operadores aplicados será [1 1 1 0 1 1 1 0 1].

O procedimento para a implementação do algoritmo PSO segue as seguintes etapas (WU, TSAI e HSU, 2007):

- 1) Escolha o tamanho da população (diferentes vetores binários contendo combinações de chaves NAs e NFs), bem como o número máximo de iterações desejadas;
- 2) Inicialize o SSS e os operadores de deslocamento SO, aleatoriamente, para a aplicação nas partículas;
- 3) Para cada partícula, avalie a função *fitness* de otimização desejada;
- 4) Compare a avaliação da etapa 2 com o *pbest* de cada partícula. Se o valor corrente for melhor do que o valor anterior, atualize o *pbest* corrente como o novo *pbest* incluindo o SSS e o valor do *fitness* do *pbest*;
- 5) Compare a avaliação de cada *pbest* com o prévio melhor valor de avaliação da população. Se o valor atual é melhor que o *gbest* anterior, atualize o valor de *gbest* incluindo o SSS e o valor do *fitness* do *gbest*;
- 6) Atualize o operador de deslocamento SO e gere um novo estado de operação das chaves (SSS) e o valor do fitness para o *gbest*
- 7) Repita o processo a partir da etapa 3 até que um critério de parada seja satisfeito, geralmente um número máximo de iterações, de modo que esse número seja adequado para garantir uma função fitness de boa qualidade.

Neste trabalho, juntamente com o PSO, foi utilizado o conceito da teoria dos grafos para que fosse garantida a radicalidade do sistema reconfigurado a cada modificação realizada pelo PSO. Os conceitos básicos sobre a teoria dos grafos bem como sua aplicação nesta pesquisa são apresentados no apêndice A.

Capítulo 4

Armazenadores de Energia

4.1 Introdução

Esta seção tem por objetivo apresentar os conceitos gerais sobre os dispositivos armazenadores de energia mais utilizados até a data de confecção deste trabalho.

4.1.1 *Armazenadores de energia elétrica*

Dentre as tecnologias que alavancam a geração distribuída, pode-se destacar a geração de energia elétrica por meio de placas fotovoltaicas em constante crescimento no Brasil e em diversos países do mundo. O acesso dos consumidores a estas tecnologias tem aumentado e, assim, o aumento da chamada penetração fotovoltaica vem trazendo novos problemas e desafios para a operação de redes de distribuição de energia elétrica. Dentre esses problemas pode-se citar a combinação entre potência ativa gerada por essas fontes renováveis e a demanda dos consumidores, nos horários de ponta e fora de ponta.

Uma vez que se pode vender às distribuidoras de energia elétrica o excesso de energia gerada por microgeradores, em determinados períodos do dia identifica-se um desbalanço de energia elétrica entre o que é gerado pelo consumidor e o que está sendo consumido pelo mesmo em seu sistema. Como exemplo, pode-se analisar o período do dia em que se tem os maiores níveis de geração fotovoltaica. Este período, durante os dias em que se trabalha na semana, para consumidores residenciais, há uma alta incidência de geração fotovoltaica e uma baixa demanda, uma vez que os consumidores não se encontram em suas residências e somente alguns equipamentos, como

refrigeradores, ficam ligados e os demais no modo de *stand-by*. Há então um excesso de energia sendo gerada e essa porção que não está sendo utilizada pelos consumidores é injetada na rede de distribuição. Para sistemas de distribuição com elevada penetração fotovoltaica, ou seja, alto índice de consumidores detentores desse tipo de geração, observa-se que nestes períodos ocorrem elevações nos níveis de tensão da rede devido à essa injeção de potência ativa e a baixa solicitação de demanda por parte dos consumidores.

O inverso ocorre no período do dia em que os consumidores se encontram em suas residências retornando do seu trabalho, geralmente entre as 17:00 e 20:00 (chamado horário de ponta), observa-se uma elevação na demanda de energia elétrica e uma baixa geração advinda das placas fotovoltaicas, uma vez que neste período a irradiação solar começa a diminuir.

Outro aspecto que deve ser avaliado do uso da geração fotovoltaica é a sua natureza intermitente, ou seja, só há energia disponível caso tenha sol, quando o céu fica nublado o fornecimento fica reduzido, devido à diminuição da incidência da radiação solar nas placas o que pode vir a acarretar subtensões no sistema onde estão conectados.

Portanto, para cada período especificado anteriormente é interessante que se mantenha sempre o mesmo nível de suprimento de energia, uma vez que sobretensões e subtensões são indesejáveis e sua sensibilidade está diretamente ligada ao fornecimento e consumo de energia elétrica dos consumidores existentes nestes sistemas distribuição de energia elétrica.

Considerando que nos próximos 20 - 30 anos todo tipo de energia sustentável deverá ser baseado no uso racional de fontes tradicionais e um maior uso de fontes renováveis (IBRAHIM, ILINCA e PERRON, 2008), serão necessários o desenvolvimento de técnicas para o controle dos níveis de operação dos sistemas de distribuição. Uma das maneiras de se fazer isso, atualmente, é utilizando dispositivos armazenadores de energia elétrica, facilitando assim o controle das variáveis presentes na inserção da geração distribuída.

Armazenadores de energia elétrica (AEE) utilizam o processo de conversão de energia elétrica de um sistema de potência para uma forma de energia que possa ser armazenada (CHEN et. al, 2009).

Existem diversas aplicações para a utilização de armazenadores de energia, dentre elas podem ser destacados (BARSALI et. al, 2015):

- Controle de pico de tensão com o compartilhamento de carga feito com o uso de armazenadores de energia elétrica por curtos períodos de tempo;
- Redução de interrupções temporárias;
- Regulação de freqüência em sistemas ilhados;
- Redução de perdas no sistema aumentando sua eficiência energética;
- Grandes sistemas de armazenadores de energia elétrica podem ainda ajudar na redução de interrupções de longa duração.

Como exemplos de utilização desta técnica, pode-se destacar primeiramente a proposta feita por Hill et. al (2012), os autores apresentam um estudo da operação e controle de AEEs inseridos em redes de média tensão no Hawaii, Lanai. Neste estudo, são analisados os impactos negativos da introdução da geração distribuída por meio de placas fotovoltaicas, bem como a melhora, no geral, da operação da rede de distribuição devido à implantação do AEEs.

Strickland e Bai (2014) propõem um dimensionamento visando o reforço de uma rede de distribuição devido ao aumento de cargas, situada em Milton Keynes - Inglaterra.

Em Koller et. al. (2015), apresentam os resultados da aplicação de um sistema de AEEs de 1MW conectado na rede existente em Zurique, Suíça. Foram feitas considerações teóricas e medições da operação desse sistema. Observou-se uma melhoria nas características de operação da rede de distribuição, levando em consideração o controle de frequência e o corte de pico de demanda. Este estudo foi realizado em uma micro-rede.

De acordo com Dell e Rand (2001), grandes sistemas de AEEs de chumbo - ácido (MWh) tem sido testados em países como a Alemanha, Japão, Porto Rico e EUA.

O conceito de AEE utilizados em meios de transportes também vem sendo utilizado e estudado nos últimos anos.

A Southeastern Pennsylvania Transportation Authority's (SEPTA's) tem como um de seus projetos o investimento nesta tecnologia com a integração de tecnologias emergentes de *smart grids* com sua infraestrutura de transito de trens elétricos. Quando estes freiam, seus motores elétricos produzem energia (GILLESPIE, JOHANSON e MONTVYDAS, 2014). Diferente dos veículos híbridos (que utilizam combustível e eletricidade) os trens não são projetados com AEE. Sem capacidade de armazenamento, a energia gerada quando da frenagem dos mesmos, só pode ser utilizada se outro trem

está acelerando na mesma área. De outra maneira, a energia gerada é desperdiçada sendo dissipada nos bancos de resistores existentes na parte de cima dos trens elétricos.

Instalando-se bancos de AEE's em paralelo com os sistemas tradicionais, a SEPTA pode aproveitar parte dessa energia em corrente contínua gerada. O dispositivo pode armazenar essa energia provinda dos motores dos trens elétricos e disponibilizar ao sistema elétrico de potência quando necessário. Estima-se que essa iniciativa retorno mais de U\$ 250.000,00 por ano em benefícios para a SEPTA (GILLESPIE, JOHANSON e MONTVYDAS, 2014).

4.2 Motivação e estado da arte

O papel desempenhado pelas baterias de chumbo-ácido tem sido, há muito, objeto de interesse de pesquisadores ao redor do mundo.

Mckinnon (1940), já apontava as inúmeras aplicações deste tipo de armazenador de energia bem como sua utilização para a redução de picos de potência ativa em redes de distribuição de energia elétrica.

Em Manwell e Jon (1993), é feita uma proposta de dimensionamento baseado na abordagem da cinética química de baterias de chumbo-ácido, na tentativa de superar dificuldades associadas com métodos existentes até o momento de sua publicação. O método proposto por Manwell e Mcgowan, intitulado de KBM (Kinetic Battery Model), tem sido amplamente utilizado, como pode ser visto nos trabalhos de Wang et. al. (2014) e Baboli, Shahparasti e Moghaddam (2014). No entanto, o dimensionamento da capacidade de armazenamento de AAEs segue, na verdade, o mesmo processo.

Em Hashemi, Ostergaard e Yang (2014) é proposto um método de dimensionamento para a mínima capacidade de armazenamento requerida para AEEs a serem instalados em diversos locais de uma rede de baixa tensão, considerando alta penetração fotovoltaica.

Ammar e Joós (2014), propõem um dimensionamento a curto prazo para supercapacitores armazenadores de energia, com o objetivo de melhorar a qualidade da tensão de um sistema com geração eólica distribuída.

Em Farrokhifar (2016), simulações foram realizadas para a análise da redução de perdas técnicas em redes de distribuição com a adição de AEE nesta.

Os autores em Carpinelli et. al. (2013), oferecem um método ótimo de dimensionamento de AEE levando em consideração a localização em que se instalam os mesmos e levando em consideração a demanda e GD encontradas no sistema em estudo.

Narizapuya et. al. (2015), propõem, também, a alocação e dimensionamento ótimos para AEE do tipo bateria, com a finalidade de regulação de tensão em um sistema IEEE 14 - barras, considerando para isso penetração fotovoltaica.

Métodos heurísticos, algoritmo genético e *simulated annealing*, são utilizados em Crossland, Jones e Wade (2014) para a resolução do problema de localização e dimensionamento de AEE de bateria considerando, mais uma vez, penetração fotovoltaica.

A obtenção do dimensionamento ótimo de AEE, considerando geração eólica, por meio de algoritmos genéticos é proposta em Chen e Li (2012).

Outras análises como a implementação de controle primário para AEEs utilizados em geração fotovoltaica descentralizada, a utilização de AEE de bateria para o aumento da capacidade de energia aceita por uma rede de distribuição com geração eólica, o estudo do gerenciamento pelo lado da demanda considerando AEEs, o uso de AEEs para auxílio do aumento da estabilidade em mini-grids, podem ser vistos em (HOLLINGER et. al., 2016), (CARR et. al., 2014), (SOLIMAN e GARCIA, 2014) e (SINGH, LOPES e NINAD, 2015) respectivamente.

No entanto, de todos os trabalhos citados, não se encontra um estudo direcionado a AEEs levando em consideração o aumento da demanda e o aumento da introdução de GDs nos sistemas de distribuição de energia elétrica.

Segundo (DUFO-LÓPEZ, LUJANO-ROJAS e BERNAL-AUGUSTÍN, 2014), estudos mostram que testes reais geralmente resultam em expectativa de vida superiores a 4 anos e, em alguns casos, se a bateria é utilizada sob baixos ciclos de descarga e esses são controlados de maneira adequada, sua vida útil pode ultrapassar os 15 anos. Ainda em (DUFO-LÓPEZ, LUJANO-ROJAS e BERNAL-AUGUSTÍN, 2014), os autores afirmam que utilizando um bom controlador de carga, onde se garanta que a mesma energia é utilizada em ambos os ciclos, carga e descarga, aumenta a vida útil da bateria. A mesma bateria exposta a ciclos irregulares tem sua vida útil reduzida显著mente.

4.3 Classificação

Existem dois critérios para se classificar (AEE): função e forma (CHEN, et. al., 2009). As técnicas de armazenamento podem ser divididas em quatro categorias, de acordo com suas aplicações (IBRAHIM, ILINCA e PERRON, 2008):

1. Aplicações em baixa potência em áreas isoladas, para alimentar essencialmente transdutores e terminais de emergência.
2. Aplicações em média potência em áreas isoladas (sistemas elétricos individuais, suprimento de cidades).
3. Aplicações em redes com picos de potência.
4. Qualidade da energia elétrica.

As primeiras duas categorias são para sistemas de menor escala onde a energia pode ser armazenada como energia cinética (*flywheel*), energia química, ar comprimido ou em supercapacitores ou supercondutores (energia armazenada em forma de campo magnético).

As outras duas categorias são para escalas maiores onde a energia pode ser armazenada como energia gravitacional (sistemas hidráulicos), energia química (acumuladores, baterias de fluxo), ou ar comprimido (utilizando armazenamento de gás líquido ou natural).

A descrição dos tipos de sistemas armazenadores de energia é feita no tópico seguinte.

4.3.1 Tipos de sistemas armazenadores de energia

Nesta seção são descritos os sistemas de armazenamento de energia elétrica e suas particularidades. Devido ao fato dessas tecnologias serem mundialmente conhecidas através de seus nomes em língua inglesa, serão citadas ao longo do texto pela sua sigla correspondente à esses nomes, posteriormente a sua tradução para o português.

O processo de funcionamento de um armazenador de energia se divide em dois estágios: carga e descarga.

O processo de carga acontece quando o sistema de energia elétrica em que faz parte o AEE está com excedente de potência circulando na rede. O processo de descarga acontece quando há a necessidade de um aumento de potência na rede.

4.3.1.1 Armazenador hidroelétrico bombeado

Existem diversas formas de se armazenar energia e posteriormente transformá-la em energia elétrica. Uma dessas tecnologias é a PHS (do inglês *Pumped hydroelectric storage*), que é o sistema de armazenamento de energia elétrica mais largamente empregado no mundo. Este, faz uso da energia potencial da água, vide as hidroelétricas, para poder fazer uso da energia elétrica quando convier ao sistema elétrico.

O arranjo consiste de dois reservatórios de água localizados em diferentes elevações, figura 27. Uma unidade de bombeamento bombeia a água para o reservatório superior, utilizando para tal um motor elétrico, armazenando energia em forma de energia potencial hidráulica, durante os horários fora de pico, ou seja, horários em que a disponibilidade de energia elétrica na rede é maior do que a demanda dos consumidores. Este processo corresponde ao carregamento do PHS (CHEN et. al., 2009).

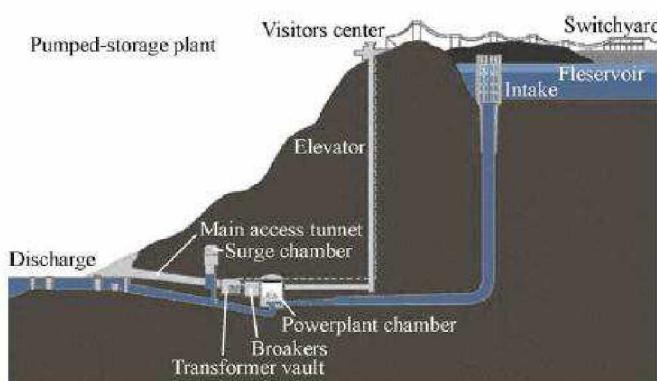


Figura 27 - Esquema armazenador hidroelétrico bombeado.
Fonte: (CHEN, et. al. 2009).

Como neste processo se faz uso de um motor elétrico e, sabe-se que se trata de uma máquina elétrica e que as mesmas funcionam tanto como motor quanto gerador elétrico, nos horários de ponta quando a demanda de energia é maior do que a disponível na rede de distribuição a água flui do reservatório superior para o inferior e o motor agora funciona como um gerador, entregando energia elétrica para o sistema elétrico em que está conectado (GRBRVIĆ, 2014).

A energia armazenada em um PHS pode ser calculada por (50):

$$W_{PHS} = V_0 \rho g H \quad (50)$$

Sendo,

$V_0(\text{m}^3)$ - volume do reservatório superior;

$\rho(\text{kg/m}^3)$ - densidade da água;

$g(\text{m/s}^2)$ - aceleração da gravidade ($\cong 9,81$);

$H (\text{m})$ - distância vertical entre o reservatório superior e a máquina elétrica.

A tecnologia PHS é utilizada para grandes volumes, longos períodos de armazenamento, elevada eficiência e relativamente baixo investimento por unidade de energia (CHEN et. al., 2009). Devido à evaporação da água nos reservatórios e as perdas na conversão da energia, sistemas PHS tem uma eficiência entre aproximadamente 65-80% (IBRAHIM, ILINCA e PERRON, 2008). Sistemas desse tipo tem uma vida útil maior do que 40 anos (KONDOK et. al. 2000) e não se tem um número máximo de ciclos de carga e descarga, uma vez que não se utiliza de nenhum processo eletroquímico, dependendo apenas da vida útil da máquina elétrica envolvida no processo e dos níveis dos reservatórios de água (CHEN et. al., 2009). Estes armazenadores tem capacidade de potência entre 100 e 5000 MW e tempo de descarga de 1 a 24 horas.

Ambientalmente esta tecnologia apresenta impacto negativo, uma vez que é necessário a poda de árvores e desmatamento para a construção dos reservatórios (CHEN et. al., 2009).

4.3.1.2 Armazenador de energia a ar comprimido

A tecnologia CAES (do inglês *Compressed Air Energy Storage*) armazena a energia na forma de ar comprimido. O CAES é o único sistema comercialmente disponível, além do PHS, capaz de armazenar uma grande quantidade de energia.

O sistema consiste de um motor elétrico, um gerador elétrico e duas ou mais turbinas a gás (no caso do esquema da figura 28, duas turbinas). O processo de armazenamento de energia consiste em armazenar o ar comprimido nos horários fora de

ponta, através do motor elétrico, em um reservatório de ar. Porém, são necessários grandes reservatórios para grandes armazenamentos e dessa maneira os melhores locais para se realizar este processo são as cavernas. Para minimizar os custos, minas abandonadas são preferencialmente utilizadas, ou ainda minas de sal abandonadas. A vantagem de se armazenar o ar comprimido em minas de sal se deve ao fato de que, quando o ar está sendo armazenado este, sob grande pressão, está a altas temperaturas também e, misturado com o sal cria um gás que se deposita nas eventuais fissuras da caverna selando a mesma quase que por inteiro e aumentando a eficiência do sistema, uma vez que a quantidade de ar comprimido que vazia é reduzida. O processo de armazenamento de ar é o equivalente ao carregamento de uma bateria eletroquímica.

Durante os horários de ponta, alta demanda é encontrada, o ar comprimido é retirado do reservatório através de uma turbina a gás multi-estágio. A turbina aciona o gerador elétrico que converte a energia mecânica em energia elétrica e alimenta o sistema elétrico via transformadores (GRBRVIĆ, 2014).

Um dos problemas desse sistema é o armazenamento do ar comprimido a elevadas temperaturas, uma vez que durante o período em que fica armazenado o mesmo perde o calor que tinha quando do processo inicial reserva. As turbinas a gás são semelhantes a turbinas de avião e para se ter a pressão necessária no processo apresentado na figura 28 o ar comprimido é misturado a algum combustível fóssil (querosene no caso de turbinas à jato). Porém, isto eleva o custo do processo de armazenamento de energia.

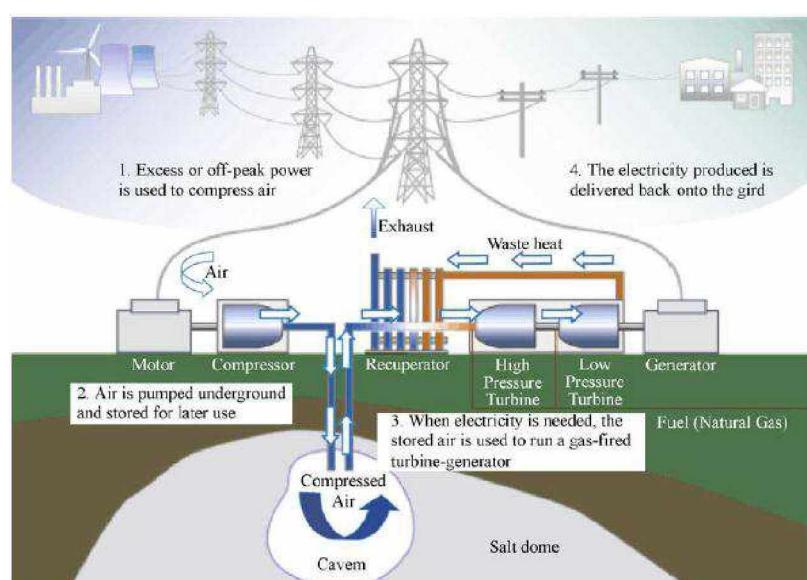


Figura 28 - Esquema CAES.

Fonte: (CHEN, et. al. 2009).

Para solucionar esse problema são utilizadas rochas denominadas "Pebble Beds" ou conglomerados de quartzo. Essas rochas tem a propriedade de alta absorção de calor e quando o ar aquecido passa por elas no estágio do armazenamento de energia, essas rochas absorvem esse calor e quando o processo de fornecimento de energia é iniciado o ar comprimido já resfriado, devido ao tempo em que ficou armazenado, passa novamente por onde estão essas rochas e assim são aquecidos. Este processo pode ser visualizado na figura 29.

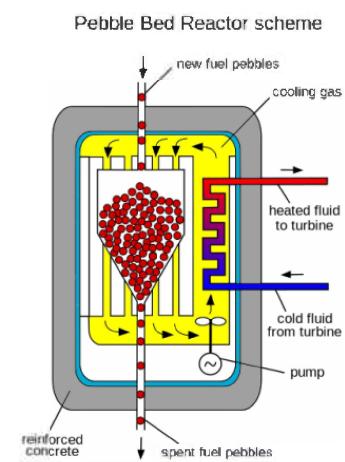


Figura 29 - Reator com Pebble Beds.

A eficiência de um CAES varia entre 70 - 90%, devido a vazão do ar comprimido no reservatório. Sua vida útil varia entre 20 a 40 anos. Assim como a PHS o CAES não passa por processos químicos, então não existe limite para ciclos de carga e descarga durante sua vida útil (KONDOH et. al. 2000).

A capacidade de potência média instalada do CAES pode variar entre 5 - 300 MW e seu tempo de descarga variar entre 1 a 24 horas (CHEN et. al., 2009).

Ambientalmente, os sistemas CAES que utilizam minas de sal, apresentam impactos negativos devido à emissões derivadas da combustão do gás criado no processo (CHEN et. al. 2009).

4.3.1.3 Armazenador de energia de roda livre

O AEE de roda livre (do inglês *Flywheel*) armazena energia em forma de energia cinética de um corpo girante. Esta tecnologia consiste de um rotor com grande inércia e um conversor eletromecânico bi-direcional tal como uma máquina elétrica trifásica que

fica conectado ao mesmo eixo do rotor com alta inércia (GRBRVIĆ, 2014). A figura 30 ilustra um sistema deste tipo.

A energia cinética do *flywheel* é dada por (51):

$$W_{FW} = \frac{1}{2} J_0 \omega_0 \quad (51)$$

Sendo:

J_0 é o momento de inércia de todo o sistema rotacional, incluindo os rotores da máquina elétrica e do próprio *flywheel*;

ω_0 é a velocidade angular do *flywheel*.

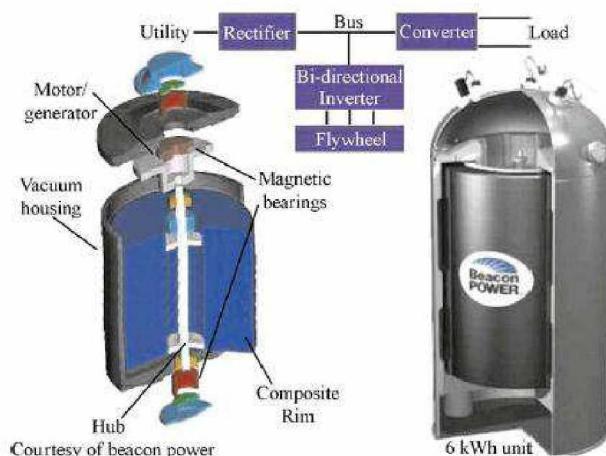


Figura 30 - Sistema flywheel.
Fonte: (CHEN et. al., 2009).

Durante a carga, a máquina elétrica opera como motor e acelera o rotor do *flywheel*. Durante a descarga o oposto ocorre, e o rotor do *flywheel* acoplado ao eixo da máquina elétrica faz com que a mesma opere como gerador. Como se pode ver por (51), a energia cinética depende fortemente da velocidade do rotor do AEE. Dessa maneira, dois tipos de *flywheel* surgiram: de alta velocidade (cerca de 40.000 rpm) e o de baixa velocidade (cerca de 7.000 rpm). Sistemas modernos alcançam uma eficiência superior a 90%.

Sua vida útil varia entre 10.000 a 100.000 ciclos (~15 anos), determinado pela fadiga originada do tipo de projeto do AEE (IBRAHIM, ILINCA e PERRON, 2008).

A capacidade de potência média instalada do *flywheel* pode variar entre 0 - 250 kW e seu tempo de descarga variar de milisegundos a 15 minutos (CHEN et. al., 2009).

Ambientalmente esse tipo de sistema quase não oferece risco algum, uma vez que não utiliza de processos químicos para o seu funcionamento.

4.3.1.4 Armazenador de energia supercondutor magnético

O Armazenador de energia supercondutor magnético (do inglês *Super-
Conducting Magnetic Energy Storage - SMES*) é um dispositivo que armazena energia na forma de campo magnético que é criado por uma corrente contínua em uma bobina supercondutora (BS) (MOLINA, 2012). O SMES é composto por uma bobina supercondutora e um conversor bi-direcional.

Uma bobina supercondutora é um indutor linear com indutância L_0 , geralmente feito de nióbio- titânio (NbTi). A energia do SMES carregado pela corrente I_0 é (52):

$$W_{SMES} = \frac{1}{2} L_0 I_0^2 \quad (52)$$

De (52) é possível concluir que grandes quantidades de energia requerem alta indutância e uma alta corrente. A resistência de um supercondutor é, virtualmente, zero. Devido a sua propriedade supercondutora magnética, uma indutância da ordem de dezenas de Henry pode ser facilmente alcançada, enquanto que I_0 pode ser da ordem de milhares de ampéres. Assim, uma capacidade de energia da ordem de dezenas de megajoules pode ser alcançada (GRBRVIĆ, 2014). A figura 31 ilustra a estrutura básica de um SMES.

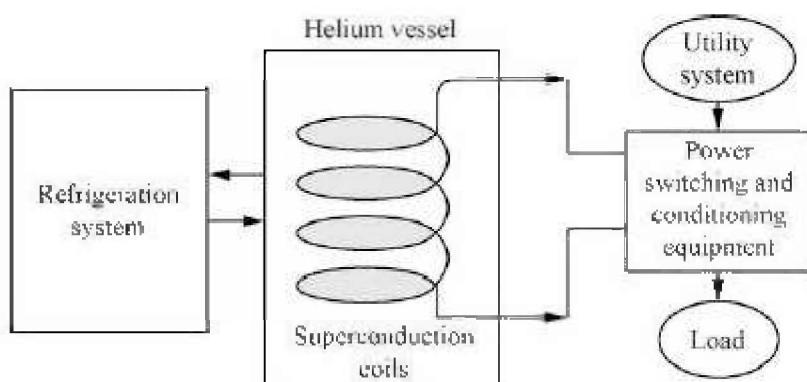


Figura 31 - Sistema SMES.
Fonte (CHEN et. al., 2009).

O princípio básico de funcionamento consiste que quando a BS está carregada, a corrente não decai e a energia magnética pode ser armazenada indefinidamente. Essa energia armazenada pode ser liberada de volta a rede elétrica simplesmente descarregando-se a BS (MOLINA, 2012).

Umas das vantagens desse AEE é a boa eficiência instantânea de carga/descarga que chega a aproximadamente 95%. Além do mais, esses sistemas são capazes de descarregar praticamente toda a energia armazenada, oposto do que ocorre em baterias eletroquímicas. Estes são muito úteis para aplicações onde exigem-se elevados ciclos de cargas/descarga. Sua vida útil varia entre 10.000 a 100.000 ciclos (+20 anos) (IBRAHIM; ILINCA e PERRON, 2008).

A capacidade de potência média instalada do SMES pode variar entre 100 W - 10 MW e seu tempo de descarga variar de milisegundos a 8 segundos (CHEN et. al., 2009).

Do ponto de vista da degradação do meio ambiente, esse tipo de sistema pode se tornar negativo, uma vez que produz fortes campos eletromagnéticos para o armazenamento da energia.

4.3.1.5 Capacitores (*Supercapacitores*)

A maneira mais direta de se armazenar energia elétrica é por meio de capacitores. De forma simples, um capacitor consiste em duas placas de metal separadas por um material dielétrico.

Os capacitores podem ser substituídos substancialmente mais rápidos do que baterias convencionais e serem submetidos à ciclos da ordem de dezenas de milhares de vezes e com elevada eficiência (CHEN et. al., 2009).

Progressos recentes na tecnologia voltada a capacitores culminaram no surgimento dos supercapacitores. Esses dispositivos consistem de uma estrutura porosa de carbono ativado, para um ou ambos os eletrodos, que ficam imersos em uma solução eletrolítica (tipicamente hidróxido de potássio ou ácido sulfúrico) e um separador que previne o contato físico entre os eletrodos, porém permite a transferência de íons entre os mesmos (MOLINA, 2012). Esta estrutura cria 2 capacitores, um para cada eletrodo, conectados em série (GRBRVIĆ, 2014), como ilustrado na figura 32.

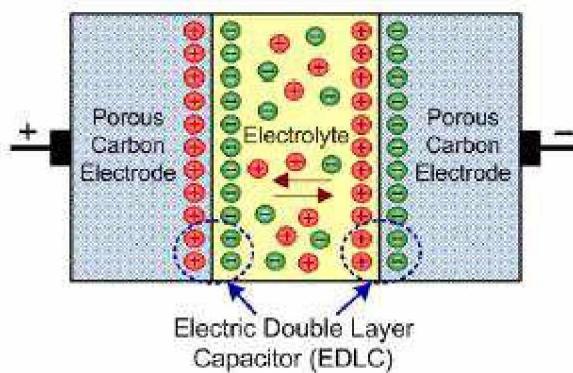


Figura 32 - Estrutura de um supercapacitor.
Fonte: (MOLINA, 2012).

A capacidade depende da quantidade dos íons e da superfície do eletrodo condutor. Uma vez que o diâmetro dos íons é da ordem de ångstroms², enquanto que a superfície é da ordem de milhares de metros quadrados, a capacidade é da ordem de milhares de Farads, o que é muito maior do que as capacidades de capacitores eletrolíticos comuns (GRBRVIĆ, 2014).

O supercapacitor é um capacitor não linear. A capacidade é controlada por meio da tensão de capacidade, definida como (53):

$$C(u) = C_0 + k_C u \quad (53)$$

Sendo:

C_0 é a capacidade inicial, que representa a capacidade eletrostática do capacitor;

k_C é um coeficiente que representa os efeitos da camada difusa do supercapacitor;

u é a tensão de capacidade.

Carregando o supercapacitor por meio de uma tensão U_0 . A energia do supercapacitor é (54):

$$W_E = \frac{1}{2} \left(C_0 + \frac{4}{3} k_C U_0 \right) U_0^2 \quad (54)$$

² O ångström (\AA) é uma unidade de medida de comprimento que se relaciona com o metro através da relação: $1 \text{\AA} = 10^{-10} \text{ m}$

Sua vida útil varia entre aproximadamente de 8 - 10 anos, com uma eficiência de 95% (IBRAHIM; ILINCA e PERRON, 2008).

A capacidade de potência média instalada dos supercapacitores pode variar entre 0 - 300 kW e seu tempo de descarga pode variar de milisegundos a 60 minutos (CHEN et. al., 2009).

Causa pouco impacto ao meio ambiente devido ao seu descarte quando da sua troca.

4.3.1.6 *Baterias eletroquímicas*

As baterias eletroquímicas, chamadas também de baterias secundárias, são a forma mais antiga de se armazenar energia, em forma de energia química. Uma bateria é composta de uma ou mais células eletroquímicas e cada célula consiste de um eletrodo positivo (anodo) líquido, pastoso, ou sólido, juntamente com um eletrodo negativo (catodo) (CHEN et. al., 2009), imersos em um meio eletrólito (GRBRVIĆ, 2014). Durante a descarga, ocorrem reações eletroquímicas nos dois eletrodos gerando um fluxo de elétrons por meio de um circuito externo. As reações são reversíveis, permitindo a bateria de ser recarregada pela simples aplicação de uma tensão externa nos eletrodos.

Dependendo do material empregado no eletrodo e o eletrólito, pode-se distinguir diferentes tipos de baterias eletroquímicas. Como exemplo têm-se:

- Baterias de chumbo-ácido;
- Baterias de níquel-cadmio;
- Baterias de ferro-níquel;
- Baterias de sódio-enxofre;
- Baterias de sódio-níquel clorídrico;
- Baterias de litio-íon.

Devido à extensa gama de baterias existentes, esta seção focará apenas na bateria de chumbo-ácido, uma vez que este tipo de bateria é o que foi levado em consideração para o desenvolvimento desse estudo.

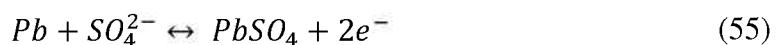
Baterias de chumbo-ácido tem sido invariavelmente escolhidas para instalações de geração distribuída por meio de placas solares ou turbinas eólicas, devido a sua ampla disponibilidade de tamanho e custo (DELL e RAND, 2001).

4.3.1.6.1 Baterias de chumbo-ácido

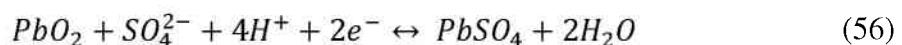
As baterias de chumbo-ácido, inventadas em 1859, são as mais antigas e difundidas baterias eletroquímicas. Este tipo de bateria, consiste de eletrodos de chumbo metálico e óxido e um eletrólito de ~37% de ácido sulfúrico. No estágio de descarga ambos os eletrodos se transformam em sulfato de chumbo e o eletrólito perde seu ácido sulfúrico dissolvido e se torna essencialmente água.

As reações químicas são:

Anodo (55)



Catodo (56)



Existem diversos tipos de baterias de chumbo-ácido, incluindo a bateria inundada que requer reposição de água destilada regularmente (CHEN et. al., 2009).

Um sistema contendo bateria eletroquímica é ilustrado pela figura 33.

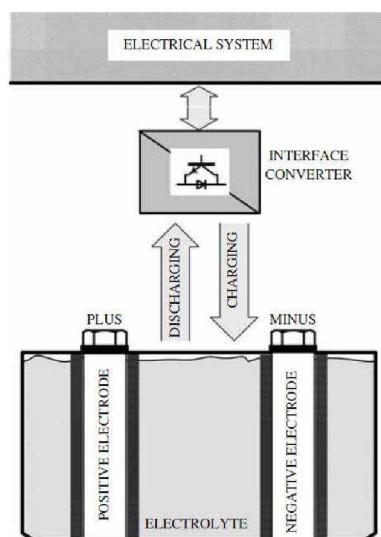


Figura 33 - Sistema de uma bateria eletroquímica.
Fonte: (GRBRVIĆ, 2014).

Sua vida útil varia entre ~5 - 15 anos, com uma eficiência de 70 - 90% (CHEN et. al., 2009).

A capacidade de potência média instalada de baterias de chumbo-ácido pode variar entre 0 - 20 MW e seu tempo de descarga variar de segundos a horas (CHEN et. al., 2009).

Ambientalmente, este tipo de tecnologia causa impactos negativos, uma vez que se utiliza de um processo químico para o seu funcionamento, podendo resultar na liberação de resíduos tóxicos caso não tenha um armazenamento correto para a sua utilização ou descarte.

CAPÍTULO 5

Resultados

5.1 Introdução

Neste capítulo são apresentados os resultados obtidos nesta pesquisa. Os resultados aqui apresentados se referem a:

- Testes realizados com os algoritmos de treinamento da RNA;
- Uma proposta para dimensionamento a longo prazo de armazenadores de energia do tipo chumbo-ácido;
- Análise a longo prazo da minimização de perdas por potência ativa, utilizando RNA e armazenadores de energia do tipo chumbo-ácido;
- A minimização de perdas por potência ativa por meio da reconfiguração de redes de distribuição de energia elétrica, utilizando o algoritmo de otimização PSO e armazenadores de energia do tipo bateria de chumbo-ácido.

5.2 Análise do desempenho de algoritmos de treinamento da RNA para a estimação de geração fotovoltaica

Nos tópicos a seguir são apresentados os dados obtidos por meio dos algoritmos de treinamento analisados na rede neural artificial escolhida.

Os algoritmos de treinamento são os mesmos apontados na seção 3.3.5, são eles:

1. *BFGS Quasi-Newton (BFG)*;
2. *Bayesian Regularization (BR)*;

3. *Conjugate Gradient with Powell/Beale Restarts (CGB);*
4. *Polak-Ribiére Conjugate Gradient (CGP);*
5. *Resilient Backpropagation (RP);*
6. *Scaled Conjugate Gradient (SCG);*
7. *Levenberg-Marquardt (LM).*

5.2.1 Dados solares da região de coleta de dados.

Para este trabalho, foram obtidos dados climáticos de irradiação (W/m^2), temperatura ambiental ($^{\circ}\text{C}$), potência medida (W), temperatura da placa solar ($^{\circ}\text{C}$) e as horas do dia (h) para o mês de outubro de 2015 na cidade de Uberlândia - MG (Brasil). Esses dados serviram como dados de entrada para a preparação da rede. Este mês foi escolhido por ser o mês com maior incidência solar da região onde os dados foram coletados.

Os dados foram modelados de hora em hora com 3 tipos de dados numéricos. Após o treinamento da RNA, os mesmos tipos de dados foram utilizados como entradas para a estimação da RNA, porém esses dados foram coletados para o mês de novembro de 2015. Os dados de entrada foram coletados do Instituto Nacional de Pesquisas Espaciais - INPE

Uberlândia se localiza no Estado de Minas Gerais, no triângulo mineiro, próxima ao Estado de Goiás, caracterizando-se por ser um município com clima tropical com temperatura média anual de $21,5^{\circ}\text{C}$ e radiação média anual de $6 \text{ kWh/m}^2/\text{dia}$. Nessa região a vegetação característica é o cerrado e suas variáveis (UFU, 2016). A figura 34 ilustra a radiação solar média diária anual na cidade de Uberlândia (CEMIG, 2012).



Figura 34 - Atlas solarimétrico de Minas Gerais - Radiação média diária anual.
Fonte: Adaptado (CEMIG, 2012).

A figura 35 mostra a potência gerada por uma placa fotovoltaica de acordo com os dados coletados em um período de 30 dias. Os dados de potência ativa gerada, de acordo com os dados de entrada citados anteriormente, serviram como dados de treinamento para a preparação da rede neural artificial.

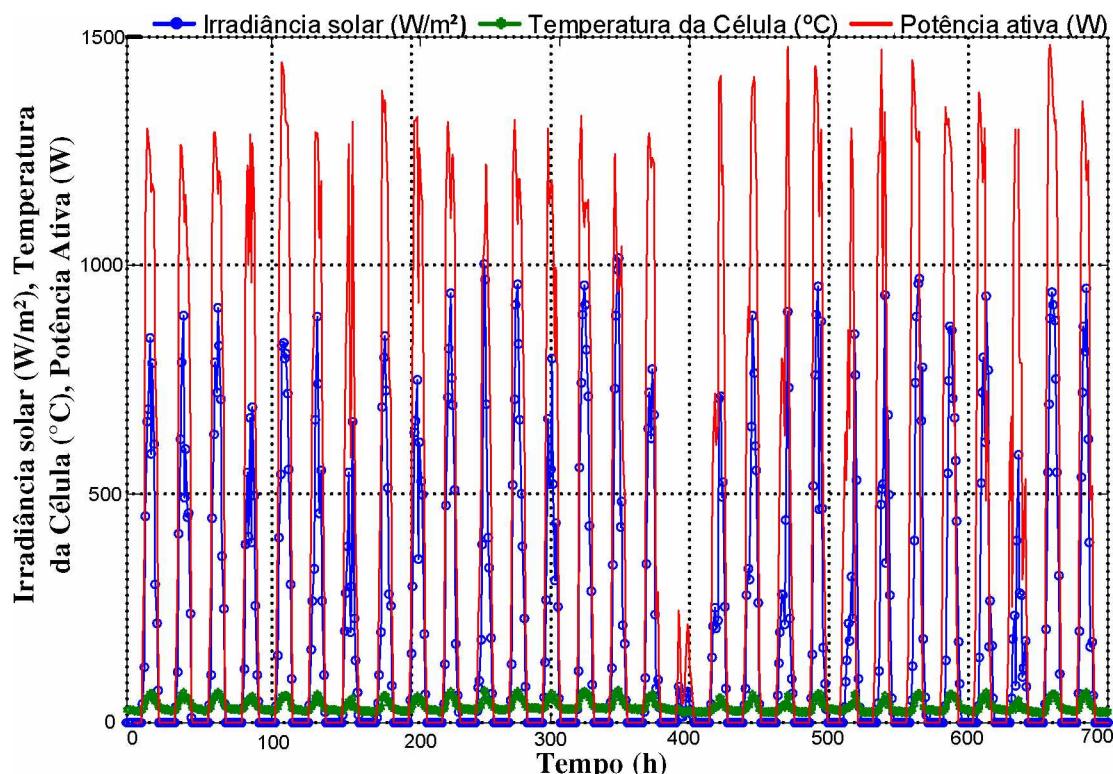


Figura 35 - Irradiância, temperatura da célula e potência gerada.

Foram utilizadas 7 placas solares conectadas em série do tipo JT235PC de silício policristalino, de fabricação da empresa Jetion Solar (JETION SOLAR, 2015), e suas características são mostradas na tabela 6.

Tabela 6 - Características elétricas da placa solar

Desempenho elétrico nas condições padrões de irradiação de 1.000 W/m², AM=1,5 e temperatura da célula de 25 °C (STC)	
Potência Máxima: P _{máx} (W)	235 W (0/+5%)
Tensão de Potência Máxima: V _{mpp} (V)	30,5 V
Corrente de Potência Máxima: I _{mpp} (A)	7,71 A
Tensão de Circuito Aberto: V _{OC} (V)	37 V
Corrente de Curto Circuito: I _{CC} (A)	8,4 A
Tensão Máxima (V)	1000 V
Coeficiente de Temperatura de V _{OC}	- 0,4049 %/°C
Coeficiente de Temperatura de I _{CC}	0,0825 %/°C
Desempenho elétrico a 800 W/m², NOCT 20 °C, AM=1,5, Velocidade do Vento 1 m/s	
Potência Máxima: P _{máx} (W)	172 W
Tensão de Potência Máxima: V _{mpp} (V)	27,7 V
Corrente de Potência Máxima: I _{mpp} (A)	6,2 A
Tensão de Circuito Aberto: V _{OC} (V)	33,9 V
Corrente de Curto Circuito: I _{CC} (A)	6,8 A

Os dados utilizados e apresentados na figura 35 são justificados a seguir.

5.2.1.1 O efeito da irradiação na fotocélula

A corrente gerada por uma fotocélula é diretamente relacionada à irradiação solar em sua superfície. A corrente de curto-circuito é linearmente proporcional a esta irradiação.

Já a tensão de circuito aberto se refere à tensão através do diodo interno da junção *p-n* quando a fotocorrente gerada passa por ele. A dependência da tensão de circuito aberto à irradiação corresponde à dependência que a tensão da junção *p-n* tem

com a fotocorrente, de forma que quando a irradiação é baixa, sendo também a fotocorrente gerada, a tensão de circuito aberto é baixa.

A figura 36 mostra as curvas de corrente por tensão para diversas irradiações nas photocélulas.

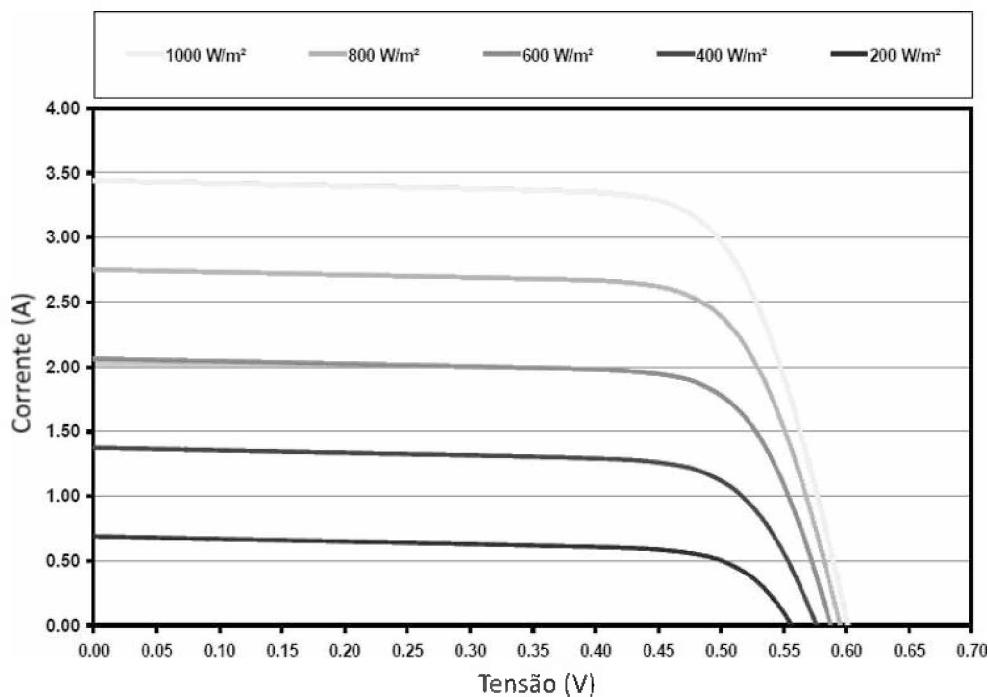


Figura 36 - Curva corrente por tensão de uma photocélula com diferentes irradiações.

5.2.1.2 O efeito da temperatura na photocélula

Em semicondutores a largura de banda de energia diminui com o aumento da temperatura. Em uma photocélula, com a temperatura mais alta, mais fôtons têm energia suficiente para criar pares *p-n*.

A tensão de circuito aberto é fortemente dependente da temperatura decrescendo substancialmente e fazendo com que a corrente de curto-círcuito cresça levemente (SKOPLAKI, BOUDOUVIS e PALYVOS, 2008). A figura 37 ilustra o efeito da temperatura em uma photocélula.

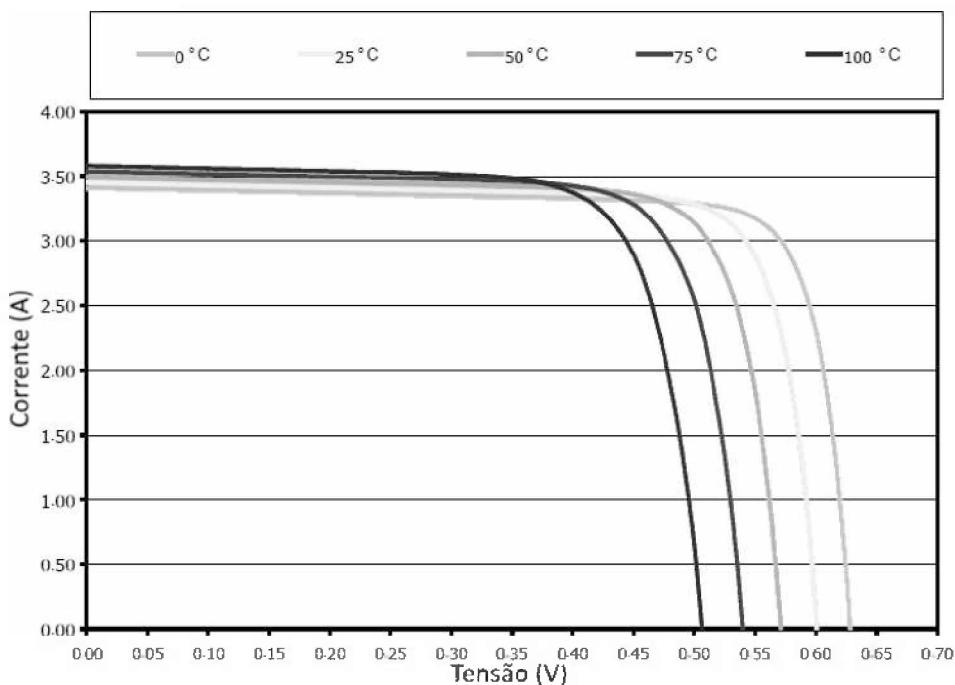


Figura 37 - Curva de corrente por tensão de uma fotocélula com diferentes temperaturas.

5.2.2 Estrutura da RNA

Para a preparação da rede neural artificial, foi utilizado o *software* MATLAB. Esse software disponibiliza em sua toolbox modelos de redes neurais artificiais, das quais podemos citar: Fitting tools; Pattern-Recognition tool; Clustering tool; Time series Tool.

Para esta pesquisa foi utilizada a ferramenta para a previsão temporal de dados *time series tool*.

A ferramenta escolhida ainda dá a opção de 3 tipos de soluções para problemas, a NARX (Non-linear Auto-Regressive eXogenous); a NAR (Non-linear Auto-regressive); e a Non-Linear Input-Output. Foi escolhida a solução NARX.

5.2.2.1 Preparação da rede e índices de desempenho

Normalizados os dados de entrada e de saída da rede neural escolhida, foi feito o treinamento dessa rede através dos 7 algoritmos citados anteriormente. A capacidade da rede utilizada para o treinamento foi 70%. Para a validação e teste, ambos, 15%. Ao todo, entre dados de entrada e de objetivo, foram utilizados 2820 dados para a preparação e treinamento da rede. Os testes foram feitos em um PC com 3.40GHz Intel Core i7A Pentium® e 8 GB de memória RAM.

Com relação ao treinamento da rede neural, uma das alternativas para resolver o problema da parada do treinamento é a técnica da validação cruzada. Ao invés de definir o número exato de iterações de ajuste de pesos no treinamento, divide-se, aleatoriamente, o conjunto de dados em 3 subconjuntos: treinamento, validação e testes. Com isso, a cada iteração a rede é treinada, já com os pesos ajustados, é testada com o subconjunto de validação e o erro da predição é calculado ao final da iteração. A motivação é ajustar os pesos com os dados do subconjunto de treinamento e calcular o erro com os dados do subconjunto de validação, fornecendo assim, dados diferentes à rede. Assim, o erro da validação cruzada começa alto, decresce até certo ponto e depois aumenta. Enquanto o erro da validação está diminuindo a rede está generalizando, quando o erro começa a aumentar, ao mesmo tempo em que o erro do treinamento continua a diminuir, a rede começa a decorar as entradas, perdendo a capacidade de generalização. Nesse momento a rede deve parar o treinamento.

Como ferramenta utilizada para a validação dos dados utilizou-se a regressão linear. Trata-se de um processo estatístico que ajuda a deduzir a relação entre um determinado número de variáveis dependentes e variáveis independentes. Essa análise é útil em estudos de dependência funcional entre fatores de entrada e saída, implicando que cada variável de entrada (x_1, x_2, x_3, \dots) parcialmente, determina o nível da variável de saída (y). Cada valor da variável independente x é associado com um valor da variável dependente y . Uma explicação mais detalhada desta ferramenta pode ser encontrada em (PULIPAKA, MANI e KUMAR, 2016) e em (İZGI et. al., 2012).

Outra ferramenta estatística utilizada para se obter o desempenho da rede neural em estudo é o erro médio percentual absoluto (do inglês MAPE - *mean absolute percentage error*). O MAPE é uma medida estatística da precisão de séries temporais, representando essa precisão em forma de porcentagem (CELIK, 2011), (OLATOMIWA et. al., 2015), (BHARDWAJ et. al., 2013) e pode ser definida por (57):

$$MAPE(\%) = \left(\frac{1}{n} \sum_{i=1}^n \frac{|y_i - x_i|}{x_i} \right) \times 100 \quad (57)$$

sendo x os dados de entrada e y os dados previstos pela rede neural.

Por fim, também como ferramenta estatística a ser utilizada para a análise do desempenho dos algoritmos de treinamento, fez se uso do erro médio quadrático (do inglês RMSE - *Root Mean Square Error*). O RMSE dá a informação do desempenho em

curto prazo da correlação "r", comparando a extensão do desvio do valor previsto a partir do valor real medido (MENTASCHI et. al., 2013), (KAUSHIKA, TOMAR e KAUSHIK, 2014) e (BERNECKER, et. al., 2014). A correlação "r" e RMSE são definidos por (58) e (59), respectivamente:

$$r = \frac{\sum_{i=1}^n (y_i - \bar{y}) \cdot (x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y}) \cdot \sum_{i=1}^n (x_i - \bar{x})}} \quad (58)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}} \quad (59)$$

sendo x e y os dados de entrada e previstos, respectivamente, \bar{x}_i e \bar{y}_i são os valores médios de x e y e n é o número total de valores.

Quanto menores os valores do MAPE e do RMSE, melhor é o desempenho da rede neural (OLATOMIWA et. al., 2015).

5.2.3 Resultados e discussões

Após inseridos os dados de entrada (irradiação solar, temperatura ambiental e temperatura das placas solares) e os dados de objetivo (potência ativa medida), foi feito o treinamento e, o primeiro resultado analisado foi o número de iterações necessárias para que a rede fosse treinada e validada de acordo com o algoritmo de treinamento que estava sendo utilizado. Um maior número de iterações para validação, treinamento e teste, resulta em mais tempo que a rede gasta para ser preparada. O tempo de treinamento e preparação da rede está diretamente ligado aos algoritmos de treinamento, uma vez que são as reduções dos erros promovidas por eles que servem de critério para a validação cruzada.

Por ordem de melhor desempenho para a validação cruzada dos algoritmos, o algoritmo que obteve o treino mais rápido foi o CGP, levando um total de 6 iterações para o treino, validação e teste; seguido do CGB com 21 iterações; com 36 iterações, em terceiro lugar vem o algoritmo SCG; o algoritmo RP necessitou de 75 iterações para o processo de treinamento; para o algoritmo LM foram necessárias 134 iterações; o algoritmo BR necessitou de 168 iterações; e por último, com o tempo mais demorado, vem o algoritmo BFG com 354 iterações para o processo.

O segundo índice a ser analisado é a regressão linear resultante entre os dados previstos e os medidos, de acordo com cada algoritmo de treinamento. Para isso, foi feita a estimativa de energia gerada em um intervalo de 72 horas, para valores de dados futuros, correspondentes aos dados de entrada utilizados para a preparação e treinamento da rede. A tabela 7 traz um resumo dos dados que foram utilizados nesta análise. A figura 38 ilustra as regressões obtidas.

Tabela 7 - Síntese dos dados analisados de acordo com os algoritmos de treinamento

Algoritmos de treinamento	Iterações para validação cruzada da RNA	Regressão linear	MAPE (%)	RMSE (%)
BR	168	0,9999	0,02	0,11
LM	134	0,9999	0,31	0,74
CGB	21	0,9977	5,28	6,13
SCG	36	0,9992	6,33	5,15
CGP	6	0,9919	6,27	10,41
RP	75	0,9958	7,85	8,76
BFG	354	0,9967	10,37	9,06

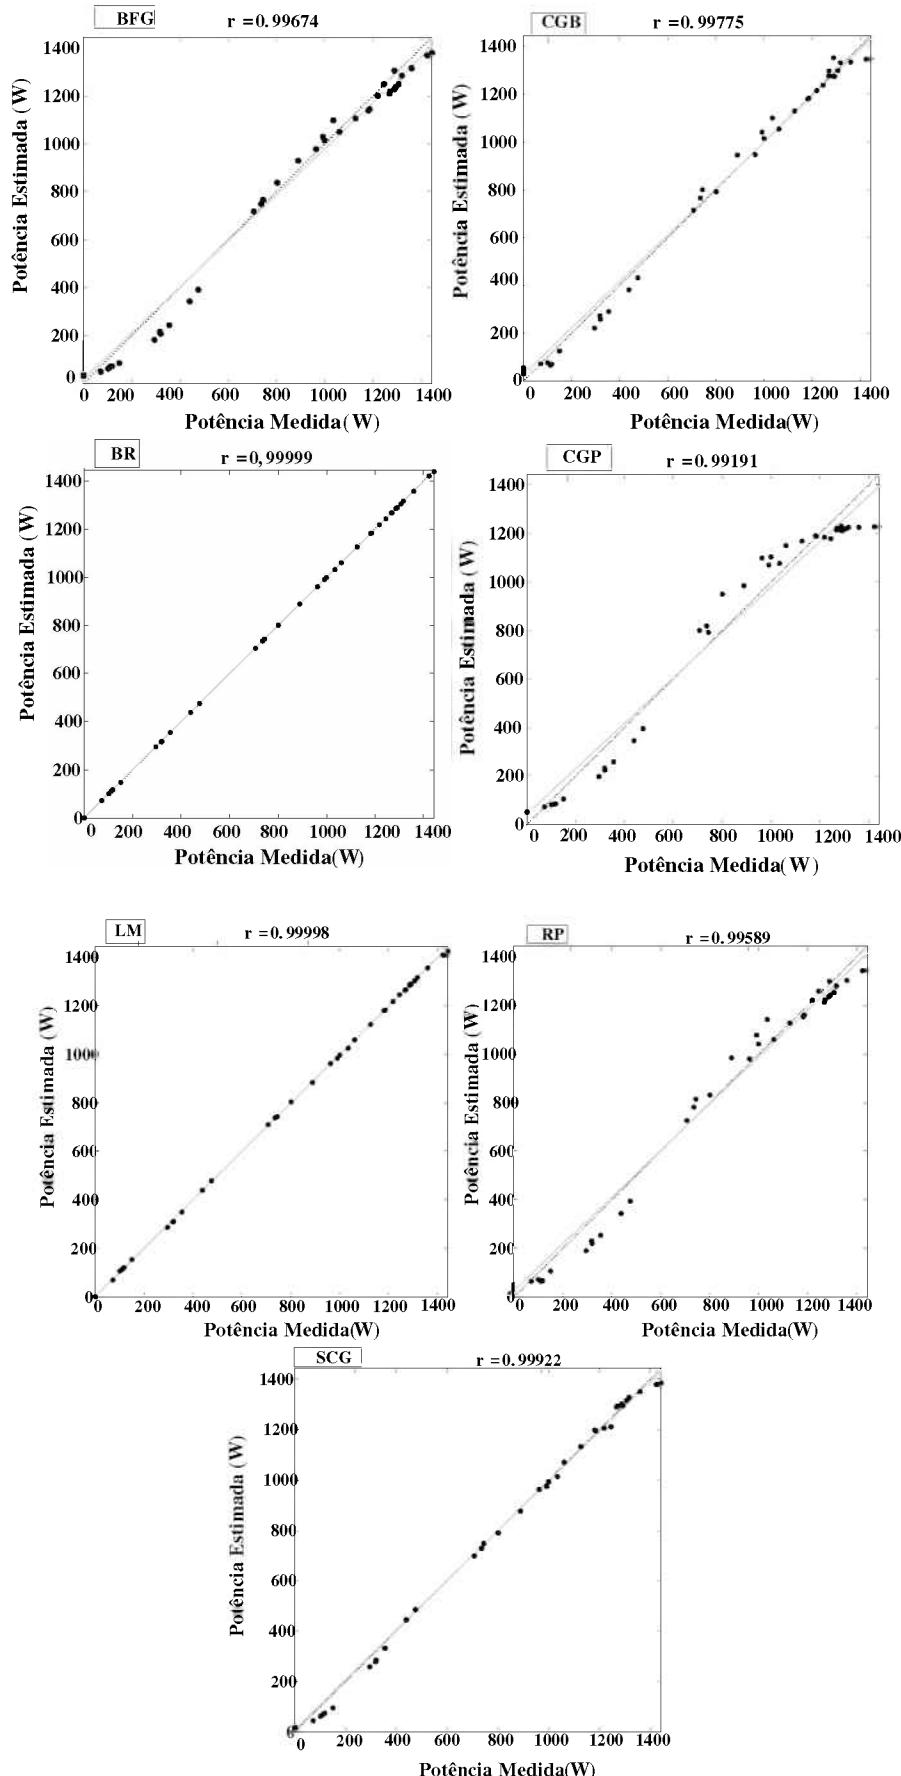


Figura 38 - Regressão linear para os algoritmos de treinamento.

O algoritmo BR, apesar de não ter sido validado, apresentou a melhor regressão linear dentre todos os outros com um valor de $r = 0,9999$; seguido do LM que apresentou uma regressão de $r = 0,9998$; o algoritmo SCG resultou em uma regressão de $r = 0,9992$; com uma regressão de 0,9977 vem o algoritmo CGB; com a quinta melhor regressão encontrou-se o algoritmo 0,9967; em seguida vem o RP com uma regressão de $r = 0,9958$; e finalmente com a pior regressão linear dentre todos os algoritmos de treinamento avaliados vem o algoritmo CGP com $r = 0,9919$.

Corroborando com o exposto anteriormente, as figuras 39 a 45, ilustram a comparação entre os dados medidos e os dados previstos para os algoritmos BFG, BR, CGB, CGP, RP, SCG e LM, respectivamente.

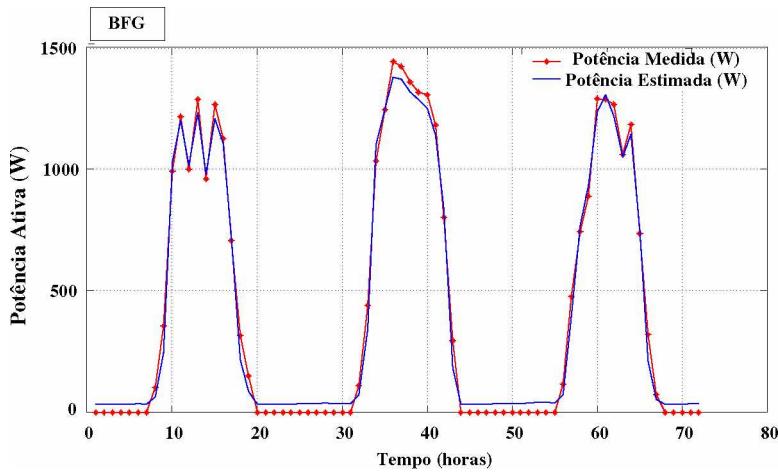


Figura 39 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento BFG.

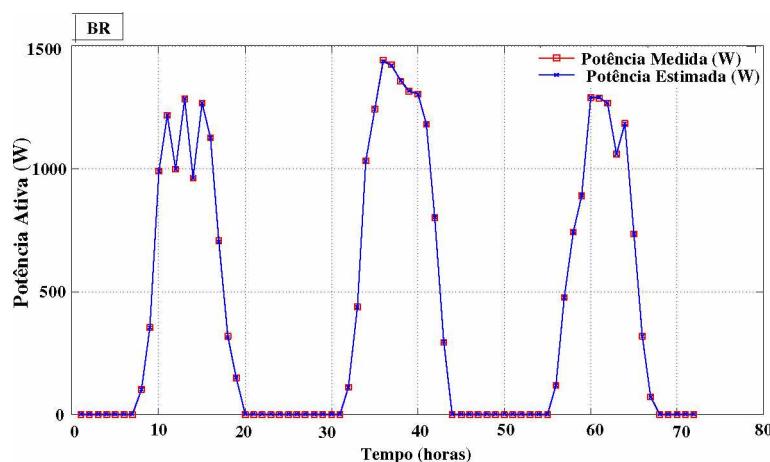


Figura 40 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento BR.

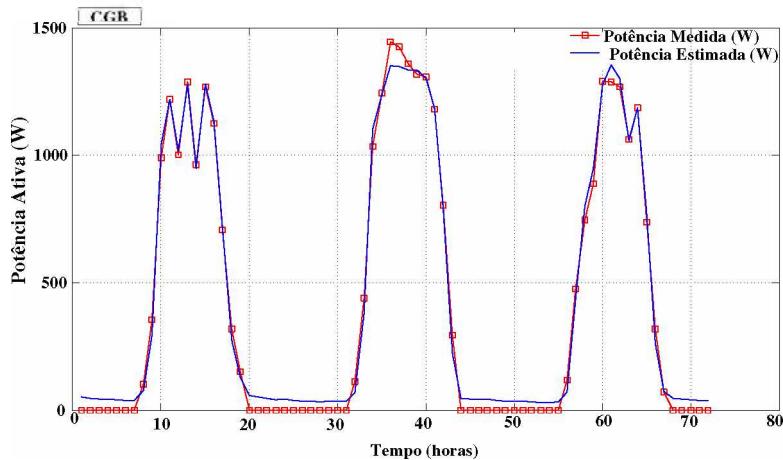


Figura 41 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento CGB.

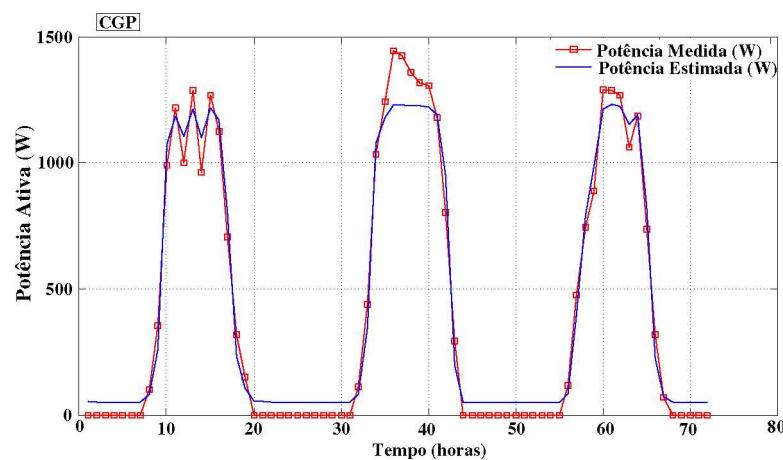


Figura 42 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento CGP.

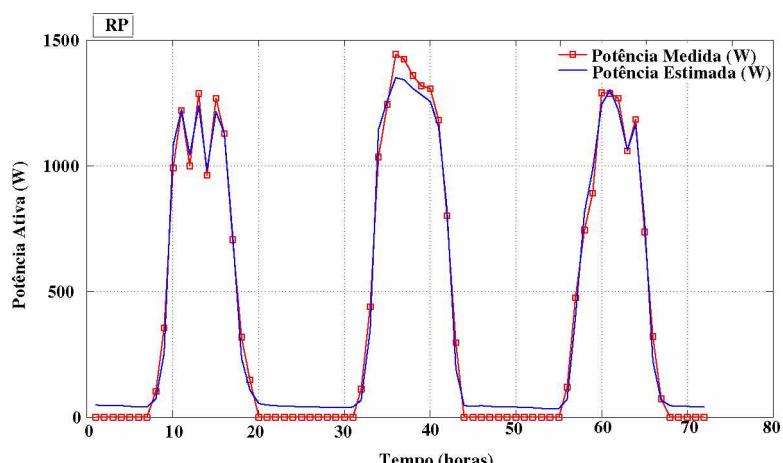


Figura 43 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento RP.

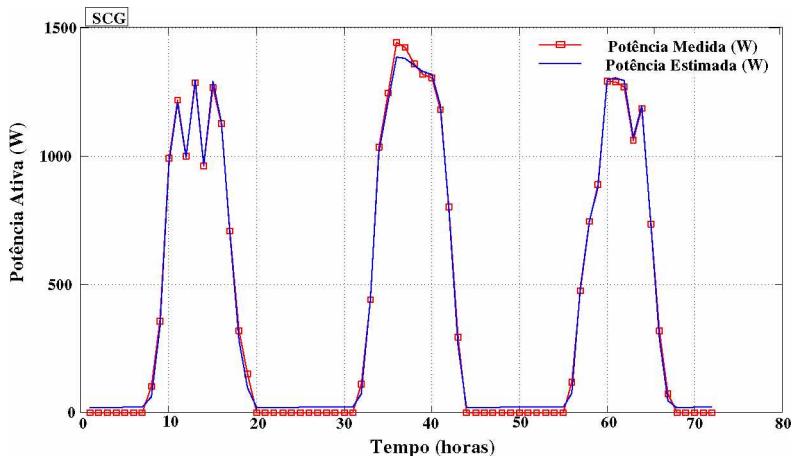


Figura 44 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento SCG.

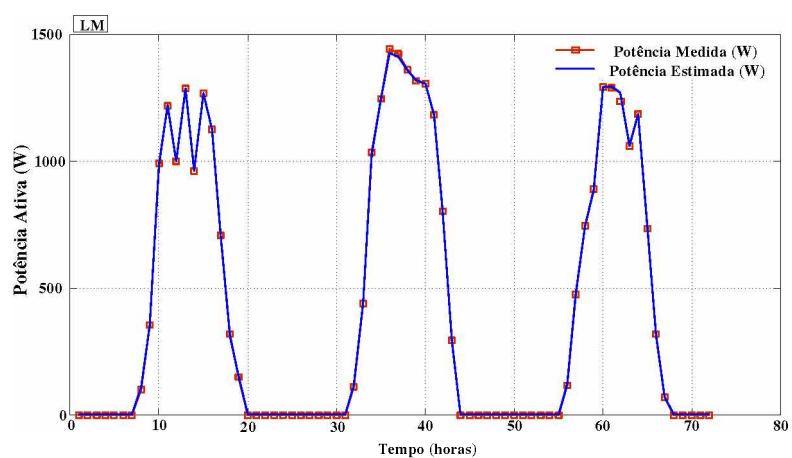


Figura 45 - Potência medida (W) e potência estimada (W) em um intervalo de 72 horas para o algoritmo de treinamento LM.

No entanto, para verificar se a possibilidade da generalização da RNA treinada pelos métodos BR e LM, ou seja, a RNA copiar as entradas nas saídas, outros testes foram feitos utilizando-se dados mais diversificados. Para esses testes, foram utilizados dados de 3 dias com irradiação intermitente, ou seja, dias parcialmente nublados. Os resultados são ilustrados nas figuras 46 e 47.

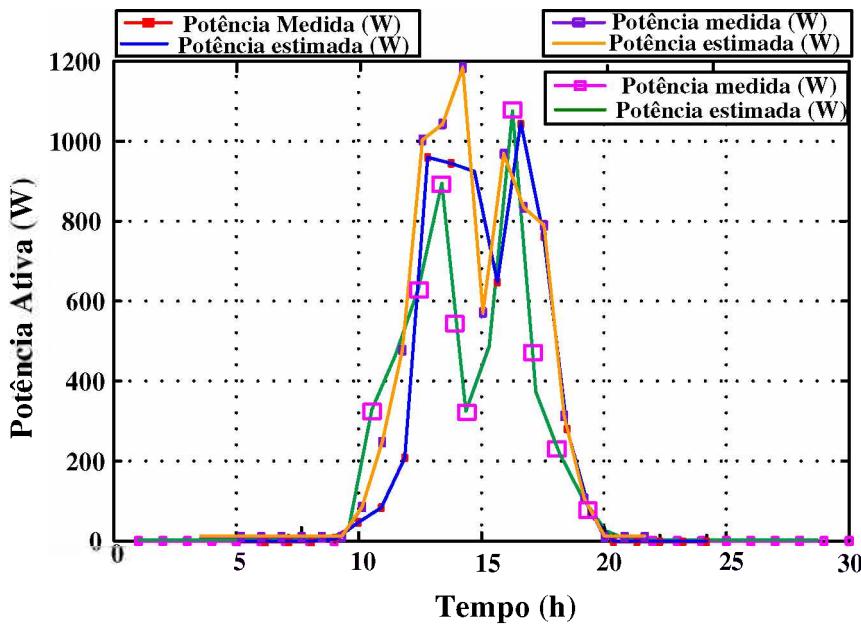


Figura 46 - Potência ativa medida e estimada (W) para os 3 dias de irradiação intermitente. Algoritmo BR.

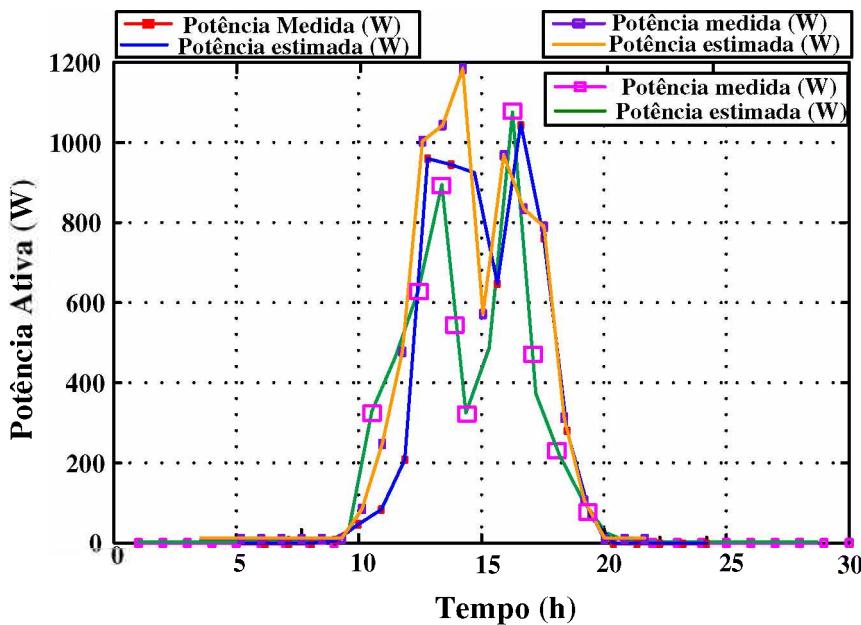


Figura 47 - Potência ativa medida e estimada (W) para os 3 dias de irradiação intermitente. Algoritmo LM.

Pode-se notar, por meio das figuras 46 e 47, que a potência ativa medida e estimada, obtiveram resultados bem precisos. Portanto, mesmo com dados diversificados, as respostas foram as mesmas das mostradas anteriormente pelas figuras 40 e 45, respectivamente.

Como os últimos índices de desempenho a serem analisados, tem-se o MAPE e o RMSE. O algoritmo de treinamento BR obteve os menores índices analisados com um MAPE de 0,02% e um RMSE de 0,11%. O LM apresentou um MAPE de 0,31% e um RMSE de 0,74. Com uma MAPE de 5,28% e um RMSE de 6,13% vem o CGB. Em

seguida com um MAPE de 6,27% e um RMSE de 10,41% se encontra o algoritmo CGP. Para o algoritmo SCG o MAPE foi de 6,33% e o RMSE de 5,15%. O algoritmo de treinamento RP resultou um MAPE de 7,85% e um RMSE de 8,76%. Analisando o algoritmo BFG encontrou-se um MAPE de 10,37% e um RMSE de 9,06%. É natural que os RMSE de alguns algoritmos sejam maiores do que os seus MAPES, uma vez que no RMSE se tem uma soma quadrática, o que não subtrai os índices negativos da soma, contrário do que ocorre no MAPE. A figura 48 ilustra os resultados dos MAPEs e RMSEs obtidos.

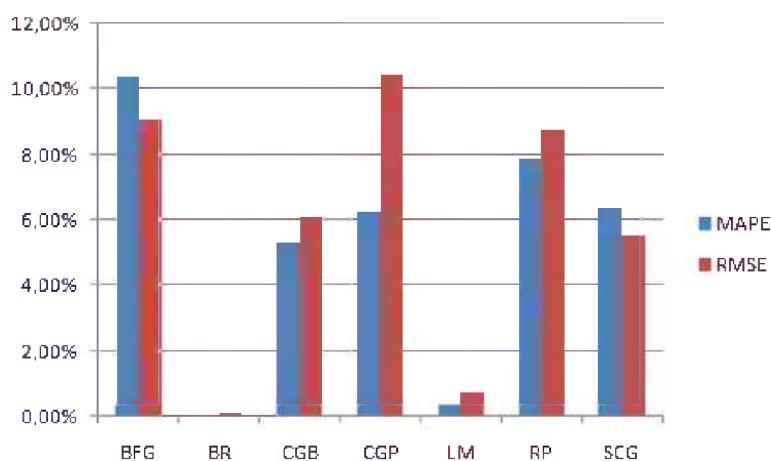


Figura 48 - MAPEs e RMSEs obtidos por algoritmo de treinamento.

5.2.4 Conclusão parcial

Nesta análise comparou-se os algoritmos de treinamentos mais difundidos e utilizados para a estimação temporal de dados utilizando o *software* MATLAB.

Para uma quantidade de dados relativamente grande utilizadas na rede neural analisada nesta seção, ao contrário do que se encontra em muitas publicações, o algoritmo de treinamento que obteve o melhor desempenho dentre todos os algoritmos analisados foi o Bayesian Regularization. Porém, apesar de ter obtido o segundo melhor desempenho, o algoritmo Levenberg-Marquardt necessitou de um tempo menor para treinar e preparar a rede neural. Os algoritmos derivados do algoritmo de treinamento Conjugate Gradient (CGB e SCG) também obtiveram resultados satisfatórios.

Portanto, para o tipo de análise feita neste trabalho, recomenda-se o uso do algoritmo de treinamento denominado Bayesian Regularization ou o Levenberg-Marquardt.

Por fim, uma interface gráfica foi criada para que o usuário obtenha uma interação mais amigável com a técnica de RNA utilizada neste trabalho. Os detalhes dessa interface podem ser vistos no anexo A deste documento.

5.3 Proposta de dimensionamento a longo prazo de armazenadores de energia do tipo chumbo-ácido

Como já tratado no capítulo 2, a introdução de fontes renováveis de energia elétrica por consumidores residenciais, que ao adquiri-las para geração própria também podem compensar o excedente de energia gerada e não utilizada para as concessionárias e permissionárias, tem trazido novos desafios a engenheiros e projetistas.

Por meio da figura 49, se visualiza que devido às características do perfil de demanda residencial em algumas horas do dia a geração de potência ativa por meio de fontes renováveis, no caso desse estudo a fotovoltaica, excede o consumo dessa mesma energia. O perfil de demanda de potência ativa de consumidores residenciais pode ser obtido em (JARDINI et. al., 2000).

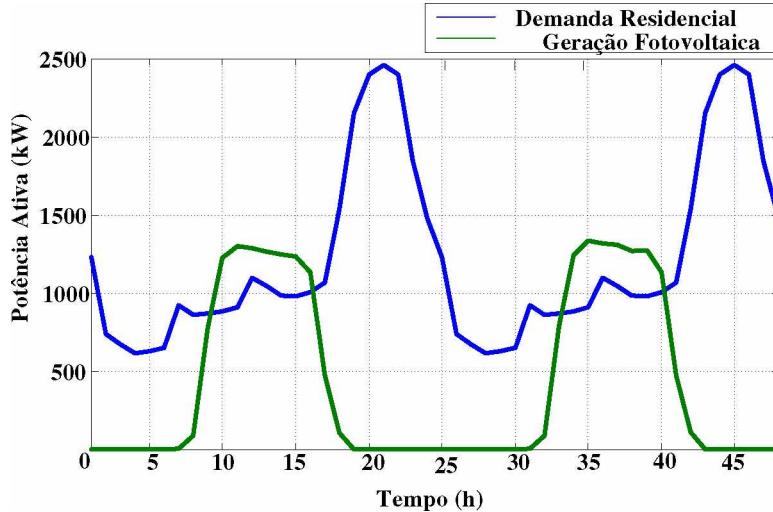


Figura 49 - Demanda de potência ativa x Geração fotovoltaica de potência ativa.
Fonte: (O autor, 2016).

Para contornar os efeitos causados por esse excesso de potência ativa injetada na rede de distribuição, faz-se o estudo e o uso da introdução de armazenadores de energia dos mais diversos tipos, como os apresentados nas subseções da seção 4.3.

Esta proposta é feita uma vez que os trabalhos descritos na seção 4.2 não levam em consideração um planejamento energético, ou seja, em nenhum dos trabalhos

descritos os autores se atentam para possíveis aumentos de demanda e de penetração fotovoltaica.

Devido a simplicidade de aquisição e instalação, manutenção e por ser de baixo custo, nesta pesquisa são feitas análises de dimensionamento e operação de baterias de chumbo-ácido, destinadas ao auxílio na redução de perdas técnicas em redes de distribuição de energia elétrica não isoladas. Os custos de aquisição para este tipo de bateria, de potência ativa (kW) e energia elétrica (kWh), podem ser vistos em (ROSS et. al., 2010) e (CHEN et. al., 2009).

5.3.1 Características e parâmetros da bateria

Nesta seção são apresentados os principais parâmetros analisados da bateria em questão, para se avaliar o desempenho da mesma em relação ao método de dimensionamento proposto.

5.3.1.1 Estado de carga (State of Charge - SoC)

A bateria é um dos AEEs mais atrativos devido a sua alta eficiência e baixa poluição. O SoC de uma bateria é utilizado para descrever sua capacidade restante, sendo um parâmetro muito importante para estratégia de controle (CHANG, 2013). No geral, o SoC é definido como a média da capacidade de carga $Q(t)$ pela capacidade nominal (Q_n). Baixos valores de SoC durante um longo período de tempo, implicam em perda de capacidade devido ao stress mecânico nas massas ativas e também devido ao aumento do tamanho dos cristais de sulfato (DULFO-LÓPEZ, LUJANO-ROJAS e BERNAL-AUGUSTÍN, 2014). Valores típicos desejados de SoC das baterias devem estar entre os limites $20\% \leq SoC \leq 95\%$, para se manter a integridade da bateria (CHIASSON e VAIRAMOHAN, 2005).

Diversos métodos diretos podem ser empregados para se obter o SoC: método da tensão medida; Força eletromotiva (ElectroMotive Force - EMF); tensão de circuito aberto (Open Circuit Voltage - OCV); método de impedância medida; e o método de contagem de Coulomb (WATRIN, BLUNIER e MIRAOUI, 2012) utilizado nesta pesquisa.

O método de contagem de Coulomb mede a corrente de descarga da bateria e a integra em relação ao tempo com o objetivo de estimar o SoC (SOON et. al., 2009).

Este método é utilizado para estimar o SoC(t), que é estimado a partir da corrente de descarga $i(t)$, e de valores prévios de SoC ($SoC(t - 1)$). Por meio de (60) se calcula o SoC com o método de contagem de Coulomb:

$$SoC(t) = SoC_{init} - \frac{1}{Q_n} \cdot \int_0^t i(t) \cdot dt \quad (60)$$

Outros métodos para se calcular o SoC podem ser vistos mais detalhadamente em (CHANG, 2013), (CHIASSON e VAIRAMOHAN, 2005), (WATRIN, BLUNIER e MIRAOUI, 2012) e (SOON et. al., 2009).

5.3.1.2 Profundidade de descarga (Depth of Discharge - DoD)

O armazenamento de energia é um processo lento que subseqüentemente necessita rapidamente liberar energia de acordo com a demanda. A energia de saída, ou descarga, pode ser um fator limitante chamado "média de energia transmitida". Essa média de entrega determina o tempo necessário para extrair a energia armazenada. A energia deve estar disponível para a entrega durante as horas de pico, o que quer dizer que a quantidade de energia utilizada, se significante, representa um sistema elétrico com uma configuração ruim, uma vez que quanto mais energia se solicita da bateria, maior é a relação da diferença entre demanda e a penetração fotovoltaica (IBRAHIM, ILINCA e PERRON, 2008).

Quando uma bateria está descarregando, o DoD pode ser expresso como a porcentagem da capacidade de energia que está sendo descarregada, $Q_{liberada}$, relativamente à sua capacidade nominal, $Q_{nominal}$, (61) (SOON et. al., 2009):

$$DoD = \frac{Q_{liberada}}{Q_{nominal}} \times 100\% \quad (61)$$

onde $Q_{liberada}$ é a capacidade de energia descarregada.

5.3.1.3 Estado de vida útil (State of Health - SoH)

O estado de vida útil reflete as condições gerais da bateria. Variações de estado de vida útil implicam na capacidade e queda de energia, o estado de vida útil diminui a medida que a bateria é utilizada. As mudanças na capacidade e resistência dos valores

nominais da célula nova induzem essa queda (WATRIN, BLUNIER e MIRAOUI, 2012). O SoH pode ser calculado pela relação entre a máxima energia disponível no momento, $Q_{\text{Máx}(t)}$, pela capacidade nominal da bateria, Q_{nominal} , (62):

$$\text{SoH} = \frac{Q_{\text{Máx}(t)}}{Q_{\text{nominal}}} \times 100\% \quad (62)$$

5.3.2 Proposta de dimensionamento da capacidade de armazenamento de baterias

Para estimar a capacidade de armazenamento anual dos armazenadores de energia a serem dimensionados, se fez necessário realizar a estimação temporal da potência gerada por meio de placas fotovoltaicas, uma vez que é exatamente a injeção dessa potência na rede que se deseja diminuir com a utilização dos AEEs.

Esta estimação temporal de dados foi feita por meio dos dados obtidos da RNA da seção 5.2.3.

Nesta seção é feita a proposta de dimensionamento da capacidade de armazenamento dos AEEs do tipo bateria.

5.3.2.1 Potência da Bateria

Quando um projetista dimensiona um armazenador de energia, a escolha da capacidade deve ser feita em função da energia armazenada. Para cada tecnologia um dado valor de energia nominal corresponde a uma máxima potência que pode ser compartilhada. Por exemplo, se deseja-se entregar 2 MW por 1 hora com baterias eletroquímicas, são necessários 2 MWh de armazenamento disponível. Se deseja-se 1 MW por 5 horas então 5 MWh são necessários.

Dessa maneira, a potência nominal necessária a ser dimensionada para a bateria, $P_{bat,max}$, é o valor máximo de potência, observada ao longo do ano Y, da diferença entre a potência gerada pela geração distribuída por hora h , $P_{pv,h}$, e a demanda solicitada da rede, $P_{L,h}$. Segundo (ROSS et. al., 2010), este valor pode ser calculado por (63):

$$P_{bat,max} = \max_{\forall h \in Y} |P_{pv,h} - P_{L,h}| \quad (63)$$

A máxima energia necessária, $E_{bat,max}$, que o AEE deve armazenar, é o somatório das potências individuais durante um tempo desejado ‘n’ para a operação do mesmo, dado por (64):

$$E_{bat,max} = \max_{\forall h \in Y} \left| \sum_{h=1}^n (P_{pv,h} - P_{L,h}) \right| \quad (64)$$

Porém, (63) e (64) contemplam apenas a situação atual de um sistema de distribuição de energia elétrica com consumidores residenciais.

Sabe-se que é de extrema importância, na elaboração de projetos de redes de distribuição, a aplicação de métodos para estimação de aumento de demanda sazonal com a finalidade de se obter uma maior capacidade de distribuição para o bom funcionamento do sistema a longo prazo.

Portanto, aqui é proposto um método de dimensionamento de baterias levando em consideração não só um possível aumento de demanda mas também um possível aumento da penetração fotovoltaica, ou seja, um dimensionamento a longo prazo.

5.3.2.2 Dimensionamento a longo prazo considerando aumento de demanda e geração não constantes

Para este método a longo prazo, o primeiro fator a se analisar é a detenção das informações relativas a porcentagem anual do aumento de demanda e de geração distribuída.

Caso não hajam dados referentes à esses aumentos deve-se utilizar a regressão polinomial como ferramenta, para que dessa forma possa-se prever os aumentos de carga e geração na rede em estudo.

5.3.2.2.1 Regressão Polinomial

A teoria da regressão polinomial pode ser vista em (KIM et. al., 2015). O modelo de regressão é dado por (65):

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_{ii}^2 + \varepsilon \quad (65)$$

onde ε representa o erro estatístico, o qual é geralmente assumido como uma distribuição normal com a média em zero e covariância de σ^2 .

Utilizando essa técnica é possível determinar equações para que se encontre as demandas e potências geradas, previstas para um horizonte de tempo definido P_{pv} e P_L e assim aplicá-las nas Eqs. (63) e (64), resultando em (66) e (67):

$$P_{fct,bat,max} = \left(\max_{\forall h \in X} |(\beta_{pv,0} + \beta_{pv,1}x + \beta_{pv,2}x^2) - (\beta_{L,0} + \beta_{L,1}x + \beta_{L,2}x^2)| \right) \quad (66)$$

$$E_{fct,bat,max} = |\sum_{h=1}^n (P_{fct,bat,max})| \times 1.2 \quad (67)$$

onde os índices pv e L correspondem a geração fotovoltaica e carga, respectivamente.

A expressão exponencial parabólica é a que se ajustar melhor às curvas de demanda e, portanto, deve ser a utilizada.

5.3.2.3 Dimensionamento a longo prazo considerando aumento de demanda e geração constante - Método direto

O método descrito pela equação (68), pode ser aplicado quando considera-se uma previsão constante da projeção de aumento de demanda e geração fotovoltaica, sendo:

$$PD_{fct,bat,max} = \left(\max_{\forall h \in Y} |P_{pv,0}(1 + tx_{pv})^y - P_{L,0}(1 + tx_d)^y| \right) \quad (68)$$

onde:

$PD_{fct,bat,max}$ = Potência máxima do AEE prevista para o horizonte de tempo definido;

$P_{pv,0}$ = Potência inicial da geração distribuída (neste caso, fotovoltaica);

$P_{L,0}$ = Demanda inicial da rede de distribuição;

tx_{pv} = Taxa de crescimento da geração distribuída anual prevista (%);

tx_d = Taxa de crescimento da demanda anual prevista (%);

y = horizonte que se deseja fazer a previsão em anos.

A energia armazenada mínima da bateria, então, se dá por (69):

$$ED_{fct,bat,max} = |\sum_{h=1}^n (PD_{fct,bat,max})| \times 1.2 \quad (69)$$

Recomenda-se multiplicar a energia dimensionada por um fator igual a 1.2 para que se garanta que a bateria operará abaixo do limite imposto pelo SoC, garantindo assim o seu correto funcionamento.

5.3.2.4 Previsão de vida útil da bateria

Uma maneira de se prever a vida útil de uma bateria de chumbo-ácido é por meio da profundidade de descarga da mesma. A figura 50 relaciona a quantidade de ciclos que uma bateria de chumbo-ácido pode realizar de acordo com profundidade de descarga do ciclo (DULFO-LÓPEZ, LUJANO-ROJAS e BERNAL-AUGUSTÍN, 2014).

Dessa maneira, propõe-se um método rápido de se estimar a vida útil de uma bateria de acordo com a relação apresentada na figura 50.

Como a proposta é de se dimensionar a capacidade de armazenamento do AEE a longo-prazo, sabe-se que nos primeiros anos de utilização da bateria a energia solicitada da mesma será inferior à sua capacidade nominal. Dessa maneira, a tendência é que se aumente a vida útil da bateria, uma vez que a mesma realizará ciclos de carga e descarga à baixos DoD.

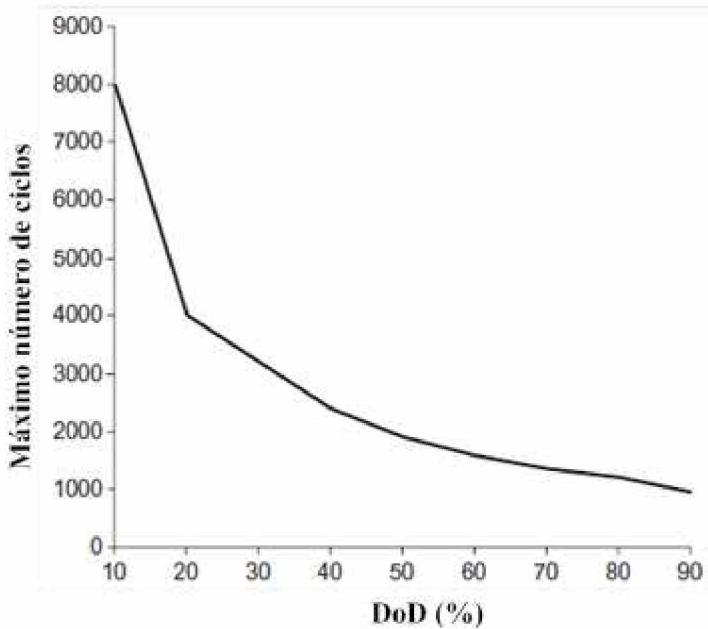


Figura 50 - Relação entre DoD(%) e o numero máximo de ciclos que uma bateria de chumbo-ácido pode realizar.

Fonte: Adaptado (DULFO-LÓPEZ, LUJANO-ROJAS e BERNAL-AUGUSTÍN, 2014).

Portanto, para se estimar a vida útil da bateria, calcula-se para o início de cada ano de operação o DoD(%) e contabiliza-se a relação entre o máximo número de ciclos, de acordo com o DoD(%) anual na figura 50, $Cic_{DoD(y)}$, com o número de ciclos anuais previstos pelo projetista, Cic_{anual} . A soma desses valores, em porcentagem, resultará a porcentagem de vida útil utilizada pela bateria anualmente Vu_y (70). Subtrai-se então esse valor de 100, para contabilizar a quantidade de vida útil percentual restante da bateria, Vu_{rest} (71). Como, em média, o fim da vida útil da bateria é alcançada quando sua capacidade já foi utilizada em 80% da capacidade nominal (DoD = 80%) (DULFO-LÓPEZ, LUJANO-ROJAS e BERNAL-AUGUSTÍN, 2014), calcula-se a porcentagem de vida útil restante da bateria quando o DoD de um determinado ano chega a 80%, $Vu_{80\%}$ (72). Divide-se o percentual restante pelo percentual a 80% de DoD para se ter este valor em anos e, soma-se o resultado com a quantidade de anos de operação com DoD $\leq 80\%$, $n_{\leq 80\%}$, para obter então, a vida útil total da bateria Vu_T (73).

$$Vu_y = \sum_y^n \frac{Cic_{DoD(y)}}{Cic_{anual}} \times 100 \quad (70)$$

$$Vu_{rest} = 100 - Vu_y \quad (71)$$

$$Vu_{80\%} = \frac{Cic_{anual} * 100}{Cic_{80\%}} \quad (72)$$

$$Vu_T = \left(\frac{Vu_{rest}}{Vu_{80\%}} \right) + n_{\leq 80\%} \quad (73)$$

Para facilitar a obtenção dos valores dos DoD anuais, uma equação foi obtida por meio de regressão logarítmica, afim de tornar esse processo mais rápido e possibilitando sua inclusão no algoritmo criado para o dimensionamento proposto.

5.3.2.4.1 Regressão não linear logarítmica

Matematicamente, um modelo não linear nada mais é do que uma função não linear nos parâmetros. Estatisticamente, um modelo de regressão não linear, descreve alguma quantidade relacionada à distribuição de probabilidades de uma variável aleatória Y como uma função não linear nos parâmetros. Na grande maioria das vezes, a quantidade de interesse é a média de Y . A Eq. (74) representa um modelo que descreve, como quantidade de interesse, a média de uma variável aleatória Y em termos da variável explicativa ' x ' e do vetor de ' p ' parâmetros $\theta = (\theta_1, \dots, \theta_p)$ por meio da função não linear η (RITZ e STREIBIG, 2008).

$$E(Y|x) = \eta(x, \theta) \quad (74)$$

Sendo:

$$\eta(x, \theta_0, \theta_1, \theta_2) = \theta_0 + \theta_1 x + \theta_2 x^2 \quad (75)$$

$$\eta(x, \theta_a, \theta_e, \theta_c) = \theta_a (1 - \exp\{-\theta_e(x - \theta_c)\}) \quad (76)$$

Por definição, o modelo é não linear se pelo menos uma das derivadas de η com relação à um dos parâmetros em θ envolver parâmetros. Ao avaliar-se as derivadas de (75) em (77):

$$\frac{\partial \eta}{\partial \theta} = 1, \quad \frac{\partial \eta}{\partial \theta_1} = x, \quad \frac{\partial \eta}{\partial \theta_2} = x^2 \quad (77)$$

Verifica-se que (77) não envolve parâmetros mas apenas as quantidades conhecidas 1, x e x^2 . Por isso (75) é um modelo linear nos parâmetros. Por outro lado, ao avaliar-se as derivadas de (76), resultam (78), (79) e (80):

$$\frac{\partial \eta}{\partial \theta_a} = 1 - \exp\{-\theta_e(x - \theta_c)\} \quad (78)$$

$$\frac{\partial \eta}{\partial \theta_e} = -\theta_a(\theta_c - x) \exp\{-\theta_b(x - \theta_c)\} \quad (79)$$

$$\frac{\partial \eta}{\partial \theta_b} = -\theta_a \theta_b \exp\{-\theta_b(x - \theta_c)\} \quad (80)$$

Observa-se que pelo menos dois parâmetros foram envolvidos nas derivadas e por isso (76) é modelo não linear. Alguns autores definem classificações intermediárias. Um modelo é linearizável se por meio de uma transformação se torna um modelo linear.

É o caso de (81),

$$\eta(x, \theta) = \exp\{\theta_0 + \theta_1 x\} \quad (81)$$

que ao aplicar a transformação log se transforma em um modelo linear (82):

$$\log(\eta(x, \theta)) = \theta_0 + \theta_1 x \quad (82)$$

De acordo com a teoria exposta, foi encontrada (83), que melhor descreve o comportamento da curva ilustrada na figura 50:

$$\text{Ciclos} = -2182 \times \log(\text{DoD}(\%)) + 10580 \quad (83)$$

5.3.2.5 Algoritmo de dimensionamento proposto para cálculo da vida útil das baterias

Para que fosse possível realizar as simulações e testar a proposta de dimensionamento, um algoritmo foi desenvolvido.

A figura 51 mostra o fluxograma do algoritmo proposto.

- No começo, é feita a estimativa da geração fotovoltaica por meio da rede neural artificial previamente treinada.
- No segundo passo, é solicitada a informação de qual método deve ser utilizado de acordo com as informações prévias de crescimento de demanda e GD, se constante ou não. Ainda no segundo passo, devem ser introduzidas as informações referentes

ao intervalo de tempo da projeção desejada para o dimensionamento da capacidade da bateria, o regime de funcionamento diário em horas e o número de ciclos diários.

- No terceiro passo, é calculada a energia para a projeção solicitada no segundo passo, de acordo com (84) para o cálculo da carga quando a bateria está carregando e (85) para o cálculo quando estiver descarregando (FARROKHIFAR, 2016).
- No quarto passo, de acordo com a energia calculada ao longo da projeção desejada, calcula-se o DoD(%) final e, com esses dados no quinto passo calcula-se a vida útil por meio do método proposto na seção 5.3.2.4.
- No sexto passo, verifica-se de acordo com a previsão do passo anterior, se haverá um aumento de vida útil ou não. Se houver, calcula-se novamente a energia utilizada ao longo da vida útil total e calcula-se novamente o DoD(%). Caso não haja aumento de vida útil, em relação à vida útil inicial, o algoritmo continua para o cálculo do SoH(%) e SoC(%) no sétimo passo, procedendo assim para o final da sua execução.

O procedimento é feito paralelamente para o dimensionamento a curto prazo, com o objetivo de comparar se haverá ou não vantagens no dimensionamento proposto a longo prazo.

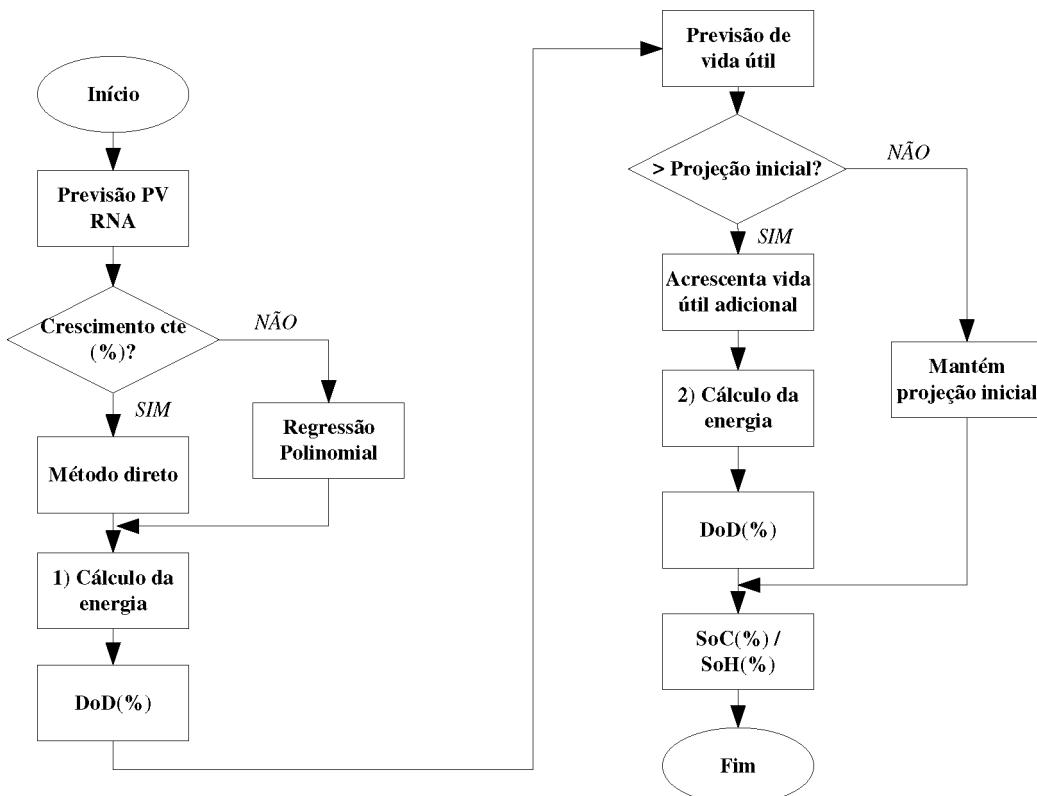


Figura 51- Fluxograma do algoritmo proposto.

$$E_{N+1} = E_N + P_N(\eta_B \eta_C \eta_T) \Delta t \quad (84)$$

$$E_{N+1} = E_N - P_N(\eta_C^{-1} \eta_T^{-1}) \Delta t \quad (85)$$

onde

E_N é a energia na bateria no intervalo de tempo N (kWh);

P_N é a potência de carga e descarga solicitada pela rede no intervalo de tempo N (kW);

Δt é a duração do Nth intervalo de tempo (hora);

η_B é a eficiência da bateria;

η_C é a eficiência do dispositivo inversor de frequência.

η_T é a eficiência do transformador de potência.

5.3.3 Resultados e discussões

Para a verificação do dimensionamento proposto, foram feitas duas simulações a longo prazo com projeções de tempo diferentes. O sistema utilizado foi o IEEE 37 barras (Anexo B). Os níveis de demanda de potência ativa e de geração fotovoltaica são ilustrados na figura 49. As simulações foram feitas para um intervalo de 71 dias no ano, de acordo com a disponibilidade de potência fotovoltaica gerada encontrada de acordo com a estimativa da RNA. Utilizou-se também uma taxa de crescimento de demanda de 1%, enquanto que para o crescimento de geração fotovoltaica 3%. O método utilizado aqui foi o método direto. A tabela 8 mostra os parâmetros utilizados nas simulações. a figura 52 ilustra o diagrama da conexão do AEE na rede.

Por meio da figura 52, pode-se ver que é necessário o uso de um inversor de frequência trifásico e um transformador de potência trifásico para a conexão do AEE à rede de média tensão.

Tabela 8 - Parâmetros utilizados nas simulações.

Parâmetros	Símbolo	Valores
η_B	%	85
η_C	%	95
η_T	%	97
Δt	h	1
tx_{pv}	%	3
tx_d	%	1
Tempo de descarga	h	6
Tempo de carga	h	6

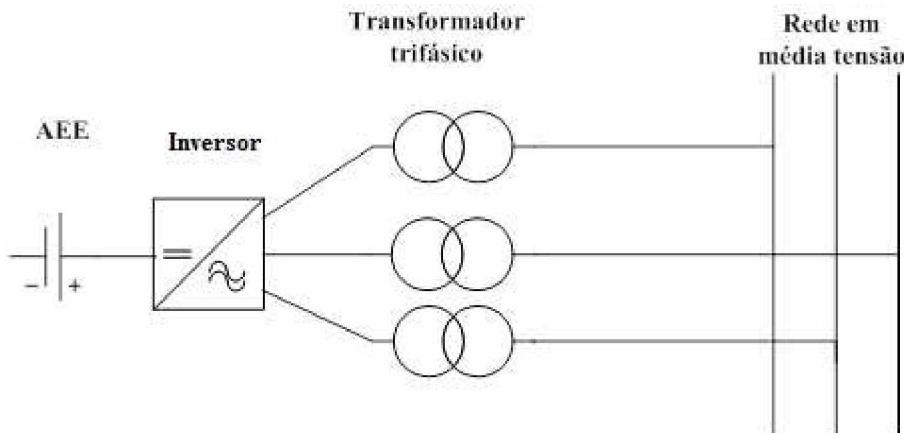


Figura 52 - Diagrama do sistema do AEE conectado à rede de distribuição de média tensão.

A tabela 9 apresenta os resultados obtidos de ambas as simulações.

Tabela 9 - Resultados das simulações a longo prazo para duas projeções de tempo diferentes comparativamente ao dimensionamento a curto prazo.

			Longo prazo		Curto prazo	
			10 anos 110 kW / 54 MWh	5 anos 82 kW / 41 MWh		
Ano	GD (kW)	Demand (kW)	DoD (%)	SoH (%)	DoD (%)	SoH (%)
1	147.82	246	16.70	100	16.71	100
2	152.27	248	23.12	92.30	24.63	90.50
3	156.84	251	29.92	84.13	33.46	79.90
4	161.59	253	37.30	75.27	42.74	68.74
5	166.35	256	45.31	65.66	52.88	56.57
6	171.36	258	54.38	54.77	63.89	43.36
7	176.57	261	63.90	43.34	74.94	30.09
8	181.82	263	74.04	31.17	85.99	16.82
9	187.26	266	84.97	18.04	97.00	3.60
10	192.87	269	96.28	4.46	-	-

*Para o dimensionamento com horizonte de 5 anos e a curto prazo, após o quinto ano, as potências (kW) GD e demanda não se alteram.

Analizando a tabela 9, primeiramente para a simulação a longo prazo para 5 anos e a curto prazo, nota-se que o DoD(%) da bateria dimensionada a longo prazo, alcança o seu limite teórico de funcionamento sem apresentar falhas, 80%, no começo do sexto ano de sua vida útil, porém chegando ao seu limite no começo do sétimo ano de vida útil. Entretanto, o dimensionamento a curto prazo alcança o seu limite no começo do quinto ano de vida útil, ou seja, no dimensionamento a longo prazo para 5 anos prolongou-se a vida útil da bateria em aproximadamente 28%. Comparado à potência (kW) e à energia (MWh) dimensionado para ambos, houve um aumento de aproximadamente 28% para ambas as grandezas.

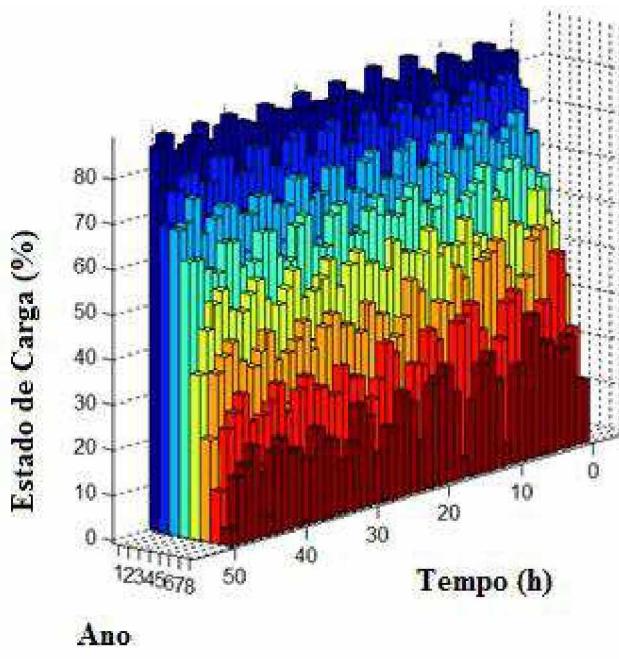
Já no dimensionamento à longo prazo considerando um período de projeção de 10 anos, observa-se que houve um aumento de aproximadamente 43% na vida útil, uma

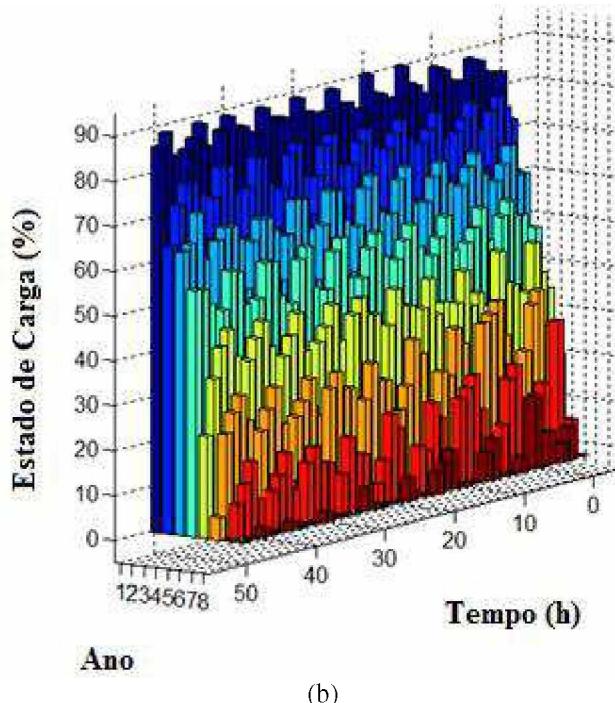
vez que a bateria atingiu o seu DoD(%) limite no começo do oitavo ano.^b Observa-se também que necessitou-se de um aumento de aproximadamente 71% na potência ativa nominal da bateria (kW) e um aumento de aproximadamente 72% na energia armazenada mínima (MWh) necessária da bateria.

No entanto, para o dimensionamento para 5 anos, a cada troca da bateria dimensionada a curto prazo, sobram pouco mais de 2 anos de vida útil para a bateria dimensionada a longo prazo, ou seja, a cada 3 trocas da bateria a curto prazo troca-se apenas 2 vezes a bateria a longo prazo o que resulta em um investimento aproximadamente 14% menor ao final das 3 trocas.

A vantagem do dimensionamento a longo prazo fica mais evidente quando analisa-se o dimensionamento para 10 anos de projeção. Há uma economia de 11% somente na primeira aquisição, levando em consideração a duração de 6 anos da bateria dimensionada a curto prazo e pouco mais que 9 anos da bateria dimensionada a longo prazo.

As figuras 53 e 54 ilustram o SoC(%) para todos os casos simulados, para um período de 50 horas, ou seja, pouco mais de 4 ciclos.





(b)

Figura 53 - SoC(%). (a) Projeção a longo prazo para 5 anos. (b) Projeção a curto prazo.

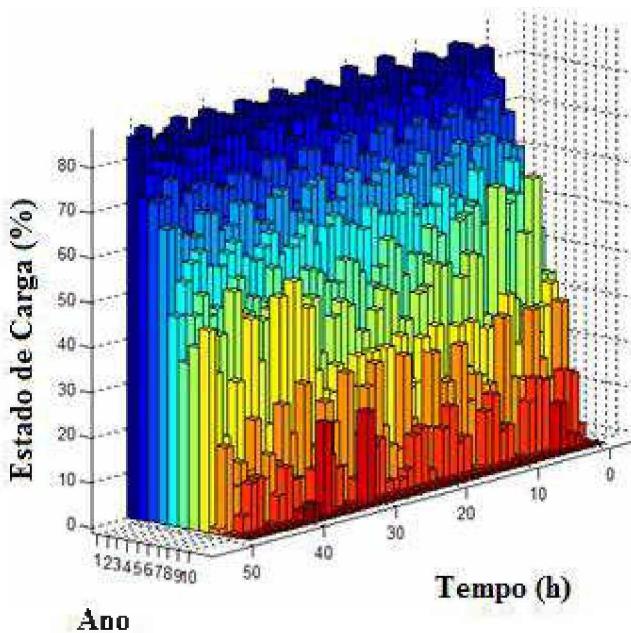


Figura 54 - SoC(%). Projeção a longo prazo para 10 anos.

Por meio das figuras 53 e 54, observa-se que o SoC(%) das baterias dimensionadas a longo prazo permanece dentro dos limites práticos estabelecidos. Nota-se também, que para os dimensionamentos a longo prazo, figura 53 (a) e figura 54, os níveis de SoC(%) são mais adequados para o bom funcionamento do ESS a partir do quinto ano de vida útil das baterias.

As figuras 55 a 57, ilustram o comportamento da energia armazenada do sistema de AEEs durante a vida útil da bateria de acordo com cada horizonte de projeção.

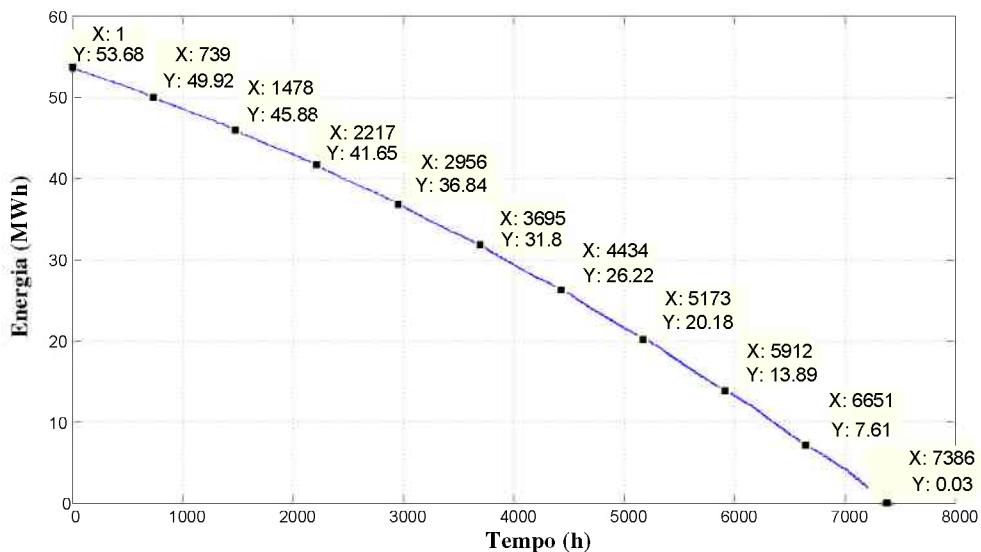


Figura 55 - Comportamento da energia armazenada nos AEEs para a projeção a longo prazo de 10 anos.

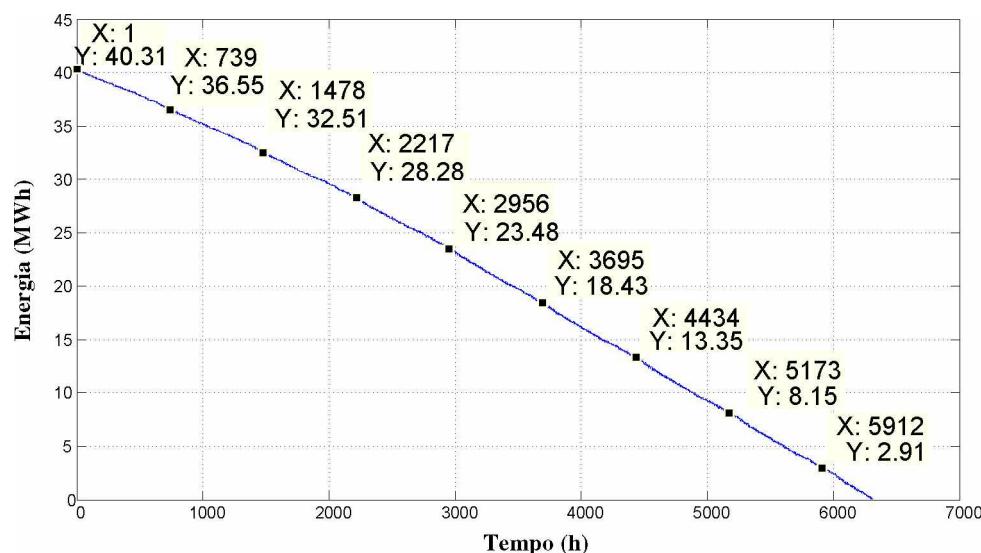


Figura 56 - Comportamento da energia armazenada nos AEEs para a projeção a longo prazo de 5 anos.

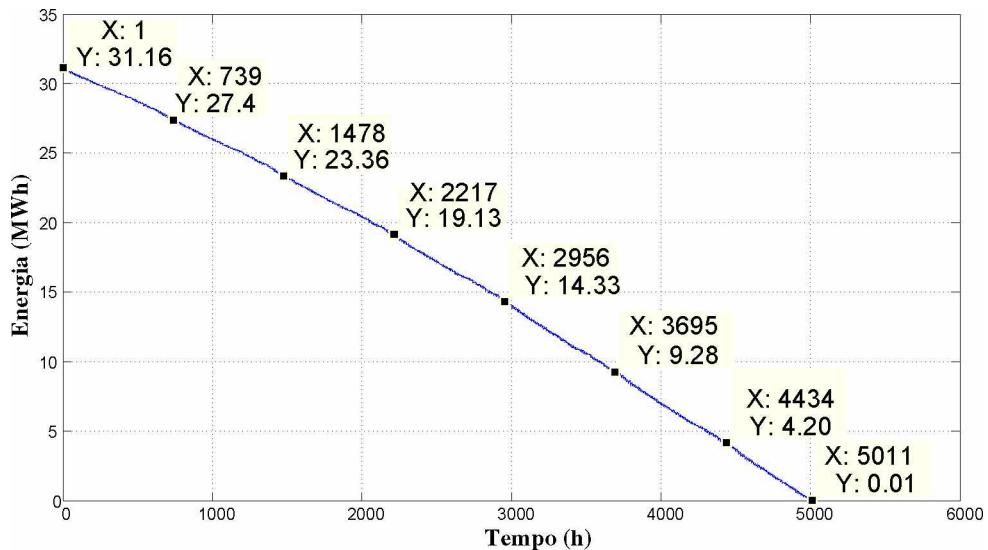


Figura 57 - Comportamento da energia armazenada nos AEEs para a projeção a curto prazo.

Pode-se ver que no método de dimensionamento proposto, a energia é utilizada uniformemente durante a vida útil da bateria dimensionada, validando computacionalmente as soluções propostas uma vez que se tem energia suficiente para a vida útil dimensionada.

As figuras 58 a 60, ilustram o comportamento do DoD(%) e do SoH(%) de acordo com cada horizonte de projeção.

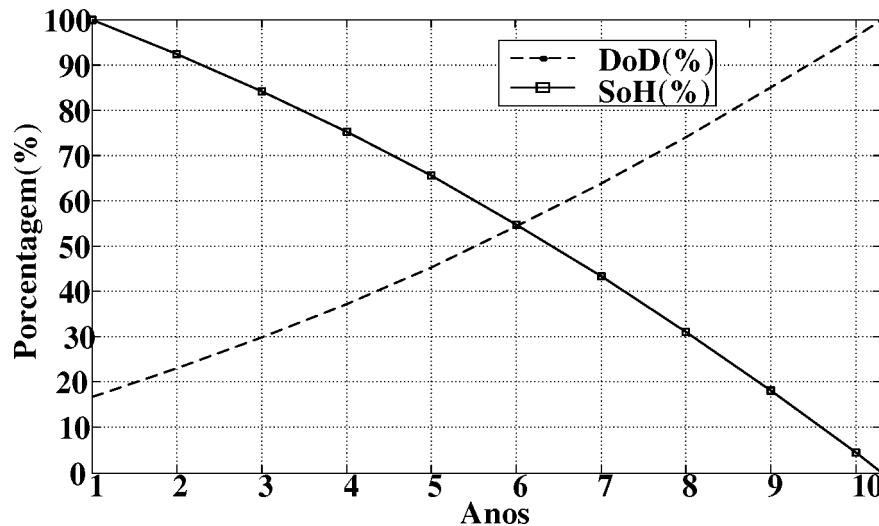


Figura 58 - DoD(%) e SoH(%) dos AEEs para a projeção a longo prazo de 10 anos.

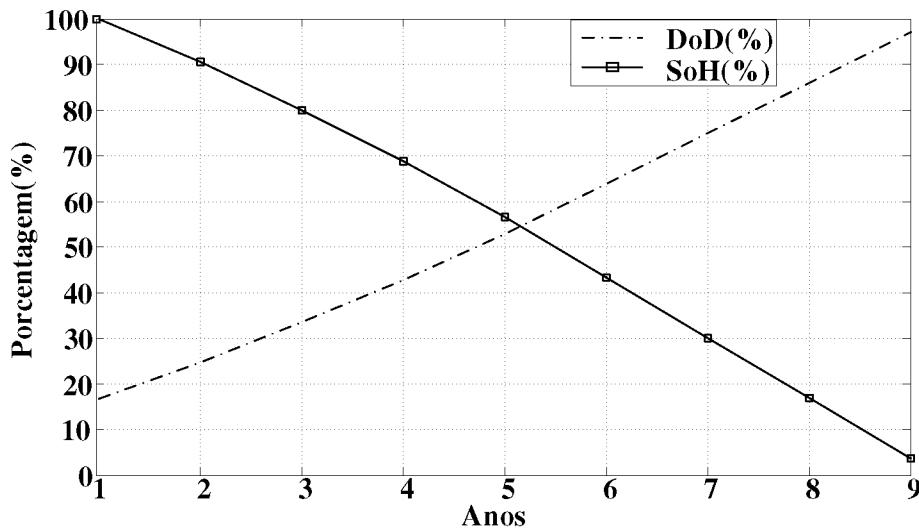


Figura 59- DoD(%) e SoH(%) dos AEEs para a projeção a longo prazo de 5 anos.

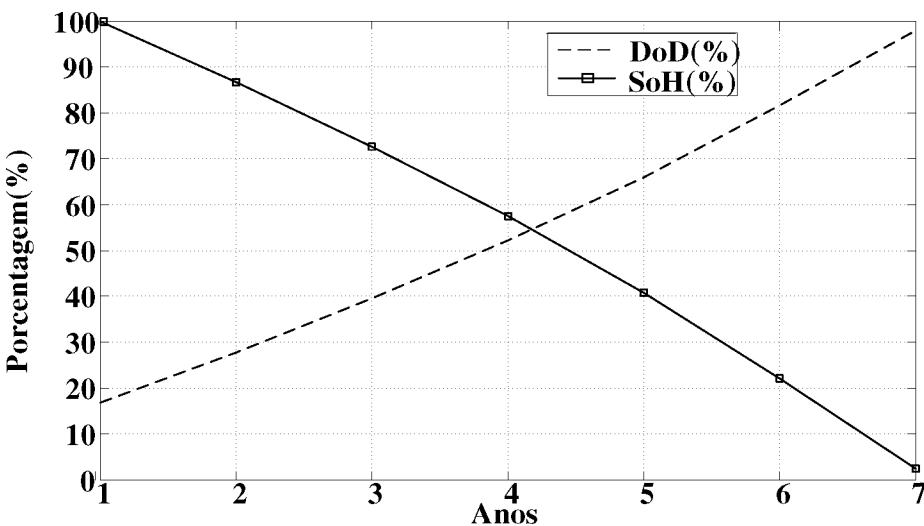


Figura 60 - DoD(%) e SoH(%) dos AEEs para a projeção a curto prazo.

As figuras. 58 a 60 são úteis para que se tenha uma análise visual do comportamento do DoD(%) e do SoH(%) do BES dimensionado.

5.3.4 Conclusão Parcial

Nesta seção foi feita uma proposta de dimensionamento a longo prazo de armazenadores de energia do tipo bateria de chumbo-ácido com o auxílio de redes neurais artificiais, destinados à redução de perdas técnicas em redes de distribuição de energia elétrica em média tensão.

Para que esse dimensionamento fosse feito, foram propostos 2 métodos de dimensionamento. Um para uma taxa de crescimento de demanda e geração distribuída por meio de placas fotovoltaicas constantes e outro não constante.

Colaborando com o método proposto, foi proposto um método de dimensionamento da vida útil das baterias por meio da relação entre o DoD(%) e o número de ciclos realizados pelo sistema anualmente.

Por fim, um algoritmo foi criado e testado para horizontes de projeção de 5 e 10 anos.

Por meio dos resultados obtidos para ambos os horizontes mostrou-se que a proposta de dimensionamento foi validada e além disso, que dependendo do horizonte de projeção e planejamento desejados, o dimensionamento a longo prazo de armazenadores de energia podem ser bastante atrativos do ponto de vista de prolongamento da vida útil dos AEEs, o que reflete diretamente na redução dos investimentos destinados à esse tipo de sistema devido ao prolongamento do intervalo de troca desses equipamentos.

5.4 Análise a longo prazo da minimização de perdas por potência ativa, utilizando RNA e armazenadores de energia do tipo chumbo-ácido

Para alcançar os resultados apresentados nesta seção, foram utilizados os métodos apresentados nas seções 5.2 e 5.3. Os valores nominais dos armazenadores de energia e as previsões de geração de energia por meio de placas fotovoltaicas foram realizadas de acordo com esses procedimentos já citados. Assim, para os armazenadores de energia, os valores nominais considerados para este estudo podem ser encontrados na tabela 9. As simulações foram feitas considerando 2 períodos a longo prazo, 5 e 10 anos.

Assim como feito no estudo na seção 5.3, optou-se por dimensionar os AEE para apenas 10% da diferença entre os valores nominais de geração fotovoltaica e demanda máxima, do contrário, devido a demanda do sistema teste, os valores dimensionados para os AEE seriam difíceis de serem alcançados.

O sistema teste utilizado aqui é o IEEE 37 barras modificado. A modificação se refere a não consideração da barra que contém o posto transformador, barra 775. Por se tratar de um sistema de distribuição, foi implementado um fluxo de carga trifásico por meio do método trifásico de Newton-Raphson, com o intuito de se obterem resultados mais próximos dos alcançados neste tipo de sistema, considerando para tanto, as particularidades de cada fase da rede como os parâmetros das fases e os desbalanceamentos entre as mesmas. Para a o cálculo e previsão das perdas técnicas são utilizadas redes neurais artificiais (RNA) e diferentes métodos para o seu uso são apresentados para a previsão dos turnos diurno e noturno. Foram feitos 4 estudos diferentes considerando a alocação dos AEE. Portanto, as contribuições deste estudo são:

- A análise trifásica de perdas técnicas em sistema de distribuição de energia elétrica, considerando demanda variável, aumentos de demanda e penetração fotovoltaica a longo prazo;
- A utilização de redes neurais artificiais para a previsão de perdas técnicas em sistemas de distribuição de energia elétrica, considerando armazenadores de energia e penetração fotovoltaica;
- Uma proposta de uso de dados de treinamento e objetivo para redes neurais artificiais para períodos diurnos e noturnos;
- E o estudo da alocação de AEE considerando as condições do sistema de distribuição de energia elétrica a longo prazo.

5.4.1. Redes neurais artificiais utilizadas

De posse dos dados anteriores foram simulados os dados diários de perdas técnicas para o período considerado de 71 dias. A arquitetura de rede utilizada foi a NARX.

Com um total de 12 horas diárias de uso dos armazenadores de energia, 4 casos a serem analisados e 71 dias por caso, tornou-se viável o uso da rede neural NARX com as particularidades que serão descritas. Para todos os casos foi considerado um período de 12 horas, ou seja, 6 horas diárias de carga e 6 horas noturnas de descarga.

O objetivo da utilização da RNA neste estudo é o de obterem-se as perdas técnicas de acordo com os níveis horários de geração fotovoltaica, demanda e

quantidade de energia armazenada ou sendo armazenada pelos AEE. Assim, duas metodologias de uso para a RNA neste tipo de previsão são propostas aqui. Se faz necessária a separação entre períodos diurnos e noturnos, uma vez que em se tratando de geração fotovoltaica nos períodos noturnos ela não está disponível.

A primeira delas consiste na previsão de perdas técnicas para o período diurno. A quantidade de energia armazenada durante o dia pelos AEE deve ser a mesma a ser entregue a rede durante a noite, uma vez que de acordo com (FARROKHIFAR, 2016):

- Uma das restrições para encontrar os melhores perfis de carga e descarga de um dispositivo armazenador de energia é que a soma da energia injetada e absorvida da rede seja igual a zero no final de cada ciclo de otimização (Um ciclo completo é igual a um dia de estudo).

Dessa maneira, para o período diurno, foram utilizados dados horários de potência gerada, demanda e a diferença de energia horária entre esses dois dados, o que reflete diretamente na energia necessária que os AEE devem armazenar por hora. A tabela 10 mostra os dados de 6 horas diurnas consecutivas encontradas para 1 dia em estudo, para o primeiro ano simulado.

Tabela 10 - Dados horários diurnos de 1 dia simulado - dia 15

Hora	PV (kW)	Demandas (kW)	Energia AEE (kWh) - Carga	Energia AEE (kWh) – Carga 10%
1	1181	1044	137	13,7
2	1181	1044	137	13,7
3	1269	982	287	28,7
4	1225	981	244	24,4
5	1235	1007	228	22,8
6	1182	1069	113	11,3

Apesar do objetivo deste trabalho ser minimizar as perdas técnicas utilizando AEE, a introdução de geradores distribuídos já traz benefícios neste sentido. Porém, a utilização dos AEE além de auxiliar ainda mais na redução de perdas técnicas, principalmente em períodos noturnos onde não há geração por placas fotovoltaicas, auxilia ainda em contingências do sistema já destacadas.

Para o período noturno não há geração fotovoltaica, portanto, não se tem esse dado para o treinamento da RNA. Porém, os dados de energia armazenada no período de carga já foram calculados e encontram-se disponíveis até aqui. Assim, esses dados

são aproveitados e utilizados como dados de descarga, entrando no fluxo de potência trifásico como dados de geração nas barras determinadas de acordo com os casos que serão apresentados nos próximos tópicos.

Sendo $z(t) \in u(t)$, onde $z(t)$ são os dados de energia armazenada contabilizados no período diurno e $u(t)$ o conjunto de dados a que $z(t)$ pertence, então $z(t)$ pode ser usado como dado de entrada para treinamento e previsão da RNA juntamente com os dados de demanda noturna. Assim, tem-se a utilização de 2 RNAs do tipo NARX, como ilustra a figura 61.

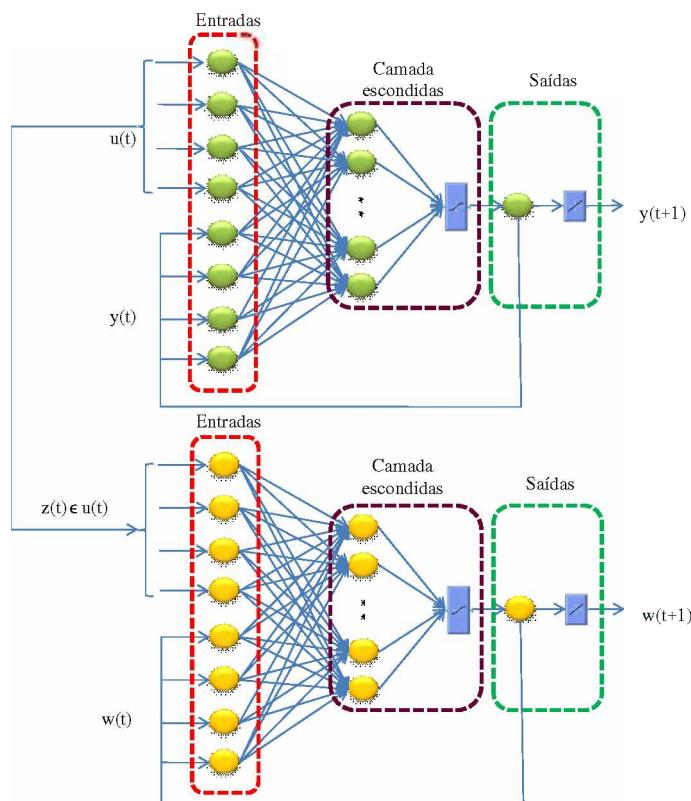


Figura 61 - RNAs utilizadas para a previsão de dados.

A tabela 11 mostra os dados noturnos utilizados, para o mesmo dia da tabela 10, utilizados como dados de entrada para a RNA.

Tabela 11 - Dados horários noturnos de 1 dia simulado - dia 15

Hora	Demand (kW)	Energia AEE (kWh) – Descarga
1	2150	13,7
2	2150	13,7
3	2396	28,7
4	2457	24,4

5	2395	22,8
6	1843	11,3

Novamente, se fez uso do MAPE e do RMSE, para determinar o desempenho das previsões geradas.

O MAPE e o RMSE encontrados entre os dados previstos e simulados, neste estudo, foram 0,11% e 0,007%, respectivamente.

5.4.2 Estudos de caso

Os estudos realizados aqui foram concentrados em 4 casos. Nas simulações realizadas, foi observado que a penetração dos geradores distribuídos teve maior influência na região mais afastada da fonte do sistema estudado, ou seja, na parte final da linha. Dessa maneira, para todos os estudos de caso, os geradores distribuídos foram alocados nas barras 710, 711 e 741, conforme os resultados encontrados nas simulações.

Os estudos de caso foram feitos levando-se em consideração as regiões do sistema de maior concentração de carga. Dessa maneira o sistema foi dividido entre as regiões A, B e C, conforme a figura 62.

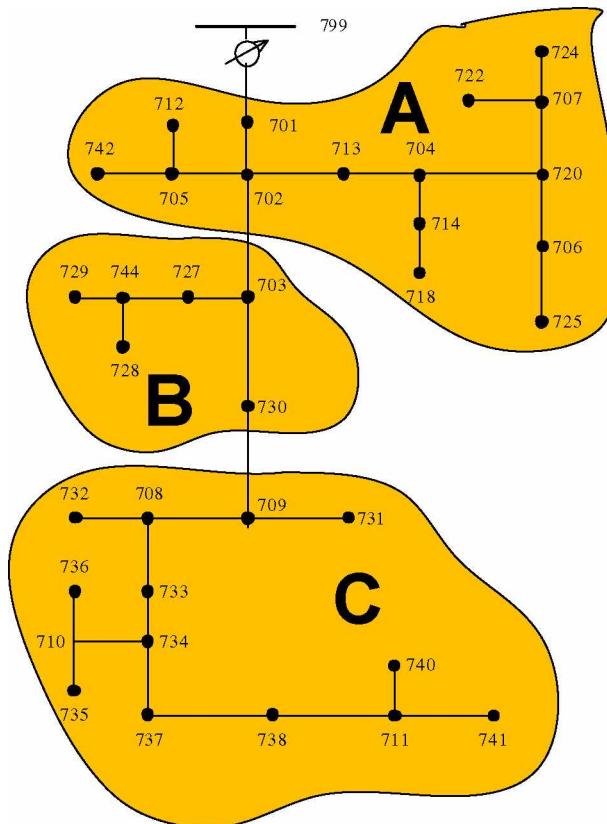


Figura 62 - Regiões de concentração de carga do sistema IEEE 37 barras modificado.

A. Estudo de caso 1 – AEE concentrados

Para o primeiro estudo de caso a topologia de distribuição dos AEE foi a concentrada. As barras com geração distribuída foram as já citadas, 710, 711 e 741. O nível de potência gerada pela GD foi realizado de acordo com os resultados encontrados na seção 5.2. Para a topologia concentrada, a barra escolhida para abrigar os AEE foi a de número 730, localizada na região B da figura 62. Dessa maneira, hora os AEE funcionam como carga, período diurno, hora funcionam como geração, período noturno. Neste estudo de caso, foram simulados os eventos correspondentes a 12 horas de serviço, ou seja, 6 horas diurnas e 6 horas noturnas.

B. Estudo de caso 2 – AEE concentrados

Para o segundo estudo de caso a topologia de distribuição dos AEE foi a concentrada. As barras com geração distribuída foram as já citadas, 710, 711 e 741. O nível de potência gerada pela GD foi realizado de acordo com os resultados encontrados na seção 5.2. Para a topologia concentrada, a barra escolhida para abrigar os AEE foi a de número 738, localizada na região C da figura 62. Dessa maneira, hora os AEE funcionam como carga, período diurno, hora funcionam como geração, período noturno. Neste estudo de caso, foram simulados os eventos correspondentes a 12 horas de serviço, ou seja, 6 horas diurnas e 6 horas noturnas.

C. Estudo de caso 3 – AEE distribuídos

Para o terceiro estudo de caso a topologia de distribuição dos AEE foi distribuída. As barras com geração distribuída foram as já citadas, 710, 711 e 741. O nível de potência gerada pela GD foi realizado de acordo com os resultados encontrados na seção 5.2. Para a topologia concentrada, as barras escolhidas para abrigar os AEE foram as de número 701, 730, 738, localizadas nas regiões A, B e C. Dessa maneira, hora os AEE funcionam como carga, período diurno, hora funcionam como geração, período noturno. Neste estudo de caso, foram simulados os eventos correspondentes a 12 horas de serviço, ou seja, 6 horas diurnas e 6 horas noturnas.

D. Estudo de caso 4 – AEE distribuídos

Por fim, no quarto estudo de caso a topologia de distribuição dos AEE foi distribuída. As barras com geração distribuída foram as já citadas, 710, 711 e 741. O nível de potência gerada pela GD foi realizado de acordo com os resultados encontrados na seção 5.2. Para a topologia distribuída, as barras escolhidas para abrigar os AEE foram as de número 724, 729, 738, localizadas nas regiões A, B e C. Dessa maneira, hora os AEE funcionam como carga, período diurno, hora funcionam como geração, período noturno. Neste estudo de caso, foram simulados os eventos correspondentes a 12 horas de serviço, ou seja, 6 horas diurnas e 6 horas noturnas.

5.4.3 Modelo matemático com demanda variável

Considerando a natureza desbalanceada de um sistema de distribuição, o problema de otimização pode ser formulado de acordo com (SOUZA et. al., 2016a) e modificado para atender a configuração trifásica, sendo a minimização o total de perdas por potência ativa a soma das três fases (86):

$$\text{Min} \quad \sum_{i,k} P_{\text{perdas}}^{\rho} = \sum_{i,k} \sum_{m=a,b,c} C_d^{\$} \Delta_d [G_{ik}^{\rho m} (V_i^{m2} + V_k^{m2} - 2V_i^m V_k^m \cos \theta_{i,k}^{\rho})] \quad (86)$$

Sujeito a:

$$V_{\min}^{\rho} \leq V_{i,k}^{\rho} \leq V_{\max}^{\rho} \quad (87)$$

$$PI_i^{\rho} - PD_i^{\rho} - \sum P_{i,k}^{\rho} = 0 \quad (88)$$

$$QI_i^{\rho} - QD_i^{\rho} - \sum Q_{i,k}^{\rho} = 0 \quad (89)$$

Sendo:

P_{perdas}^{ρ} - custo da perda ativa trifásica;

$C^{\$}$ - custo da perdas de energia no nível de demanda d;

Δ_d - duração do nível de demanda d;

$G_{ik}^{\rho m}$ - condutância trifásica do circuito;

V_i^m - magnitude de tensão das três fases no nó i;

V_k^m - magnitude de tensão das três fases no nó k;

$\cos\theta_{i,k}^\rho$ - diferença do ângulo de fase entre os nós i e k para as três fases;

V_{min}^ρ - magnitude tensão mínima das três fases;

V_{max}^ρ - magnitude de tensão máxima das três fases;

PI_i^ρ - potência ativa injetada no nó i para as três fases;

PD_i^ρ - potência ativa drenada no nó i para as três fases;

QI_i^ρ - potência reativa injetada no nó i para as três fases;

QD_i^ρ - potência reativa drenada no nó i para as três fases;

$P_{i,k}^\rho$ - fluxo de potência ativa que vai do nó i para o nó k das três fases;

$Q_{i,k}^\rho$ - fluxo de potência reativa que vai do nó i ao nó k para as três fases.

A formulação deste problema considera na minimização da função de perdas ativas (86) os custos relacionados à demanda variável.

A restrição (87) estabelece a faixa da magnitude de tensão de cada barra (ex. $V_{min}^\rho = 0.95$ pu e $V_{max}^\rho = 1.05$ pu). Isso dependerá da base regulatória da região a que cada rede pertence.

As restrições (88) e (89) representam a equação de balanço para todas as barras do Sistema e são calculadas de acordo com as equações (9) e (10).

5.4.3 Resultados

Em uma primeira análise, os resultados mostrados aqui são referentes ao crescimento de demanda e GD calculados na seção 5.3. As taxas anuais de crescimento são aquelas mostradas na tabela 8, tx_d e tx_{pv} . A figura 63 ilustra o comportamento de ambos os aumentos de demanda e GD previstos ao longo de 10 anos.

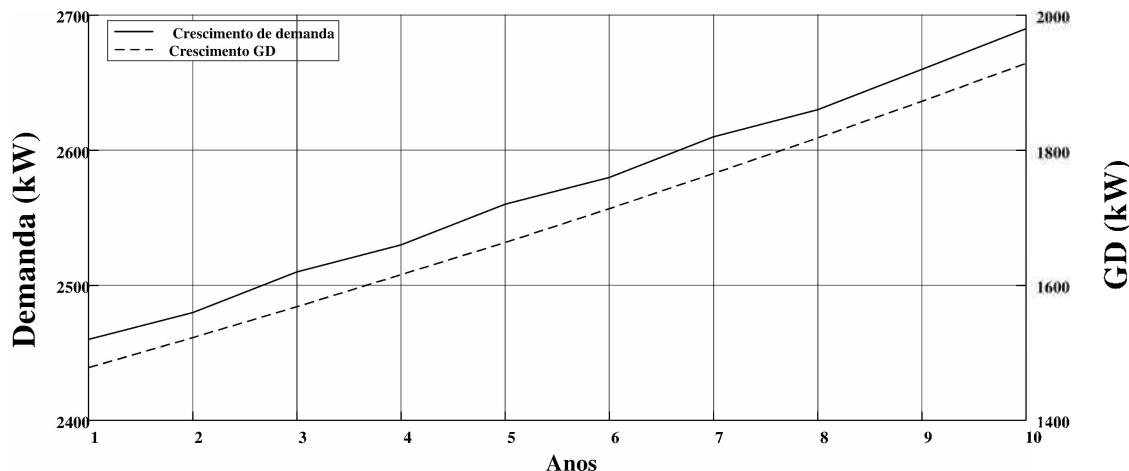


Figura 63 - Crescimento de demanda e GD previstos ao longo de 10 anos.

Os resultados totais das perdas técnicas calculadas com GD e sem BES (Battery Energy Storage), com GD e com BES, para o primeiro ano de operação considerando somente o período previsto de funcionamento dos BES. A figura 64 mostra a faixa de tempo utilizado durante o dia e a noite e a demanda residencial total com o perfil de geração fotovoltaica.

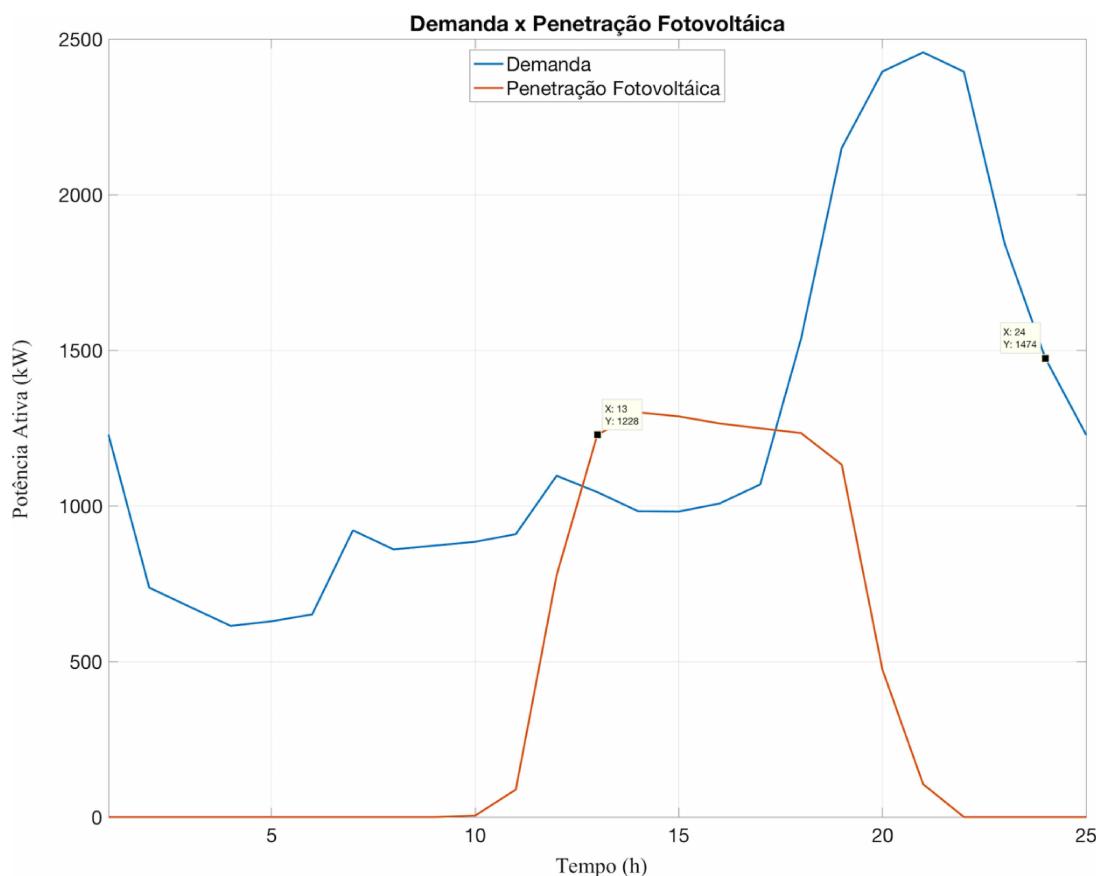


Figura 64 – Perfil de demanda e geração fotovoltaica durante 1dia.

Assim, a tabela 12 mostra os fatores que foram aplicados a demanda total para que fossem obtidos os níveis de demanda para as horas do dia analisadas e assim, proceder com as simulações. Esses fatores de demanda foram retirados de (JARDINI et. al., 2000). Os custos relacionados as perdas ativas de energia podem ser encontrados em (SOUZA et. al., 2016b) e são mostrados na tabela 12. É importante ressaltar que as potências reativas das cargas foram modificadas para que se mantivesse os mesmos fatores de potências.

Tabela 12 - Fatores de carga e custos de perdas por potência ativa

Nível de demanda (horas do dia)	Fator	Fase A (kW)	Fase B (kW)	Fase C (kW)	Total (kW)	Custo (US\$/kWh)
13	0,441	327,15	287,55	481,94	1096,64	0,1100
14	0,42499	308,97	271,57	463,66	1044,2	0,1100
15	0,4	290,8	255,6	436,4	982,8	0,1300
16	0,39958	290,5	255,33	435,94	981,77	0,1300
17	0,41	298,07	261,99	447,31	1007,37	0,1300
18	0,43499	316,24	277,96	474,57	1068,77	0,1300
19	0,62499	454,37	399,37	681,86	1535,6	0,1500
20	0,87499	636,12	559,12	954,61	2149,85	0,1500
21	0,97499	708,82	623,02	1063,71	2395,55	0,1500
22	1	727	639	1091	2457	0,0650
23	0,97499	708,2	623,02	1063,71	2394,93	0,0650
24	0,75	545,25	479,25	818,25	1842,75	0,0650

A figura 65 mostra os perfis de demanda das três fases do sistema analisado.

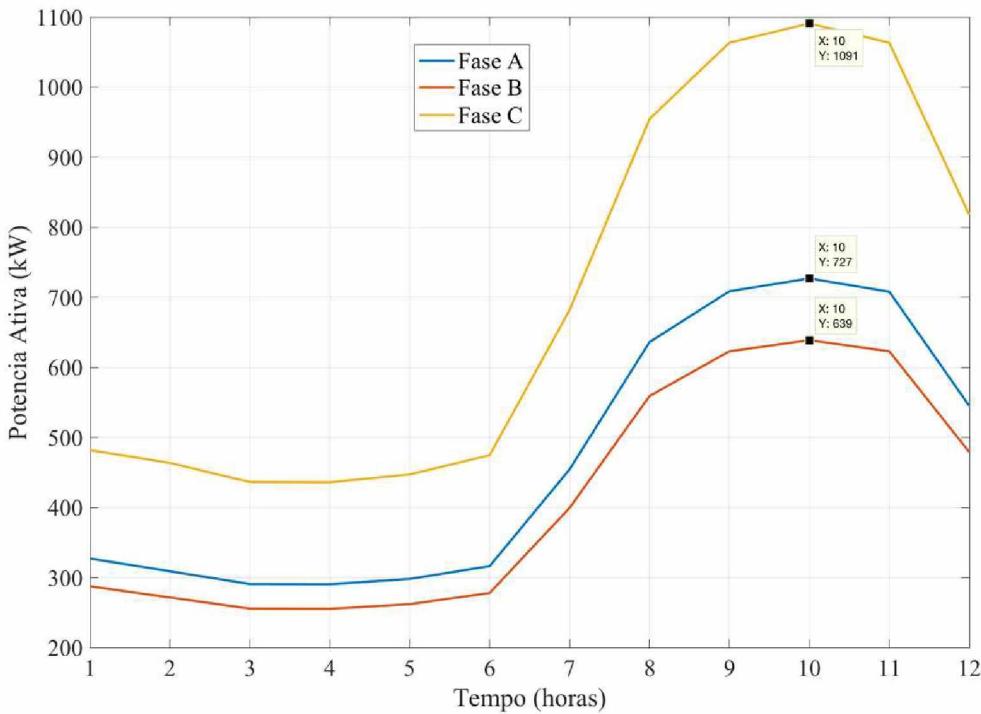


Figura 65 - Perfil de demanda trifásico

A figura 66 mostra como os custos relacionados às perdas de energia variam de acordo com o período analisado. Os custos mostrados na tabela 12 foram multiplicados pelas perdas obtidas pelo fluxo de potência para que fossem obtidos os valores da função objetivo.

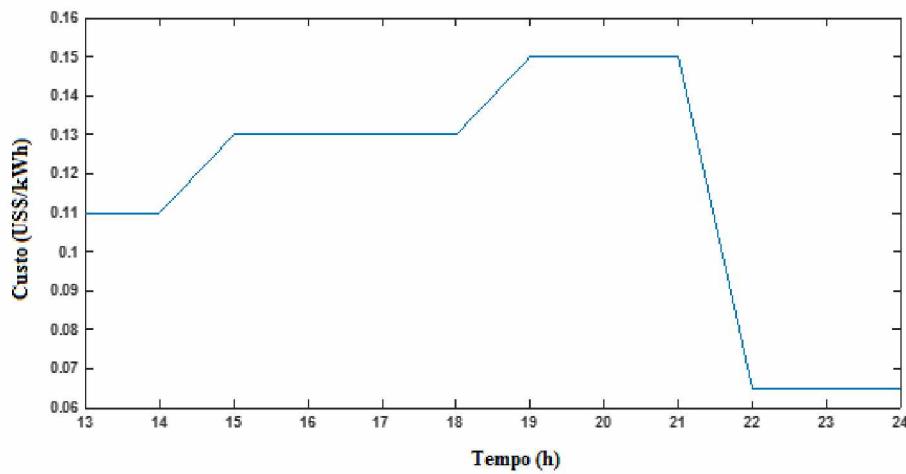


Figura 66 - Custos das perdas ativas

Os resultados diários totais das perdas técnicas calculados com GD e sem BES, com GD e com BES, para o primeiro ano de operação considerando somente o período de funcionamento previsto do BES, são mostrados na tabela 13.

Tabela 13 - Resultado do primeiro ano para os 4 casos simulados.

Sbase = 100 kVA				
Caso	Perdas sem/BES (p.u)	Custo (US\$)	Perdas com/BES (p.u)	Custo (US\$)
1	60,8744	750.581,35	59,4416	732.914,92
2	59,9345	738.992,38	57,42213	708.014,86
3	60,1673	741.862,80	58,7204	724.022,53
4	60,1489	741.635,93	58,78049	724.763,44

De acordo com a tabela 13, tem-se que a topologia que melhor atendeu aos objetivos da utilização dos BES foi a topologia apresentada no caso 2, ou seja, BES concentrado próximo à GD. Uma vez que os valores noturnos das perdas encontradas são proporcionais às diárias, ou seja, a topologia que obteve menor perdas durante o dia também a obterá durante a noite, será feita uma análise completa apenas para o caso 2. A tabela 14 mostra as relações noturnas para 1 dia entre os casos 1 e 2.

Tabela 14 - Valores de perdas técnicas com bes, encontradas em 1 dia de simulação para o período noturno. casos 1 e 2.

Valores em p.u. Sbase = 100 kVA	
Caso	Dia 55 – Perdas
1	1,2322
2	1,2296

A figura 67 mostra o ciclo diário de uma bateria e o perfil das perdas para seis dias (estudo de caso 2). A linha vermelha e as verdes se referem ao eixo y esquerdo e direito, respectivamente.

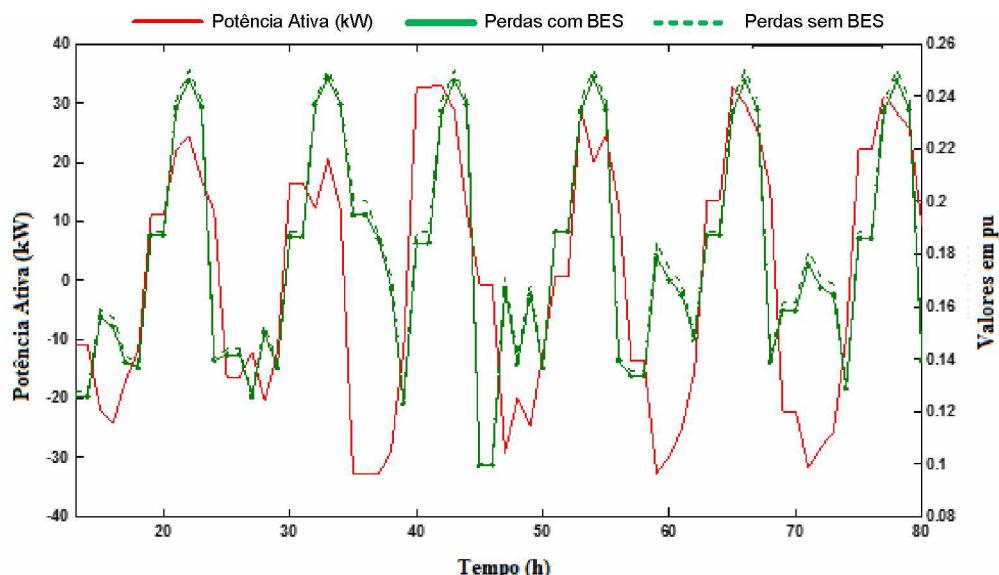


Figura 67 - Perfil diário da bateria, perfil de perdas com e sem Baterias para 6 dias de análises.

Uma vez que a taxa de crescimento de demanda e a taxa de crescimento de geração distribuída não são iguais, se fazem necessários cálculos anuais para se obter o aumento das perdas técnicas com e sem BES durante os 10 anos estudados. Dessa maneira, levando em consideração que o valor total encontrado em um dia do ano é proporcional as perdas totais anuais de acordo com cada taxa de crescimento, foram simuladas as perdas diárias de 1 dia para cada ano desejado para o caso 2. Esses resultados são apresentados na tabela 15.

Tabela 15 - Valores simulados para 1 dia no período diurno durante 10 anos

Sbase = 100 kVA				
Ano	Perdas sem/BES (p.u)	Custo (US\$)	Perdas com/ BES (p.u)	Custo (US\$)
1	0,8989	10.373,30	0,8817	10.174,81
2	0,9502	11.228,47	0,91822	10.850,56
3	1,0211	12.355,88	0,97928	11.849,84
4	1,0950	13.568,12	1,03802	12.862,08
5	1,1626	14.751,49	1,09071	13.839,32
6	1,2215	15.870,80	1,13507	14.747,83
7	1,2718	16.920,93	1,17073	15.576,22
8	1,3121	17.876,08	1,19888	16.333,57
9	1,3420	18.722,24	1,22132	17.038,64
10	1,3633	19.475,86	1,23963	17.709,14

De posse dos dados da tabela 15, obtém-se o aumento percentual de perdas de cada ano, em relação ao primeiro ano. Esses valores são mostrados na tabela 16.

Tabela 16 - Valores percentuais de aumento de perdas técnicas anuais em relação ao primeiro ano

Ano	Aumento s/ BES (%)	Aumento c/ BES (%)
1	-	-
2	5,70	4,15
3	13,59	11,06
4	21,81	17,72
5	29,33	23,70
6	35,88	28,73
7	41,48	32,78
8	45,96	35,97
9	49,29	38,51
10	51,66	40,59

Os valores percentuais da tabela 16 são utilizados para que sejam encontrados os valores anuais totais de perdas técnicas com GD e com e sem BES durante o período desejado de 10 anos, para o caso 2. A tabela 17 mostra esses valores.

De acordo com a tabela 17, tem-se que ao final do décimo ano há a previsão de que sejam evitadas 45,53 (p.u) em perdas técnicas ao fim de 5 anos de utilização dos BES e 152,35 (p.u) de perdas técnicas no sistema simulado ao fim de 10 anos de utilização dos BES, de acordo com as características impostas nas simulações.

Tabela 17 - Valores anuais previstos de perdas técnicas com e sem BES e sua diferença.

Sbase = 100 kVA				
Ano	Perdas sem/BES (p.u)	Perdas com/ BES (p.u)	Diferença (p.u)	Economia (US\$)
1	148,3153	142,9423	5,373	62.004,42
2	156,7689	148,8744	7,8945	93.288,99
3	168,4713	158,7517	9,7196	117.612,67
4	180,6629	168,2717	12,3912	153.539,11
5	191,8162	176,8196	14,9966	190.282,32
Total 5 anos	-	-	45,53	616.727,51
6	201,5308	184,0096	17,5212	227.650,93
7	209,8365	190,0704	19,7661	262.982,31
8	216,481	194,3586	22,1224	301.396,18
9	221,4199	197,9894	23,4305	326.878,99
10	224,935	200,9626	23,9724	342.465,58
Total 10 anos	-	-	152,35	2.078.101,50

De acordo com a tabela 17, foi previsto por meio de simulação que ao fim de 5 anos a economia feita com o uso dos BES seria de U\$ 616.727,51 e, ao fim de 10 anos U\$ 2.078.101,50.

No entanto, uma grande quantidade de energia armazenada foi calculada para esse estudo. Quanto maior o custo do \$/kWh para determinada tecnologia, pode não ser tão viável a utilização de armazenadores de energia de chumbo-ácido. Algumas das tecnologias de armazenadores de energia mais utilizadas e seus custos para a aplicação no sistema estudado de acordo com este estudo são mostradas na tabela 18 (WANG et. al., 2017):

Tabela 18 - Tecnologias de armazenadores de energia.

Sistemas	Potência disponível	\$/kW	\$/kWh	Custo ao final de 5 anos (U\$)	Custo ao final de 10 anos (U\$)
CAES	5-300 MW	400-800	2-50	89.200,00	135.200,00
CES	100 kW-300 MW	200-300	3-30	108.600,00	159.600,00
PHS	100-5000 MW	600-2000	5-100	197.800,00	294.800,00
HT-TES	0-60 MW	-	30-60	960.000,00	1.380.000,00
VRB	30 kW-3 MW	600-1500	150-1000	4.837.800,00	6.964.800,00
L-A	0-20 MW	300-600	200-400	6.418.900,00	9.232.400,00
Li-ion	0-100 kW	1200-4000	600-2500	6.475.600,00	27.729.600,00

CAES – Compressed Air Energy Storage; CES – Cryogenic Energy Storage; PHS – Pumped Hydroelectric Storage; HT-TES - High Temperature TES; VRB – Vanadium Redox Battery; L-A – Lead-Acid Battery; Li-ion – Lithium Ion Battery.

Como pode se observar na tabela 18, tecnologias com um baixo custo de energia armazenada (\$/kWh) são mais atrativas para a aplicação na análise feita aqui. No entanto, mais análises, como o controle do perfil de tensão de redes de distribuição, manutenção, impactos ambientais, número de substituições, devem ser realizadas para que se tome uma melhor decisão quando da escolha da tecnologia a ser empregada.

5.4.4 Conclusão parcial

Esta seção teve por objetivo investigar os benefícios da inserção a longo prazo de armazenadores de energia do tipo bateria de chumbo-ácido em um sistema elétrico. Para isso foi utilizado um sistema teste IEEE 37 barras modificado. As análises foram feitas por meio do método trifásico de Newton-Raphson utilizando-se para tanto um algoritmo de fluxo de carga desenvolvido.

Foram testados 2 tipos de alocação dos BES ao longo do sistema, 2 concentradas e 2 distribuídas. Como resultado obteve-se que os BES concentrados próximos às concentrações de GD resultaram em melhor desempenho para o objetivo traçado nesta pesquisa, ou seja, a redução de perdas técnicas em redes de distribuição trifásicas.

Com o auxílio de Redes Neurais Artificiais, foi possível fazer a previsão das perdas anuais durante os períodos de 5 e de 10 anos, mesmos períodos em que se previram a vida útil do sistema de BES.

Os resultados finais se mostraram bastante satisfatórios, uma vez que foram demonstrados que as perdas técnicas podem ser evitadas significantemente a longo prazo, o que reflete em redução de custos para as empresas de energia elétrica.

5.5 Reconfiguração otimizada por BPSO

Nesta seção é apresentado o resultado final no qual, para tanto, utilizou-se todas as ferramentas e análises feitas até aqui.

Como o intuito desse estudo é o de propor e verificar a utilização do algoritmo de otimização BPSO, foram feitas análises para o pior caso de operação do sistema de distribuição analisado, ou sejam o horário de pico no horário de ponta.

Como já citado anteriormente, o sistema utilizado foi o IEEE 37 barras modificado.

Tratando-se de um sistema puramente radial sem recurso, fez-se necessário a adição de rotas alternativas para o fluxo de carga por meio da adição de novos trechos ao sistema, criando assim um sistema malhado. Os custos adicionais pela adição dos novos trechos não devem ser levados em consideração aqui, portanto, deve-se tratar o sistema como se já existente da maneira como é proposto e ilustrado na figura 68.

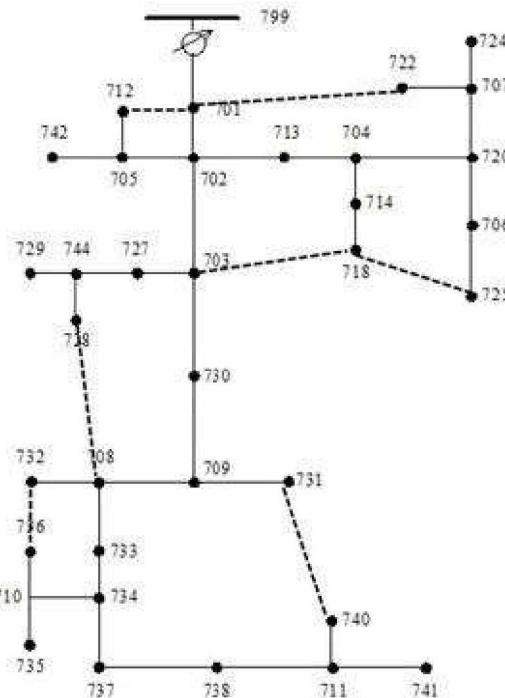


Figura 68 - Sistema IEEE 37 barras modificado.

Pode-se ver pela figura 68 que foram adicionados os seguintes trechos:

- 712-701;
- 701-722;

- 703-718;
- 718-725;
- 728-708;
- 732-736;
- 730-741.

A todos os trechos adicionados foram atribuídos os mesmos parâmetros de linha que os do trecho 701-702 que se encontra especificado no Anexo B, por se tratar de um trecho onde originalmente a maior parte do fluxo de carga se encontra.

A condição necessária, porém, não suficiente, para que uma topologia seja radial é (90) (CINVALAR, GRAINGER e LEE, 1988):

$$\text{Linhas} = \text{barras} - 1 \quad (90)$$

Sendo,

Linhas – o número de linhas do sistema;

Barras – o número de barras do sistema.

O número de chaves que podem ser abertas para a reconfiguração pode ser determinado por (91):

$$\text{Chaves} = \text{Linhas}_m - \text{Linhas}_r \quad (91)$$

Onde,

Linhas_m – é o número de linhas do sistema malhado;

Linhas_r – é o número de linhas do sistema radial.

Tem-se então, para o caso analisado aqui um número total de 5 chaves que deverão ser abertas para a reconfiguração, uma vez que o sistema possui 42 linhas após as modificações.

O espaço de busca para o problema apresentado aqui pode ser obtido por análise combinatória, onde o número de combinações de N_B elementos tomados N a N é definido como (92) (NUNES e BRETAS, 2016):

$$C_{NB}^N = \frac{NB!}{N!(NB-N)!} \quad (92)$$

De acordo com (92) tem-se um espaço de busca de 850.668 possibilidades, justificando, portanto, a utilização de um algoritmo de otimização para a resolução do problema.

Antes da reconfiguração do sistema em análise, as perdas técnicas encontradas eram da ordem de 0,3921 p.u., figura 68.

A função objetivo da otimização é dada por (93):

$$\text{Min } \sum(R \cdot I^2)^\rho \quad (93)$$

Onde

$(R \cdot I^2)^\rho$ – Perdas ativas nas fases a, b e c.

As restrições impostas aqui são as mesmas de (87), (88) e (89).

Como não se tem conhecimento do valor ótimo para esta otimização, optou-se por testar a quantidade de partículas de 10 em 10 para 100 iterações cada. As figuras de 69 a 78 mostram os melhores resultados alcançados para partícula de 10 a 100, testadas 100 iterações cada. O computador utilizado para essas simulações é um iMac com processador 4 GHz Intel Core i78 e 32 GB de memória RAM.

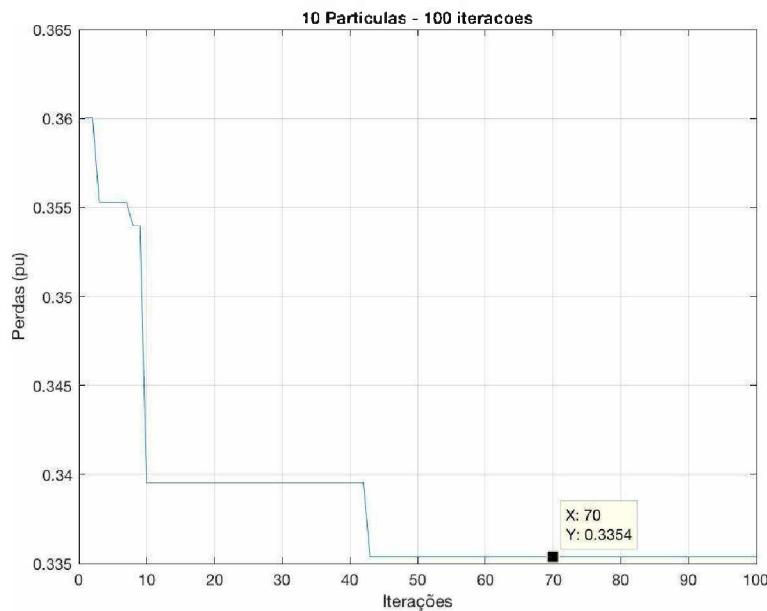


Figura 69 - Convergência do BPSO para 10 partículas e 100 iterações.

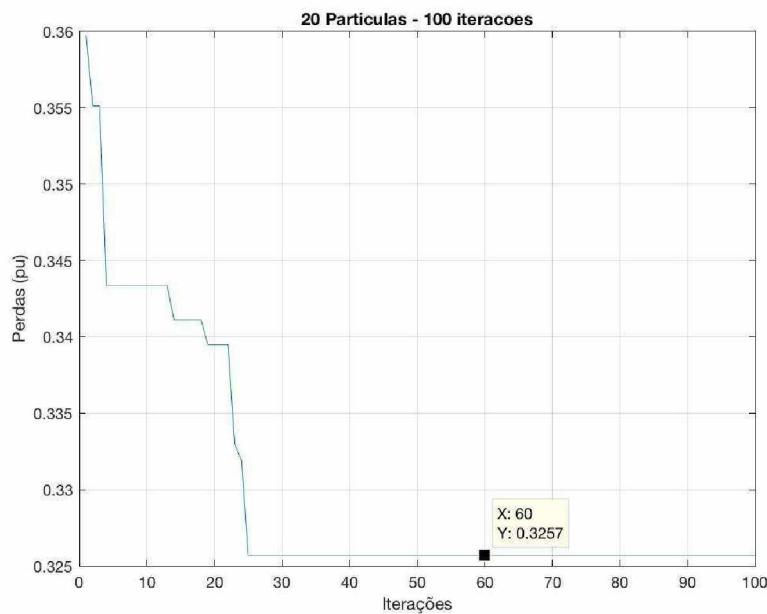


Figura 70 - Convergência do BPSO para 20 partículas e 100 iterações.

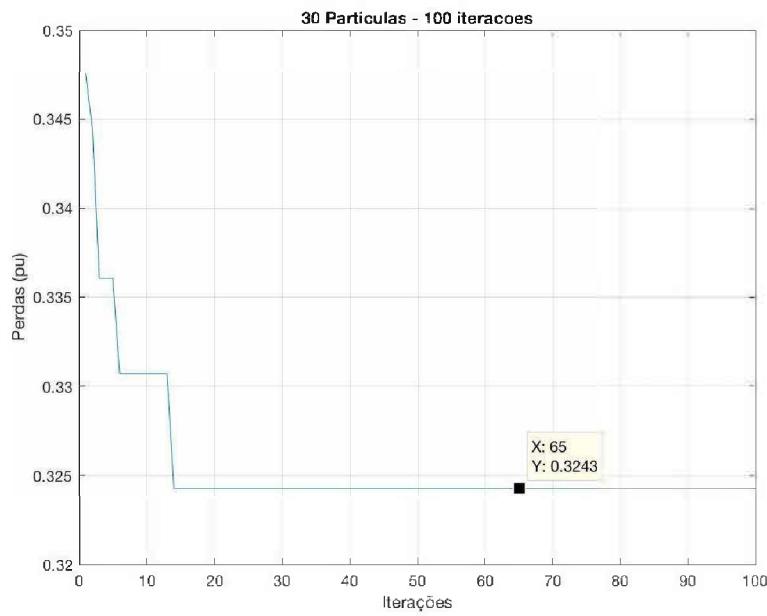


Figura 71 - Convergência do BPSO para 30 partículas e 100 iterações.

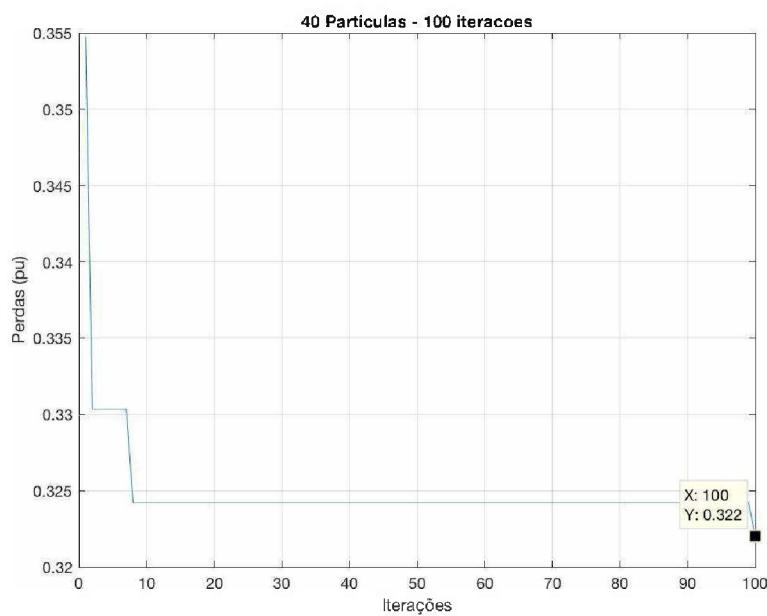


Figura 72 - Convergência do BPSO para 40 partículas e 100 iterações.

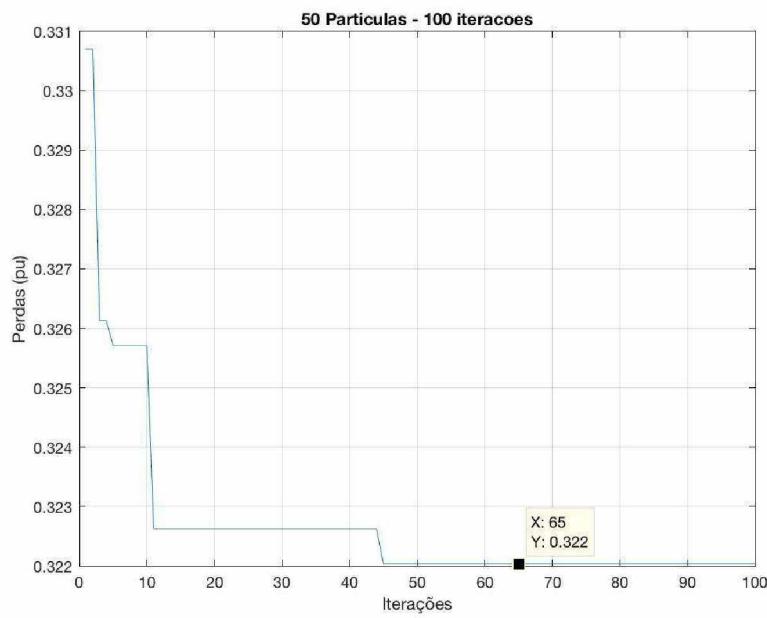


Figura 73 - Convergência do BPSO para 50 partículas e 100 iterações.

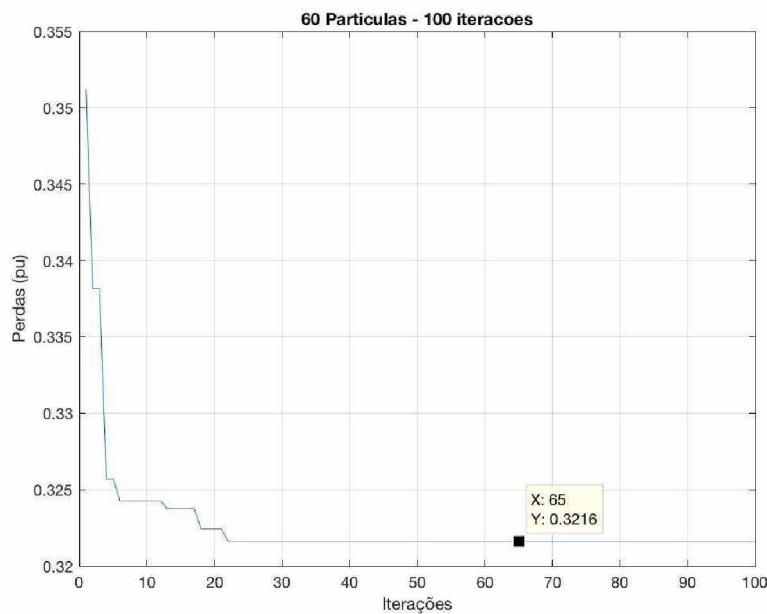


Figura 74 - Convergência do BPSO para 60 partículas e 100 iterações.

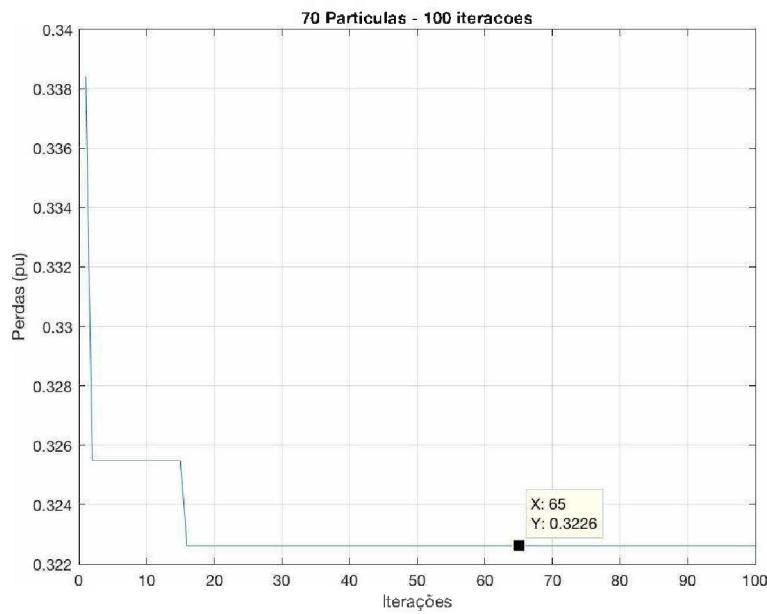


Figura 75 - Convergência do BPSO para 70 partículas e 100 iterações.

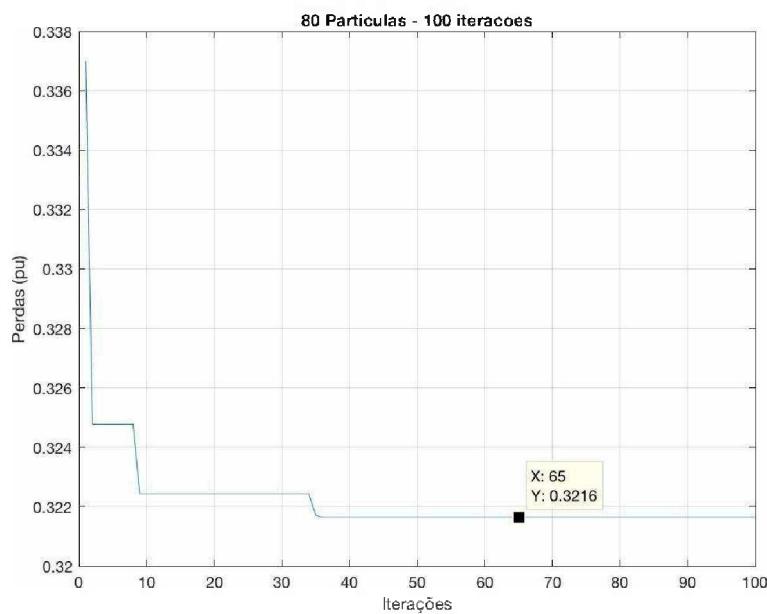


Figura 76 - Convergência do BPSO para 80 partículas e 100 iterações.

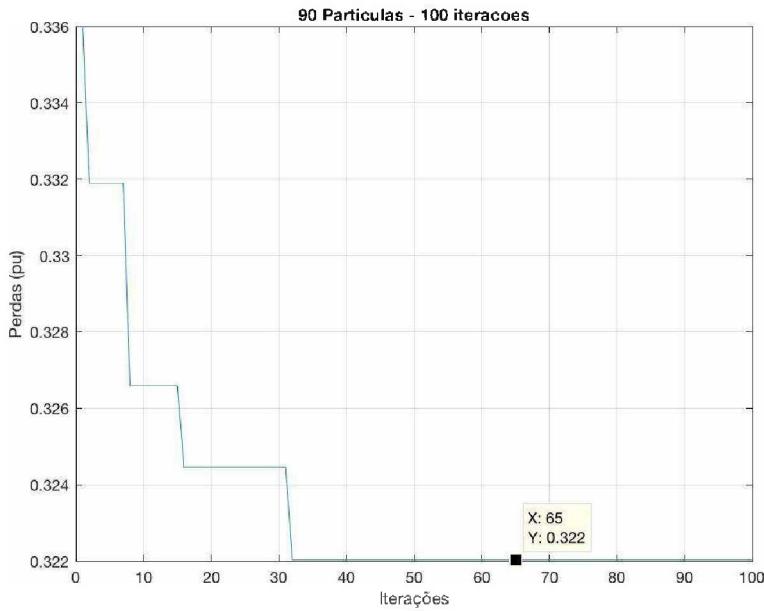


Figura 77 - Convergência do BPSO para 90 partículas e 100 iterações.

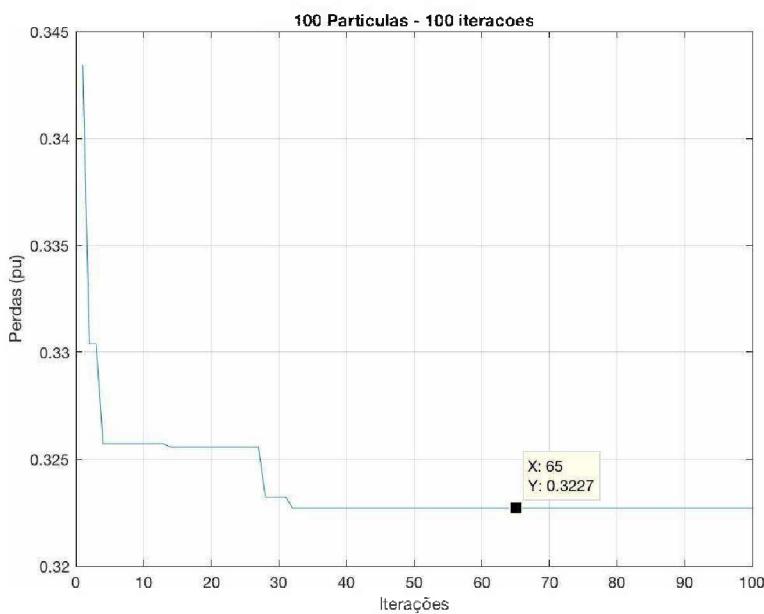


Figura 78 - Convergência do BPSO para 100 partículas e 100 iterações.

De acordo com as figuras de 69 a 78, verificou-se que com os testes com 60 partículas para 100 iterações o algoritmo alcançou o seu melhor resultado dentre todas as demais quantidades, exceto pela otimização com 80 partículas que obteve o mesmo resultado. Porém, como se busca a otimização e deve-se levar em consideração que

quanto mais partículas são utilizadas mais tempo computacional se gasta, recomenda-se que para este caso sejam utilizadas 60 partículas para 100 iterações.

A tabela 19 apresenta a numeração dada aos trechos de linha e a tabela 20 mostra, para cada quantidade de partículas, as sequências de trechos abertos que tiveram os melhores resultados no processo de otimização. Na tabela 19 os trechos em vermelho são os trechos adicionados.

Tabela 19 - Trechos e numeração atribuída.

Trecho		Numeração atribuída
701	702	2
701	712	3
701	722	4
702	705	5
702	713	6
702	703	7
703	727	8
703	730	9
703	718	10
704	714	11
704	720	12
705	742	13
705	712	14
706	725	15
718	725	16
707	724	17
707	722	18
708	733	19
708	732	20
728	708	21
709	731	22
709	708	23
710	735	24
710	736	25
711	741	26
711	740	27
713	704	28
714	718	29
720	707	30
720	706	31
727	744	32
730	709	33
733	734	34
734	737	35

734	710	36
737	738	37
738	711	38
744	728	39
744	729	40
740	731	41
732	736	42
799	701	1

Tabela 20 - Número de partículas, trechos abertos e perdas em pu.

Número de partículas	Trechos abertos	Perdas (p.u)	Média
10	5 – 10 – 19 – 21 – 28	0,3354	0,32775
20	10 – 11 – 12 – 21 – 42	0,3257	0,3245
30	5 – 10 – 11 – 12 – 20	0,3243	0,32515
40	5 – 10 – 11 – 28 – 42	0,322	0,32235
50	5 – 10 – 11 – 28 – 42	0,322	0,3223
60	5 – 10 – 15 – 28 – 37	0,3216	0,322
70	5 – 10 – 15 – 25 – 28	0,3226	0,32345
80	5 – 10 – 15 – 28 – 37	0,3216	0,32205
90	5 – 10 – 11 – 28 – 42	0,322	0,32235
100	10 – 11 – 25 – 28 – 37	0,3227	0,3222

De acordo com a tabela 20 acima, pode-se ver que o algoritmo convergiu para o valor de 0,32 p.u, uma vez que a média dos 10 resultados obtidos nas simulações de cada quantidade de partículas mostra essa convergência.

De posse da sequência de trechos abertas que obteve o melhor resultado, é possível de se obter o valor das perdas levando em consideração a utilização de armazenadores de energia. Com os resultados encontrados na seção 5.4, adicionou-se ao sistema o efeito dos armazenadores de energia na barra 738. A tabela 21 mostra a comparação entre as perdas com e sem AEE para a sequência de trechos abertos encontrados pela otimização por BPSO com 60 partículas e 100 iterações. Vale ressaltar que as perdas do sistema sem a mudança da topologia e sem AEE eram de 0,3921 p.u.

Tabela 21 - Perdas sem e com AEE para a melhor configuração encontrada no processo de otimização

Perdas sem AEE (p.u)	Perdas com AEE (p.u)	Percentual da diferença (%)
0,3216	0,3125	2,82

5.5.1 Conclusão parcial

Nessa seção foram apresentados os resultados finais deste trabalho. Os resultados alcançados aqui levaram em consideração todas as técnicas desenvolvidas e analisadas nas seções anteriores deste capítulo.

O algoritmo BPSO se mostrou eficiente no que diz respeito a otimização de um sistema de distribuição de energia elétrica visando a minimização de perdas técnicas. Seu uso se justifica pela grande quantidade de possibilidades de topologias, 850.668, o que tornaria difícil a tarefa de se encontrar uma boa topologia por métodos iterativos.

A convergência do BPSO para este caso se deu para o valor de 0,32 de acordo com a média encontrada nas simulações feitas para as quantidades de partículas e número de iterações apresentados. A melhor topologia encontrada necessitou de 60 partículas e 100 iterações para ser encontrada.

Após encontrada a topologia otimizada, verificou-se que com o uso de AEE a redução das perdas técnicas é ainda mais acentuada, 0,3125 p.u.

Por fim, conclui-se que para processos de otimização o uso do BPSO para a reconfiguração de sistemas de energia elétrica se mostrou uma ferramenta viável de ser utilizada.

CAPÍTULO 6

Considerações Finais

Este trabalho teve por objetivo a análise da reconfiguração otimizada de um sistema de distribuição de energia elétrica considerando os efeitos da geração distribuída por meio de sistemas que utilizam fontes de energia renováveis, em nosso caso os sistemas fotovoltaicos e, armazenadores de energia elétrica. Como citado e referenciado ao longo deste trabalho, o fluxo de carga que, antes da introdução dos geradores distribuídos, era unidirecional, agora passa a ser bidirecional, ou seja, da rede para a carga e da carga para a rede.

Com a crescente aplicação de armazenadores de energia elétrica em sistemas elétricos e levado pelos desafios que as atuais configurações apresentadas por redes de distribuição, este trabalho veio a considerar os elementos já citados para que uma análise presente fosse realizada.

Para isto, optou-se, pela necessidade que as concessionárias de energia elétrica têm apresentado, pela análise da redução das perdas técnicas por meio da reconfiguração otimizada de um sistema de distribuição de energia elétrica, levando-se em consideração todos os elementos supracitados.

Esta proposta levou em consideração, também, a utilização de ferramentas oriundas da Inteligência Artificial, mais precisamente as redes neurais artificiais e o algoritmo de otimização por enxame de partículas binário (BPSO). Com a utilização das RNA's, pode-se fazer a estimativa da geração fotovoltaica para um horizonte de tempo desejado. Os resultados mostraram que essa ferramenta é bastante precisa e sua

utilização é de grande valia para que se possa prever o estado dos sistemas em que a geração distribuída se faz presente.

No desenvolvimento desta pesquisa, foi desenvolvida uma modelagem matemática para o dimensionamento de sistemas de armazenadores de energia elétrica a longo prazo, levando-se em consideração os aumentos de demanda e penetração fotovoltaica em um horizonte de tempo desejado.

A análise da redução das perdas técnicas com a utilização de AEE foi feita por meio de simulação do fluxo de carga do sistema teste escolhido, IEEE 37 barras modificado, por meio do método trifásico de Newton-Raphson. Todas as ferramentas desenvolvidas e analisadas durante esta pesquisa foram aplicadas nesta análise. Uma análise de custo, levando-se em consideração diversas tecnologias de sistemas armazenadores de energia, foi feita. Como resultado, concluiu-se que tecnologias com alto custo de aquisição da energia armazenada (\$/kWh) não foram atrativas para o estudo proposto. Porém, complementa-se que outras análises, além da redução de perdas técnicas, devem ser feitas para que uma decisão seja tomada no sentido de qual tecnologia de AEE deve ser escolhida.

Por fim, o estudo e a proposta da reconfiguração otimizada do sistema teste foi realizada com o uso do BPSO. A utilização desta ferramenta se justifica pelo alto número de combinações possíveis, que o sistema proposto apresenta, para a reconfiguração desejada. Para que a radialidade do sistema não fosse perdida, fez-se uso da análise da rede por teoria dos grafos, utilizando-se para tanto, a matriz Laplaciana. Os resultados dessa reconfiguração, levando-se em consideração a penetração fotovoltaica e os sistemas AEE, se mostraram positivos uma vez que se obteve como resultado uma redução de aproximadamente 0.8 pu nas perdas por potência ativa. Vale ressaltar que os armazenadores de energia elétrica foram dimensionados para suprir apenas 10% da diferença entre a máxima penetração fotovoltaica considerada e a demanda.

Conclui-se, portanto, que a utilização de armazenadores de energia e as ferramentas ligadas a inteligência artificial apresentadas e analisadas aqui, podem auxiliar na tomada de decisões quanto à configuração de sistemas de distribuição de energia elétrica objetivando a operação eficiente e econômica dos mesmos.

6.1 Sugestões para trabalhos futuros

Como sugestões para trabalhos futuros, são apontadas as análises a seguir:

- 1) O desenvolvimento de ferramentas de controle para os armazenadores de energia, uma vez que se tem a necessidade de que este controle seja bidirecional, pois, deve-se carregar e descarregar os AEEs;
- 2) A análise da qualidade de energia elétrica pelo lado da responsabilidade de demanda levando-se em consideração a utilização de armazenadores de energia e alta penetração fotovoltaica com controles eficientes, como por exemplo, o MPC (*Model Predictive Control* ou Controle Preditivo Baseado em Modelo), que faz o uso da teoria do *Receding Horizon*, onde o controle faz o uso da previsão do estado do sistema que está controlando para a ajuste do controle no seu instante presente de atuação;
- 3) A análise da qualidade de energia elétrica pelo lado da responsabilidade de demanda com o auxílio de armazenadores de energia, levando em consideração alta penetração de geração distribuída com controle estocástico, para que assim o controle não dependa de um modelo de um determinado sistema e possa ser mais generalista;
- 4) A proposta da verificação da radialidade do sistema por um método mais eficiente e rápido do que o método proposto utilizando a teoria dos grafos;
- 5) A alocação otimizada de armazenadores de energia elétrica levando em consideração possíveis mudanças de topologia nos sistemas de distribuição de energia elétrica;
- 6) A utilização de armazenadores de energia elétrica para melhorar a estabilidade e dinâmica de sistemas elétricos quando da ocorrência de determinados distúrbios no sistema;
- 7) A análise de contingências utilizando armazenadores de energia elétrica com o intuito de se evitar os cortes de cargas de determinadas regiões do sistema devido a ocorrência de algum distúrbio no sistema de distribuição ou transmissão de energia elétrica;
- 8) A análise multiobjetivo, por meio de algoritmos de otimização, para a melhoria da eficiência e da operação de sistemas de distribuição levando em consideração os custos e a qualidade de energia.

Referências

- ABDELAZIZ, Y.; MEKHAMER, S. F.; BADR, M. A. L.; MOHAMED, F. M. A **Modified Particle Swarm Algorithm for Distribution Systems Reconfiguration**. IEEE Power & Energy Society General Meeting, pp. 1 - 8, 2009.
- ACHA, E.; ESQUIVEL, C. R. F.; PEREZ, H. A.; CAMACHO, C. A. **FACTS - Modelling and Simulation in Power Networks**. England. John Wiley & Sons, LTD, 2004, 399p.
- ACKERMANN, T, ANDERSSON, G., SODER, L, **What is distributed generation?**. Estocolmo, Suécia: 2001.
- Agência Nacional de Energia Elétrica – ANEEL. **Atlas de energia elétrica do Brasil**. 2^a Ed. Brasília - DF. 2005.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, **Procedimentos de Distribuição: Cartilha de Acesso ao Sistema de Distribuição**. 2011.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, **Procedimentos de Distribuição: Módulo 3 - Acesso ao Sistema de Distribuição**. 2012.
- AMMAR, M.; JOÓS, G. **A Short-Term Energy Storage System for Voltage Quality Improvement in Distributed Wind Power**. IEEE Transactions on Energy Conversion, vol. 29, no. 4, pp. 997–1007, dez. 2014.
- ANEEL
ANEELErro! Indicador não definido., BIG – Banco de Informações de Geração.
Capacidade de Geração do Brasil
Disponível em <http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>.
Acesso em 02 set. 2017.
- ARYA, L. D.; TIRARE, L. S.; KOTHARI, D. P. **Improved particle swarm optimization applied to reactive power reserve maximization**. International Journal of Electrical Power and Energy Systems, vol. 32, no. 5, pp. 368–374, 2010.
- BABOLI, T.; SHAHPARASTI, M.; MOGHADDAM, M. P. **Energy management and operation modelling of hybrid AC – DC microgrid**. IET Generation, Transmission & Distribution, vol. 8, pp. 1700–1711, nov. 2014.

- BARSALI, S.; CERAOLO, M.; GIGLIOLI, R.; POLI, D. **Storage applications for Smartgrids.** Electric Power Systems Research. vol. 120, pp. 109–117, Ago. 2015.
- BEHRANG, M. A.; ASSAREH, E.; GHANBARZADEH, A.; NOGHREHABADI, A. R. **The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data.** Solar Energy, vol. 84, no. 8, pp. 1468–1480, jun. 2010.
- BERNECKER, D. ; RIESS, C.; ANGELOPOULOU, E.; HORNEGGER, J. **Continuous short-term irradiance forecasts using sky images.** Solar Energy, vol. 110, pp. 303–315, set. 2014.
- BHARDWAJ, S.; SHARMA, V.; SRIVASTAVA, S.; SASTRY, O. S.; BANDYOPADHYAY, B.; CHANDEL, S. S.; GUPTA, J. R. P. **Estimation of solar radiation using a combination of Hidden Markov Model and generalized Fuzzy model.** Solar Energy, vol. 93, pp. 43–54, 2013.
- BISERICA, M.; BESANGER, Y.; CAIRE, R.; CHILARD, O.; DESHAMPS, P. **Neural Networks to Improve Distribution State Estimation — Volt Var Control Performances.** IEEE Transactions on Smart Grid, vol. 3, no. 3, pp. 1137–1144, set. 2012.
- BRASIL. **Decreto 5.163, de 30 de Julho de 2004: Regulamenta a comercialização de energia elétrica, o processo de outorga de concessões e de autorizações de energia elétrica, e dá outras providências.** 2004.
- BROOKS, J.; BAROOAH, P. **Consumer-aware load control to provide contingency reserves using frequency measurements and inter-load communication.** American control conference (ACC), pp 5008-5013, jul. 2016.
- CANIVAN, J. **Solar thermal engine** [online]. 2012. Disponível em http://www.jc-solarhomes.com/fair/solar_engine18.htm. Acessado em 15 jan. 2015.
- CARPINELLI, G.; CELLI, G.; MOCCI, S.; MOTTOLA, F.; PILO, F.; PROTO, D. **Optimal integration of distributed energy storage devices in smart grids.** IEEE Transactions on Smart Grid, vol. 4, no. 2, pp. 985–995, Jun. 2013.

- CARR, S.; PREMIER, G. C.; GUWY, A. J.; DINSDALE, R. M.; MADDY, J. **Energy storage for active network management on electricity distribution networks with wind power.** IET Renewable Power Generation, pp. 249–259, 2014.
- CATALÃO, J. P. S.; MARIANO, S. J. P. S.; MENDES, V. M. F.; FERREIRA, L. A. F. M. **Short-term electricity prices forecasting in a competitive market: A neural network approach.** Electric Power Systems Research, vol. 77, no. 10, pp. 1297–1304, 2007.
- CELIK, N. **Artificial neural network modelling and experimental verification of the operating current of mono-crystalline photovoltaic modules.** Solar Energy, vol. 85, no. 10, pp. 2507–2517, 2011.
- CEMIG - Companhia Energética de Minas Gerais. **Atlas Solarimétrico de Minas Gerais.** Belo Horizonte: Cemig, 2012. 80 p.
- CHANG, W. Y. **The State of Charge estimating methods for battery: A review.** Applied Mathematics, vol. 2013, no. 1, 2013.
- CHEN, H.; CONGE, T. N.; YANG, W.; TAN, C.; LI, Y.; DING, Y. **Progress in electrical energy storage system: A critical review.** Progress in Natural Science., vol. 19, no. 3, pp. 291–312, jul. 2009.
- CHEN, Z.; LI, Q. B. **Energy Storage Sizing for Dispatchability of Wind Farm.** 11th Environmental. and Electrical Engineering International Conference, (EEEIC), 2012, pp. 382-387.
- CHIASSON, J.; VAIRAMOHAN, B. **Estimating the State of Charge of a battery.** IEEE Transactions on Control Systems Technology, vol. 13, no. 3, pp. 465–470, mai. 2005.
- CIVANLAR, S.; GRAINGER, J. J.; LEE, S. S. H. **Distribution Feeder Reconfiguration for Loss Reduction.** IEEE Transaction on Power Delivery, vol. 3, n. 3, pp. 1217–1223, 1988.
- CROSSLAND, A. F.; JONES, D.; WADE, N. S. **Planning the location and rating of distributed energy storage in LV networks using a genetic algorithm with simulated annealing.** International Journal of Electrical Power and Energy Systems, vol. 59, pp. 103–110, mar. 2014.

- CUNHA, G. H. B. **Modelagem matemática e implementação computacional no ATP de um sistema solar fotovoltaico conectado a rede de baixa tensão.** Dissertação de Mestrado. FEEL (Faculdade de Engenharia Elétrica). UFU (Universidade Federal de Uberlândia). Julho de 2013.
- DEGEFA, M. Z.; LEHTONEN, M.; MILLAR, R. J.; ALAHÄIVÄLÄ, A.; SAARIJÄRVI, E. **Optimal voltage control strategies for day-ahead active distribution network operation.** Electric Power Systems Research, vol. 127, pp. 41–52, 2015.
- DELL, R. M.; RAND, D. A. J. **Energy storage - A key technology for global energy sustainability.** Journal of Power Sources, vol. 100, no. 1–2, pp. 2–17, 2001.
- DESCHEEMAEKER, J.; RYCKEGHEM, V. J.; STEENBERGE, C. V.; DEBRUYNE, C.; DESMET, J., **Incentives and technical considerations related to increased voltage tolerance in low voltage distribution grids.** ICHQP. Romênia. mai. 2014.
- DIAS, M. V. X., BOROTNI, E. da C., HADDAD J., **Geração distribuída no Brasil: Oportunidades e barreiras.** 11 p., 2005.
- DUFO-LÓPEZ, R.; LUJANO-ROJAS, J. M.; BERNAL-AGUSTÍN, J. L. **Comparison of different lead – acid battery lifetime prediction models for use in simulation of stand-alone photovoltaic systems.** Applied energy, vol. 115, pp. 242–253, 2014.
- DUNN, S., FLAVIN, C., **Sizing up micropower.** The World watch Institute, Washington – DC, 2000.
- EBERHART, C. **Particle Swarm Optimization : Developments , applications and resources.** Congress on Evolutionary Computation, pp. 81–86, 2001.
- EBERHART, C. R.; SHI, Y. **Guest Editorial Special Issue on Particle Swarm Optimization.** IEEE Transactions on Evolutionary Computation, vol. 8, no. 3, pp. 201–203, 2004.
- EL-DIB, A.; YOUSSEF, H. K. M.; OSMAN, Z. **Optimum VAR sizing and allocation using particle swarm optimization.** Electric Power Systems Research, vol. 77, Ago. 2006, pp. 965–972, 2007.

- EL-KJATTAN, W., SALAMA, M. M. A. **Distributed generation technologies: definitions and benefits.** Eletric Power Systems Research, vol. 71, pp. 119–128, 2004.
- EMPRESA DE PESQUISA ENERGÉTICA - EPE, **Balanço Energético Nacional.** Ministério de Minas e Energia - MME. Rio de Janeiro - RJ. Junho, 2016.
- ENGELBRECHT, A. P. **Computational intelligence an introduction.** Segunda Edição. Wiley, 2007.
- ESMIN, A. A.; LAMBERT-TORRES, G.; SOUZA, A. C. Z. A. **Hybrid Particle Swarm Optimization applied to loss power minimization.** IEEE Transactions on Power Systems, vol. 20, no. 2, pp. 859–866, 2005.
- FARROKHIFAR, M. **Optimal operation of energy storage devices with RESs to improve efficiency of distribution grids; technical and economical assessment.** International Journal of Electrical Power and Energy Systems, vol. 74, pp. 153–161, ago. 2016.
- FILHO, C. M. de O. **Metodologia para estudo de implantação de uma usina heliotérmica de receptor central no brasil.** 2014. Tese de Doutorado. Universidade Federal do Rio de Janeiro.
- Focando a luz solar através de lentes ópticas,** anterior a 1794, autor desconhecido. Imagem disponível em <http://www.shraboise.com/2014/11/111914-solar-power-in-the-19th-century/>. Acessado em 15 jan. 2015.
- FOROUZANFAR, M.; DAJANI, H. R.; GROZA, V. Z.; BOLIC, M.; RAJAN, S. **Comparison of Feed-Forward Neural Network training algorithms for oscillometric blood pressure estimation.** 4th International Workshop on Soft Computing Applications (SOFA), pp. 119–123, 2010.
- GILLESPIE, J.; JOHANSON, E. S.; MONTVYDAS, D. T. **Energy Storage in Pennsylvania.** IEEE Vehicular Technology Maganize, pp. 76-84, June, 2014.
- GOMEZ-GONZALEZ, M.; LÓPEZ, A.; JURADO, F. **Optimization of distributed generation systems using a new discrete PSO and OPF.** Electric Power Systems Research, vol. 84, no. 1, pp. 174–180, 2012.

- GRBOVIC, P. J. **Energy Storage Technologies and Devices.** Ultra-Capacitors in Power Conversion Systems: Analysis, Modeling and Design in Theory and Practice, 2014.
- HASHEMI, S.; OSTERGAARD, J.; YANG, G. **A scenario-based approach for energy storage capacity determination in LV grids with high PV penetration.** IEEE Transactions on Smart Grid, vol. 5, no. 3, pp. 1514–1522, mai. 2014.
- HAYKIN, S. **Redes neurais. Princípios e prática.** Segunda edição, Bookman, trad. 900 p.
- HAZRA, J.; DASGUPTA, K.; PADMANABAN, M.; VERMA, A.; MATHEW, S.; PETRA, I. **Optimal Power Flow with Grid Scale Battery Storage.** IEEE Innovative Smart Grid Technologies - Asia (ISGT ASIA), pp. 1 - 6, 2015.
- HAYES B. P.; PRODANOVIC M. **State Forecasting and Operational Planning for Distribution Network Energy Management Systems.** IEEE Transactions on Smart Grid, vol. 7, no. 2, pp. 1002–1011, 2016.
- HILL, C. A.; SUCH, M. C.; CHEN, D.; GONZALEZ, J.; GRADY, W. M. **Battery energy storage for enabling integration of distributed solar power generation.** IEEE Transactions on Smart Grid, vol. 3, no. 2, pp. 850–857, jun. 2012.
- HOLLINGER, R.; DIAZGRANADOS, L. M.; BRAAM, F.; ERGE, T.; BOPP, G. **Distributed solar battery systems providing primary control reserve.** IET Renewable Power Generation, vol. 10, no. 1, pp. 63–70, 2016.
- IBRAHIM, H.; ILINCA, A.; PERRON, J. **Energy storage systems - characteristics and comparisons.** Renewable Sustainable Energy Reviews, vol. 12, no. 5, pp. 1221–1250, 2008.
- INEE – Instituto Nacional de Eficiência Energética. **O que é geração distribuída.** Disponível em <http://www.inee.org.br/forum_ger_distrib.asp?Cat=gd>. Acesso em Abril de 2017.
- İZGI, E.; ÖZTOPAL, A.; YERLİ, B.; KAYMAK, M. K.; ŞAHİN, A. D. **Short–mid-term solar power prediction by using artificial neural networks.** Solar Energy, vol. 86, no. 2, pp. 725–733, 2012.

- JARDINI, J. A.; TAHAN, C. M. V.; GOUVEA, M. R.; AHN S. U.; FIGUEIREDO, F. M., **Daily Load Profiles for Residential, Commercial and Industrial Low Voltage Consumers.** IEEE Transactions on Power Delivery, vol. 15, no. 1, pp. 375–380, 2000.
- JANG, J. S. R.; SUN, C. T.; MIZUTANI, E. **Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence.** Prentice-Hall, NJ, 1997.
- JETION SOLAR. Disponível em: <http://www.jetionsolar.com/>. Acessado em novembro de 2015.
- JEYADEVI, S.; BASKAR, S. **Power Flow Control in FACTS Using Particle Swarm Optimization.** India International Conference on Power Electronics, pp. 226–231, 2006.
- JOO, M. E.; LIU, F. **Genetic Algorithms for MLP neural network parameters optimization.** Chinese Control and Decision Conference (2009), pp. 3653–3658.
- KALOGIROU, S. A. **Solar energy engineering: processes and systems.** Academic Press, 2013. 813p.
- KAUSHIKA, D.; TOMAR, R. K.; KAUSHIK, S. C. **Artificial neural network model based on interrelationship of direct, diffuse and global solar radiations.** Solar Energy, vol. 103, pp. 327–342, mar. 2014.
- KENNEDY, J.; EBERHART, R. C. **A discrete binary version of the particle swarm algorithm.** IEEE International Conference on Systems, Man, and Cybernetics, pp. 4104-4108. 1997.
- KHWAJA, S.; NAEEM, M.; ANPALAGAN, A.; VENETSANOPoulos, A.; VENKATESH, B. **Improved short-term load forecasting using bagged neural networks.** Electric Power Systems Research, vol. 125, pp. 109–115, 2015.
- KIM, S. J.; KIM, C. H.; KIM, JUNG S. Y.; KIM ,Y. J. **Optimal design of novel pole piece for power density improvement of magnetic gear using polynomial regression analysis.** IEEE Trans. on Ener. Conv., vol 30, no 3, pp 1171-1179, Sep. 2015

- KOLLER, M.; BORSCHE, T.; ULBIG, A.; ANDERSSON, G. **Review of grid applications with the Zurich 1MW battery energy storage system.** Electric Power Systems Research, vol. 120, pp. 128–135, 2015.
- KONDOH, J.; ISHII, I.; YAMAGUCHI, H.; MURATA, A.; OTANI, K.; SAKUTA, K.; HIGUCHI, N.; SEKINE, S.; KAMIMOTO, M. **Electrical energy storage systems for energy networks.** Energy Conversion & Management., vol. 41, no. 17, pp. 1863–1874, 2000.
- LEETON, U.; UTHITSUNTHORN, D.; KWANNETR, U.; SINSUPHUN, N.; KULWORAWANICHPONG, T. **Power loss minimization using optimal power flow based on particle swarm optimization.** Electric Engineering/Eletronics Computer Telecommunications and Information Technology (ECTICON), pp. 440–444, 2010.
- LERA, G.; PINZOLAS, M. **A quasi-local levenberg-marquardt algorithm for neural network training.** Neural Networks Proceedings, IEEE World Congr. Comput. Intell. vol. 3, pp. 2242–2246, 1998.
- LODI, C. **Perspectivas para a Geração de Energia Elétrica No Brasil Utilizando a Tecnologia Solar Térmica Concentrada.** 127 p. Dissertação (Mestrado em Ciências) - Instituto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, 2011.
- LORA, S., HADDAD, E. E, **Geração distribuída: aspectos tecnológicos, ambientais e institucionais.** Rio de Janeiro – RJ, 2006.
- LUCHESI, C. L. **Introdução à Teoria dos Grafos.** Instituto de Matemática Pura e Aplicada. 12º Colóquio Brasileiro de Matemática. Poços de Caldas. 1979.
- LI, X.; WANG, D. **A sensor registration method using improved Bayesian regularization algorithm.** International Joint Conference on Computational Sciences and Optimization, pp;195–199, 2009.
- MALFA, E., **ABB no Sustainable Energy Markets,** Universitá di Brescia, 2002.
- MANWELL, F.; JON, G. **Lead acid battery storage model for hybrid energy systems.** Solat Energy, vol. 50, no. 5, pp. 399–405, 1993.

- MARQUEZ, R.; COIMBRA, C. F. M. **Forecasting of global and direct solar irradiance using stochastic learning methods, ground experiments and the NWS database.** Solar Energy, vol. 85, no. 5, pp. 746–756, 2011.
- MCKINNON, E. C. **Storage batteries: A review of their application.** IEEE Electrical Engineers, Journal of the Institution, Vol. 87, Issue:525, pp.225-242, 1940.
- MELLIT, A.; PAVAN, A. M. **A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy.** Solar Energy, vol. 84, no. 5, pp. 807–821, 2010.
- MENTASCHI, L.; BESIO, G.; CASSOLA, F.; MAZZINO, A. **Problems in RMSE-based wave model validations.** Ocean Model, vol. 72, pp. 53–58, 2013.
- MOLINA, M. G. **Distributed Energy Storage Systems for Applications in Future Smart Grids.** IEEE Transmission and Distribution Latin America Conference and Exposition (T&D-LA), Sixth IEEE/PES, pp. 1–7, 2012.
- MONTICELLI, A. J. **Fluxo de carga em redes de energia elétrica.** São Paulo: Edgard Blücher, 1983.
- MONTEIRO, R. V. A.; GUIMARÃES, G. C.; MOURA, F. A. M.; ALBERTINI, M. R. M. C.; ALBERTINI, M. K. **Estimating photovoltaic power generation: Performance analysis of artificial neural networks, Support Vector Machine and Kalman Filter.** Elect. Power Sys. Res., vol. 143, Novembro, 2016
- MOUCHOT, A. **Refletor Cônico Truncado,** Exposição Universal de Paris em 1872.
Autor desconhecido. Imagem disponível em <http://landartgenerator.org/blagi/archives/2004>. Acessado em 15 jan. 2016.
- MÜLLER, H. H. **Redes Neurais Artificiais Aplicadas a Sistemas de Potência.** Tese de Doutorado, Universidade Estadual de Campinas, 2008.
- NAING, L. P.; SRINIVASAN, D. **Estimation of solar power generating capacity.** IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems (PMAPS), pp. 95–100, 2010.
- NAZARIPOUYA, H.; WANG, Y.; CHU, P.; POTA, H. R.; GADH, R. **Optimal sizing and placement of battery energy storage in distribution system based on solar size**

- for voltage regulation.** IEEE Power & Energy Society General Meeting, 2015, pp. 1 - 5.
- NOURI, S.; JADID, S. **Comparison of Loss Allocation Methods Using Particle Swarm Optimization.** IEEE 40th North American Power Symposium, pp. 1–8.
- NUNES, J., U., N.; BRETAS, A. S. **Alocação ótima de reguladores de tensão em sistemas de distribuição baseada em busca Tabu.** Simpósio brasileiro de sistemas elétricos – SBSE, 2016.
- OLATOMIWA, L.; MEKHILEF, S.; SHAMSHIRBAND, S.; MOHAMMADI, K.; PETKOVIĆ, D.; SUDHEER, C. **A support vector machine–firefly algorithm-based model for global solar radiation prediction.** Sol. Energy, vol. 115, pp. 632–644, 2015.
- Operador Nacional do Sistema Elétrico. **Situação dos Principais Reservatórios do Brasil 27/01/2015** [online]. 2015. Disponível em http://www.ons.org.br/tabela_reservatorios/conteudo.asp. Acesso em 27 jan. 2016.
- PULIPAKA, S.; MANI F.; KUMAR R. **Modeling of soiled PV module with neural networks and regression using particle size composition.** Sol. Energy 123, pp. 116–126, 2016.
- RITZ, R.; STREIBIG, J. C. **Nonlinear Regression with R.** 1 ed., Springer, 2008.
- RIEDMILLER, M.; BRAUN, H. **A direct adaptive method for faster backpropagation learning: the RPROP algorithm.** IEEE International Conference on Neural Networks , vol 1, pp. 586–591, 1993.
- RODRIGUES, F.F.C. **Programação de Contratação de Energia Considerando Geração Distribuída como Novo Modelo do Setor Elétrico Brasileiro.** Dissertação de Mestrado Universidade Federal do Rio de Janeiro, Rio de Janeiro - RJ, 2006.
- RODRÍGUEZ, C. R. C. **Mecanismos Regulatórios, Tarifários e Econômicos na Geração Distribuída: o Caso dos Sistemas Fotovoltaicos Conectados à Rede.** Dissertação de Mestrado, Universidade Estadual de Campinas, Campinas – SP, 2002.

ROSS, M.; HIDALGO, R.; ABBEY, C.; MODEL, A. M. **Analysis of Energy Storage Sizing and Technologies.** IEEE Electric Power and Energy Conference (EPEC), pp. 1 - 6, 2010.

SANTOS, F. A., SANTOS, F. M., **Geração distribuída versus centralizada.** Revista Millenium, N° 35, 2008.

SARFI, R. J.; SALAMA M. M. A.; CHIKHANI, A. Y. **Distribution system reconfiguration for loss reduction: a new algorithm based on a set of quantified heuristic rules.** Electrical and Computer Engineering, Conference Proceedings. 1994, Pages: 125 -130 vol.1.

SEVERINO, M. M., **Avaliação técnico-econômica de um sistema híbrido de geração distribuída para atendimento a comunidades isoladas da Amazônia.** Tese de Doutorado, Universidade de Brasília, 2008.

SINGH, M.; LOPES, L. A. C.; NINAD, N. A. **Grid forming Battery Energy Storage System (BESS) for a highly unbalanced hybrid mini-grid.** Electric Power Systems Research, vol. 127, pp. 126–133, jun. 2015.

SKOPLAKI, E.; BOUDOUVIS, A. G.; PALYVOS, J. A. **A simple correlation for the operating temperature of photovoltaic modules of arbitrary mounting.** Solar Energy Materials & Solar Cells, vol. 92, no. 11, pp. 1393–1402, jul. 2008.

SOARES, T.; PEREIRA, F.; MORAIS, H.; VALE, Z. **Cost allocation model for distribution networks considering high penetration of distributed energy resources.** Electric Power Systems Research, vol. 124, pp. 120–132, 2015.

Solar Motor Company. ENEAS, Aubrey G. **Solar Generator.** Número 670917. 20 ago. 1900; 26 mar. 1901. US670917-A 5p.

SOLIMAN, H. M.; LEON-GRACIA, A. **Game-theoretic demand-side management with storage devices for the future smart grid.** IEEE Transactions on Smart Grid, vol. 5, no. 3, pp. 1475–1485, mai. 2014.

SOON K.; MOO, C.; CHEN, Y.; HSIEH, Y. **Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries,** Appl. Energy, pp. 1506–1511, 2009.

- SOUZA, S. S. F.; ROMERO, R.; PEREIRA, J.; SARAIVA, J. T. **Reconfiguration of radial distribution systems with variable demands using the clonal selection algorithm and the specialized genetic algorithm of Chu-Beasley**, J. Control Autom. Electr. Syst. pp. 689-701, 2016a.
- SOUZA, S. S. F.; ROMERO, R.; PEREIRA, J.; SARAIVA, J. **Artificial immune algorithm applied to distribution systems reconfiguration with variable demand**, Int. J. Elect. Power Sys. pp. 561-568, 2016b.
- STRICKLAND, D.; BAI, X. **Sizing energy storage on the 11 kV distribution network**. Conference on Power Electronics, Machines and Drives (PEMD 2014), 7th IET International, pp. 1 - 6, 2014.
- TANDON A.; SAXENA, D. **Optimal Reconfiguration of Electrical Distribution Network Using Selective Particle Swarm Optimization Algorithm**. IEEE International Conference on Power, Control and Embedded Systems (ICPCES), pp. 1 - 6, 2014.
- TRIGOSO, F. M., QUAGLIA, R. B., MORAES, A. M., OLIVEIRA, S. H. F. **Panorama de geração distribuída no brasil utilizando a tecnologia solar fotovoltaica**. Florianópolis - SC: 2008.
- TURKSON, W., WOHLGEMUTH, N. **Power sector reforms and distributed generation in sub-saharan africa**, Energy Policy, vol. 29, pp. 134-145, 2001.
- TZENG, Y.-M.; HO, S.-Y. **To Approach Minimum Losses of the Distribution Systems by Artificial Neural Networks**. First International Conference on Innovation Computer and Information Control, vol. 1, pp. 6–9, 2006.
- UFU - Universidade Federal de Uberlândia. **A cidade de Uberlândia**. Disponível em <http://www0.ufu.br/catalogo_novo/idiomas/pt/cidade.htm>. Acesso em Jan. 2016.
- UJFALUDI, L. **A Napenergia-Hasznosítás Rövid Története**. 2003. Universidade Charles Esterhazy, Eger. Imagem disponível em: <http://fizikaiszemle.hu/archivum/fsz0303/ujfal0303.html>. Acessado em 15 jan. 2016.
- Um breve histórico do uso da Energia Solar. Universidade de São Paulo. Centro de Ensino e Pesquisa Aplicada. [online]. 2009. Disponível em: <http://www.cepa.if.usp.br/energia> Acesso em: 15 jan. 2015.

- WAHAB, A. A. **Artificial neural network-based prediction technique for transformer oil breakdown voltage.** Electric Power system Research, vol. 71, no. 1, pp. 73–84, 2004.
- WANG, D.; GE, S.; JIA, H.; WANG, C.; ZHOU, Y.; LU, N.; KONG, X. **A demand response and battery storage coordination algorithm for providing microgrid Tie-Line smoothing services.** IEEE Transactions on Sustainable Energy, vol. 5, no. 2, pp. 476–486, abr. 2014.
- WANG, Y.; DVORKIN, Y.; BLANCO, R. F.; XU, B.; QIU, T.; KIRSCHEN, S. D. **Look-ahead bidding strategy for energy storage.** IEEE Transactions on Sustainable Energy. vol. 8, no 3., pp. 1106-111,7 jul. 2017.
- WATRIN, N.; BLUNIER, B.; MIRAOUI, A. **Review of adaptive systems for lithium batteries State-of-Charge and State-of-Health estimation.** IEEE Transportation Electrification Conference and Expo (ITEC), no. 3, pp 1-6, 2012.
- WILLIS, H. L., SCOTT, W. G. **Distributed Power Generation: Planning and Evaluation.** CRC Press, 2000.
- WordPress. **Nothing new under the sun?** 2010. SHUMAN, Frank e BOYS, Charles Vernon, imagem disponível em <https://ruins.wordpress.com/2010/05/04/nothing-new-under-the-sun-solar-heatings-philadelphia-story/>. Acessado em 15 jan. 2016.
- WU, W.; TSAI, M.; HSU, F. **A New Binary Coding Particle Swarm Optimization for Feeder Reconfiguration.** Intelligent Systems Applications to Power Systems -ISAP pp 1- 6, 2007.
- XU, H.; HUIMING, L.; JIE, L. **Research on application of Artificial Neural Network in the network loss calculation of power system.** IEEE Conference on Cybernetics Intelligence Systems, pp. 318–320, 2008.
- YOSHIDA, H.; KAWATA, K.; FUKUYAMA, Y.; TAKAYAMA, S.; NAKANISHI, Y. **A Particle Swarm Optimization for reactive power and voltage control considering voltage security.** IEEE Transactions on Power Systems, vol. 15, no. 4, pp. 1232–1239, 2000.

ZHANG, H.; XU, F.; ZHOU, L. **Artificial Neural Network for load forecasting in smart grid.** International Conference on Machine Learning and Cybernetics, no. July, pp. 11–14, 2010.

ZHAO, B.; GUO, C. X.; CAO, Y. J. **Improved Particle Swam Optimization Algorithm for OPF Problems.** IEEE Power Systems Conference and Exposition - PES, pp. 233 - 238.

APÊNDICE A

A.1 Representação por grafos

Diversas situações podem ser representadas por meio de diagramas formados por um conjunto de pontos e linhas que os ligam. Por exemplo, os pontos podem ser as esquinas de uma cidade e as linhas as ruas; os pontos podem ser cidades e as linhas as rotas aéreas feitas por aviões; ou ainda, os pontos podem ser as barras de um sistema elétrico e as linhas, as suas linhas de transmissão ou distribuição. A abstração matemática de situações desse tipo dá lugar ao conceito de grafo.

Um dos meios mais práticos de se representar um sistema de distribuição radial (SDR) é por meio de cadeias de grafos. Um sistema de distribuição de energia elétrica, devido à sua radialidade, pode ser representado por uma floresta de grafos. Nesta seção é apresentada introdução à teoria dos grafos e apresentado um método simples de se representar computacionalmente um sistema radial utilizando essa técnica.

A.1.1 Teoria dos grafos

Segundo Lucchesi (1979), um grafo G consiste de um conjunto finito de elementos chamados vértices $V(G)$, um conjunto de $A(G)$ de elementos chamados arestas, uma função de incidência φ_G que associa cada aresta α de G a um par não ordenado de vértices (não necessariamente distintos) de G , chamados de extremos de α .

Grafos podem ser representados por diagramas, onde cada vértice é representado por um ponto e cada aresta por uma linha ligando os pontos que representam seus extremos, figura A.1.

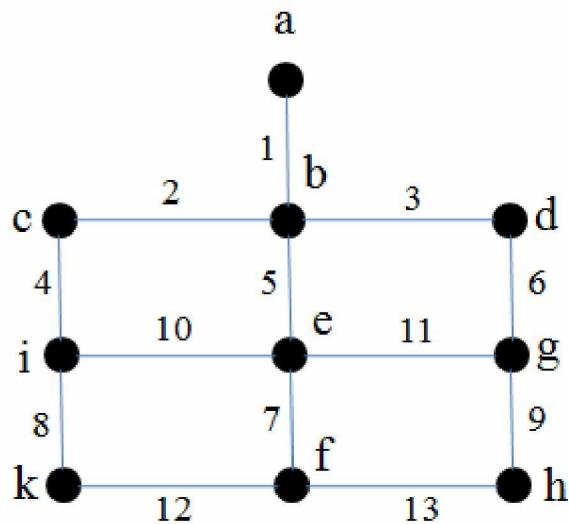


Figura A.1 - Exemplo de um diagrama representando um grafo G.

Fonte: (O autor, 2016).

Analizando a figura A.1, por definição tem-se que se c e b são dois vértices do grafo, e a ligação entre o par $\{c, b\}$ forma uma aresta, diz-se que essa aresta conecta c e b . Uma aresta é um laço se seus extremos coincidem, uma ligação caso contrário.

O grau $g_G(v)$ de um vértice v num grafo G corresponde ao número de arestas que incidem em v . Na figura A.1, o grau do vértice b é 4.

Uma sequência de arestas de um grafo G , se todas as arestas forem diferentes, é chamado caminho. Se os nós desse grafo são distintos, esse caminho é chamado cadeia. Se os nós são iguais, esse caminho é chamado de ciclo. A tabela A. 1 representa um grafo por meio de diagrama.

Tabela A. 1 - Um grafo G, figura A. 1, e suas representações em diagrama

a	$\phi G(a)$	a	$\phi G(a)$	a	$\phi G(a)$
1	{a, b}	7	{e, f}	13	{f, h}
2	{c, b}	8	{i, k}		
3	{b, d}	9	{g, h}		
4	{c, i}	10	{i, e}		
5	{b, e}	11	{e, g}		
6	{d, g}	12	{k, f}		

A tabela A. 2 apresenta exemplos de caminho, cadeia e ciclo com os respectivos vértices que os formam.

Tabela A. 2 - Exemplos de caminho, cadeia, ciclo e seus respectivos pares de vértices.

Exemplos	Pares de vértices
Caminho	$\{a, b\}, \{b, c\}, \{c, i\}, \{i, k\}, \{k, f\}$
Cadeia	$\{a, b\}, \{b, c\}, \{c, i\}$
Ciclo	$\{b, c\}, \{c, i\}, \{i, e\}, \{e, b\}$

Um grafo simples é aquele que não contém laços nem duas ligações distintas com o mesmo par de extremos.

Um grafo completo é um grafo simples em que quaisquer dois vértices distintos são adjacentes. A figura A. 1 representa um grafo completo.

A.1.2 Técnica para verificação da radialidade do SDR

Tomando-se como exemplo o grafo da figura A. 1 de maneira a considerar que cada vértice seja uma barra e cada aresta uma linha de um sistema de distribuição, o primeiro passo é obter o mapeamento das linhas relacionado suas barras terminais e de origem. Para isso a nomenclatura dos vértices e arestas foram substituídas por números, para facilitar a compreensão do método, resultando na figura A. 2.

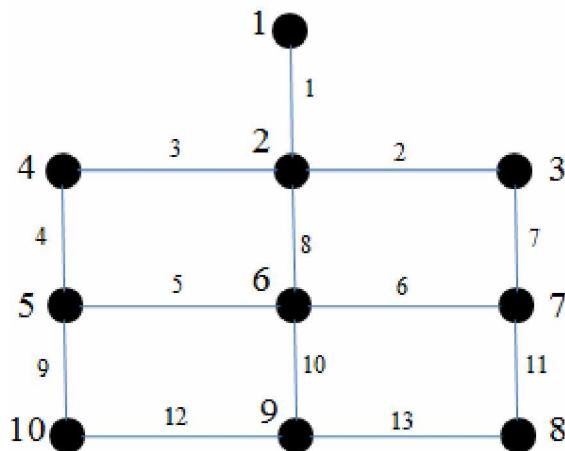


Figura A. 2 - Representação de um sistema elétrico malhado.
Fonte: (O autor, 2016).

Para determinar a conectividade de cada uma das barras, lança-se mão da tabela A. 3.

Tabela A. 3 - Conectividade das barras do sistema representado na figura A. 2.

Linha	Barra inicial	Barra final
1	1	2
2	2	3
3	2	4
4	4	5
5	5	6
6	6	7
7	3	7
8	2	6
9	5	10
10	6	9
11	7	8
12	10	9
13	9	8

A partir desse ponto é utilizado o conceito de matriz Adjacência e matriz Laplaciana (BROOKS e BAROOAH, 2016) e chamaremos o grafo representado pela figura A. 2 de G.

Dado o grafo $G = (V, E)$ com n vértices, a matriz de adjacência de G é a matriz de ordem n dada por $A(G) = [a_{ij}]$, onde $a_{ij} = 1$ se $v_i v_j \in E$, sendo E a energia do grafo, e $a_{ij} = 0$ nas entradas restantes.

A matriz Laplaciana de G é a matriz de ordem n dada por $L(G) = [l_{ij}]$, onde $l_{ij} = -1$ se $v_i v_j \in E$, $l_{ii} = d(v_i)$ e $l_{ij} = 0$ nas entradas restantes. A matriz Laplaciana e a matriz adjacência se relacionam da seguinte forma:

$$L = D - A$$

Onde D é a matriz diagonal com o grau dos vértices. Como forma de exemplificar essa teoria, o exemplo a seguir é dado.

A matriz a é formada de maneira que suas linhas e colunas correspondam ao número de barras do sistema, obtendo-se assim, uma matriz quadrada. Neste caso específico tem-se uma matriz 10×10 . Atribui-se o valor -1 para indicar a conectividade entre as barras. As barras que não possuem conectividade entre si recebem o valor 0. Por exemplo, na matriz a os elementos a_{ij} , sendo i a coluna e j a linha, onde $i = 2$ e $j = 3$, a_{23} , é atribuído o valor -1, indicando a conectividade entre as barras 2 e 3. Já em a_{210} , é atribuído o valor 0, uma vez que a barra 2 não tem conectividade com a barra

10. Esse processo é feito para todas as barras e, por fim, os valores atribuídos em cada coluna da matriz a , são somados e armazenados na diagonal principal correspondente a cada barra. Para a compreensão desse conceito é feito um exemplo.

Considerando que nenhuma linha esteja aberta, a matriz a teria da seguinte composição, figura A. 3:

$$a = \begin{vmatrix} -1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -1 & -4 & -1 & -1 & 0 & -1 & 0 & 0 & 0 & 0 \\ 0 & -1 & -2 & 0 & 0 & 0 & -1 & 0 & 0 & 0 \\ 0 & -1 & 0 & -2 & -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1 & -3 & -1 & 0 & 0 & 0 & -1 \\ 0 & -1 & -1 & 0 & -1 & -4 & -1 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1 & -3 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & -1 & -2 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1 & 0 & -1 & -3 & -1 \\ 0 & 0 & 0 & 0 & -1 & 0 & 0 & 0 & -1 & -2 \end{vmatrix}$$

Figura A. 3 - Matriz a para o caso de todas as linhas ativas

Fonte: (O autor, 2016).

Verifica-se que as somas dos valores armazenados às colunas correspondentes à cada barra foram somadas e atribuídas a diagonal principal da matriz.

Agora, considere que a linha 2 e a linha 6, do sistema representado na figura A. 3, sejam retiradas da configuração. A matriz a passaria então a ter a composição conforme a figura A. 4.

Por meio da figura A. 4 pode-se visualizar, nos elementos destacados, que os valores atribuídos às diagonais principais correspondentes às barras que as linhas retiradas estavam conectadas, obtiveram uma redução nos seus valores. Isso ocorre porque de acordo com o método utilizado, as posições a_{23} , a_{32} , a_{67} e a_{76} foram zeradas representando a desconexão das linhas 2 e 6, respectivamente.

$$a = \begin{vmatrix} -1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -1 & -3 & 0 & -1 & 0 & -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 & 0 & -1 & 0 & 0 & 0 \\ 0 & -1 & 0 & -2 & -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1 & -3 & -1 & 0 & 0 & 0 & -1 \\ 0 & -1 & -1 & 0 & -1 & -3 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & -2 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & -1 & -2 & -1 & 0 \\ 0 & 0 & 0 & 0 & -1 & 0 & 0 & -1 & -3 & -1 \\ 0 & 0 & 0 & 0 & -1 & 0 & 0 & 0 & -1 & -2 \end{vmatrix}$$

Figura A. 4 - Matriz a para o caso das linhas 2 e 6 inativas ou abertas.

Fonte: (O autor, 2016).

A factibilidade consiste então, em detectar quais configurações da matriz a são permitidas e quais não são para que o sistema seja solucionável ou factível.

Sendo assim, uma verificação imediata que pode-se ter é para o caso de alguma diagonal principal apresentar valor 0. Isto significaria que a barra correspondente àquela coluna está isolada. O sistema, então, perderia sua radialidade e, portanto, uma solução com essa configuração não seria factível. Quanto maior a complexidade do sistema maior será o número de análises e casos a serem observados, levando a possíveis métodos iterativos.

APÊNDICE B***ARTIGOS PUBLICADOS RELATIVOS AO TEMA DA TESE***

- 1) MONTEIRO, R. V. A.; GUIMARÃES, GERALDO C.; SILVA, A. M. B.; TAMASHIRO, M. A.; SILTA, F. B. Three - Phase Analysis of Active Losses on Conventional and Compact Distribution Networks. IEEE Latin America Transactions. v.15, p.682 - 689, 2017.
- 2) SILVA, T. V.; MONTEIRO, RAUL V.A.; GUIMARAES, G. C.; MOURA, F. A. M.; ALBERTINE, M. M. C.; TAMASHIRO, M. A. Performance Analysis of Neural Network Training Algorithms and Support Vector Machine for Power Generation Forecast of Photovoltaic Panel. IEEE Latin America Transactions. v.15, p.1091 - 1100, 2017.
- 3) MONTEIRO, R. V. A., GUIMARÃES, G. C., MOURA, F. A. M., ALBERTINI, M. R. M. C., SILVA, F. B. Long-term sizing of lead-acid batteries in order to reduce technical losses on distribution networks: A distributed generation approach. Electric Power Systems Research, 144, 163–174. 2016.
- 4) MONTEIRO, R. V. A., GUIMARÃES, G. C., MOURA, F. A. M., ALBERTINI, M. R. M. C., ALBERTINI, M. K. Estimating photovoltaic power generation: Performance analysis of artificial neural networks, Support Vector Machine and Kalman filter. Electric Power Systems Research, 143, 643–656. 2016.
- 5) MONTEIRO, R. V. A.; GUIMARAES, G. C.; TAMASHIRO, M. A.; MOURA, F. A. M.; ALBERTINE, M. M. C. Avaliação de algoritmos de treinamento para redes neurais artificiais para previsão temporal de geração fotovoltaica. Ingeniería Energética. 2016.
- 6) DIAS, P. H. A.; GUIMARÃES, G. C.; MONTEIRO, R. V. A.; PICCINI, A. T. Análise de Perdas em Linhas de Distribuição Convencional e Compacta. XIV Conferência de Estudos em Engenharia Elétrica - CEEL, 2016. Uberlândia - MG.
- 7) NEVES, D. P.; RODRIGUES, L. M. R.; MONTEIRO, R. V. A.; SILVA, L. R. C.; GUIMARÃES, G. C. Desenvolvimento de Interface em Matlab para a Previsão do Comportamento de um Sistema Elétrico com Penetração

Fotovoltaica Utilizando Inteligência Artificial. XIV Conferência de Estudos em Engenharia Elétrica - CEEL, 2016. Uberlândia - MG.

ANEXO A

Apesar do MATLAB® possuir interface gráfica por meio do comando "nntool", foi criada uma interface gráfica mais amigável para a utilização da rede NARX com o objetivo de realizar previsões temporais de dados. Esta interface foi feita via um projeto de pesquisa PIBIC com o auxílio do que foi absorvido na pesquisa apresentada aqui.

Para a construção da interface gráfica foi utilizada uma função do *software* MATLAB® conhecida como GUI (*Graphical User Interface*) capaz de fornecer ao usuário uma gama de recursos para que este tenha liberdade de criar interfaces das mais variadas formas. O protótipo da interface desenvolvida neste trabalho pode ser visualizado na figura AN 1.

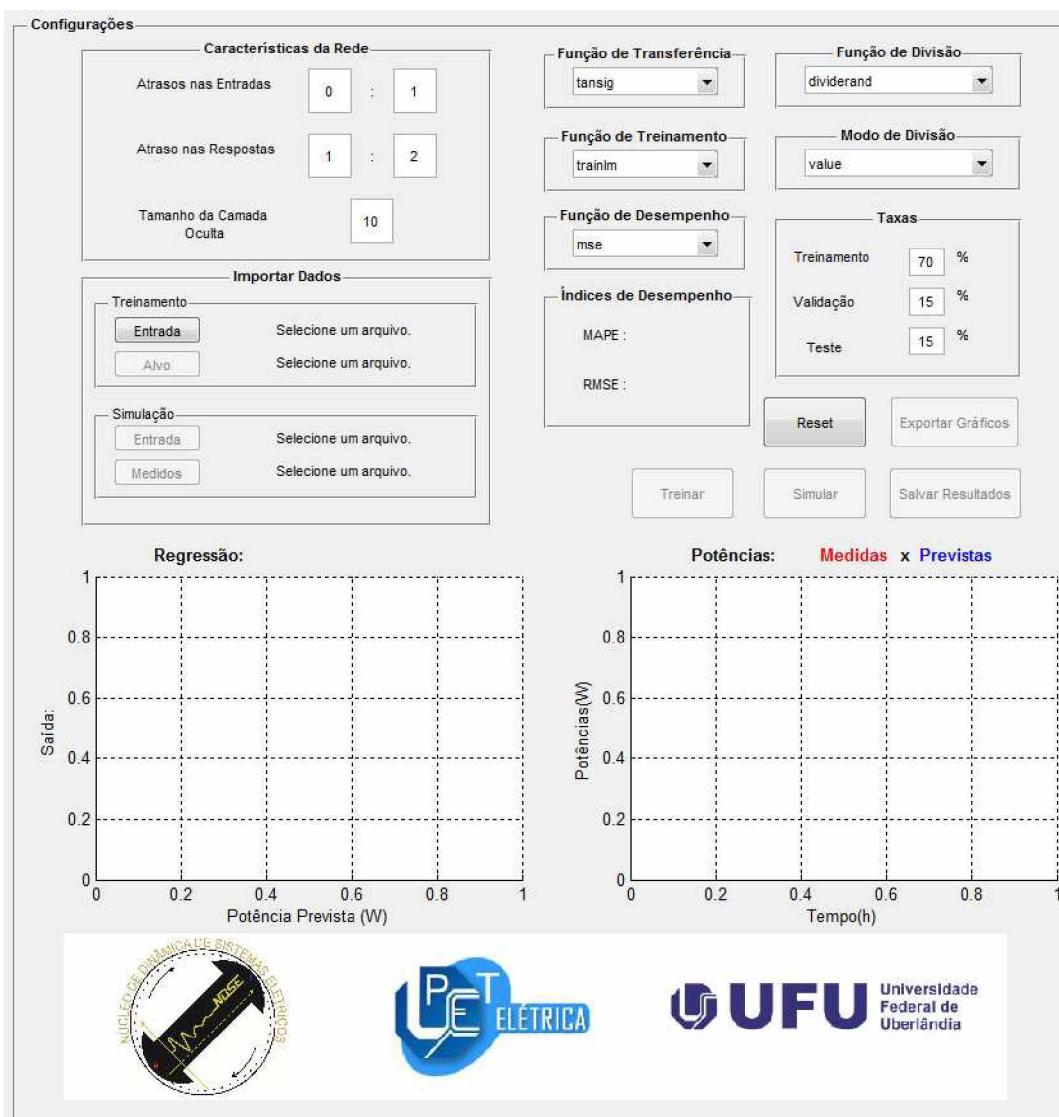


Figura AN 1 - Interface construída.

No emprego das RNA's é necessário especificar o intervalo de valores de atrasos das entradas e saídas, sendo estes atrasos, necessários para realizar a retroalimentação da rede NARX. Além disso, é necessário se especificar um algoritmo de treinamento o qual é responsável por ajustar os pesos e limiares para a realização da estimação. O *software* disponibiliza uma lista de funções de treinamento, cabendo ao usuário escolher a que lhe convém.

Para verificação do desempenho da rede é necessário utilizar uma função de desempenho, as quais o *software* possui uma lista para a escolha do usuário. A interface tem como padrão a função MSE (*Mean Squared Error*), que verifica o desempenho através do erro médio quadrático entre os valores desejados (alvos) e a saída da estimação.

Para aperfeiçoar o processo de treinamento da rede, é necessária uma divisão dos dados com valores desejados (alvos) onde, para esta operação, necessita-se utilizar uma função de divisão. O objetivo desta função é dividir os alvos em três subgrupos. O primeiro subgrupo é o conjunto de treinamento que atualiza os pesos e *biases* da rede e calcula o gradiente (necessário para se fazer as atualizações). O segundo subgrupo é o conjunto de validação e o último é destinado a realizar testes na rede.

O *software* disponibiliza alguma dessas funções sendo a padrão, a função conhecida como "dividerand", que divide os alvos aleatoriamente para uma taxa de valores em que será dividido cada subgrupo, sendo estes valores, inseridos pelo próprio usuário. Depois de feita a escolha da função que dividirá os alvos em subgrupos, é necessário definir qual modo será utilizado para se fazer esta divisão. O *software* permite fazer a divisão dos dados de acordo com um conjunto de amostras, ou através do valor de cada dado, ou de acordo com intervalos de tempo, sendo o padrão o valor dos dados.

Com todos os parâmetros selecionados o usuário é capaz de realizar o treinamento da rede neural, por meio do botão 'Treinar'. Por meio do botão 'Entrada' no espaço 'Treinamento', se inserem os dados de entrada da rede. No botão 'Alvos' no mesmo espaço, se inserem os dados de saída compatíveis com os de entrada da rede. Com a rede treinada, é necessário que o usuário insira novos dados de entrada para realizar a simulação (por meio do botão 'Entrada' no espaço 'Simulação'). Feita a simulação o software irá gerar um arquivo de saída contendo os valores de potência previstos para aquele conjunto de dados de entrada. Como forma de se comparar os dados de previstos com os medidos para aquele período desejado, o usuário por meio do

botão 'Medidos', pode adicionar os dados medidos para o período previsto e comparar com os dados previstos pela rede neural. Também será gerado um gráfico demonstrando como a potência se comporta ao longo do tempo.

A interface possui uma ferramenta de comparação entre os valores de potência previstos e os valores medidos reais em campo. Assim que carregado, o *software* irá fazer uma regressão linear e uma comparação gráfica entre os valores medidos e previstos conforme mostrados nas figuras AN 2 e AN 3 que demonstram um exemplo da utilização da rede.

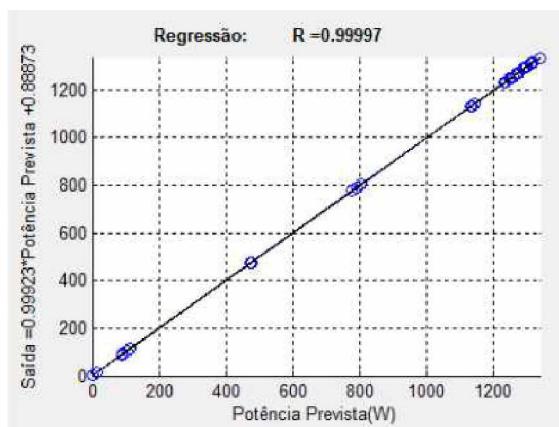


Figura AN 2 - Regressão linear entre potências medidas e previstas.

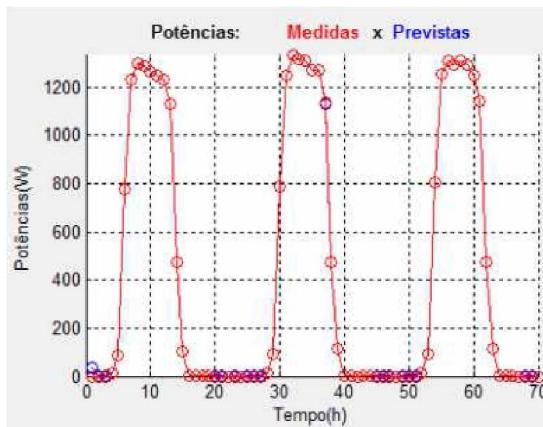


Figura AN 3 - Comparação gráfica entre potências medidas e previstas.

Além disso, a interface tem a função de exportar estes gráficos para outra tela permitindo ao usuário uma maior liberdade para manipular os gráficos da maneira que desejar. Esta função pode ser verificada na figura AN 4.

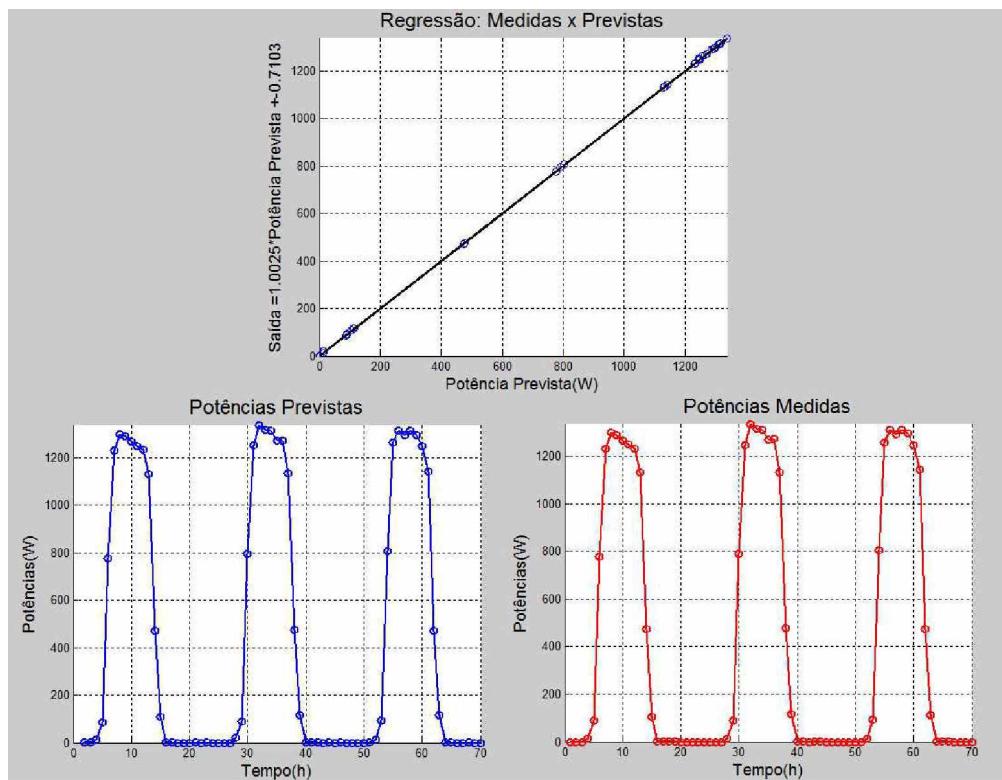


Figura AN 4 - Gráficos gerados a partir do botão exportar gráficos.

Caso queira, o usuário também pode salvar os dados de potência previstas em seu computador num formato de tabela para ser aberto no Excel, através do botão 'Salvar Resultados'.

A interface ainda tem um espaço onde apresentam dados estatísticos entre os resultados medidos em campo e os previstos pela RNA. Esses dados podem ser vistos no espaço 'Índices de Desempenho'.

ANEXO B

Tabela ANB 1 - Dados de carga do sistema teste IEEE 37 barras.

Barra	Fase A	Fase A	Fase B	Fase B	Fase C	Fase C
	kW	kVAr	kW	kVAr	kW	kVAr
701	140	70	140	70	350	175
712	0	0	0	0	85	40
713	0	0	0	0	85	40
714	17	8	21	10	0	0
718	85	40	0	0	0	0
720	0	0	0	0	85	40
722	0	0	140	70	21	10
724	0	0	42	21	0	0
725	0	0	42	21	0	0
727	0	0	0	0	42	21
728	42	21	42	21	42	21
729	42	21	0	0	0	0
730	0	0	0	0	85	40
731	0	0	85	40	0	0
732	0	0	0	0	42	21
733	85	40	0	0	0	0
734	0	0	0	0	42	21
735	0	0	0	0	85	40
736	0	0	42	21	0	0
737	140	70	0	0	0	0
738	126	62	0	0	0	0
740	0	0	0	0	85	40
741	0	0	0	0	42	21
742	8	4	85	40	0	0
744	42	21	0	0	0	0
Total	727	357	639	314	1091	530

Tabela ANB 2 - Impedâncias próprias utilizadas nas simulações. Sistema IEEE 37 barras modificado.

De	Para	Zaa (Ω/km)	Zbb (Ω/km)	Zcc (Ω/km)
701	702	0,0287+j*0,0180	0,0271+j*0,0162	0,0287+j*0,0180
702	705	0,0528+j*0,0195	0,0531+j*0,0186	0,0528+j*0,0195
702	713	0,0293+j*0,0152	0,0295+j*0,0143	0,0293+j*0,0152
702	703	0,0395+j*0,0247	0,0373+j*0,0223	0,0395+j*0,0247
703	727	0,0317+j*0,0117	0,0319+j*0,0112	0,0317+j*0,0117

703	730	0,0489+j*0,0254	0,0492+j*0,0239	0,0489+j*0,0254
704	714	0,0106+j*0,0039	0,0106+j*0,0037	0,0106+j*0,0039
704	720	0,0652+j*0,0338	0,0656+j*0,0319	0,0652+j*0,0338
705	742	0,0422+j*0,0156	0,0425+j*0,0149	0,0422+j*0,0156
705	712	0,0317+j*0,0117	0,0319+j*0,0112	0,0317+j*0,0117
706	725	0,0370+j*0,0137	0,0372+j*0,0130	0,0370+j*0,0137
707	724	0,1003+j*0,0371	0,1009+j*0,0354	0,1003+j*0,0371
707	722	0,0158+j*0,0059	0,0159+j*0,0056	0,0158+j*0,0059
708	733	0,0261+j*0,0135	0,0262+j*0,0128	0,0261+j*0,0135
708	732	0,0422+j*0,0156	0,0425+j*0,0149	0,0422+j*0,0156
709	731	0,0489+j*0,0254	0,0492+j*0,0239	0,0489+j*0,0254
709	708	0,0261+j*0,0135	0,0262+j*0,0128	0,0261+j*0,0135
710	735	0,0264+j*0,0098	0,0265+j*0,0093	0,0264+j*0,0098
710	736	0,1689+j*0,0625	0,1699+j*0,0596	0,1689+j*0,0626
711	741	0,0326+j*0,0169	0,0328+j*0,0159	0,0326+j*0,0169
711	740	0,0264+j*0,0098	0,0265+j*0,0093	0,0264+j*0,0098
713	704	0,0424+j*0,0222	0,0427+j*0,0207	0,0424+j*0,0220
714	718	0,0686+j*0,0254	0,0690+j*0,0242	0,0686+j*0,0254
720	707	0,1214+j*0,0450	0,1221+j*0,0429	0,1214+j*0,0450
720	706	0,0489+j*0,0254	0,0492+j*0,0239	0,0489+j*0,0254
727	744	0,0684+j*0,0355	0,0230+j*0,0111	0,0228+j*0,0118
730	709	0,0163+j*0,0085	0,0164+j*0,0080	0,0163+j*0,0085
733	734	0,0456+j*0,0237	0,0459+j*0,0223	0,0456+j*0,0237
734	737	0,0522+j*0,0271	0,0525+j*0,0255	0,0522+j*0,0271
734	710	0,0686+j*0,0254	0,0690+j*0,0242	0,0686+j*0,0254
737	738	0,0326+j*0,0169	0,0328+j*0,0159	0,0326+j*0,0169
738	711	0,0326+j*0,0169	0,0328+j*0,0159	0,0326+j*0,0169
744	728	0,0264+j*0,0098	0,0265+j*0,0093	0,0264+j*0,0098
744	729	0,0370+j*0,0137	0,0372+j*0,0130	0,0370+j*0,0137
799	701	0,0341+j*0,0230	0,0308+j*0,0221	0,0341+j*0,0230

Tabela ANB 3 - Impedâncias mútuas utilizadas nas simulações. Sistema IEEE 37 barras modificado.

De	Para	Zab (Ω/km)	Zac (Ω/km)	Zcb (Ω/km)
701	702	0,0099-j*0,0020	0,0075-j*0,0037	0,0099-j*0,0020
702	705	0,0131+j*0,0069	0,0124+j*0,0053	0,0131+j*0,0069
702	713	0,0110+j*0,0048	0,0104+j*0,0034	0,0110+j*0,0048
702	703	0,0135-j*0,0027	0,0103-j*0,0050	0,0135-j*0,0027
703	727	0,0079+j*0,0041	0,0074+j*0,0032	0,0079+j*0,0041
703	730	0,0184+j*0,0080	0,0173+j*0,0057	0,0184+j*0,0080
704	714	0,0026+j*0,0014	0,0025+j*0,0011	0,0026+j*0,0014
704	720	0,0245+j*0,0106	0,0231+j*0,0077	0,0245+j*0,0106

705	742	0,0105+j*0,0055	0,0099+j*0,0043	0,0105+j*0,0055
705	712	0,0077+j*0,0041	0,0074+j*0,0032	0,0079+j*0,0041
706	725	0,0092+j*0,0048	0,0087+j*0,0037	0,0092+j*0,0048
707	724	0,0249+j*0,0131	0,0236+j*0,0101	0,0249+j*0,0131
707	722	0,0039+j*0,0021	0,0037+j*0,0016	0,0039+j*0,0021
708	733	0,0098+j*0,0043	0,0092+j*0,0031	0,0098+j*0,0043
708	732	0,0105+j*0,0055	0,0099+j*0,0043	0,0105+j*0,0055
709	731	0,0184+j*0,0080	0,0173+j*0,0057	0,0184+j*0,0080
709	708	0,0098+j*0,0043	0,0092+j*0,0031	0,0098+j*0,0043
710	735	0,0066+j*0,0034	0,0062+j*0,0027	0,0066+j*0,0034
710	736	0,0420+j*0,0221	0,0397+j*0,0171	0,0420+j*0,0221
711	741	0,0123+j*0,0053	0,0116+j*0,0038	0,0123+j*0,0053
711	740	0,0066+j*0,0034	0,0062+j*0,0027	0,0066+j*0,0034
713	704	0,0160+j*0,0069	0,0150+j*0,0050	0,0160+j*0,0069
714	718	0,0170+j*0,0090	0,0161+j*0,0070	0,0170+j*0,0090
720	707	0,0302+j*0,0159	0,0285+j*0,0123	0,0302+j*0,0159
720	706	0,0184+j*0,0080	0,0173+j*0,0057	0,0184+j*0,0080
727	744	0,0258+j*0,0111	0,0243+j*0,0080	0,0086+j*0,0037
730	709	0,0061+j*0,0027	0,0058+j*0,0019	0,0061+j*0,0027
733	734	0,0172+j*0,0075	0,0162+j*0,0054	0,0172+j*0,0074
734	737	0,0196+j*0,0085	0,0185+j*0,0061	0,0196+j*0,0085
734	710	0,0170+j*0,0090	0,0161+j*0,0070	0,0170+j*0,0090
737	738	0,0123+j*0,0053	0,0116+j*0,0038	0,0123+j*0,0053
738	711	0,0123+j*0,0053	0,0116+j*0,0038	0,0123+j*0,0053
744	728	0,0066+j*0,0034	0,0062+j*0,0027	0,0066+j*0,003
744	729	0,0092+j*0,0048	0,0087+j*0,0037	0,0092+j*0,0048
799	701	0,0078-j*0,0043	0,0039-j*0,0049	0,0078-j*0,0043

Tabela ANB 4 - Admitâncias próprias utilizadas nas simulações. Sistema IEEE 37 barras modificado.

De	Para	Yaa ($\mu\text{S}/\text{km}$)	Ybb ($\mu\text{S}/\text{km}$)	Ycc ($\mu\text{S}/\text{km}$)
701	702	23,24	23,24	23,24
702	705	4,56	4,56	4,56
702	713	5,1	5,1	5,1
702	703	31,96	31,96	31,96
703	727	2,74	2,74	2,74
703	730	8,5	8,5	8,5
704	714	0,91	0,91	0,91
704	720	11,34	11,34	11,34
705	742	3,65	3,65	3,65
705	712	2,74	2,74	2,74
706	725	3,2	3,2	3,2
707	724	8,67	8,67	8,67

707	722	1,37	1,37	1,37
708	733	4,54	4,54	4,54
708	732	3,65	3,65	3,65
709	731	8,5	8,5	8,5
709	708	4,54	4,54	4,54
710	735	2,28	2,28	2,28
710	736	14,61	14,61	14,61
711	741	5,67	5,67	5,67
711	740	2,28	2,28	2,28
713	704	7,37	7,37	7,37
714	718	5,93	5,93	5,93
720	707	10,5	10,5	10,5
720	706	8,5	8,5	8,5
727	744	3,97	3,97	3,97
730	709	2,83	2,83	2,83
733	734	7,94	7,94	7,94
734	737	9,07	9,07	9,07
734	710	5,93	5,93	5,93
737	738	5,67	5,67	5,67
738	711	5,67	5,67	5,67
744	728	2,28	2,28	2,28
744	729	3,2	3,2	3,2
799	701	55,99	55,99	55,99

Tabela ANB 5 - Admitâncias mútuas utilizadas nas simulações. Sistema IEEE 37 barras modificado.

De	Para	Yab ($\mu\text{S}/\text{km}$)	Yac ($\mu\text{S}/\text{km}$)	Ybc ($\mu\text{S}/\text{km}$)
701	702	0	0	0
702	705	0	0	0
702	713	0	0	0
702	703	0	0	0
703	727	0	0	0
703	730	0	0	0
704	714	0	0	0
704	720	0	0	0
705	742	0	0	0
705	712	0	0	0
706	725	0	0	0
707	724	0	0	0
707	722	0	0	0
708	733	0	0	0
708	732	0	0	0
709	731	0	0	0

709	708	0	0	0
710	735	0	0	0
710	736	0	0	0
711	741	0	0	0
711	740	0	0	0
713	704	0	0	0
714	718	0	0	0
720	707	0	0	0
720	706	0	0	0
727	744	0	0	0
730	709	0	0	0
733	734	0	0	0
734	737	0	0	0
734	710	0	0	0
737	738	0	0	0
738	711	0	0	0
744	728	0	0	0
744	729	0	0	0
799	701	0	0	0