

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ALOCÇÃO ÓTIMA DE PARQUES EÓLICOS EM SISTEMAS DE DISTRIBUIÇÃO
CONSIDERANDO INCERTEZAS DE VENTO E CARGA
UTILIZANDO ALGORITMO GENÉTICO

SEBASTIÃO BORGES FONSECA

DM: 31 / 2016

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2016

Dados Internacionais de Catalogação - na – Publicação (CIP) Sistema de
Bibliotecas da UFPA

Fonseca, Sebastião Borges, 1981-

Alocação ótima de parques eólicos em sistemas de distribuição considerando incertezas de vento e carga utilizando algoritmo genético / Sebastião Borges Fonseca.- 2016.

Orientador a: Carolina de Mattos Affonso

Dissertação (Mestrado) - Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2016.

1. Força eólica. 2. Turbinas eólicas. – métodos estatísticos. 3. Algoritmos genéticos. I. Título.

CDD 23. ed. 621.312136

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

SEBASTIÃO BORGES FONSECA

ALOCÇÃO ÓTIMA DE PARQUES EÓLICOS EM SISTEMAS DE DISTRIBUIÇÃO
CONSIDERANDO INCERTEZAS DE VENTO E CARGA
UTILIZANDO ALGORITMO GENÉTICO

DM: 31 / 2016

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2016

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

SEBASTIÃO BORGES FONSECA

ALOCÇÃO ÓTIMA DE PARQUES EÓLICOS EM SISTEMAS DE DISTRIBUIÇÃO
CONSIDERANDO INCERTEZAS DE VENTO E CARGA
UTILIZANDO ALGORITMO GENÉTICO

Dissertação submetida à Banca
Examinadora do Programa de Pós-
Graduação em Engenharia Elétrica da
UFPA para a obtenção do Grau de
Mestre em Engenharia Elétrica na
área de Computação Aplicada

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2016

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ALOCÇÃO ÓTIMA DE PARQUES EÓLICOS EM SISTEMAS DE DISTRIBUIÇÃO
CONSIDERANDO INCERTEZAS DE VENTO E CARGA
UTILIZANDO ALGORITMO GENÉTICO

AUTOR: SEBASTIÃO BORGES FONSECA

DISSERTAÇÃO DE MESTRADO SUBMETIDA À AVALIAÇÃO DA BANCA
EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-
GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO
PARÁ E JULGADA ADEQUADA PARA OBTENÇÃO DO GRAU DE MESTRE EM
ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA

APROVADA EM ____/____/____

BANCA EXAMINADORA:

Prof.^a Dr.^a Carolina de Mattos Affonso
(ORIENTADORA – PPGEE/UFPA)

Prof. Dr. Roberto Célio Limão de Oliveira
(COORDENADOR – PPGEE/UFPA)

Prof. Dr. João Paulo Abreu Vieira
(MEMBRO – PPGEE/UFPA)

Prof. Dr. Filipe de Oliveira Saraiva
(MEMBRO EXTERNO – PPGCC/UFPA)

VISTO:

Prof. Dr. Evaldo Gonçalves Pelaes
(COORDENADOR DO PPGEE/ITEC/UFPA)

DEDICATÓRIA

Dedico este trabalho ao meu pai Eloy Margalho Fonseca e à minha mãe Haydeé Borges Fonseca pelo amor e educação essenciais à minha formação.

AGRADECIMENTOS

Agradeço à minha esposa Medillin Borges por ter cuidado de mim com amor e disposição proporcionando companheirismo, compreensão e incentivo durante o desenvolvimento deste trabalho.

Aos meus pais Eloy Margalho e Haydeé Borges pela minha formação moral, educacional e por todo carinho e apoio que me confortaram nos momentos de maior dificuldade.

A toda minha família, em especial às minhas irmãs e irmãos pelo incentivo, confiança e orgulho que sempre expressaram a mim, principalmente minha irmã Danya Borges que acompanhou de perto esta trajetória.

Sou muito grato à minha orientadora, Prof.^a Dr.^a Carolina de Mattos Affonso, pela excelência na orientação, sendo sempre prestativa e compreensiva ao compartilhar seus conhecimentos e ensinamentos.

Ao meu coorientador Prof. Dr. Roberto Célio Limão de Oliveira por ter despertado em mim o interesse em aprofundar os estudos em inteligência computacional e pelas relevantes contribuições a esta pesquisa.

Aos amigos e colegas do Serpro que torceram por mim, em especial ao Francival Lima, Priscilla Lanne e Antônio Peixoto pelo incentivo e conselhos durante o mestrado.

Ao Serpro, através do corpo gerencial, pela flexibilidade de horário de trabalho e incentivo à educação.

Ao Programa de Pós-graduação em Engenharia Elétrica da UFPA (PPGEE/UFPA), em especial ao coordenador Prof. Dr. Evaldo Gonçalves Pelaes e aos professores do programa por compartilharem seus conhecimentos com qualidade, de modo inspirador e motivador visando o desenvolvimento dos alunos e as relevantes contribuições científicas.

Por fim, agradeço a Deus pelas leis que regem o Universo.

“O que importa são os incontáveis pequenos atos de pessoas desconhecidas, que fundam as bases para os eventos significativos que se tornam história.”

(Howard Zinn & Noam Chomsky)

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	1
1.1 Motivação	1
1.2 Objetivo	3
1.3 Revisão Bibliográfica	3
1.4 Estrutura da Dissertação	5
CAPÍTULO 2 - GERAÇÃO EÓLICA	6
2.1 Considerações Iniciais	6
2.2 Crescimento da Geração Eólica	6
2.3 Tecnologias de Aerogeradores.....	9
2.4 Tipos de Geradores.....	11
2.4.1 Gerador de Indução em Gaiola de Esquilo (GIGE).....	11
2.4.2 Gerador de Indução Duplamente Alimentado (GIDA)	12
2.4.3 Gerador Síncrono com Ímãs Permanentes (GSIP).....	13
2.4.4 Gerador Síncrono Excitado Eletricamente (GSEE)	14
2.5 - Curva de Potência	15
2.6 – Análise Probabilística da Ocorrência do Vento	16
2.6.1 Distribuição de Weibull	17
CAPÍTULO 3 - ALGORITMOS GENÉTICOS	20
3.1 Considerações Iniciais	20
3.2 Conceitos Básicos	20
3.2.1 Gene.....	20
3.2.2 Cromossomo	21
3.2.3 Indivíduo	21
3.2.4 Função de Aptidão.....	21
3.2.5 População	21
3.2.6 Geração	22
3.3 Algoritmo Genético Básico	22
3.4 Codificação de Indivíduo.....	24
3.5 População Inicial.....	25
3.6 Avaliação	26
3.6.1 Restrições.....	27
3.7 Seleção.....	28

3.7.1 Método da Roleta	28
3.7.2 Seleção por <i>Ranking</i>	29
3.7.3 Método do Torneio	29
3.8 Cruzamento.....	30
3.9 Mutação	32
3.10 Elitismo.....	32
CAPÍTULO 4 - METODOLOGIA	33
4.1 Considerações Iniciais	33
4.2 Modelagem das Incertezas.....	33
4.2.1 Carga.....	33
4.2.2 Velocidade do Vento e Potência Gerada pela Eólica	34
4.2.3 Velocidade do Vento e Probabilidade de ocorrência.....	35
4.2.4 Análise Probabilística	36
4.3 Metodologia Proposta.....	38
4.3.1. Formulação.....	38
4.4.3. Algoritmo Genético	39
CAPÍTULO 5 - RESULTADOS	42
5.1 Considerações Iniciais	42
5.2 Sistema de Distribuição	42
5.3 Incertezas consideradas no modelo	43
5.4 Restrições do Modelo de Otimização	45
5.5 Simulações Computacionais	45
5.5.1 Caso Base: nenhum parque eólico conectado ao sistema	46
5.5.2 Caso I: alocação de um parque eólico no sistema	46
5.5.3 Caso II: alocação de dois parques eólicos no sistema	58
5.5.4 Discussão dos resultados obtidos	72
CAPÍTULO 6 – CONCLUSÃO	73
6.1 Considerações Finais.....	73
6.2 Trabalhos Futuros.....	74
REFERÊNCIAS BIBLIOGRÁFICAS.....	75

LISTA DE FIGURAS

Figura 1.1 – Capacidade anual instalada no mundo por região 2007 a 2015.....	1
Figura 1.2 – Oferta interna de energia elétrica por fonte em 2014.....	2
Figura 2.1 – Crescimento do tamanho e capacidade instalada das turbinas.....	6
Figura 2.2 – Capacidade eólica instalada no mundo do ano de 2000 a 2015.....	7
Figura 2.3 – Potencial eólico instalado no ano de 2015.....	8
Figura 2.4 – Potencial eólico acumulado no ano de 2015.....	8
Figura 2.5 – Componentes básicos de aerogeradores de eixo horizontal.....	9
Figura 2.6 – Principais componentes de um gerador do tipo GIGE.....	11
Figura 2.7 – Estrutura de um gerador tipo GIDA.....	12
Figura 2.8 – Estrutura de um gerador de acionamento direto do tipo GSIP.....	13
Figura 2.9 – Esquema de um gerador de acionamento direto do tipo GSEE.....	14
Figura 2.10 – Curva de potência de uma turbina eólica.....	16
Figura 2.11 – Velocidade do vento variando em 96 horas.....	17
Figura 2.12 – Distribuição Weibull variando o parâmetro “k”.....	18
Figura 2.13 – Distribuição Weibull variando o parâmetro “c”.....	18
Figura 3.1 – Cromossomos com diferentes representações.....	21
Figura 3.2 – Representação das populações ao longo das gerações.....	22
Figura 3.3 – Esquema de um AG básico.....	23
Figura 3.4 – Concatenação de variáveis codificadas em um cromossomo binário.....	25
Figura 3.5 – Método de Seleção por Roleta.....	28
Figura 3.6 – Cruzamento de um ponto.....	30
Figura 3.7 – Cruzamento de dois pontos.....	31
Figura 3.8 – Cruzamento Uniforme.....	31
Figura 3.9 – Operador de Mutação.....	32
Figura 4.1 – Curva de potência.....	34
Figura 4.2 – Histograma da distribuição de Rayleigh.....	36
Figura 4.3 – Fluxograma da Metodologia Proposta.....	41
Figura 5.1 – Topologia do sistema de distribuição de 33 barras.....	42
Figura 5.2 – Evolução da população inicial ao longo das gerações do AG.....	48
Figura 5.3 – Menores valores para a função objetivo (MW).....	49
Figura 5.4 - Média dos menores valores para a função objetivo (MWh).....	49
Figura 5.5 - Elementos de um box-plot.....	50

Figura 5.6 – Boxplot da função objetivo das perdas de potência (MW).....	50
Figura 5.7 – Evolução da população inicial ao longo das gerações do AG.....	52
Figura 5.8 – Menores valores para a função objetivo (MWh).....	53
Figura 5.9 – Média dos menores valores para a função objetivo (MWh).....	53
Figura 5.10 – Boxplot da função objetivo das perdas de energia anual (MWh).....	54
Figura 5.11 – Perfis de tensão dos resultados da abordagem probabilística e do caso base....	54
Figura 5.12 – Perdas Anuais(MWh).....	56
Figura 5.13 – Média das Perdas Anuais (MWh).....	57
Figura 5.14 – Menores valores para a função objetivo (MW).....	60
Figura 5.15 – Média das Perdas de Potência (Menores, Maiores e Média) (MW).....	61
Figura 5.16 – Média das Menores Perdas de Potência (MW).....	62
Figura 5.17 – Boxplot da função objetivo das perdas de potência (MW).....	63
Figura 5.18 – Menores valores para a função objetivo (MWh).....	65
Figura 5.19 – Média das Perdas de Energia (Menores, Maiores e Média) (MWh).....	66
Figura 5.20 – Média dos menores valores para a função objetivo (MWh).....	67
Figura 5.21 – Boxplot da função objetivo das perdas de energia anual (MWh).....	68
Figura 5.22 – Perfis de tensão dos resultados da abordagem probabilística e do caso base....	68
Figura 5.23 – Perdas Anuais(MWh).....	70
Figura 5.24 – Média das Perdas Anuais (MWh).....	71

LISTA DE QUADROS

Quadro 2.1 – Classificação dos Aerogeradores.....	10
Quadro 4.1 – Relação entre estados do vento e potência de saída.....	35
Quadro 5.1 – Resultados obtidos para o Caso I: alocação de um parque eólico no sistema...	58
Quadro 5.2 – Consolidação dos Melhores Resultados para o Cenário II.....	71
Quadro 5.3 – Consolidação das Menores Perdas Anuais.....	72

LISTA DE TABELAS

Tabela 4.1 – Estados de carga.....	34
Tabela 4.2 – Probabilidade de ocorrência de uma faixa de velocidade do vento.....	37
Tabela 5.1 – Estados da velocidade, potência e probabilidade.....	43
Tabela 5.2 – Estados de carga.....	44
Tabela 5.3 – Estados de carga e potência combinados.....	44
Tabela 5.4 – Resultados usando Análise Determinística com AG para o Caso I.....	47
Tabela 5.5 – Resultados usando Análise Probabilística com AG para o Caso I.....	51
Tabela 5.6 – Resultados usando Análise Probabilística com Recozimento Simulado para o Caso I.....	55
Tabela 5.7 – Resultados usando Análise Determinística com AG para o Caso II.....	59
Tabela 5.8 – Resultados usando Análise Probabilística com AG para o Caso II.....	64
Tabela 5.9 – Resultados usando Análise Probabilística com Recozimento Simulado para o Caso II.....	69

LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmo Genético
FP	Fator de Potência
GD	Geração Distribuição
GIDA	Gerador de Indução Duplamente Alimentado
GIGE	Gerador de Indução em Gaiola de Esquilo
GSIP	Gerador Síncrono com Ímãs Permanentes
GSEE	Gerador Síncrono Excitado Eletricamente
IEEE-RTS	IEEE <i>Reliability Test System</i>
PCH	Pequenas Centrais Hidrelétricas
PNLIM	Programação Não Linear Inteira Mista
PROINFA	Programa de Incentivo às Fontes Alternativas de Energia Elétrica
PSO	<i>Particle Swarm Optimization</i>
RS	Recozimento Simulado
SIN	Sistema Elétrico Interligado Nacional

RESUMO

Esta dissertação propõe uma abordagem probabilística para determinar a ótima localização, dimensionamento e fator de potência de parques eólicos em sistemas de distribuição com base em Algoritmo Genético. O método proposto considera a natureza intermitente da geração eólica e da carga para minimizar as perdas anuais de energia no sistema em estudo. Recentes avanços tecnológicos possibilitaram a operação de parques eólicos fornecendo potência reativa para o sistema, sendo importante considerar a possibilidade de operação com diferentes valores de fator de potência. O sistema utilizado é uma rede de distribuição com 33 barras e os resultados comprovaram a eficácia do método proposto e a importância de considerar as incertezas da carga e do vento no planejamento de sistemas de energia elétrica.

PALAVRAS-CHAVES: Geração Eólica, Algoritmo Genético, Análise Probabilística, Alocação Ótima.

ABSTRACT

This master's thesis proposes a probabilistic approach to determine the optimal location, sizing and power factor of wind parks in power systems based on Genetic Algorithm. The proposed method considers the intermittent nature of wind and load to minimize the annual energy losses in the system under study. Recent technological advancement has created the opportunity to operate wind parks injecting reactive power into the system, making important to consider different power factor modes. The test system used is a distribution system with 33 buses and the results proved the efficiency of the proposed method and the importance to consider load and wind uncertainties in power system planning.

KEYWORDS: Wind Generation, Genetic Algorithm, Probabilistic Approach, Optimal Allocation.

CAPÍTULO 1


INTRODUÇÃO

1.1 MOTIVAÇÃO

O aumento da demanda de energia e a preocupação crescente com questões ambientais são alguns dos principais fatores que contribuíram para o crescimento da produção de energia renovável no mundo. A alta dos preços do petróleo na década de 70 provocou uma retomada em pesquisas e desenvolvimento por alternativas energéticas. Neste contexto houve um aumento no investimento em energia eólica por países como Alemanha, Suécia, Dinamarca, Estados Unidos e Reino Unido. A energia eólica tornou-se uma promissora fonte de energia limpa e confiável, em contraste ao uso de fontes de energia baseadas na queima de combustíveis fósseis, que produzem grande quantidade de gases danosos ao meio ambiente.

Nos últimos anos, a geração de energia eólica tem despertado cada vez mais a atenção das pessoas e empresas em diversos países. O desenvolvimento tecnológico e os subsídios recebidos pelas indústrias de aerogeradores possibilitou o crescimento da energia eólica no mundo. A figura 1.1 apresenta a evolução da capacidade eólica instalada no mundo, por região, entre os anos de 2007 e 2015 (GWEC, 2015).


Figura 1.1 – Capacidade anual instalada no mundo por região 2007 a 2015.



Fonte: GWEC (2016)

No Brasil, segundo dados do Balanço Energético Nacional, a energia eólica atingiu 2% da oferta interna de energia elétrica em 2014, e foi a fonte de energia que apresentou o maior crescimento de potência instalada (EPE, 2015), conforme ilustra a figura 1.2. Apesar de a geração eólica ter crescido consideravelmente no Brasil, nota-se que a matriz energética brasileira ainda é predominantemente hidráulica.

Figura 1.2 – Oferta interna de energia elétrica por fonte em 2014.



Fonte: EPE (2015)

A produção de energia eólica não utiliza insumos fósseis e tem pouco impacto negativo para o ambiente, possibilitando melhor sustentabilidade energética para a sociedade. A construção de parques eólicos demanda menos tempo e custo para a construção quando comparados as tradicionais usinas de grande porte como hidrelétricas (Alves; Branco, 2012). Além disso, a utilização da energia eólica pode trazer como benefício a segurança energética devido à diversificação da matriz energética.

A integração de parques eólicos em sistemas de potência pode trazer benefícios ou danos à operação da rede (Prado, 2013). As perdas de energia nas redes é um problema que afeta principalmente as concessionárias que administram o sistema de energia elétrica. Para que o efeito da geração distribuída seja benéfico, faz-se necessário uma adequada alocação e dimensionamento do parque eólico no sistema, sendo esta uma etapa muito importante do planejamento de sistemas de potência.

A intermitência do vento é um dos problemas mais importantes no que se refere à energia eólica, pois a geração de energia depende da disponibilidade e velocidade do vento. Assim, diz-se que essas plantas são fontes não despacháveis de energia, pois não podem ser controladas pelo operador do sistema, diferentemente da geração térmica convencional.

Em um cenário tradicional, ou determinístico, a alocação e dimensionamento do parque eólico considera a velocidade do vento e a demanda do sistema constantes. No entanto, sabe-se que tanto a carga quanto a geração eólica varia ao longo do tempo. Essa característica de variabilidade e intermitência da geração eólica deve ser considerada no planejamento de sistemas de potência, através de uma análise probabilística.

1.2 OBJETIVO

Esta dissertação de mestrado tem como objetivo desenvolver um método de otimização probabilístico para determinar a localização, dimensionamento e fator de potência de parques eólicos em sistemas de potência utilizando Algoritmo Genético (AG). O objetivo do método é minimizar as perdas anuais de energia em sistemas de potência, com um e dois parques eólicos com aerogerador do tipo GIDA, considerando as restrições e as incertezas características do problema.

1.3 REVISÃO BIBLIOGRÁFICA

Diversos trabalhos têm sido publicados recentemente com propostas para alocação e dimensionamento ótimo de parques eólicos em sistemas de potência, conforme a revisão bibliográfica a seguir.

Muitos estudos encontrados na literatura utilizam a abordagem determinística para determinar a alocação ótima de parques eólicos (Abou El-Ela; Allam; Shatla, 2010; Elnashar, Shatshat; Salama, 2010; El-Zonkoly, 2011; Moradi; Abedini, 2012; Mohammadi; Nafar, 2013). No entanto, sabe-se que métodos determinísticos que consideram apenas um cenário de operação não são adequados para o planejamento de sistemas de potência com geração eólica, por se tratar de uma fonte intermitente.

Poucos são os trabalhos que consideram a intermitência do vento no problema. Em (Yu, et al, 2009), uma solução que combina um método de fluxo de carga probabilístico com método de Monte Carlo é apresentada para obter a função densidade de probabilidade da geração da turbina eólica. O método considera as incertezas da carga e da geração eólica. A metodologia fez uso de um algoritmo genético de dois passos para acelerar o processo de otimização. Para o modelo de carga considerou-se variáveis aleatórias segundo a distribuição

normal, enquanto que o modelo do comportamento do vento utilizado foi a distribuição de *Weibull*.

Em (Atwa; El-Saadany, 2011) é apresentada uma técnica que utiliza uma abordagem probabilística e Programação Não Linear Inteira Mista (PNLIM) para minimizar as perdas anuais de energia na rede. O método considera as restrições técnicas do sistema e que todas as unidades de Geração Distribuída (GD) operam com fator de potência unitário. Para representar o comportamento do vento foi utilizada a distribuição de *Rayleigh*.

O trabalho de (Ugranlı; Karatepe, 2013) propõe determinar a alocação ótima de parque eólico usando as técnicas de algoritmo genético com *Fuzzy-C Means*. O algoritmo busca minimizar as perdas anuais considerando incertezas presentes tanto na carga quanto na geração eólica. O método considera que as turbinas eólicas operam com fator de potência constante. Os modelos de vento e carga foram os mesmo do artigo (Atwa; El-Saadany, 2011).

Em (Jain; Singh; Scrivastava, 2014) é apresentada uma abordagem baseada no método de Monte Carlo e otimização por enxame de partículas (*Particle Swarm Optimization* - PSO), utilizando uma função multiobjetivo para alocação ótima de geradores eólicos. A metodologia propõe o uso da distribuição normal para o modelo de variação da carga e a distribuição de *Rayleigh* para modelar a incerteza do vento.

O artigo de (Hung; Mithulananthan; Lee, 2014) propõe uma metodologia para minimização de perdas anuais de energia de fontes renováveis despacháveis e não despacháveis. O trabalho considera as incertezas dos cenários sazonais de geração de energia eólica e biomassa para encontrar a ótima localização, dimensão e fator de potência da unidade de GD. A unidade de biomassa foi modelada como uma máquina síncrona, e a unidade eólica como um gerador de indução duplamente alimentado.

Neste contexto, nota-se que apesar de alguns trabalhos já terem sido realizados, ainda há campo em aberto para realização de novos estudos e propostas nesta área, que façam uma análise probabilística para alocação ótima de parques eólicos em sistemas de potência, considerando como variável o local onde o parque deve ser instalado, sua potência e o fator de potência o qual este deve operar.

1.4 ESTRUTURA DA DISSERTAÇÃO

Este trabalho está organizado em seis (6) capítulos, tal como segue:

O capítulo 2 apresenta uma visão geral do crescimento da energia eólica mundo. Aborda as principais tecnologias de aerogeradores, curva de potência e modelos probabilísticos que representam as incertezas no comportamento do vento.

O capítulo 3 descreve os principais conceitos e características do Algoritmo Genético (AG). Explica as sequências de operações que ocorrem em um AG e as principais técnicas adotadas nestas etapas.

O capítulo 4 apresenta a metodologia proposta nesta dissertação de mestrado, e descreve o uso da abordagem probabilística em um AG, para o dimensionamento e alocação ótima de um parque eólico em um sistema de potência.

O capítulo 5 apresenta o sistema teste utilizado e os resultados das simulações obtidos, para os cenários selecionados, com o método proposto.

Por fim, no capítulo 6 são apresentadas as conclusões e as sugestões para trabalhos futuros.

CAPÍTULO 2

GERAÇÃO EÓLICA

2.1 CONSIDERAÇÕES INICIAIS


Este capítulo aborda o crescimento da geração eólica no Brasil e no mundo; descreve as principais tecnologias e tipos de aerogeradores utilizados pela indústria; apresenta a curva de potência dos aerogeradores; e por fim, apresenta modelos probabilísticos mais utilizados para representar o comportamento aleatório da velocidade do vento.

2.2 CRESCIMENTO DA GERAÇÃO EÓLICA

O interesse mundial pela geração de energia eólica começou na década de 1970, quando os Estados Unidos da América (EUA) e países da Europa buscavam o desenvolvimento de fontes alternativas para reduzir a dependência do carvão e petróleo (Reis, 2013). A crise do petróleo e a necessidade de novas formas de geração de energia elétrica, por questões econômicas e ambientais, levaram às pesquisas e desenvolvimento em geração de energia eólica no mundo (Fiorin, 2014).

Os investimentos e o avanço tecnológico em torno da energia eólica tornaram os produtos mais eficientes, maiores e com maior potencial de geração (IEA, 2014; Fiorin, 2014). A figura 2.1 ilustra o crescimento das turbinas e o aumento da potência dos geradores eólicos, no mundo, desde 1980 até projeções futuras.

Figura 2.1 – Crescimento do tamanho e capacidade instalada das turbinas.




Fonte: IEA (2014)

Nas últimas décadas a indústria de energia eólica no mundo tem crescido consideravelmente. Segundo o GWEC (2016), no ano 2000 o potencial eólico instalado no mundo foi de 3760 MW, em 2010 foi de 39058 MW, e no ano de 2015 o potencial instalado

no mundo foi de 63467 MW. A figura 2.2 mostra o potencial eólico instalado no mundo, ano a ano, de 2000 a 2015.

Figura 2.2 – Capacidade eólica instalada no mundo do ano de 2000 a 2015.




Fonte: GWEC (2016)

No Brasil, o Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA) foi criado em 2002 e regulamentado em 2004 pelo governo federal, com objetivo em aumentar a participação do setor elétrico de fonte eólica, biomassa ou de Pequenas Centrais Hidrelétricas (PCH) no Sistema Elétrico Interligado Nacional (SIN) (Dutra; Szklo, 2006).

O PROINFA teve como resultado, até 31 de dezembro de 2011, a implantação de 119 empreendimentos com um total de 2649,87 MW de capacidade instalada (ELETROBRÁS, 2015). Destes empreendimentos, 41 foram relativos à energia eólica, que atingiram 963,99 MW de capacidade instalada (ELETROBRÁS, 2015).

Diversas iniciativas no âmbito governamental, empresarial e tecnológica contribuíram para o crescimento da capacidade de instalação de energia eólica no Brasil. Em 2015, o Brasil foi o país da América Latina com maior crescimento e capacidade instalada em energia eólica (GWEC, 2016). Neste ano o país realizou 2754 MW em novas instalações, foi o 4º maior do mundo, atrás apenas de China, EUA e Alemanha. A figura 2.3 mostra o potencial eólico instalado em 2015.


Figura 2.3 – Potencial eólico instalado no ano de 2015.



Fonte: GWEC (2016)

Em 2015, o Brasil atingiu 8,715 GW em capacidade instalada acumulada e permaneceu como o 10º maior do mundo (GWEC, 2016). A figura 2.4 mostra o potencial eólico acumulado, dos países, até dezembro de 2015.

Figura 2.4 – Potencial eólico acumulado no ano de 2015.



Fonte: GWEC (2016)


Apesar do crescimento da geração eólica no Brasil nos últimos anos, este tipo de geração ainda representa um percentual pequeno na matriz energética brasileira, correspondendo a 5,4% do total instalado até o final de 2015 (MME, 2016). Na União Europeia (UE) esse tipo de energia já possui uma participação na matriz energética de 15,6% (EWEA, 2016).

2.3 TECNOLOGIAS DE AEROGERADORES

O crescimento da energia eólica foi impulsionado pelo avanço tecnológico, onde os diferentes tipos de aerogeradores foram desenvolvidos para aumentar a eficiência na conversão de energia cinética do vento em energia elétrica.

Ao longo do tempo surgiram diversos tipos de turbinas eólicas, com eixos verticais ou horizontais, com diferentes quantidades de pás, entre outras características. No entanto, consolidaram-se os aerogeradores com rotor de eixo horizontal, composto por três pás (ANEEL, 2002; ABDI, 2014). A figura 2.5 ilustra os componentes básicos dos aerogeradores de eixo horizontal, sendo que existem diversas configurações para os componentes apresentados.

Figura 2.5 – Componentes básicos de aerogeradores de eixo horizontal.



Fonte: Guerreiro (2014)

As tecnologias desenvolvidas para os componentes das turbinas resultaram em diferentes classificações para os aerogeradores. O quadro 2.1 exhibe os diferentes tipos de classificação dos aerogeradores.

Quadro 2.1 – Classificação dos Aerogeradores.

Classificação	Característica
Porte	Pequeno – potência nominal menor que 500 KW
	Médio – potência nominal entre 500 KW e 1000 KW
	Grande – potência nominal maior que 1 MW
Velocidade de rotação	Velocidade fixa (VF)
	Velocidade variável (VV)
Regulagem de força ou mecanismo de controle	Controle estol (<i>stall</i>);
	Controle de estol ativo
	Controle de passo (<i>pitch</i>);
Trem de acionamento (<i>Drive Train</i>)	Com caixa de engrenagem (multiplicadora)
	Sem caixa de engrenagem (acionamento direto)
Tipo de gerador	Gerador de Indução em Gaiola de Esquilo (GIGE)
	Gerador de Indução Duplamente Alimentado (GIDA)
	Gerador Síncrono com Ímãs Permanentes (GSIP)
	Gerador Síncrono Excitado Eletricamente (GSEE)
Aplicação	Conectadas à rede elétrica
	Fornecimento de eletricidade a comunidades ou sistemas isolados
Local de instalação	Terra Firme (<i>Onshore</i>)
	Fundações Subaquáticas (<i>Offshore</i>)

Fontes: UPWIND (2007); ANEEL (2002)

Aerogeradores de velocidade fixa possuem a rotação a uma velocidade constante em regime permanente, independente das variações da velocidade do vento. A velocidade do rotor do gerador depende, principalmente, da frequência da rede elétrica e do número de polos do gerador. É comum o uso dos geradores do tipo GIGE em turbinas eólicas a velocidade fixa.

Aerogeradores de velocidade variável adaptam a velocidade do rotor da turbina para diferentes velocidades do vento. Esta característica é possível devido o conversor eletrônico de potência que realiza a conversão entre as tensões e frequências geradas para as frequências e tensões da rede elétrica. É comum o uso dos geradores GIDA ou GSIP em turbinas eólicas a velocidade variável.

As principais tecnologias utilizadas pelos geradores serão abordadas na próxima seção.

2.4 TIPOS DE GERADORES


Um sistema de conversão da energia mecânica de rotação eólica em energia elétrica possui tecnologias bem estabelecidas na indústria. No entanto, a configuração entre o gerador e o restante do sistema eólico depende de diversos fatores, como: variações na velocidade do vento; variações do torque de entrada; questões geográficas que dificultam a instalação, operação e manutenção; entre outros fatores (CRESESB, 2008).

Várias tecnologias foram desenvolvidas para serem aplicadas em diferentes cenários, com isso surgiram vários tipos de geradores, onde os mais utilizados na indústria são: Gerador de Indução em Gaiola de Esquilo – GIGE (*Squirrel Cage Induction Generator – SCIG*); Gerador de Indução Duplamente Alimentado – GIDA (*Doubly Fed Induction Generator – DFIG*); Gerador Síncrono com Ímãs Permanentes – GSIP (*Permanent Magnet Synchronous Generator – PMSG*); e o Gerador Síncrono Excitado Eletricamente – GSEE (*Electrically Excited Synchronous Generator – EESG*) (ABDI, 2014).

2.4.1 Gerador de Indução em Gaiola de Esquilo (GIGE)

O gerador de indução em gaiola de esquilo foi predominante nas décadas de 80 e 90, sendo conectado à rede através de um transformador, com topologia de um aerogerador com velocidade fixa, controle estol, caixa de engrenagem de múltiplo estágio (ABDI, 2014). A figura 2.6 ilustra os principais componentes deste tipo de gerador.

Figura 2.6 – Principais componentes de um gerador do tipo GIGE.



Fonte: Adaptado de ABDI (2014)

O gerador de indução em gaiola de esquilo possui variação de velocidade pequena, em torno de 1% da sua velocidade nominal, onde esta velocidade é definida pela frequência da rede e o número de polos do enrolamento do estator. Os aerogeradores deste tipo não possuem conversor de energia e apresentam baixo número de polos (Reis, 2013).


Geradores do tipo GIGE possuem simplicidade, robustez e baixo custo de construção e manutenção. No entanto, apresentam baixa eficiência na conversão de energia, principalmente

provocado pela falta de controle; perturbações na rede provocadas pelas variações da potência, influenciadas pela velocidade do vento; e o alto consumo de potência reativa, sendo necessária a utilização de bancos de capacitores (Silva, 2015; Reis, 2013).

2.4.2 Gerador de Indução Duplamente Alimentado (GIDA)

Os geradores GIDA possuem uma máquina de indução, com rotor bobinado, conectada diretamente à rede pelo estator. Possui duas pontes conversoras trifásicas bidirecionais que liga o circuito do rotor, permitindo a troca de potência ativa entre a rede elétrica e o rotor (Monteiro, 2013; Silva, 2015; Reis, 2013). O gerador de indução liga-se ao rotor da turbina através da caixa de transmissão e a turbina utiliza controle de passo. A unidade eólica do tipo GIDA é muito utilizada para aerogeradores de grande porte (ABDI, 2014). Um esquema simplificado dos geradores do tipo GIDA é ilustrado na figura 2.7.

Figura 2.7 – Estrutura de um gerador tipo GIDA.



Fonte: Adaptado de ABDI (2014)

Este tipo de gerador possui um desempenho otimizado na conversão de energia, pois possuem controle de tensão e da velocidade de rotação. Isto é possível devido o funcionamento dos conversores eletrônicos, que do lado do rotor controla as potências ativas e reativas e do lado da rede controla a tensão do elo CC. A conversão de energia ocorre entre 30% abaixo e 30% acima da velocidade de rotação do gerador (Monteiro, 2013; Reis, 2013; Sohn, 2014).

As unidades eólicas de velocidade variável operam em faixas de velocidades superiores às unidades de velocidade fixa, obtendo maior eficiência aerodinâmica. Os avanços nas tecnologias de controle contribuíram para o aumento no rendimento na produção de energia elétrica e melhorias na qualidade e segurança dos sistemas elétricos (Santos; Bezerra; Machado, 2007; Sohn, 2014).


Os geradores GIDA possuem um custo mais elevado do que geradores de velocidade fixa. Este tipo de gerador precisa de um sistema de proteção contra altas tensões no circuito do rotor, que pode afetar o conversor eletrônico de potência (Sohn, 2014; Silva, 2015).

2.4.3 Gerador Síncrono com Ímãs Permanentes (GSIP)

Um gerador GSIP possui rotor excitado por ímãs permanentes; estator bobinado; conversores, com sistema de proteção, para ajustes na tensão e frequência da rede elétrica; e turbina de velocidade variável com controle de passo, para aumentar a eficiência na captação da energia do vento (Nascimento, 2009). Apesar de existirem modelos de geradores GSIP com caixa de engrenagens, os mais atuais não possuem caixa de engrenagem nem escovas, o que contribui para a utilização em instalações *offshore* (parques eólicos ao longo da costa marítima), que requerem o mínimo de intervenções com manutenção (ABDI, 2014).

Este tipo de aerogerador gira a baixa velocidade, exigindo uma taxa de torque elevada, pois o rotor está ligado diretamente ao cubo do rotor das pás. É comum estes geradores utilizarem grande número de polos do tipo polos salientes (Monteiro, 2013). Os conversores eletrônicos controlam a potência reativa, pois desacopla o aerogerador da rede elétrica, o que contribui para a entrega constante da potência mesmo em grandes variações na velocidade do vento (Nascimento, 2009). A figura 2.8 mostra um esquema de um gerador GSIP.

Figura 2.8 – Estrutura de um gerador de acionamento direto do tipo GSIP.



Fonte: Adaptado de ABDI (2014)

Aspectos positivos destes aerogeradores são: a obtenção da excitação da corrente sem fonte externa; a baixa perda e a alta eficiência na conversão da energia; redução do peso, tamanho e níveis de ruídos do gerador, pois não utiliza caixa de engrenagens.


A perda da qualidade magnética, o custo e manutenção dos ímãs permanentes são as principais desvantagens dos geradores GSIP (Reis, 2013). A desmagnetização é provocada principalmente pelas altas temperaturas, tornando necessária uma supervisão constante, bem como a adaptação de sistemas de arrefecimento (Monteiro, 2013). Gradativamente, o custo do ímã está sendo reduzido, tornando os geradores GSIP mais atrativos (ABDI, 2014).

2.4.4 Gerador Síncrono Excitado Elettricamente (GSEE)

Os geradores do tipo GSEE também são conhecidos como Geradores Síncronos de Rotor Bobinado (GSRB), ou em inglês, *Wound Rotor Synchronous Generator* (WRSG). Estes geradores, na maioria das vezes, não possuem caixa de engrenagem. Para gerar o fluxo magnético do rotor, o gerador utiliza um sistema com enrolamento de campo bobinado em torno dos polos (ABDI, 2014; Reis, 2013).

Os polos dos geradores podem ser lisos ou salientes. Os geradores GSEE comumente apresentam grande número de polos salientes e baixa velocidade de rotação, o que possibilita a conexão direta entre o gerador e a turbina, do mesmo modo que os geradores GSIP. As turbinas possuem velocidade variável e controle de passo (Fiorin, 2014; Nascimento, 2009). Conversores estáticos conectam o gerador à rede, este desacoplamento permite que o gerador opere com frequência diferente da rede. A figura 2.9 mostra os principais componentes de um gerador GSEE.

Figura 2.9 – Esquema de um gerador de acionamento direto do tipo GSEE.



Fonte: Adaptado de ABDI (2014)

Os geradores GSEE não utilizam ímãs permanentes, por outro lado, a fabricação dos conversores torna-se dispendiosa, devido os componentes eletrônicos e a necessidade de intensa refrigeração (ABDI, 2014). O grande número de componentes e o peso do sistema contribuem para aumentar o custo da solução. Existe a necessidade de um conversor adicional para excitar o enrolamento do rotor. Outro fator que colabora para o custo elevado é a necessidade de manutenção quando ocorre o uso de anéis coletores e escovas para excitar o rotor com DC. Apesar do elevado custo dos geradores GSEE, os conversores são muito importantes para equilibrar as variações de energia provenientes de rajadas de vento ou instabilidade na rede e para controle do fluxo magnético e sincronismo com a rede elétrica (Monteiro, 2013). O gerador GSEE é adequado para uso em alta tensão e possui diversas características positivas, tais como: controle independente para potência ativa e reativa; melhoria no fator de potência; ausência de caixa de engrenagem; menos propenso a problema de conexão com a rede devido o isolamento elétrico.

2.5 - CURVA DE POTÊNCIA

As unidades eólicas utilizam a energia cinética de translação do vento, captada pelas pás ligadas ao rotor, para converter em energia cinética rotacional. A massa de ar precisa ser suficiente para fornecer torque mecânico ao gerador elétrico.

A potência mecânica P_m (W) da turbina eólica pode ser calculada pela equação 2.1. onde ρ (kg/m³) é a densidade do ar, V (m/s) é a velocidade do vento, A (m²) é a área varrida pelas pás da turbina e C_p é coeficiente de potência da turbina.

$$P_m = \frac{1}{2} \rho A V^3 C_p \quad (2.1)$$

O coeficiente C_p representa a eficiência da turbina em converter a energia do vento disponível em energia cinética rotacional entregue ao eixo do rotor (Salles, 2009; Leite; Falcão; Borges, 2006). De acordo com o limite de Betz, o coeficiente C_p possui o valor máximo teórico de 59,26% (16/27) (Salles, 2009).

Para realizar a conversão da energia são introduzidos controles na potência da turbina em função da velocidade do vento. Vento com velocidade muito alta pode danificar componentes da turbina, enquanto que velocidade muito baixa produz potência menor que a necessária para o acionamento do gerador. O comportamento da potência de um aerogerador desde o início da geração de energia até a velocidade em que a turbina precisa ser desligada é descrito pela sua curva de potência.


A curva de potência possui uma forma similar mesmo em diferentes aerogeradores, no entanto, os valores de velocidade que alteram o estado de operação da unidade eólica variam de acordo com o fabricante, tecnologia ou capacidade (Ochoa, 2006).

Os dados fornecidos pelo fabricante sobre as turbinas eólicas são: a potência nominal (P_n), velocidade mínima (V_m), velocidade nominal (V_n) e velocidade de corte (V_c). A potência de saída P_w pode ser calculada através da equação 2.2.

$$P_w = \begin{cases} 0 & 0 \leq V \leq V_m \\ P_n * \frac{(V - V_m)}{V_n - V_m} & V_m \leq V \leq V_n \\ P_n & V_n \leq V \leq V_c \\ 0 & V_c \leq V \end{cases} \quad (2.2)$$

Os valores de velocidade e potência determinam a curva de potência com operações definidas em quatro (4) regiões, tal como mostrado na figura 2.10.

Figura 2.10 – Curva de potência de uma turbina eólica.



Fonte: Elaboração própria

Quando a turbina eólica opera na região I, a mesma não gera energia, pois a velocidade do vento está abaixo da velocidade mínima V_m . É comum a velocidade mínima ter valores entre 2,5 m/s e 5 m/s.

A região II é o intervalo entre a partida da turbina eólica até a potência do gerador atingir o valor máximo. A velocidade do vento é maior que a velocidade mínima e menor do que a velocidade nominal, a qual existe uma relação linear entre a velocidade e a potência fornecida pela usina eólica. A velocidade nominal está geralmente entre 12 m/s e 16 m/s.

Quando a turbina eólica opera na região III, a velocidade do vento é maior do que a velocidade nominal e menor que a velocidade de corte. Neste intervalo a potência mecânica é máxima e constante. A velocidade de corte ocorre entre 20 m/s e 25 m/s.

Na região IV as velocidades do vento são maiores que a velocidade de corte da turbina eólica. Por razões de segurança o aerogerador é desligado quando a velocidade do vento atinge estes valores.

2.6 – ANÁLISE PROBABILÍSTICA DA OCORRÊNCIA DO VENTO


Um sistema elétrico que utiliza aerogeradores depende da estimativa da velocidade do vento durante o dia. O vento pode variar durante o dia, mês, ou de forma sazonal, em decorrência de diversos fatores ambientais. Os dados históricos destas variações contribuem para estimar o suprimento da demanda de um sistema elétrico (Leite; Falcão; Borges, 2006; Leite; Filho, 2011).

A coleta dos dados permite identificar a velocidade média, desvio padrão, entre outras características do vento. No entanto, métodos determinísticos não consideram a incerteza da

disponibilidade da geração. Por isso distribuições probabilísticas são utilizadas para representar a velocidade do vento de um local (Silva, 2003).

Diversos modelos probabilísticos podem ser utilizados para representar o comportamento aleatório da velocidade do vento. A distribuição de probabilidade de Weibull e a distribuição probabilidade Rayleigh são os modelos mais utilizados para realizar o planejamento do sistema e estimativa da geração de energia eólica em um período determinado (Leite; Filho, 2011). Figura 2.11 ilustra a velocidade do vento variando por quatro dias, ou 96 horas, segundo a distribuição de Rayleigh.

Figura 2.11 – Velocidade do vento variando em 96 horas.



Fonte: Ugranlı & Karatepe (2013)


2.6.1 Distribuição de Weibull

A distribuição de probabilidade de Weibull descreve a variação da velocidade do vento através do parâmetro de forma (k) e o parâmetro de escala (c). A distribuição de Weibull é expressa pela função densidade de probabilidade, conforme a equação 2.3 (Patel, 2006). O parâmetro “ k ” é adimensional, representa o formato da curva; o parâmetro “ c ” é um fator de escala em unidade de velocidade do vento, e “ v ” é a velocidade do vento.

$$f(v) = \left(\frac{k}{c}\right) \left(\frac{v}{c}\right)^{k-1} e^{-\left(\frac{v}{c}\right)^k} \quad (2.3)$$

O fator “ k ” possui uma medida inversamente proporcional ao desvio padrão da velocidade do vento, ou seja, “ k ” é pequeno quando a velocidade do vento se distribui com muita variação em relação à média, e “ k ” é grande quando a velocidade do vento se distribui em torno da média (Silva, 2003). A figura 2.12 mostra a distribuição Weibull com diferentes valores de “ k ”, considerando “ c ” constante e com valor unitário.


Figura 2.12 – Distribuição Weibull variando o parâmetro “k”.



Fonte: Silva (2003)

O fator “c” está relacionado à magnitude da velocidade do vento, ou seja, quanto maior a velocidade, maior será o fator de escala (Silva, et al, 1999; Silva, 2003). A figura 2.13 mostra a variação do fator “c”, quando “k” é constante e igual a 2.

Figura 2.13 – Distribuição Weibull variando o parâmetro “c”.



Fonte: Silva (2003)

A função densidade de probabilidade de Rayleigh é um caso especial da função de distribuição de Weibull, quando o fator de forma k é igual a 2. A distribuição de Rayleigh representa bem o comportamento do vento para velocidades moderadas (Silva, et al, 1999). A equação 2.4 representa a função densidade de probabilidade de Rayleigh.

$$f(v) = \frac{2v}{c^2} e^{-\left(\frac{v}{c}\right)^2} \quad (2.4)$$

A distribuição de Rayleigh é utilizada por sua simplicidade, pois utiliza apenas a velocidade média (V_m) para determinar o valor do parâmetro de escala “ c ”, tal como mostra a equação 2.5 (Ugranlı; Karatepe, 2013).

$$c = \frac{2}{\sqrt{\pi}} \cdot V_m, \text{ ou } c \cong 1,128 \cdot V_m \quad (2.5)$$

A função de distribuição acumulada $F(v_b)$ de Rayleigh, associada à probabilidade da velocidade do vento ser menor ou igual a v_b é dada pela equação 2.6 (Walck, 1996; Bhattacharya, 2011).

$$F(v_b) = Prob(v \leq v_b) = \int_{-\infty}^{v_b} f(v)dv = 1 - e^{-\left(\frac{v_b}{c}\right)^2} \quad (2.6)$$

Já a probabilidade da velocidade do vento assumir valores entre v_a e v_b é calculada pela equação 2.7:

$$Prob(v_a \leq v \leq v_b) = \int_{v_a}^{v_b} f(v)dv = F(b) - F(a) = e^{-\left(\frac{v_a}{c}\right)^2} - e^{-\left(\frac{v_b}{c}\right)^2} \quad (2.7)$$

CAPÍTULO 3

ALGORITMOS GENÉTICOS

3.1 CONSIDERAÇÕES INICIAIS

A Computação Natural é uma área de pesquisa que abrange diversas técnicas de inteligência computacional, onde a natureza é a principal inspiração para o desenvolvimento de algoritmos e técnicas computacionais. A Computação Bioinspirada é uma subárea da computação natural que se inspira em processos biológicos. A Computação Evolutiva ou Algoritmos Evolucionários são técnicas bioinspiradas que usam modelos computacionais baseados na Genética e na Teoria da Evolução para resolver diversos tipos de problemas. Os Algoritmos Genéticos (AGs) são um ramo da Computação Evolutiva (Faceli, et al, 2011).

Os AGs são heurísticas de busca utilizadas em problemas de otimização combinatória (Artero, 2009). Os indivíduos de uma população e a interação entre eles são modelados pelo Algoritmo Genético (AG), onde um dos principais objetivos é a disseminação das características dos indivíduos mais adaptados, de modo que a população possua uma grande variabilidade de características para que a busca seja mais efetiva.

Os fundamentos do AG foram apresentados por John Holland em 1975. Holland propôs um modelo que usa processos evolutivos para encontrar soluções aproximadas de problemas até então insolúveis. As primeiras pesquisas com estratégias evolucionárias surgiram uma década antes do trabalho de Holland (Linden, 2012).

Neste capítulo são apresentados os conceitos, características e procedimentos realizados pelo AG.

3.2 CONCEITOS BÁSICOS

Como o AG é uma técnica bioinspirada, então a terminologia usada no AG também possui origem na biologia. Portanto, esta seção apresenta os principais termos empregados aos elementos do AG para melhor compreensão da técnica.

3.2.1 Gene

O gene corresponde à representação de uma característica ou parâmetro. Eles podem possuir valores representados em binários, inteiros, reais, nó de uma árvore, ou por outras estruturas de dados. O valor de um gene é conhecido como alelo, no caso de um gene codificado em binário, os alelos são os valores 0 ou 1 (Linden, 2012).

3.2.2 Cromossomo

O cromossomo é composto por um conjunto de genes, sendo representado por uma estrutura de dados que codifica uma possível solução de um problema. Os cromossomos são geralmente representados por vetores de valores binários, inteiros, reais, ou pela estrutura de dados árvore (Artero, 2009). A figura 3.1 mostra exemplos de representações de cromossomos.

Figura 3.1 – Cromossomos com diferentes representações.

Cromossomo Binário	1	0	0	1	0	1	0
Cromossomo Inteiro	4	1	8	3			
Cromossomo Real	2,5	7,4	9,1	6,3	2,0	5,8	

Fonte: Elaboração própria

3.2.3 Indivíduo

O indivíduo é geralmente representado por um cromossomo, e por isso são tratados muitas vezes como sinônimos. Um indivíduo é uma solução candidata para um problema de otimização. O valor da adaptação do indivíduo é definido após o mesmo ser submetido à avaliação por uma função de aptidão.

3.2.4 Função de Aptidão

A função de aptidão é usada para avaliar um indivíduo e medir a adaptabilidade do mesmo perante determinado problema. No AG é comum a função de aptidão ser representada por uma função matemática (Artero, 2009). A função de aptidão deve refletir matematicamente os objetivos a serem alcançados na resolução do problema (Linden, 2012).

Em muitos casos os termos função de avaliação e função custo são usados para o mesmo propósito da função de aptidão.


3.2.5 População

A população é o conjunto de indivíduos, ou conjunto de soluções, presentes em uma determinada geração. Os indivíduos de uma mesma população interagem e transmitem suas características para seus descendentes. É comum a primeira população ser formada por indivíduos que possuam cromossomo com valores pseudoaleatórios.

3.2.6 Geração

Uma geração é o momento discreto atribuído ao estado de uma população. Por exemplo: a primeira população pertence à geração um, enquanto os descendentes da primeira população vão compor a geração dois, e assim sucessivamente. É comum o uso do número de gerações para critério de parada do AG. A figura 3.2 ilustra exemplos de populações ao longo das gerações, exibindo os cromossomos dos indivíduos da população.

Figura 3.2 – Representação das populações ao longo das gerações.



Fonte: Elaboração própria

3.3 ALGORITMO GENÉTICO BÁSICO

O procedimento básico do AG permite a busca de soluções, de forma paralelizada, para problemas de otimização que não existe um método estabelecido. O AG é um método de busca global, pois realiza busca simultânea em várias regiões do espaço de soluções (Artero, 2009).

O AG é aplicado principalmente em problemas de otimização de funções não lineares e problemas de otimização combinatória. No entanto, não é recomendado para problemas de otimização de funções lineares, pois o alto custo computacional utilizado no AG pode não compensar o uso para problemas que podem ser resolvidos usando métodos lineares ou combinações cuja execução requer um tempo curto de execução (Linden, 2012).


Nem sempre a melhor solução encontrada é a solução ótima, pois o AG é um algoritmo estocástico e não determinístico. A composição da população inicial ocorre de

forma pseudoaleatória e a fase de evolução produz uma busca probabilística direcionada pelo processo de seleção, que privilegia os indivíduos mais aptos na geração de novos indivíduos.

Esta característica estocástica dificulta a perfeita reprodutibilidade dos resultados, pois os algoritmos evolucionários são heurísticas que tendem a se aproximar ou encontrar a solução ótima, ou seja, não garantem o melhor resultado em todas as execuções (Linden, 2012).

O AG básico inicia com um conjunto de soluções, ou indivíduos, gerado de forma pseudoaleatória, estas soluções compõem a população inicial; as soluções são avaliadas considerando a aptidão das mesmas perante o problema; as soluções mais aptas são selecionadas e combinadas para compor um novo conjunto de solução; as soluções do novo conjunto são modificadas através da mutação; as soluções do novo conjunto são avaliadas refazendo o mesmo ciclo até que ocorra um critério de parada, tal como, o ciclo atingir determinado número de gerações; por fim é selecionada a melhor solução que foi apresentada durante as gerações e obtêm-se os valores das variáveis ou características que compõem esta solução. A figura 3.3 apresenta um esquema abordando os passos elementares de um AG básico.

Figura 3.3 – Esquema de um AG básico.



Fonte: Elaboração própria

O funcionamento básico do AG é a busca das soluções que possuem melhores características em cada população ao longo das gerações. As melhores características são encontradas através dos métodos de seleção, enquanto que a mutação contribui para aumentar a diversidade da população e consequentemente ampliar a exploração das soluções (Linden, 2012).

Nas próximas seções são apresentadas as principais etapas do AG.

3.4 CODIFICAÇÃO DE INDIVÍDUO

As soluções candidatas de um problema de otimização são representados pelos indivíduos no AG. As soluções candidatas precisam ser codificadas como cromossomos. O cromossomo deve ter uma estrutura de dados que corresponda à natureza do problema e que facilite o desenvolvimento do algoritmo. É comum que as variáveis de um problema sejam definidas como genes ou conjuntos de genes de um cromossomo, e este representado como um vetor de valores binários, inteiros ou reais.

Existem algumas orientações para escolher a representação do cromossomo (Linden, 2012):

- A representação deve ser simples;
- As restrições nas soluções do problema não devem ter uma representação;
- Se o problema exigir condições específicas, estas condições devem estar implícitas na representação.

Uma das maneiras mais simples de codificar um indivíduo é representá-lo como um cromossomo de valores binários. Um cromossomo binário é um vetor de bits, onde cada bit é a codificação de um gene. A representação binária foi a primeira a ser idealizada por Holland e devido a sua simplicidade foi largamente difundida pelos pesquisadores (Linden, 2012).

Os valores reais dos parâmetros de um problema possuem um intervalo de busca e uma precisão, que influenciam diretamente no tamanho do cromossomo binário correspondente ao indivíduo codificado.

A equação 3.1 apresenta o cálculo da precisão (P) de uma variável (X) contínua, com intervalo entre o limite inferior (min) e limite superior (max), codificada em um cromossomo binário com tamanho (k) (Linden, 2012).

$$P \cong \frac{max-min}{2^k-1} \quad (3.1)$$

Para calcular o tamanho (k) de um cromossomo binário a expressão pode ser reescrita conforme a equação 3.2.

$$k = \left\lceil \log_2 \left[1 + \left(\frac{\max - \min}{P} \right) \right] \right\rceil \quad (3.2)$$


Para converter um cromossomo binário (X_{bin}) em valor real é necessário calcular o valor inteiro do cromossomo (X_{int}), esta operação é equivalente a converter um número binário em número de base decimal. Em seguida deve-se usar o valor inteiro e a precisão para converter o valor do cromossomo em valor real. A equação 3.3 apresenta a equivalência entre o valor do cromossomo na base inteira com o valor na base binária. A equação 3.4 exibe o cálculo da conversão do valor binário do cromossomo para o valor real correspondente.

$$X_{int_{10}} \Leftrightarrow X_{bin_2} \quad (3.3)$$

$$X = \min + P \cdot X_{int} \quad (3.4)$$

Quando um indivíduo possui diversas variáveis reais, o cromossomo codificado é formado pela concatenação das listas de bits. Cada variável codifica uma lista de bits, onde o tamanho da lista depende das características de cada variável. A figura 3.4 ilustra a concatenação de três variáveis codificadas em um cromossomo.

Figura 3.4 – Concatenação de variáveis codificadas em um cromossomo binário.



Fonte: Elaboração própria

3.5 POPULAÇÃO INICIAL

A população inicial é o conjunto de indivíduos presentes na primeira geração. Esta é usualmente formada por indivíduos cujos valores dos cromossomos são atribuídos de forma pseudoaleatória. É comum fixar o tamanho da população, ou seja, o número de indivíduos permanece o mesmo ao longo das gerações. Estas estratégias são mais simples e geram bons resultados, pois a geração pseudoaleatória garante uma boa distribuição das soluções (Linden, 2012).

Dependendo do problema, a população inicial pode ser definida com dados que melhore a busca dos valores ótimos. Em outros casos, particionar o espaço de busca contribui

para a realização de buscas locais, que combinadas extraem as melhores características de todo espaço de busca.

O tamanho da população também depende do problema de otimização, pois uma população com muitos indivíduos aumenta o espaço de busca, no entanto, uma superpopulação pode gerar problemas de desempenho computacional, pois a cada geração será também ampliado o número de recorrência à função de aptidão.

3.6 AVALIAÇÃO

Na etapa de avaliação cada indivíduo é submetido à função de aptidão, que atribui um valor para o indivíduo de acordo com o seu desempenho em resolver o problema de otimização. Este valor atribuído ao indivíduo também é chamado de aptidão ou *fitness*.

Um indivíduo é a representação da solução do problema, portanto, em uma população é necessário decodificar um cromossomo em valores que representem o domínio do problema. Por exemplo, se um problema utiliza parâmetros reais, então um cromossomo binário deve ser convertido em valores reais para então ser avaliado.

Para avaliar um indivíduo os valores decodificados são passados por uma função objetivo. Esta função usualmente é uma função matemática inerente ao problema em que se deseja encontrar os valores ótimos. A avaliação do indivíduo é a principal ligação entre o AG com o problema a ser resolvido, pois os elementos e as etapas do AG são genéricos para os diversos problemas. Quanto mais conhecimento do problema for embutido no AG, mais especializada será a solução do problema (Linden, 2012).

É comum a função objetivo também ser a função aptidão, no entanto, existem casos em que a função de aptidão utiliza procedimentos adicionais ao resultado da função objetivo para avaliar o *fitness* de um indivíduo. Estes procedimentos adicionais podem ser simples, como a normalização do resultado da função objetivo, ou estratégias mais complexas, como interação social baseado em teoria dos jogos (Teixeira, et al., 2011).

A etapa de avaliação é encerrada após cada indivíduo, de uma determinada geração, obter um valor de aptidão. Os indivíduos com melhores aptidões são mais propensos a gerar descendentes que irão compor a geração seguinte. Porém, somente na etapa de seleção que os indivíduos são escolhidos para transmitir as suas informações cromossômicas para as próximas gerações.

3.6.1 Restrições

Durante a etapa de avaliação as restrições do problema podem ser tratadas somente após a execução da função objetivo. Neste caso, quando um indivíduo possui, como resultado da função objetivo, um valor que não pertence às restrições do problema, então o indivíduo é passado por uma técnica de tratamento de restrições que afetará a sua aptidão.

Os indivíduos podem apresentar soluções inadequadas ou proibidas para o problema. As restrições para as soluções inadequadas, porém permitidas, são chamadas de *soft constraints*. As restrições para as soluções proibidas são chamadas de *hard constraints* (Linden, 2012).

Seguem as principais técnicas que podem ser adotadas para lidar com restrições:

- Método da pena de morte ou Eliminação de soluções: consiste em remover as soluções que violam as restrições e substituir por novas soluções. A técnica possui facilidade para a implementação, porém um alto custo computacional e pode não ser efetiva nas primeiras gerações;
- Representação e operadores que satisfazem as restrições: com esta técnica, são criados apenas indivíduos que satisfaçam as restrições. Esta abordagem nem sempre pode ser considerada, pois as restrições podem depender do resultado da função objetivo, ou por outro motivo não ser possível abranger previamente os limites do espaço de busca;
- Funções Decodificadoras: este método transforma um cromossomo em uma solução válida. Esta técnica pode trazer bons resultados, no entanto, a implementação pode ser complexa e gerar um alto custo computacional;
- Reparo na solução: as soluções que violam as restrições podem ser corrigidas por um algoritmo de reparo. Neste caso, uma solução que viola as restrições pode estar próxima de uma solução admissível, então é aplicada uma heurística própria para tornar a solução aceita. Os principais problemas desta abordagem é o custo computacional e a especificidade na resolução do problema;
- Função de Penalidade: esta técnica consiste na aplicação de penalidades para as soluções que violam as restrições. Dessa forma, em problemas de maximização o indivíduo sofre uma redução no *fitness* e em problemas de minimização o indivíduo sofre um aumento no *fitness*, ficando mais longe da solução ótima. Esta abordagem é simples de ser implementada e possui baixo custo computacional, no entanto, não é garantido de modo determinístico que as soluções que violam as restrições serão eliminadas ao longo das gerações.

A equação 3.5 representa o uso de penalidades (F_p) no cálculo da aptidão (F_a) para soluções que possuem determinada função objetivo (F_o) em problemas com restrições. Considera-se $F_p(x) = 0$ quando a solução não viola as restrições e $F_p(x) > 0$ quando a solução viola as restrições.

$$\begin{cases} F_a(x) = F_o(x) + F_p(x), & \text{se minimização} \\ F_a(x) = F_o(x) - F_p(x), & \text{se maximização} \end{cases} \quad (3.5)$$

3.7 SELEÇÃO

A etapa de seleção ocorre após a avaliação dos indivíduos de uma população. É quando o AG seleciona os indivíduos (pais) que vão se reproduzir e gerar descendentes.

Para que ocorra a evolução de forma similar ao explicado pela Biologia, é necessário que indivíduos mais aptos possuam maior probabilidade em transmitir os seus genes. Dessa forma o AG contribui para aumentar as chances em manter as melhores características para as gerações futuras.


A evolução também depende da diversidade genética, pois contribui para a exploração das melhores características mesmo em indivíduos pouco aptos (Crepinsek, et al., 2013). Portanto, o AG não pode desprezar os menos aptos, pois as suas características podem contribuir para gerar uma solução ótima para o problema.

Existem diversos métodos de seleção, onde o principal objetivo é manter os melhores indivíduos, mas preservando a diversidade. Os métodos mais comuns para a seleção de indivíduos são: método da roleta, seleção por *ranking* e método do torneio.

3.7.1 Método da Roleta

No método da roleta uma roleta circular é dividida no mesmo número de partes que a quantidade de indivíduos da população, onde cada indivíduo possui uma parte da roleta proporcional a sua aptidão (Faceli, et al, 2011). A figura 3.5 ilustra a seleção por roleta em uma população com quatro indivíduos, com aptidões $F_a(X_1) > F_a(X_4) > F_a(X_3) > F_a(X_2)$.

Figura 3.5 – Método de Seleção por Roleta.



Fonte: Elaboração própria

A cada giro aleatório da roleta um indivíduo é selecionado, portanto os indivíduos mais aptos possuem maior probabilidade de serem escolhidos mais vezes pelo cursor. É comum girar a roleta o mesmo número de vezes que o tamanho da população.

O método da roleta permite uma rápida convergência da população.

3.7.2 Seleção por *Ranking*

A seleção por *ranking* permite reduzir a distância entre as aptidões dos indivíduos. Com isso, evita que a população fique semelhante aos melhores indivíduos de modo prematuro, ou seja, a convergência fica mais lenta. Isto contribui para a diversidade genética, mas torna o processo de busca mais lento.

O principal método utilizado para aproximar as avaliações dos indivíduos é usando o método linear, onde as avaliações dos indivíduos são ordenadas e assumem novos valores de acordo com a equação 3.6 (Linden, 2012).

$$Fa'(x) = \text{Min} + (\text{Max} - \text{Min}) * \frac{\text{Rank}(x) - 1}{N - 1} \quad (3.6)$$

Onde:

- $Fa'(x)$ é o novo valor da avaliação do indivíduo “x”;
- Min é o menor valor arbitrado da avaliação;
- Max é o maior valor arbitrado da avaliação;
- Rank(x) é a posição que o indivíduo ocupa na lista ordenada de avaliações;
- N é o tamanho da população.

Os valores de “Min” e “Max” são arbitrados e influenciam diretamente na pressão seletiva, ou seja, podem contribuir para que os melhores indivíduos sejam, na maioria das vezes, selecionados ou podem oportunizar também os piores indivíduos.

Após os indivíduos assumirem os novos valores de avaliações a seleção por *ranking* pode ser combinada com o método da roleta para a seleção dos indivíduos.

3.7.3 Método do Torneio

No método do torneio um indivíduo é selecionado se vencer a competição entre “k” indivíduos. Se o objetivo for selecionar “n” indivíduos, então é necessário realizar “n” torneios para selecionar os pais da geração posterior.

Em cada torneio são escolhidos aleatoriamente os “k” participantes que vão competir, o vencedor é o indivíduo com maior aptidão. É comum utilizar o $k = 2$, ou seja, realizar torneios com dois indivíduos.

Variações do método podem acrescentar uma alternância entre o vencedor e perdedor com uma probabilidade α . Por exemplo, se $\alpha = 10\%$ então é acrescentada uma etapa que gera 10% de chances do perdedor se tornar vencedor. Esta estratégia pode ser útil quando for necessário reduzir ainda mais a pressão seletiva.

Existem evidências empíricas que indicam que o método do torneio, com dois participantes, apresenta melhores resultados que o método da roleta (Linden, 2012). A seleção por torneio possui uma pressão seletiva similar à seleção por *ranking*, porém possui um custo computacional menor.

3.8 CRUZAMENTO


A etapa de cruzamento, ou *crossover*, ocorre após o AG selecionar os indivíduos (pais) que vão gerar os descendentes (filhos). Um cruzamento consiste em combinar os genes dos cromossomos de dois pais para gerar dois filhos para a nova geração. Os cruzamentos ocorrem até o número de indivíduos gerados alcançarem o tamanho da população.

Os cruzamentos ocorrem com uma probabilidade pré-definida chamada de taxa de cruzamento (tc). É comum tc variar entre 60% e 90% (Artero, 2009). Quando o cruzamento é realizado os pais transmitem parte do material genético para os filhos, mas quando o cruzamento não acontece os filhos são cópias idênticas aos pais.

Existem diversos tipos de cruzamentos, os mais comuns são: cruzamento de um ponto, cruzamento de dois pontos e cruzamento uniforme.

O cruzamento de um ponto em cromossomos binários é exibido na figura 3.6.

Figura 3.6 – Cruzamento de um ponto.




Fonte: Elaboração própria

O cruzamento de um ponto é o mais simples, pois é escolhido um ponto de corte em uma posição aleatória que divide o cromossomo do “PAI 1” em duas partes, este mesmo ponto de corte divide o cromossomo do “PAI 2” também em duas partes. Cada filho é formado por uma parte de cada pai (Faceli, et al, 2011).

O ponto de corte é responsável por realizar o cruzamento do material genético. Quando existem vários pontos de cortes, o cruzamento do material genético entre os cromossomos é feito a partir de cada ponto de corte.

No cruzamento de dois pontos são escolhidos dois pontos de cortes em duas posições aleatórias. A inversão do material genético ocorre duas vezes a partir de cada ponto de corte. A figura 3.7 ilustra o cruzamento de dois pontos em cromossomos binários.


Figura 3.7 – Cruzamento de dois pontos.



Fonte: Elaboração própria

No cruzamento uniforme um filho recebe cada gene de um dos pais por um padrão (máscara) gerado de forma aleatória. A figura 3.8 mostra um exemplo de cruzamento uniforme em cromossomos binários.

Figura 3.8 – Cruzamento Uniforme.



Fonte: Elaboração própria

A figura acima mostra uma máscara com 5 bits gerada aleatoriamente. Quando o bit da máscara é 1, o Filho 1 recebe o gene do Pai 1 e o Filho 2 recebe o gene do Pai 2, mas quando o bit da máscara é 0, o Filho 1 recebe o gene do Pai 2 e o Filho 2 recebe o gene do Pai 1.

3.9 MUTAÇÃO

Na etapa de mutação a população é composta pelos novos indivíduos que foram criados ao final da etapa de cruzamento. Cada gene dos novos cromossomos possui a probabilidade de sofrer mutação. Esta probabilidade pré-definida é chamada de taxa de mutação (tm), esta varia normalmente entre 0,5% e 1%.

A mutação é um operador que contribui para a diversidade genética na população, pois a alteração nos genes pode gerar solução ainda não explorada pelo AG em um determinado problema. Por outro lado, a tm não pode ser alta, pois geraria um alto grau de aleatoriedade na busca da melhor solução.

A figura 3.9 mostra um cromossomo binário antes e depois da mutação. Cada gene teve 1% de chance de sofrer mutação, mas apenas o segundo gene aleatoriamente acertou a probabilidade.

Figura 3.9 – Operador de Mutação.

Antes da Mutação	0	1	0	0	1
Após a Mutação	0	0	0	0	1

Fonte: Elaboração própria

3.10 ELITISMO

Elitismo é uma estratégia que consiste em copiar os melhores indivíduos de uma população para a população posterior. Este operador é utilizado para que os melhores indivíduos não sofram modificações genéticas e permaneçam nas próximas gerações até que seja substituído por outra elite de cromossomo com o desempenho superior.

Este operador garante uma rápida convergência, mas se a elite representar uma parte considerável da população, isto pode afetar a diversidade e consequentemente o AG pode não evoluir o suficiente para encontrar a solução ótima do problema.

CAPÍTULO 4

METODOLOGIA

4.1 CONSIDERAÇÕES INICIAIS

Este capítulo descreve a utilização da abordagem probabilística e algoritmo genético para determinar a ótima localização, dimensionamento e fator de potência em sistemas de distribuição de energia com um parque eólico e com dois parques eólicos. O método proposto considera a natureza intermitente da geração eólica e da carga no sistema em estudo, com o objetivo em minimizar as perdas de energia no ano. O modelo também considera as restrições técnicas impostas ao sistema, tais como limites de tensão, fator de potência máximo e mínimo e o limite máximo de penetração do parque eólico. A metodologia proposta faz uso da análise probabilística em um algoritmo genético integrado à solução de fluxo de carga. Nas seções seguintes são apresentados os modelos de incerteza da geração eólica e carga; a formulação matemática do problema de otimização; e a metodologia proposta por este trabalho.

4.2 MODELAGEM DAS INCERTEZAS

Na prática, o sistema de potência é dinâmico, e a velocidade do vento e a demanda do sistema estão constantemente variando. Assim, seria razoável obter um leque de condições possíveis de operação como resultado das incertezas presentes na velocidade do vento e na carga, e não apenas uma única condição de operação, como feito na abordagem determinística.

Assim, propõe-se que as incertezas presentes na velocidade do vento e consequentemente na energia eólica gerada, além das incertezas oriundas da previsão da carga, sejam devidamente representadas no modelo, com uma abordagem probabilística, para a adequada alocação e dimensionamento dos parques eólicos. A metodologia utilizada para esta representação é descrita a seguir.

4.2.1 Carga

O comportamento da carga do sistema apresenta variações no aspecto sazonal ou mesmo durante um dia. O modelo de carga utilizado para representar as incertezas durante um dia é o mesmo do sistema *IEEE Reliability Test System* (IEEE-RTS) (Pinheiro; Dornellas; Melo, 1998). A carga foi distribuída em dez estados (L), que identificam os níveis de percentuais de carga (D_L) e a probabilidade de ocorrência $P(D_L)$, tal como mostrado na Tabela 4.1.


Tabela 4.1 – Estados de carga.

Estado (L)	% Carga D_L	Probabilidade $P(D_L)$
1	100	0,01
2	85,3	0,056
3	77,4	0,1057
4	71,3	0,1654
5	65	0,1654
6	58,5	0,163
7	51	0,163
8	45,1	0,0912
9	40,6	0,0473
10	35,1	0,033

Fonte: Elaboração própria

4.2.2 Velocidade do Vento e Potência Gerada pela Eólica

A velocidade do vento influencia diretamente a potência gerada de uma turbina eólica. A figura 4.1 ilustra a curva de potência, onde se tem a variação da potência gerada pela usina eólica (P_w) em função da velocidade do vento (v).

Figura 4.1 – Curva de potência.**Fonte: Elaboração própria**

Onde:

P_n : potência nominal;

v_n : velocidade nominal;

v_m : velocidade mínima;

v_c : velocidade de corte;

A partir do gráfico 4.1, tem-se que a potência de saída (P_w) da usina eólica pode ser calculada conforme a equação 4.1.

$$P_w = \begin{cases} 0 & 0 \leq v \leq v_m \\ P_n * \frac{(v-v_m)}{v_n-v_m} & v_m \leq v \leq v_n \\ P_n & v_n \leq v \leq v_c \\ 0 & v \geq v_c \end{cases} \quad (4.1)$$

Para a modelagem do problema, foram utilizados valores discretos para a velocidade do vento, variando de 1 m/s em 1 m/s, desde 0 m/s até a velocidade de corte v_c . Foram

considerados então diversos intervalos de variação para a velocidade do vento ($v_a \leq v \leq v_b$), e cada intervalo foi associado a um estado. Assim, a velocidade do vento pode variar por exemplo de 0 m/s a 1 m/s, de 1m/s a 2 m/s, de 2 m/s a 3 m/s e etc, e cada faixa de valores define um estado. Para cada estado com valores de velocidade do vento variando entre $v_a \leq v \leq v_b$, pode-se calcular a potência de saída da turbina utilizando a equação 4.3, conforme indica o quadro 4.1.

Quadro 4.1 – Relação entre estados do vento e potência de saída.

Estado (w)	Velocidade do vento (v)	P_w
1	0 m/s – 1 m/s	P_1
2	1 m/s – 2 m/s	P_2
3	2 m/s – 3 m/s	P_3
...	...	...

Fonte: Elaboração própria

Alguns estados foram agregados para reduzir o número total de estados de acordo com o comportamento da curva de potência da turbina eólica (Atwa; El-Saadany, 2011). Os valores com velocidade do vento inferiores a v_m foram agrupados em um único estado, pois possuem as mesmas potências de saída e iguais à zero ($P_w=0$). O agrupamento também foi realizado para velocidades entre v_n e v_c , onde as potências de saída são as mesmas e iguais à potência nominal ($P_w=P_n$).

4.2.3 Velocidade do Vento e Probabilidade de ocorrência

Neste trabalho, o comportamento da velocidade do vento foi representado usando a distribuição de *Rayleigh*, que é um caso especial da função de distribuição de *Weibull* com fator de forma igual a 2. A equação 4.2 exhibe a função distribuição de *Rayleigh*, sendo c o fator de escala, v a velocidade do vento e v_{med} a velocidade média do vento.

$$f(v) = \frac{2v}{c^2} e^{-\left(\frac{v}{c}\right)^2} \quad (4.2)$$


$$c \cong 1,128 \cdot v_{med}$$

Para cada estado com valores de velocidade do vento variando entre $v_a \leq v \leq v_b$, pode-se também calcular a sua probabilidade de ocorrência através da expressão 4.3, já apresentada no capítulo 2.

$$Prob(v_a \leq v \leq v_b) = e^{-\left(\frac{v_a}{c}\right)^2} - e^{-\left(\frac{v_b}{c}\right)^2} \quad (4.3)$$

A figura 4.2 ilustra um exemplo da probabilidade de ocorrência da velocidade do vento considerando valores discretos e utilizando a função de distribuição de *Rayleigh*.

Figura 4.2 – Histograma da distribuição de Rayleigh.



Fonte: Elaboração própria

4.2.4 Análise Probabilística

Considerando vários estados associados a faixa de valores de velocidade de vento, para qualquer estado (w), a potência de saída (P_w) pode ser calculada pela equação 4.1, enquanto que a probabilidade de ocorrência daquele estado $P(P_w)$ pode ser calculada através da somatória das probabilidades que compõe aquele estado, a partir da equação 4.3 apresentada anteriormente.

Como exemplo, considere uma turbina eólica com velocidade mínima igual a 4m/s (v_m), velocidade nominal (v_n) igual a 14m/s e velocidade média (v_{med}) igual a 6,07m/s. Agora suponha um estado em que a velocidade do vento varia entre 4m/s e 5m/s. Então, tomando a velocidade média desse estado igual a 4,5m/s e substituindo na equação 4.3, pode-se calcular a potência fornecida pela eólica em percentual da potência nominal, para este estado, dada por:

$$P_w = P_n * \frac{(4,5-4)}{14-4} = 0,05P_n = 5\%P_n \quad (4.4)$$

Para se obter a probabilidade de ocorrência da velocidade do vento para este estado, ou seja, variando entre 4m/s e 5m/s, calcula-se primeiramente o fator de escala c :

$$c = 1,128 \cdot v_{med} = 6,847 \quad (4.5)$$

Tem-se então que a probabilidade deste estado ocorrer é:

$$Prob(4 \leq v \leq 5) = e^{-\left(\frac{4}{c}\right)^2} - e^{-\left(\frac{5}{c}\right)^2} = 0,1242 = 12,42\% \quad (4.6)$$

Assim, considerando m estados onde a velocidade do vento varia de zero até a velocidade de corte, e fazendo os cálculos apresentados anteriormente, pode-se obter a tabela

4.2 abaixo. Nesta tabela, para cada estágio tem-se a faixa de valores em que a velocidade do vento varia, a potência gerada pela eólica em função da potência nominal, e a probabilidade de ocorrência deste estado, considerando a velocidade mínima (v_m), velocidade nominal (v_n) e velocidade de corte (v_c).

Tabela 4.2 – Probabilidade de ocorrência de uma faixa de velocidade do vento.

Estado (w)	Velocidade do Vento (m/s)	P_w (% P_n)	Probabilidade $P(P_w)$
1	$0 - v_m$	P_1	$P(P_1)$
2	$v_m - (v_m + 1)$	P_2	$P(P_2)$
3	$(v_m + 1) - (v_m + 2)$	P_3	$P(P_3)$
4	$(v_m + 2) - (v_m + 3)$	P_4	$P(P_4)$
...	...	...	...
$m-1$	$(v_n - 1) - (v_n)$	P_{m-1}	$P(P_{m-1})$
m	$(v_n) - (v_c)$	P_m	$P(P_m)$

Fonte: Elaboração própria

A análise probabilística propõe combinar os cenários de incerteza da velocidade do vento e carga através da convolução entre as probabilidades de cada cenário. Os cenários de velocidade do vento ocorrem de forma independente aos cenários de carga, e por esse motivo são considerados não correlacionados. O cálculo da probabilidade de ocorrência da combinação destes eventos pode ser obtido pela equação 4.7, onde $P(P_w)$ é a probabilidade de ocorrência daquele estado associado a geração eólica e $P(D_L)$ é a probabilidade de ocorrência daquela demanda.

$$P(Cs) = P(P_w) \times P(D_L) \quad (4.7)$$

O número de estados associados à velocidade do vento é dado por $n(w)$, enquanto que o número de estados associados à carga é dado por $n(L)$. Portanto, o número total de cenários N_S combinados é dado por:

$$N_S = n(w) \times n(L) \quad (4.8)$$

Como exemplo, suponha 12 estados de geração eólica combinados com 10 estados de carga, o que resulta um total de 120 estados.

No caso do sistema de distribuição utilizar mais de um gerador eólico, o cálculo da probabilidade da combinação entre os cenários deve considerar a probabilidade da potência de cada gerador eólico. A equação 4.9 mostra o cálculo da probabilidade $P(Cs)$ da combinação entre os cenários de carga com os cenários das potências geradas por duas eólicas, considerando P_w^1 e P_w^2 as potências de saída de cada eólica.

$$P(Cs) = P(P_w^1) \times P(P_w^2) \times P(D_L) \quad (4.9)$$

Neste caso, o número total de cenários (s) combinados é dado por:

$$N_s = n(w^1) \times n(w^2) \times n(L) \quad (4.10)$$

onde $n(w^1)$ é o número de estados associados a usina eólica 1 e $n(w^2)$ é o número de estados associados a usina eólica 2:

4.3 METODOLOGIA PROPOSTA

Para encontrar a melhor configuração do sistema que determine a menor perda de energia anual para o sistema de distribuição, foi desenvolvido um algoritmo genético usando a abordagem probabilística no ambiente Matlab, integrado à solução de fluxo de carga do pacote MATPOWER.

O algoritmo genético proposto utiliza como função objetivo as perdas anuais de energia do sistema calculadas através do fluxo de carga, para os diversos cenários probabilísticos. O método propõe encontrar a melhor configuração de potência, fator de potência e localização da barra para conexão do parque eólico, de modo a minimizar as perdas anuais de energia do sistema considerando as restrições e as incertezas do problema.

4.3.1. Formulação

Para calcular a perda anual de energia no sistema (E_{loss}) em MWh considerou-se 365 dias no ano e 24 horas ao longo de um dia, tendo, portanto, 8760 horas ao ano. A equação 4.5 representa a função objetivo utilizada para minimizar as perdas de energia ao longo de um ano (E_{loss}).

$$\text{Min } E_{loss} = \sum_{s=1}^{N_s} \text{Loss}_{Cs} \times P(Cs) \times 8760 \quad (4.5)$$

Onde:

Loss_s : perdas de potência ativa no sistema para o cenário Cs ;

$P(Cs)$: probabilidade de ocorrência do cenário Cs ;

N_s : número total de cenários/estados.

Para avaliar a perda de energia anual em um sistema de distribuição usando análise probabilística, é necessário considerar as condições de funcionamento do parque eólico e da demanda do sistema com suas devidas probabilidades de ocorrência. Cada cenário combinado

entre velocidade de vento e demanda (C_s) é submetido à solução do fluxo de carga, e obtém-se as perdas de potência ativa no sistema ($Loss_{Cs}$) associadas a este cenário (C_s).

O modelo considera as seguintes restrições técnicas impostas ao sistema:

- Limites de tensão nas barras de carga ($0,9pu \leq V \leq 1,1pu$);
- A potência do parque eólico não pode ultrapassar a carga;
- O fator de potência (FP) deve variar no intervalo de $\pm 0,95$.

4.4.3. Algoritmo Genético

Para buscar a melhor solução para o problema, a localização da usina eólica (*barra*), a potência nominal da usina eólica (P_n) e o fator de potência (FP) foram modelados como variáveis a serem otimizadas em um AG com representação binária. As turbinas eólicas podem fornecer ou absorver potência reativa, portanto foi criada a variável *senal* que representa esta condição do fator de potência. Cada combinação de valores destas variáveis representam um conjunto solução ou indivíduo do AG. Portanto, no sistema com um parque eólico, os cromossomos foram codificados com o tamanho de 25 bits, enquanto que no sistema com dois parques eólicos, os cromossomos foram codificados com o tamanho de 50 bits.

A função objetivo do AG, no cenário probabilístico, calcula a perda de energia do sistema ao longo de um ano considerando a combinação entre os estados de vento e carga. Portanto, a função executa o cálculo do fluxo de carga N vezes para cada indivíduo avaliado, sendo N o número total de estados combinados.

Uma vez que uma solução (indivíduo) não atenda as restrições do sistema, esta solução é penalizada com um acréscimo no valor do resultado da função objetivo, ou seja, um aumento na perda de energia anual. Neste trabalho, optou-se em aplicar as penalidades conforme equação 4.6, sendo $Fp(x)$ a penalidade aplicada ao indivíduo x , $Fa(x)$ a função de aptidão de um indivíduo e $Fo(x)$ função objetivo em uma solução, tal como apresentada na equação 3.5 do capítulo 3. Portanto, a ocorrência de penalidades aumenta o valor da função de aptidão em um problema de minimização.


$$\begin{cases} Fa(x) = Fo(x) + Fp(x) \\ Fp(x) = 2 \times (Fo(x) + 1) \end{cases} \quad (4.6)$$

Um esquema do algoritmo genético integrado à solução de fluxo de carga no cenário probabilístico é ilustrado pela figura 4.3, a seguir. Na etapa de avaliação do algoritmo genético uma solução é submetida a sucessivos cálculos de fluxo de carga para cada cenário de vento e carga, para calcular a perda anual de energia. A variável s corresponde ao estado de uma combinação entre um estado da potência gerada pela eólica com um estado da carga, conforme mencionado anteriormente na tabela 4.2. Com isso, a demanda do sistema e a potência gerada são atualizadas a cada estado s .

Os valores de potência, fator de potência e barra, correspondente a um determinado estado combinado, são submetidos ao cálculo do fluxo de carga e são obtidas as tensões nas barras e as perdas do sistema. O total de perdas (*totalPerdas*) é acumulado a cada estado s até o estado $s = N$, que corresponde ao total de estados combinados.

Ao final dos N estados combinados obtém-se a perda acumulada referente à solução candidata. Para o cálculo das perdas anuais (*perdasAnuais*) deve-se multiplicar o total de perdas por 8760, conforme a equação 4.5 explicada anteriormente. Caso a tensão em alguma barra, durante as execuções do fluxo de carga para a solução candidata, não atenda as restrições, então é aplicada a penalidade no indivíduo para que o mesmo tenha menos chance de gerar descendentes na próxima geração.

Figura 4.3 – Fluxograma da Metodologia Proposta.



Fonte: Elaboração própria

No próximo capítulo são apresentados os cenários, simulações e resultados obtidos neste trabalho.

CAPÍTULO 5

RESULTADOS


5.1 CONSIDERAÇÕES INICIAIS

Neste capítulo são apresentados os resultados das simulações realizadas para a localização ótima do parque eólico no sistema elétrico, bem como seu dimensionamento e fator de potência ótimo, de modo que conduza a operação do sistema com o mínimo de perdas ao longo do ano. Aplicou-se a metodologia de análise probabilística com algoritmo genético em cenários de geração distribuída com um e dois parques eólicos. Diversos casos foram simulados usando uma rede de distribuição com 33 barras. Nas seções seguintes são apresentadas as configurações, o ambiente utilizado para as simulações, os resultados obtidos e as discussões.

5.2 SISTEMA DE DISTRIBUIÇÃO

O sistema de distribuição de energia adotado neste trabalho foi o sistema de distribuição de 33 barras comumente utilizado na literatura (Hung; Mithulananthan; Bansal, 2010). A topologia do sistema é apresentada na figura 5.1. A demanda de potência ativa e reativa neste sistema é de 3,715MW e 2,3MVar, respectivamente, e as perdas de potência ativa no sistema são de 0,211MW. A barra 18 apresenta o nível de tensão mais baixo, de 0,9037 pu. A barra 1 é a barra de referência, enquanto que as outras barras são do tipo PQ. Portanto, com exceção da barra 1, todos os outros nós foram considerados barras candidatas para conectar ao parque eólico.

Figura 5.1 – Topologia do sistema de distribuição de 33 barras.



Fonte: Elaboração própria

5.3 INCERTEZAS CONSIDERADAS NO MODELO

Os dados de velocidade do vento e potência nominal da turbina eólica utilizados neste trabalho foram os seguintes:

- $v_m = 4$ m/s (velocidade mínima);
- $v_n = 14$ m/s (velocidade nominal);
- $v_c = 25$ m/s (velocidade de corte);
- $v_{med} = 6,07$ m/s (velocidade média do vento).

Conforme já apresentado no capítulo 4, os valores com velocidade do vento inferiores a 4m/s foram agrupados em um único estado, pois possuem a mesma potência de saída. Do mesmo modo ocorreu para velocidades superiores a 14m/s. Portanto, para este estudo foram considerados 12 estados para a velocidade do vento, onde a potência gerada pela turbina eólica associada a cada estado foi calculada utilizando a equação 4.4, e a probabilidade associada a cada estado foi calculadas utilizando a equação 4.6. A tabela 5.1 abaixo apresenta todos os estados considerados (w), bem como a velocidade do vento, a potência de saída (P_w) em função do percentual da potência nominal (P_n) e a probabilidade de ocorrência $P(P_w)$ de cada estado.

Tabela 5.1 – Estados da velocidade, potência e probabilidade.

Estado (w)	Velocidade do Vento (m/s)	P_w (% P_n)	Probabilidade $P(P_w)$
1	0 – 4	0	0,2891
2	4 – 5	5	0,1242
3	5 – 6	15	0,1227
4	6 – 7	25	0,1124
5	7 – 8	35	0,0963
6	8 – 9	45	0,0777
7	9 – 10	55	0,0592
8	10 – 11	65	0,0428
9	11 – 12	75	0,0294
10	12 – 13	85	0,0192
11	13 – 14	95	0,0119
12	14 – 25	100	0,0153

Fonte: Elaboração própria

As incertezas consideradas na carga são apresentadas na Tabela 5.2 abaixo, conforme já apresentado no capítulo 4.

Tabela 5.2 – Estados de carga.

Estado (L)	% Carga D_L	Probabilidade $P(D_L)$
1	100	0,01
2	85,3	0,056
3	77,4	0,1057
4	71,3	0,1654
5	65	0,1654
6	58,5	0,163
7	51	0,163
8	45,1	0,0912
9	40,6	0,0473
10	35,1	0,033

Fonte: Elaboração própria

Assim, considerando a presença de um parque eólico no sistema tem-se no total 120 cenários combinados N_s , obtidos pelo produto de 12 estados associados à velocidade do vento e 10 estados associados à carga. Para cada um destes 120 estados tem-se uma probabilidade de ocorrência $P(D_L)$, dada pelo produto da probabilidade de ocorrência de um cenário de geração eólica $P(P_w)$ e a probabilidade de ocorrência de um cenário de carga $P(D_L)$. A tabela 5.3 ilustra todos os 120 cenários considerados.

Tabela 5.3 – Estados de carga e potência combinados.

Estado (L)	% Carga D_L	Probabilidade $P(D_L)$	P_w (% P_n)	Probabilidade $P(P_w)$	Probabilidade $P(C_s)$
1	100	0,01	0	0,2891	0,002891
2	100	0,01	5	0,1242	0,001242
3	100	0,01	15	0,1227	0,001227
4	100	0,01	25	0,1124	0,001124
5	100	0,01	35	0,0963	0,000963
6	100	0,01	45	0,0777	0,000777
7	100	0,01	55	0,0592	0,000592
8	100	0,01	65	0,0428	0,000428
9	100	0,01	75	0,0294	0,000294
10	100	0,01	85	0,0192	0,000192
11	100	0,01	95	0,0119	0,000119
12	100	0,01	100	0,0153	0,000153
13	85,3	0,056	0	0,2891	0,0161896
14	85,3	0,056	5	0,1242	0,0069552
15	85,3	0,056	15	0,1227	0,0068712
...	...	...	...	...	...
120	35,1	0,033	100	0,0153	0,0005049

Fonte: Elaboração própria

5.4 RESTRIÇÕES DO MODELO DE OTIMIZAÇÃO

Este trabalho tem como objetivo minimizar as perdas anuais de energia conforme a função objetivo abaixo já apresentada no capítulo 4.

$$\text{Min } E_{loss} = \sum_{s=1}^{N_s} Loss_{Cs} \times P(Cs) \times 8760$$

Para tal, o problema considera as seguintes restrições:

- Limites de tensão nas barras de carga ($0,9\text{pu} \leq V \leq 1,1\text{pu}$);
- O nível máximo de penetração de energia eólica não pode ultrapassar 3,715 MW;
- O fator de potência (FP) de operação do parque eólico deve variar no intervalo de $\pm 0,95$.

5.5 SIMULAÇÕES COMPUTACIONAIS

Neste trabalho, foram considerados para análise um total de três cenários:

- Caso Base: nenhum parque eólico conectado ao sistema;
- Caso 1: alocação de um parque eólico no sistema;
- Caso 2: alocação de dois parques eólicos no sistema.

O caso em que dois parques eólicos são alocados de forma ótima no sistema é considerado por ser um cenário mais complexo, com maiores possibilidades de combinações e soluções.

Para analisar o comportamento do método proposto, foram feitas simulações computacionais em ambos os casos 1 e 2, aplicando mais dois métodos computacionais além do método probabilístico proposto que utiliza o Algoritmo Genético (AG). Assim, para os casos 1 e 2 os seguintes métodos foram utilizados:

- Método probabilístico utilizando AG (proposto);
- Método determinístico utilizando AG;
- Método probabilístico utilizando Recozimento Simulado.

Primeiramente utiliza-se o método determinístico com AG, que não considera a possibilidade de ocorrência de diversos cenários. Neste caso, a demanda do sistema é constante e o parque eólico gera sempre a potência nominal. Depois testa-se o desempenho do método probabilístico com o Recozimento Simulado (RS), que é uma metaheurística baseada no processo físico de recozimento, onde metais são fundidos em alta temperatura e depois lentamente resfriados para alcançar um estado de baixa energia (Kirkpatrick; Gelatt; Vecchi,

1983). Este é um método simples que permite escapar de mínimos locais, que foi desenvolvido originalmente por Metropolis et al. (1953).

Para o uso do AG foi desenvolvido um código completo no MATLAB, sem o uso de *toolbox*, enquanto que para a aplicação do método de Recozimento Simulado utilizou-se o *toolbox Simulated Annealing* do Matlab. As simulações foram realizadas em *softwares* e *hardware* com as seguintes configurações:

- Notebook: Positivo Sim 6120m;
- Processador: Intel Core i5-2450m de 2,5 GHz;
- Memória RAM: 8GB DDR3 ;
- Sistema Operacional: Microsoft Windows 7 Ultimate (64bits);
- Matlab: R2012b (8.0.0. 783);
- Matpower: 4.1.

5.5.1 Caso Base: nenhum parque eólico conectado ao sistema

Neste cenário considera-se que nenhum parque eólico está conectado no sistema de distribuição, e o valor das perdas anuais de energia são 1.054,62 MWh.

5.5.2 Caso I: alocação de um parque eólico no sistema

Neste cenário considera-se a alocação e dimensionamento de um parque eólico no sistema de distribuição, e como já foi mencionado três métodos foram aplicados: método probabilístico utilizando AG (proposto), método determinístico utilizando AG e método probabilístico utilizando Recozimento Simulado. Para cada método foram realizados cinco ensaios para aumentar a consistência dos resultados, os quais são apresentados a seguir.

a) Análise Determinística com AG

A configuração do AG foi escolhida a partir de diversos testes, e os resultados das simulações foram obtidos considerando a seguinte configuração:

- Seleção por Torneio com dois participantes ($k=2$) e alternância de 10% ($\alpha = 10\%$);
- Elitismo: 10%;
- Cruzamento com um ponto de corte;
- Taxa de cruzamento: 70%;
- Taxa de mutação: 3%;

- Tamanho da população: 60 indivíduos;
- Critério de parada: máximo de 60 gerações.

Com o método determinístico, a demanda do sistema é considerada constante e o parque eólico gera sempre a potência nominal, ou seja, apenas um cenário é considerado. A função objetivo minimizada neste caso foi a perda de potência ativa, e não as perdas anuais de potência.

A tabela 5.4 apresenta os resultados dos cinco ensaios realizados utilizando o método determinístico com AG. As colunas “Barra”, “Potência da Eólica” e “Fator de Potência” correspondem às soluções encontradas pelo método. A coluna “Perdas” representa a função objetivo utilizada, que são as perdas de potência ativa.

As Perdas Anuais foram calculadas através da equação 5.1, considerando os diversos cenários de velocidade de vento e demanda bem como suas probabilidades de ocorrência. Partindo da solução encontrada pelo AG (P_n - potência nominal ótima da eólica), calcula-se o fluxo de carga para cada cenário ($C_1, C_2 \dots C_n$), onde cada cenário considera uma velocidade de vento ($\%P_n$) e uma demanda. As perdas de energia para cada cenário ($Loss_{Cn}$) são então obtidas pelo fluxo de carga.

$$E_{loss} = 8760 \sum_{s=1}^n (Loss_{C1} \times Prob(C_1) + Loss_{C2} \times Prob(C_2) + \dots Loss_{Cn} \times Prob(C_n)) \quad (5.1)$$

Observa-se que o melhor resultado foi obtido no ensaio 4, pois alcançou-se 815,70 MWh de perdas anuais em 25 gerações do AG. Em média, a perda anual foi de 818,71 MWh.


Tabela 5.4 – Resultados usando Análise Determinística com AG para o Caso I.

Ensaio	Barra	Potência da Eólica (MW)	Fator de Potência	Perdas de Potência (MW)	Perdas Anuais (MWh)
1	6	2,7862	+0,95	0,07831	817,60
2	6	2,7862	+0,95	0,07831	817,60
3	6	2,8407	+0,95	0,07827	815,82
4	6	2,8443	+0,95	0,07827	815,70
5	29	1,8575	+0,95	0,08702	826,83
Média	-	-	-	0,08004	818,71

Fonte: Elaboração própria

A Figura 5.2 mostra a evolução da população inicial do 4º ensaio ao longo das gerações do AG. Na figura, tem-se no eixo x o fator de potência, no eixo y a barra na qual é conectado o parque eólico e no eixo z a potência gerada pela eólica. Nota-se que a população inicialmente é bem diversa e converge para uma região do espaço de busca. Nota-se ainda que as restrições são mantidas no fator de potência ($\pm 0,95$).


Figura 5.2 – Evolução da população inicial ao longo das gerações do AG.



Fonte: Elaboração própria

A figura 5.3 apresenta os menores valores da função objetivo (perdas de potência ativa) para as soluções encontradas pelo AG ao longo das gerações. No gráfico, cada linha representa um dos cinco ensaios realizados. Nota-se que na maioria dos ensaios, o método converge para a solução. O uso de elitismo no AG não permite o aumento do valor das melhores soluções, o que fica evidenciado no gráfico.


Figura 5.3 – Menores valores para a função objetivo (MW).



Fonte: Elaboração própria

A figura 5.4 apresenta a média dos menores valores da função objetivo ao longo das gerações, considerando os cinco ensaios. Observa-se que a média das menores soluções convergiu em torno da 15ª geração. O rápido declive para a melhor solução sugere que este problema, que possui poucas variáveis, não é de alta complexidade.


Figura 5.4 - Média dos menores valores para a função objetivo (MW).



Fonte: Elaboração própria

As soluções obtidas também são apresentadas utilizando o *boxplot* (“diagrama em caixa”), que mostra cinco medidas estatísticas conforme ilustra a figura 5.5, as quais são: valor mínimo, primeiro quartil (Q1), mediana (segundo quartil Q2), terceiro quartil (Q3), valor máximo e valores atípicos (outliers). O *boxplot* é um gráfico muito utilizado para análise de desempenho de métodos que exibem característica estocástica como o AG e o Recozimento Simulado, onde em cada ensaio pode-se chegar a uma solução diferente.


Figura 5.5 - Elementos de um *boxplot*.



Fonte: Elaboração própria

Assim, a figura 5.6 apresenta o gráfico *boxplot* das menores soluções encontradas pelo AG ao longo das gerações, em todos os ensaios. O gráfico mostra a variação nas soluções obtidas. Observa-se que as primeiras gerações possuem soluções com altos valores de perdas, mas em poucas gerações cai bastante o valor da mediana e depois se mantém estável. Nota-se que o uso de elitismo conduz a constante redução das melhores soluções. A presença de *outliers* em todas as gerações deve-se ao 5º ensaio que não convergiu tão bem.

Figura 5.6 – *Boxplot* da função objetivo das perdas de potência (MW).



Fonte: Elaboração própria

b) Análise Probabilística com AG

Neste caso, as configurações adotadas para o AG foram as seguintes:

- Seleção por Torneio com dois participantes ($k=2$) e alternância de 10% ($\alpha = 10\%$);
- Elitismo: 10%;
- Cruzamento com um ponto de corte;
- Taxa de cruzamento: 70%;
- Taxa de mutação: 3%;
- Tamanho da população: 60 indivíduos;
- Critério de parada: máximo de 60 gerações.

Os resultados dos cinco ensaios realizados são apresentados na tabela 5.5. Observa-se que o melhor resultado foi obtido no ensaio 5, pois alcançou-se 800,95 MWh de perda anual em 13 gerações. Em média, a menor perda anual foi 801,42 MWh.


Tabela 5.5 – Resultados usando Análise Probabilística com AG para o Caso I.

Ensaio	Barra	Potência da Eólica (MW)	Fator de Potência	Perdas Anuais (MWh)
1	6	3,7126	+0,95	800,95
2	26	3,6063	+0,95	803,28
3	6	3,7121	+0,95	800,95
4	6	3,7129	+0,95	800,95
5	6	3,7144	+0,95	800,95
Média	-	-	-	801,42

Fonte: Elaboração própria

A Figura 5.7 mostra a evolução da população inicial ao longo das gerações do AG. Nota-se que a população inicialmente é bem diversa e converge para uma região do espaço de busca. Nota-se ainda que as restrições são mantidas no fator de potência ($\pm 0,95$), as soluções se concentram na barra 6 e potência acima de 3,5 MW.


Figura 5.7 – Evolução da população inicial ao longo das gerações do AG.



Fonte: Elaboração própria

A figura 5.8 apresenta os menores valores encontrados para a função objetivo pelo AG ao longo das gerações. Cada linha está associada a um ensaio dos cinco ensaios realizados. Observa-se que em dois ensaios a convergência ocorre antes da 10ª geração, dois convergem em torno da 17ª geração e um após a 25ª geração. Apenas um ensaio não convergiu para a menor solução e ficou preso em um mínimo local.


Figura 5.8 – Menores valores para a função objetivo (MWh).



Fonte: Elaboração própria

A figura 5.9 mostra a média dos menores valores encontrados para a função objetivo para os cinco ensaios, referente às soluções do AG ao longo das gerações. Nota-se a gradual convergência que ocorre após 25ª geração. Apesar deste problema ainda ser resolvido muito antes da última geração, nota-se uma complexidade maior no uso da análise probabilística em relação à determinística, devido a combinação entre os diversos cenários.


Figura 5.9 – Média dos menores valores para a função objetivo (MWh).



Fonte: Elaboração própria

A figura 5.10 mostra o gráfico *boxplot* com a distribuição das médias das menores perdas de energia referente às soluções do AG ao longo das gerações, em todos os ensaios. Nota-se que em todos os ensaios os valores ficam muito próximos, com exceção de um ensaio que é evidenciado pela presença de *outliers*. Observa-se a constante redução da diferença entre o Q1 e Q3, o que mostra que os ensaios iniciados em condições diferentes atingem, em poucas gerações, as melhores soluções com valores próximos.


Figura 5.10 – Boxplot da função objetivo das perdas de energia anual (MWh).



Fonte: Elaboração própria

A figura 5.11 mostra os perfis de tensão dos melhores resultados deste cenário e do caso base. Realizou-se o fluxo de carga para o cenário probabilístico considerando a potência nominal e carga máxima. Utilizou-se a alocação da eólica na barra 6, com 3,7144 MW de potência ativa e fator de potência de +0,95. Observa-se que as tensões no cenário probabilístico, com GD, são mais próximas de 1 p.u, portanto possuem melhor qualidade no fornecimento de energia do que o caso base, que não possui a alocação da GD.

Figura 5.11 – Perfis de tensão dos resultados da abordagem probabilística e do caso base.



Fonte: Elaboração própria

c) *Análise Probabilística com Recozimento Simulado*

Para a utilização do método Recozimento Simulado considerou-se como critério de parada o número máximo de 3600 avaliações. Este número corresponde ao mesmo número de avaliações do AG com 60 indivíduos em 60 gerações, para efeito de comparação. Segue abaixo as configurações padrão do Matlab utilizadas para o RS:

- Temperatura inicial: 100;
- Taxa de resfriamento: 0,95;
- Intervalo de *reannealing*: 100;
- Probabilidade de aceitação: $\frac{1}{1+e^{\left(\frac{\Delta}{\max(T)}\right)}}$.

O parâmetro “Intervalo de *reannealing*” define o número de novas soluções aceitos para que haja o *reannealing*, ou seja, o procedimento de elevar a temperatura e reiniciar a busca, com o intuito de sair de mínimos locais.

Os resultados dos ensaios realizados são apresentados na tabela 5.6. Observa-se que o melhor resultado foi obtido no ensaio 4, pois alcançou-se 800,95 MWh de perda anual de energia em 105 iterações. Em média, a menor perda anual foi 801,88 MWh.


Tabela 5.6 – Resultados usando Análise Probabilística com Recozimento Simulado para o Caso I.

Ensaio	Barra	Potência da Eólica (MW)	Fator de Potência	Perdas Anuais (MWh)
1	26	3,6132	+0,95	803,28
2	26	3,6013	+0,95	803,28
3	6	3,7149	+0,95	800,95
4	6	3,7124	+0,95	800,95
5	6	3,7118	+0,95	800,95
Média	-	-	-	801,88

Fonte: Elaboração própria

A figura 5.12 mostra os menores valores encontrados para a função objetivo utilizando o método Recozimento Simulado ao longo das iterações, tendo sido realizados cinco ensaios. Inicialmente, quando o parâmetro temperatura é alto, aumentos significativos na função objetivo são tolerados pelo algoritmo, explorando algumas soluções longe do ótimo. No entanto, conforme a temperatura diminui apenas aumentos de menor magnitude na função objetivo são permitidos. Assim, no final, o algoritmo tem comportamento de busca local, comportamento típico do algoritmo Recozimento Simulado. O aumento das perdas de energia de forma cíclica é consequência do *reannealing*, que realiza o aumento da temperatura para tentar evitar mínimos locais e explorar novas soluções.


Figura 5.12 – Perdas Anuais (MWh).



Fonte: Elaboração própria

A figura 5.13 mostra a média dos menores valores encontrados para a função objetivo utilizando o método Recozimento Simulado ao longo das iterações, para os cinco ensaios realizados. Nota-se claramente o efeito do *reannealing*, que realiza o aumento de temperatura por volta da iteração 700 aumentando o valor da função objetivo, mas por volta da iteração 1300 permite uma considerável redução do valor da função objetivo.

Figura 5.13 – Média das Perdas Anuais (MWh).



Fonte: Elaboração própria

Para facilitar a comparação entre os métodos, o quadro 5.1 exibe as soluções ótimas encontradas para cada método utilizado no caso em que é feita a alocação de um parque eólico no sistema. Os resultados mostram que a otimização do sistema utilizando a análise probabilística apresenta maior redução das perdas anuais de energia, seja utilizando o Algoritmo Genético ou o Recozimento Simulado. No entanto, nota-se que o Algoritmo Genético apresenta um resultado similar ao Recozimento Simulado, uma vez que foram iguais as perdas anuais, no entanto, o Recozimento Simulado apresentou maior agilidade para encontrar a melhor solução.

Quadro 5.1 – Resultados obtidos para o Caso I: alocação de um parque eólico no sistema.

Método	Barra	Potência da Eólica (MW)	Fator de Potência	Geração/ Iteração ótima	Tempo de Execução	Perdas Anuais (MWh)
Análise Determinística com AG	6	2,8443	+0,95	25	0 h 0 min 13 s	815,70
Análise Probabilística com AG	6	3,7144	+0,95	13	0 h 5 min 57 s	800,95
Análise Probabilística com RS	6	3,7124	+0,95	105	0 h 1 min 44 s	800,95

Fonte: Elaboração própria

5.5.3 Caso II: alocação de dois parques eólicos no sistema

Neste caso é feita a alocação ótima de dois parques eólicos no sistema de distribuição. As simulações foram realizadas aplicando três métodos: análise probabilística utilizando AG (proposto), análise determinística utilizando AG e a análise probabilística utilizando Recozimento Simulado, as quais são apresentadas a seguir.

a) Análise Determinística com AG

Neste caso, as configurações adotadas para o AG foram:

- Seleção por Torneio com dois participantes ($k=2$) e alternância de 10% ($\alpha = 10\%$);
- Elitismo: 10%;
- Cruzamento com um ponto de corte;
- Taxa de cruzamento: 70%;
- Taxa de mutação: 3%;
- Tamanho da população: 80 indivíduos;
- Critério de parada: máximo de 80 gerações.

Foram realizados cinco ensaios e os resultados obtidos são apresentados na tabela 5.7. Observa-se que o melhor resultado foi obtido no ensaio 4, pois alcançou-se 727,20 MWh de perdas anuais em 78 gerações. Em média, a perda anual obtida com a alocação de dois parques eólicos no sistema foi de 730,35 MWh.


Tabela 5.7 – Resultados usando Análise Determinística com AG para o Caso II.

Ensaio	Barra	Potência da Eólica (MW)	Fator de Potência	Perdas de Potência (MW)	Perdas Anuais (MWh)
1	30	1,3354	+0,95	0,0454	723,66
	12	0,9845	+0,95		
2	29	1,4220	+0,95	0,0464	728,64
	13	0,8708	+0,95		
3	6	2,1187	+0,95	0,0561	747,50
	14	0,6675	+0,95		
4	30	1,3662	+0,95	0,0452	727,20
	13	0,8675	+0,95		
5	30	1,3323	+0,95	0,0453	724,74
	13	0,9288	+0,95		
Média	-	-	-	0,0477	730,35

Fonte: Elaboração própria

A figura 5.14 apresenta os menores valores da função objetivo (perdas de potência) para as soluções encontradas pelo AG ao longo das gerações, considerando os cinco ensaios. Nota-se que apenas no ensaio 3 o AG parou de evoluir brevemente, os outros ensaios reduziram os valores da função objetivo nas primeiras gerações e continuaram reduzindo gradativamente até as últimas gerações. O número de variáveis envolvidas neste problema aumentou a complexidade e levou o AG a encontrar tardiamente a melhor solução.


Figura 5.14 – Menores valores para a função objetivo (MW).



Fonte: Elaboração própria

A figura 5.15 mostra a média para os menores valores da função objetivo, maiores valores e valores médios das soluções encontradas pelo AG ao longo das gerações, considerando todos os ensaios. As menores perdas e média de perdas mostram a evolução das soluções para as menores perdas. Enquanto que os gráficos das maiores perdas não exibem um padrão de decaimento da perda durante as iterações, mas mostra uma oscilação das perdas devido às punições recebidas pelas soluções que não atendem as restrições. Observa-se que as soluções mantêm valores em torno da mesma média próximos à geração 20.


Figura 5.15 – Média das Perdas de Potência (Menores, Maiores e Média) (MW).



Fonte: Elaboração própria

A figura 5.16 mostra a média dos menores valores encontrados para a função objetivo ao longo das gerações do AG. As gerações correspondem ao eixo X e as perdas de potência (MW) ao eixo Y . Os gráficos das médias das menores perdas usando AG apenas decaem ou ficam estáveis, devido o uso de elitismo. O elitismo sempre leva as melhores soluções para a próxima geração, dessa forma gera uma tendência de apenas melhorar os resultados, ou seja, reduzir as perdas.


Figura 5.16 – Média das Menores Perdas de Potência (MW).



Fonte: Elaboração própria

A figura 5.17 mostra o gráfico *boxplot* com a distribuição das médias das menores perdas de potência referente às soluções do AG ao longo das gerações. Observa-se a constante redução do valor da mediana, o que mostra que a evolução dos valores entre os melhores resultados. O *outlier* é consequência do ensaio 3 que não obteve uma contínua redução dos melhores resultados, pois ficou estagnado em torno da 15ª geração.

Figura 5.17 – Boxplot da função objetivo das perdas de potência (MW).



Fonte: Elaboração própria

b) Análise Probabilística com AG

Seguem as configurações do AG adotadas para estas simulações:

- Seleção por Torneio com dois participantes ($k=2$) e alternância de 10% ($\alpha = 10\%$);
- Elitismo: 10%;
- Cruzamento com um ponto de corte;
- Taxa de cruzamento: 70%;
- Taxa de mutação: 3%;
- Tamanho da população: 80 indivíduos;
- Critério de parada: máximo de 80 gerações.

Os resultados dos ensaios realizados são apresentados na tabela 5.8. Observa-se que o melhor resultado foi obtido no ensaio 2, pois alcançou-se 675,95 MWh de perda anual de energia em 50 gerações. Em média, a menor perda anual foi 676,21 MWh. Nota-se que em apenas dois ensaios alcançou-se os valores ótimos, enquanto que os outros ensaios aproximaram-se da melhor solução.


Tabela 5.8 – Resultados usando Análise Probabilística com AG para o Caso II.

Ensaio	Barra	Potência da Eólica (MW)	Fator de Potência	Perdas Anuais (MWh)
1	30	1,8575	+0,95	675,95
	9	1,8567	+0,95	
2	30	1,9733	+0,95	675,95
	10	1,6726	+0,95	
3	8	1,8860	+0,95	676,32
	30	1,8277	+0,95	
4	30	1,8572	+0,95	676,85
	10	1,7024	+0,95	
5	30	1,8554	+0,95	675,98
	9	1,8583	+0,95	
Média	-	-	-	676,21

Fonte: Elaboração própria

A figura 5.18 mostra os menores valores encontrados para a função objetivo pelo AG ao longo das gerações para os cinco ensaios realizados. Cada linha representa as perdas de energia em um ensaio. Nota-se que todos os ensaios convergem para as melhores soluções. No entanto, é possível verificar que alguns ensaios têm o desempenho sensivelmente melhores que outros. A redução dos valores melhores valores em forma de escada é uma característica presença de elitismo na configuração do AG.


Figura 5.18 – Menores valores para a função objetivo (MWh).



Fonte: Elaboração própria

A figura 5.19 mostra a média para os menores valores da função objetivo, maiores valores e valores médios das soluções encontradas pelo AG ao longo das gerações, considerando todos os ensaios. Observa-se que as maiores perdas variam sem convergirem, pois estas perdas são soluções que não atendem às restrições do problema e recebem por isso penalidades, resultando em altos valores de perdas e dificultando a propagação destas soluções para as gerações seguintes. Os menores valores começam a convergir entre a 20ª e 30ª geração, mas continuam reduzindo os valores de perdas nas próximas gerações. A média deixa evidente a evolução da população e a oscilação da linha devido à influência das maiores soluções.


Figura 5.19 – Média das Perdas de Energia (Menores, Maiores e Média) (MWh).



Fonte: Elaboração própria

A figura 5.20 mostra a média dos menores valores encontrados para a função objetivo do AG ao longo das gerações. Observa-se que a convergência dos valores ocorre na metade do total de gerações, o que indica que se o número de gerações fosse muito inferior a 80 os valores ótimos poderiam não ser alcançados. Nota-se a presença de elitismo devido à curva ora descendente e ora constante.


Figura 5.20 – Média dos menores valores para a função objetivo (MWh).



Fonte: Elaboração própria

A figura 5.21 mostra o gráfico *boxplot* com a distribuição das médias das menores perdas de energia referente às soluções do AG ao longo das gerações. Observa-se a ausência de *outliers* a partir da 25ª geração, isto ocorre devido todos os ensaios convergirem com valores próximos a melhor solução. Nota-se que os *boxplots* das últimas gerações são pequenos, pouca variância entre os melhores resultados dos ensaios.


Figura 5.21 – Boxplot da função objetivo das perdas de energia anual (MWh).



Fonte: Elaboração própria

A figura 5.22 mostra os perfis de tensão dos melhores resultados deste cenário e do caso base. Realizou-se o fluxo de carga para o cenário probabilístico considerando a potência nominal e carga máxima. Utilizou-se a alocação da eólica na barra 30, com 1,9733 MW de potência e fator de potência de +0,95; e na barra 10, com 1,6726 MW de potência e fator de potência de +0,95. Observa-se valores de tensão acima de 1 p.u no cenário probabilístico, isto ocorre devido a injeção de potência da GD em duas barras, cuja geração estão mais próximas à carga do sistema.

Figura 5.22 – Perfis de tensão dos resultados da abordagem probabilística e do caso base.



Fonte: Elaboração própria

c) *Análise Probabilística com Recozimento Simulado*

Neste caso, adotou-se como critério de parada para o recozimento simulado o número máximo de 6400 avaliações. Este número corresponde ao mesmo número de avaliações do AG com 80 indivíduos em 80 gerações, para efeito de comparação. Segue abaixo as configurações padrão do Matlab utilizadas para o RS:

- Temperatura inicial: 100;
- Taxa de resfriamento: 0,95;
- Intervalo de *reannealing*: 100;
- Probabilidade de aceitação: $\frac{1}{1+e^{\left(\frac{\Delta}{\max(T)}\right)}}$.

Os resultados dos ensaios realizados são apresentados na tabela 5.9. Observa-se que o melhor resultado foi obtido no ensaio 5, pois alcançou-se 683,29 MWh de perda anual em 4971 iterações. Em média, a menor perda anual foi 698,29.


Tabela 5.9 – Resultados usando Análise Probabilística com Recozimento Simulado para o Caso II.

Ensaio	Barra	Potência da Eólica (MW)	Fator de Potência	Perdas Anuais (MWh)
1	27	1,6904	+0,95	705,47
	29	2,0126	+0,95	
2	7	2,1288	+0,95	693,72
	29	1,5824	+0,95	
3	6	2,5890	+0,95	707,86
	10	1,1214	+0,95	
4	26	2,4133	+0,95	701,02
	12	1,3016	+0,95	
5	29	1,6709	+0,95	683,39
	8	1,9171	+0,95	
Média	-	-	-	698,29

Fonte: Elaboração própria

A figura 5.23 mostra o valor da função objetivo para as soluções encontradas pelo RS ao longo das iterações para cada um dos cinco ensaios. Cada linha representa as perdas em um ensaio. Observa-se variações cíclicas nos valores das perdas devido à ação do *reannealing* com objetivo de sair dos mínimos locais. No entanto, a exploração da melhor solução pela técnica é insuficiente devido à complexidade do problema.


Figura 5.23 – Perdas Anuais (MWh).



Fonte: Elaboração própria

A figura 5.24 mostra a média dos menores valores encontrados para a função objetivo utilizando o método Recozimento Simulado ao longo das iterações, para os cinco ensaios realizados. Observa-se uma grande redução nas perdas nas primeiras iterações, mas uma relativa estagnação em mínimos locais ao longo das iterações. Nota-se a tentativa de fuga dos mínimos locais através do *reannealing*, resultando em uma sensível melhora, no entanto, menos efetivo que o AG na exploração de novas soluções.

Figura 5.24 – Média das Perdas Anuais (MWh).



Fonte: Elaboração própria

Para avaliar os resultados obtidos no caso II (alocação de dois parques eólicos), o quadro 5.2 apresenta as soluções ótimas encontradas utilizando cada técnica de otimização. Os resultados mostram que a otimização do sistema com a análise probabilística utilizando o Algoritmo Genético apresenta maior redução das perdas anuais de energia. Além disso, nota-se que o Algoritmo Genético apresenta melhor desempenho computacional quando comparado ao Recozimento Simulado, uma vez que sua convergência é bem mais rápida.

Quadro 5.2 – Consolidação dos Melhores Resultados para o Cenário II.

Método	Barra	Potência da Eólica (MW)	Fator de Potência	Iteração	Tempo de Execução	Perdas Anuais (MWh)
Análise Determinística com AG	30	1,3662	+0,95	78	0 h 0 min 55 s	727,20
	13	0,8675	+0,95			
Análise Probabilística com AG	30	1,9733	+0,95	50	9 h 34 min 9 s	675,95
	10	1,6726	+0,95			
Análise Probabilística com RS	29	1,6709	+0,95	4971	16 h 22 min 41 s	683,39
	8	1,9171	+0,95			

Fonte: Elaboração própria

5.5.4 Discussão dos resultados obtidos

Os resultados apresentados permitiram avaliar a metodologia da análise probabilística com AG; comparar a análise probabilística com a análise determinística; e analisar a diferença do uso da análise probabilística com AG e com RS.

A configuração do AG foi escolhida a partir de diversos testes iniciais, para posteriormente aplicá-la nos cenários propostos. A característica estocástica dos métodos AG e RS impedem que apenas um ensaio seja realizado para obter resultados confiáveis. Por este motivo foram registrados 5 ensaios para avaliar cada metodologia.

Os quadros consolidados com os melhores resultados apresentam o campo “Tempo de Execução”. Este campo permite comparar o desempenho computacional das técnicas utilizadas. Observa-se que o RS, por ser um método mais simples, alcança bons resultados usando um tempo inferior ao AG para o Caso I, que é um problema mais simples onde busca-se os valores das variáveis para uma eólica. Para o Caso II, a complexidade do uso de duas eólicas dobra o número de variáveis a serem otimizadas e permite que o AG encontre resultados melhores e antes do RS.

O quadro 5.3 apresenta todos os resultados obtidos utilizando todos os métodos para todos os casos considerados. Nota-se que a alocação do parque eólico no sistema reduz as perdas anuais de energia, conforme já era esperado. Nota-se também que com o uso da análise probabilística obtém-se maior redução das perdas anuais de energia quando comparado com a análise determinística para ambos os casos I e II, sendo esta redução mais evidente no caso II, em que o problema é mais complexo (de 727,20 MWh para 675,95 MWh). Vale salientar que o método probabilístico utilizando o Recozimento Simulado mostrou-se inferior computacionalmente quando comparado ao AG, por ter maior tempo de simulação.

Quadro 5.3 – Consolidação das Menores Perdas Anuais.

Caso	Método	Barra	Potência da Eólica (MW)	Fator de Potência	Perdas Anuais (MWh)
Caso Base	Sem Otimização	-	-	-	1054,62
Caso I	Análise Determinística com AG	6	2,8443	+0,95	815,70
	Análise Probabilística com AG	6	3,7144	+0,95	800,95
	Análise Probabilística com RS	6	3,7124	+0,95	800,95
Caso II	Análise Determinística com AG	30	1,3662	+0,95	727,20
		13	0,8675	+0,95	
	Análise Probabilística com AG	30	1,9733	+0,95	675,95
		10	1,6726	+0,95	
	Análise Probabilística com RS	29	1,6709	+0,95	683,39
		8	1,9171	+0,95	

Fonte: Elaboração própria

CAPÍTULO 6

CONCLUSÃO

6.1 CONSIDERAÇÕES FINAIS

Este trabalho apresentou um método para alocação ótima de parques eólicos em sistemas de distribuição de energia utilizando uma abordagem probabilística e Algoritmo Genético. O objetivo da otimização foi minimizar as perdas anuais de energia considerando as restrições características do problema. O sistema utilizado foi o sistema de distribuição de 33 barras bastante comum na literatura.

Para análise dos resultados, três cenários foram avaliados:

- Caso Base – Sem conexão com parque eólico;
- Caso I – Alocação de um parque eólico no sistema;
- Caso II – Alocação de dois parques eólicos no sistema.

Os resultados mostraram que a utilização da metodologia proposta para alocação do parque eólico reduz as perdas anuais de energia no sistema para ambos os casos I e II. No entanto, esta redução é mais significativa para o caso II. Isto ocorre pois a geração é instalada próximo à carga do sistema, reduzindo as perdas decorrentes da transmissão de energia ao longo da rede.

Para avaliar o desempenho do método proposto, a alocação ótima de parques eólicos no sistema também foi realizada utilizando os seguintes métodos, além do método proposto (Método probabilístico utilizando AG):

- Método determinístico utilizando AG;
- Método probabilístico utilizando Recozimento Simulado.

Os resultados mostraram que a metodologia proposta, que faz uso da abordagem probabilística com o AG, propiciou uma redução significativa nas perdas anuais de energia, em comparação com a abordagem determinística. Isto ocorre uma vez que a abordagem probabilística é mais realista, e considera a possibilidade de ocorrência de diversos cenários de demanda e geração eólica. Já na abordagem determinística, a demanda permanece constante, assim como a potência gerada pela eólica, o que não ocorre de fato visto que a mesma depende da velocidade do vento.

Além disso, o método probabilístico utilizando o Recozimento Simulado mostrou-se inferior computacionalmente quando comparado ao método probabilístico utilizando o AG, por apresentar maior tempo de simulação.

Para o Caso I, onde é feita a alocação de apenas uma eólica, ambos os métodos probabilístico utilizando o AG e probabilístico utilizando o Recozimento Simulado obtiveram soluções com o mesmo valor de perdas anuais de energia. Isto ocorreu devido à simplicidade do problema envolvendo um número reduzido de variáveis a serem otimizadas. Já para o Caso II, onde faz-se a alocação ótima de dois parques eólicos no sistema, os resultados da abordagem probabilística com AG foram melhores do que os resultados com Recozimento Simulado. Isto ocorreu devido à complexidade do problema ter aumentado, havendo maior número de variáveis envolvidas e maior número de cenários.

Portanto, os resultados sugerem que o AG é mais apropriado que RS para o problema proposto em condições de média e grande complexidade, mas em condições mais simples os dois métodos possuem soluções equivalentes. A simplicidade do método RS contribui para um melhor desempenho no tempo de execução.

Por fim, observa-se que a metodologia proposta do uso da abordagem probabilística com AG é satisfatória para problemas de minimização de perdas de energias em um sistema de distribuição.

6.2 TRABALHOS FUTUROS

Diversos trabalhos futuros podem ser feitos para aprimorar esta pesquisa, seguem algumas sugestões:

- Utilização de outros sistemas testes de maior dimensão;
- Utilização de sistemas malhados de subtransmissão, ao invés de sistemas radiais de distribuição;
- Utilização de dados reais para modelar o comportamento do vento considerando a região, de modo a obter resultados mais realistas;
- Realização de experimentos com outras técnicas de otimização bioinspiradas em um sistema de distribuição;
- Utilizar a abordagem probabilística proposta para a alocação ótima de parques eólicos e sistemas fotovoltaicos no sistema, sendo ambas as fontes intermitentes.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDI. **Mapeamento da Cadeia Produtiva da Indústria Eólica no Brasil**. Brasília, 2014.
- ABOU EL-ELA, A.A.; ALLAM, S.M.; SHATLA, M.M. **Maximal optimal benefits of distributed generation using genetic algorithms**. Electric Power Systems Research, 2010. Vol. 80, pp. 869–877.
- ALVES, H.N.; BRANCO, C.A.S.C. **Um algoritmo genético para a alocação ótima de unidades de geração distribuída em redes de distribuição**. XIX Congresso Brasileiro de Automática, 2012.
- ANEEL. **Atlas de Energia Elétrica do Brasil**. 2. ed. Brasília, 2002. 243p.
- ARTERO, A.O. **Inteligência Artificial: Teoria e Prática**, São Paulo, Livraria da Física, 2009.
- ATWA, Y.M.; EL-SAADANY, E.F. **Probabilistic approach for optimal allocation of wind based distributed generation in distribution systems**. IET Renew. Power Gener., 2011. Vol. 5, Iss. 1, pp. 79–88.
- BHATTACHARYA, P. **Weibull Distribution for Estimating the Parameters**. Wind Energy Management, 2011. ISBN: 978-953-307-336-1.
- CREPINSEK, M.; LIU, S. H.; MERNIK, M. **Exploration and exploitation in evolutionary algorithms: A survey**, ACM Comput. Surv., 2013. 45 (3) 33–35.
- CRESESB (Centro de Referência para Energia Solar e Eólica). **Tutorial Energia Eólica**. Rio de Janeiro, 2008. Disponível em: <www.cresesb.cepel.br>. Acesso em 05 dez. 2015.
- DUTRA, R. M.; SZKLO, A. S. **A Energia Eólica no Brasil: Proinfa e o Novo Modelo do Setor Elétrico**. XI Congresso Brasileiro de Energia (CBE). COPPE/UFRJ, Rio de Janeiro, 2006.
- ELETROBRÁS. **Programa de Incentivo às Fontes Alternativas de Energia Elétrica (Proinfa)**. Disponível em: <www.eletrobras.com>. Acesso em: 22 nov. 2015.
- ELNASHAR, M.M.; SHATSHAT, R.E.; SALAMA, M.M.A. **Optimum siting and sizing of a large distributed generator in a mesh connected system**. Electric Power Systems Research, 2010. Vol. 80, pp. 690–697.
- EL-ZONKOLY, A.M. **Optimal placement of multi-distributed generation units including different load models using particle swarm optimization**. IET Generation, Transmission & Distribution, 2011. Vol. 5, Iss. 7, pp. 760–771.
- EPE (Empresa de Pesquisa Energética). **Balanço Energético Nacional 2015: Ano base 2014**, Rio de Janeiro, 2015. Disponível em: <www.mme.gov.br>. Acesso em: 15 jul. 2016.

EWEA (European Wind Energy Association). **Wind in Power: 2015 European Statistics**, 2016. Disponível em: <www.ewea.org>. Acesso em: 09 jul. 2016.

FACELI, K.; LORENA, A.C.; GAMA, J.; CARVALHO, A.C.P.L.F. **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**. Rio de Janeiro, LTC, 2011.

FIORIN, M. **Estratégias de controle coordenado de tensão para sistemas de distribuição com geração eólica**. Dissertação. Universidade Tecnológica Federal do Paraná, Pato Branco, 2014.

GUERREIRO, G. A. V. **Análise em Regime Permanente de Parques Eólicos com Máquinas SCIG e DFIG**. 2014. 111p. Dissertação. UFRGS, Porto Alegre, 2014.

GWEC (Global Wind Energy Council). **Global Wind Report 2015**, 2016. Disponível em: <www.gwec.net>. Acesso em: 25 jun. 2016.

HUNG, D.Q.; MITHULANANTHAN, N.; BANSAL, R.C. **Analytical Expressions for DG Allocation in Primary Distribution Networks**. IEEE Transactions on Energy Conversion, Vol. 25, No. 3, 2010.

HUNG, D.Q.; MITHULANANTHAN, N.; LEE, K.Y. **Optimal placement of dispatchable and nondispatchable renewable DG units in distribution networks for minimizing energy loss**. Electrical Power and Energy Systems, Vol.55, pp. 179-186. 2014.

IEA (International Energy Agency). **Technology Roadmap: Wind Energy 2013**, 2014.

JAIN, N.; SINGH, S.N.; SRIVASTAVA, S.C. **PSO Based Placement of Multiple Wind DGs and Capacitors utilizing Probabilistic Load Flow Model**. Journal of Swarm and Evolutionary Computation, Vol. 19, 15–24. 2014.

KIRKPATRICK, S.; GELATT, C.D.; VECCHI, M.P. **Optimization by simulated annealing**, Science, v. 220, p. 671-680, 1983.

LEITE, A. P.; FALCÃO, D. M.; BORGES, C. L. T. **Modelagem de Usinas Eólicas para Estudos de Confiabilidade**. Sba Controle & Automação. 2006, vol.17, n.2, pp. 177-188. ISSN 0103-1759.

LEITE, M.L.; FILHO, J. S. V. **Ajuste de Modelos de Distribuição de Probabilidade a Séries Horárias de Velocidade do Vento para o Município de Ponta Grossa, Estado do Paraná**. Acta Scientiarum Technology, v. 33, p. 447-455, 2011.

LINDEN, R. **Algoritmos Genéticos**. 3. ed. Rio de Janeiro, Ciência Moderna, 2012.

MME (Ministério de Minas e Energia). **Resenha Energética Brasileira 2015**, 2016. Disponível em: <www.mme.gov.br>. Acesso em: 09 jul. 2016.

METROPOLIS, N.; ROSENBLUTH, M.; ROSENBLUTH, A.; TELLER, A.; TELLER, E. **Equations of state calculations by fast computing machines**. Journal of Chemical Physics, v. 21, p.1087-1092, 1953.

MOHAMMADI, M.; NAFAR, M. **Optimal placement of multitypes DG as independent private sector under pool/hybrid power market using GA-based Tabu Search method.** Int. J. Electr. Power Energy Syst., 51, 43-53. 2013.

MONTEIRO, F. **Modelos Equivalentes de Parques Eólicos usando Algoritmos Genéticos.** Dissertação. ITEC/UFPA. Belém, 2013.

MORADI, M.H.; ABEDINI, M.A. **Combination of Genetic Algorithm and Particle Swarm Optimization for Optimal DG location and sizing in Distribution Systems.** Int J Electr Power Energy Syst., 34(1):66–74. 2012.

NASCIMENTO, A.C. **Avaliação de Estratégias de Controle de Potência Reativa de Aerogeradores Síncronos em Rede Elétrica.** Tese. ITEC/UFPA, Belém, 2009.

OCHOA, L. F. P. **Desempenho de Redes de Distribuição com Geradores Distribuídos.** Tese. Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha Solteira, 2006.

PATEL, M. R. **Wind and Solar Power Systems : design, analysis, and operation.** 2nd Edition, Taylor & Francis, 2006.

PINHEIRO, J.M.S.; DORNELLAS, C.R.R.; MELO, A.C.G. **Probing the new IEEE reliability test system (RTS-96).** IEEE Trans. Power Syst., Vol.13, (1), pp. 171–176, 1998.

PRADO, I.F. **Alocação de geração distribuída utilizando o algoritmo genético de Chu-Beasley e índices de sensibilidade;** Dissertação. Universidade Federal do ABC, Santo André, 2013.

REIS, J. M. V. S. **Comportamento dos Geradores Eólicos Síncronos com Conversores diante de Curto-Circuitos no Sistema.** Dissertação. UFRJ/COPPE, Rio de Janeiro, 2013.

SALLES, M. B. C. **Modelagem e Análises de Geradores Eólicos de Velocidade Variável Conectados em Sistemas de Energia Elétrica.** Tese. Escola Politécnica da USP, São Paulo, 2009.

SANTOS, F. O.; BEZERRA, U. H.; MACHADO, R. N. M. **Uso do SVC para Melhorar a Estabilidade Transitória e o Perfil de Tensão em Sistemas Elétricos de Potência.** XXI Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNPTEE). Rio de Janeiro, 2007.

SILVA, G. R. **Características de Vento da Região Nordeste: Análise, Modelagem e Aplicações para Projetos de Centrais Eólicas.** Dissertação. Universidade Federal de Pernambuco, Recife, 2003.

SILVA, P. C.; GUEDES, V. G.; ARAUJO, M. R. O. P.; HIRATA, M. H. **Otimização dos Parâmetros da Distribuição de Weibull.** Congresso Brasileiro de Engenharia Mecânica (COBEM), Águas de Lindóia, 1999.

SILVA, S. S. J. **Avaliação da Resposta Dinâmica de Diferentes Tecnologias de Aerogeradores**. Monografia. UFRJ/ Escola Politécnica, Rio de Janeiro, 2015.

SOHN, A. P. **Estudos de Estabilidade de Sistemas Elétricos de Potência na Presença de Diferentes Modelos de Unidades Eólicas**. Dissertação. EESC/USP, São Carlos, 2014.

TEIXEIRA, O.N.; LOBATO, W.A.L.; YANAGUIBASHI, H.S.; CAVALCANTE, R.V.; SILVA, D.J.A.; OLIVEIRA, R.C.L. **Algoritmo Genético com Interação Social na Resolução de Problemas de Otimização Global com Restrições**, cap. 10, 1. ed. pp. 197–223. OMNIPAX, 2011.

UGRANLI, F.; KARATEPE, E. **Optimal wind turbine sizing to minimize energy loss**. Electrical Power and Energy Systems, Vol. 53, pp. 656–663, 2013.

UPWIND. **Concept report on generator topologies, mechanical & electromagnetic optimization**. 2007.

WALCK, C. **Hand-book on STATISTICAL DISTRIBUTIONS for experimentalists**. Internal Report SUF–PFY/96–01, Stockholm, 1996.

YU, H; CHUNG, C.Y.; WONG, K.P.; ZHANG, J.H. **A Chance Constrained Transmission Network Expansion Planning Method With Consideration of Load and Wind Farm Uncertainties**. IEEE Transactions on Power Systems, Vol. 24, No. 3. 2009.