



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
CAMPUS DE GUARATINGUETÁ

JUSTO JOSÉ ROBERTS

**OTIMIZAÇÃO DE SISTEMAS HÍBRIDOS DE GERAÇÃO DE ENERGIA
SOLAR-EÓLICO-DIESEL ATRAVÉS DE MÉTODOS METAHEURÍSTICOS
E FUNÇÃO MULTIOBJETIVO**

Guaratinguetá

2016

JUSTO JOSÉ ROBERTS

OTIMIZAÇÃO DE SISTEMAS HÍBRIDOS DE GERAÇÃO DE ENERGIA
SOLAR-EÓLICO-DIESEL ATRAVÉS DE MÉTODOS METAHEURÍSTICOS E
FUNÇÃO MULTIOBJETIVO

Tese apresentada à Faculdade de
Engenharia do Campus de Guaratinguetá,
Universidade Estadual Paulista, para a
obtenção do título de Doutor em Engenharia
Mecânica na área de Energia.

Orientador: Prof. Dr. Agnelo Marotta Cassula

Co-orientador: Prof. Dr. José Luz Silveira

Guaratinguetá

2016

R643o	Roberts, Justo José Otimização de sistemas híbridos de geração de energia solar-eólico-diesel através de métodos metaheurísticos e função multiobjetivos / Justo José Roberts – Guaratinguetá, 2016. 291 f. : il. Bibliografia : f. 214-233 Tese (doutorado) – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2016. Orientador: Prof. Dr. Agnelo Marotta Cassula Coorientadores: Prof. Dr. José Luz Silveira 1. Energia – Fontes alternativas 2. Algoritmos genéticos 3. Metodos de simulação 4. Incerteza I. Título CDU 620.91(043)
-------	--

JUSTO JOSÉ ROBERTS


**ESTA TESE FOI JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE
“DOUTOR EM ENGENHARIA MECÂNICA”**

**PROGRAMA: ENGENHARIA MECÂNICA
ÁREA: ENERGIA**


APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO


Prof. Dr. José Antonio Perrella Balestieri
Coordenador

BANCA EXAMINADORA:


Prof. Dr. AGNELO MAROTTA CASSULA
Orientador / UNESP-FEG


Prof. Dr. JOSÉ ANTONIO PERRELLA BALESTIERI
UNESP/FEG


Prof. Dr. JOSÉ FELICIANO ADAMI
UNESP/FEG


Prof. Dr. EDSON DA COSTA BORTONI
UNIFEI


Prof. Dr. RONNEY ARISMEL MANCEBO BOLOY
CEFET/RJ

Agosto de 2016

DADOS CURRICULARES

JUSTO JOSÉ ROBERTS

NASCIMENTO	09.04.1983 – BUENOS AIRES / ARGENTINA
FILIAÇÃO	Tomás Roberts María Adela Roberts
2001/2007	Curso de Graduação em Engenharia Eletromecânica na Faculdade de Engenharia da Universidade Nacional de Mar del Plata, Mar del Plata, Argentina
2010/2012	Curso de Pós-Graduação em Engenharia Mecânica, nível de Mestrado, na Faculdade de Engenharia do Campus de Guaratinguetá da Universidade Estadual Paulista, Brasil
2012/2016	Curso de Pós-Graduação em Engenharia Mecânica, nível de Doutorado, na Faculdade de Engenharia do Campus de Guaratinguetá da Universidade Estadual Paulista, Brasil

AGRADECIMENTOS

Ao meu orientador, *Prof. Dr. Agnelo Marotta Cassula* que jamais deixou de me incentivar, pela paciência e dedicação na conclusão desta tese de doutorado,

ao meu co-orientador, *Prof. Dr. José Luz Silveira* por ter-me acolhido no seu grupo de pesquisa na minha chegada ao Brasil,

ao meu ex-professor, *Msc. Pedro Osvaldo Prado* quem me mostrou a possibilidade de fazer este curso de pós-graduação e me brindou todo seu apoio.

aos colegas da Pós-graduação em Engenharia Mecânica da FEG pelo companheirismo e auxílio durante o tempo que trabalhei neste projeto.

à UNESP, a FEG, aos professores, aos funcionários da Pós-graduação pelo apoio.

à minha família, que sempre esteve presente ao longo deste período em que estivemos distantes fisicamente. Ao meu pai, minha mãe, minha irmã, minha avó e minha tia que sempre apoiaram incondicionalmente meus projetos de vida, que me ensinaram a valorizar as coisas simples e que possibilitaram que eu realizasse este trabalho.

“If I have seen further than others, it is by standing upon the shoulders of giants”

Isaac Newton

ROBERTS J.J. **Otimização de Sistemas Híbridos de Geração de Energia Solar-Eólico-Diesel através de Métodos Metaheurísticos e Função Multiobjetivo.** 2016. 275 f. Tese (Doutorado em Engenharia Mecânica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2016.

RESUMO

Sistemas Híbridos de Geração de Energia (SHGE) baseados em fontes renováveis, quando dimensionados de forma correta, apresentam menor custo de energia gerada, maior confiabilidade no fornecimento de energia, além de benefícios ambientais, comparados a sistemas baseados em uma única fonte renovável ou em fontes tradicionais de geração. No entanto, o dimensionamento deste tipo de sistema apresenta-se como uma tarefa complexa, devido à variabilidade dos recursos renováveis e da demanda de energia, além das características não lineares de alguns dos seus componentes e a alta interação entre as variáveis do sistema. No presente trabalho propõe-se um método de otimização baseado em simulação para o dimensionamento de SHGE considerando a presença de incertezas nas variáveis de entrada. O método proposto permite dimensionar o sistema considerando aspectos econômicos, de confiabilidade e ambientais como critério de otimização, e incorporar incertezas na disponibilidade dos recursos renováveis, na demanda de energia e na indisponibilidade dos componentes sujeitos a falha. A otimização é feita por meio da metaheurística de Algoritmos Genéticos. O método de amostragem de Hipercubo Latino (LHS – *Latin Hypercube Sampling*) é utilizado para gerar os cenários de incerteza nos recursos renováveis e na demanda, enquanto que Simulação de Monte Carlo é empregada para gerar históricos de operação dos componentes do sistema. A metodologia de otimização baseada em simulação é aplicada a um caso de estudo mostrando resultados satisfatórios. A abordagem apresenta-se especialmente útil em situações onde é necessário dimensionar um sistema de forma ótima e robusta. No entanto, devido ao alto custo computacional que implica a aplicação do método, sugere-se realizar uma simulação probabilística prévia para explorar a sensibilidade das soluções obtidas com o algoritmo de otimização determinístico. Caso a média das soluções determinísticas sob incerteza ultrapasse as restrições impostas pelo usuário, justifica-se aplicar a otimização probabilística.

PALAVRAS-CHAVE: Algoritmo Genético, Comunidade Rural Isolada, Dimensionamento, Energia Renovável, Ferramenta Computacional, Incerteza, Simulação Probabilística.

ROBERTS J.J. **Multi-objective Optimization of Hybrid Solar-Wind-Diesel Power Systems through Metaheuristic Methods.** 2016. 275 p. Thesis (PhD in Mechanical Engineering) – Engineering Faculty – Guaratinguetá Campus, São Paulo State University, Guaratinguetá, 2016.

ABSTRACT

When properly design, Hybrid Power Systems (HPS) based on renewable sources, present technical, economic and environmental benefits when compared to single source-based renewable power systems or traditional source-based power systems. Nonetheless, the optimal design of HPS is a daunting task, due to the stochastic behavior of the renewable resources availability and the demand to be met, the non-linear characteristic of some of the components and the high interaction between the system variables. This study proposes a simulation-based optimization approach for dimensioning HPS considering uncertainties in the input variables. The proposed methodology allows to optimal design the system considering economic, reliability and environmental criteria, while incorporating the presence of uncertainty related to the renewable resources availability, the power demand, and the availability of the components subjected to failure. The optimization is performed by means of Genetic Algorithms. The Latin Hypercube Sampling method is used to generate uncertainty scenarios related to the renewable resources and the load, while Monte Carlo simulation is employed to generate chronological system state transition process for each component of the system. The proposed methodology was applied in a case study showing satisfactory results. The simulation-based optimization approach is especially useful for dimensioning hybrid power systems that require both optimality and robustness. However, due to the method being computational intensive, it is suggested to perform a probabilistic simulation on the solutions obtained by the deterministic algorithm, in order to explore its sensitivity in the presence of uncertainty. If the average objective value of the deterministic solutions simulated under uncertainty exceeds the restrictions imposed by the user, then the increased cost of computing the probabilistic optimization is warranted.

KEYWORDS: Computational tool, Dimensioning, Genetic Algorithm, Isolated Rural Community, Probabilistic Simulation, Renewable Energy, Uncertainty.

LISTA DE FIGURAS

Figura 1.Dimensionamento complexo de SHGE.	32
Figura 2.Classificação de abordagens para otimização de SHGE.	40
Figura 3.Número de objetivos considerados e critérios de otimização mais empregados, de acordo com a pesquisa bibliográfica.....	58
Figura 4.Representação gráfica da abordagem metaheurística para otimização baseada em simulação.	62
Figura 5.Fluxograma da abordagem de otimização determinística para o problema de dimensionamento de um SHGE.....	66
Figura 6.Método de geração de amostras para a simulação probabilística do SHGE.....	70
Figura 7.Exemplo de histórico de operação do sistema gerado pela simulação de Monte Carlo cronológica.....	72
Figura 8.Fluxograma da abordagem de otimização probabilística para o problema de dimensionamento de um SHGE.....	73
Figura 9.Configuração de SHGE estudada no presente trabalho.	77
Figura 10. Representação gráfica do modelo de gerador solar fotovoltaico implementado.	79
Figura 11. Processo de cálculo da radiação solar global incidente numa superfície inclinada.....	80
Figura 12. Curva característica I-V e curva P-V para um módulo de 110 Wp na qual se destacam os pontos característicos.	85
Figura 13. Representação gráfica do modelo de gerador eólico implementado.	89
Figura 14. Representação gráfica do modelo de bateria implementado.	94
Figura 15. Ilustração do modelo equivalente de dois reservatório utilizado pelo KiBaM para representar o estado de carga da bateria.	95
Figura 16. Curva de consumo de combustível e eficiência de um moto gerador diesel de 75 kW.....	101
Figura 17. Diagrama em blocos dos subsistemas que compõem um SHGE.	102
Figura 18. Comparação dos modelos de inversor com resultados experimentais.....	105
Figura 19. Curva de carga para um dia típico de consumidor rural isolado do Estado do Pará.	107
Figura 20. Perfis de consumo gerados com os métodos de geração sintética de curvas de carga.....	110

Figura 21. Custos específicos dos componentes no mercado brasileiro para (a) aerogerador, (b) painéis fotovoltaicos, (c) moto gerador diesel, (d) bateria, (e) inversor.....	119
Figura 22. Estrutura geral do algoritmo de simulação do SHGE.....	124
Figura 23. Resultados horários da simulação de um sistema solar-diesel-bateria durante 10 dias de operação.....	127
Figura 24. Resultados gráficos da análise econômica para o SHGE simulado no exemplo; (a) balanço dos custos de cada componente e, (b) participação dos custos de cada componente no custo nivelado total do sistema.	128
Figura 25. Diagrama de funcionamento do Algoritmo Genético simples	131
Figura 26. Estrutura operacional da <i>GAtoolbox</i>	133
Figura 27. Diferença em as abordagens de otimização mono e multiobjective.....	141
Figura 28. Representação de várias soluções num problema de otimização com dois objetivos (f_1 e f_2) a ser minimizados.....	143
Figura 29. Procedimento do algoritmo de otimização multiobjective NSGA-II.....	145
Figura 30. Avaliação do desempenho do AG.	147
Figura 31. Perfil de consumo de um dia típico para o caso de (a) Vila Campinas, (b) Vila São Tomé.	155
Figura 32. Valores mensais das variáveis meteorológicas velocidade do vento, radiação solar e temperatura para o caso de (a) Vila Campinas, (b) Vila São Tomé.....	156
Figura 33. Geração de séries sintéticas de dados horários de carga para a Vila Campinas e a Vila São Tomé.....	157
Figura 34. Evolução da função objetivo NPV_C e média da população para a configuração de menor complexidade do problema de otimização mono-objetivo, (a) Vila Campinas e (b) Vila São Tomé.	168
Figura 35. Evolução da função objetivo NPV_C e média da população para a configuração de maior complexidade do problema de otimização mono-objetivo, (a) Vila Campinas e (b) Vila São Tomé.	171
Figura 36. Participação de cada componente na geração mensal para os casos de estudo (a) Vila Campinas e (b) Vila São Tomé.	175
Figura 37. Participação dos custos de cada componente no custo nivelado total do sistema, casos de estudo Vila Campinas (a) e Vila São Tomé (b).	176

Figura 38. Evolução da fronteira de Pareto para o problema de otimização multiobjetivo, minimização do NPV_C e minimização do LPS , caso Vila Campinas.	183
Figura 39. Fronteira de Pareto da última geração para o problema de otimização multiobjetivo, minimização do NPV_C e minimização do LPS , caso Vila Campinas.	183
Figura 40. Evolução da fronteira de Pareto para o problema de otimização multiobjetivo, minimização do NPV_C e minimização das $EMCO_2$, caso Vila Campinas.	187
Figura 41. Fronteira de Pareto da última geração para o problema de otimização multiobjetivo, minimização do NPV_C e minimização das $EMCO_2$, caso Vila Campinas.	187
Figura 42. Evolução da fronteira de Pareto para o problema de otimização multiobjetivo, minimização do NPV_C , minimização do LPS e minimização das $EMCO_2$, caso Vila Campinas.	191
Figura 43. Fronteira de Pareto da última geração para o problema de otimização multiobjetivo, minimização do NPV_C , minimização do LPS e minimização das $EMCO_2$, caso Vila Campinas.	191
Figura 44. Projeções nos planos ortogonais das soluções da fronteira de Pareto para o problema de otimização multiobjetivo, minimização do NPV_C , minimização do LPS e minimização das $EMCO_2$, caso Vila Campinas.	192
Figura 45. Variabilidade das soluções determinísticas sob a influência de incertezas, problema de otimização multiobjetivo minimização do NPV_C e minimização do LPS , caso Vila Campinas.....	197
Figura 46. Funções densidade de probabilidade das soluções determinísticas sob a influência de incertezas, problema de otimização multiobjetivo minimização do NPV_C e minimização do LPS , caso Vila Campinas.	198
Figura 47. Funções densidade de probabilidade das soluções determinísticas sob a influência de incertezas, problema de otimização multiobjetivo minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.	199
Figura 48. Funções densidade de probabilidade das soluções determinísticas sob a presença de incertezas, problema de otimização multiobjetivo, minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.	200

Figura 49. Fronteira de Pareto determinística e probabilística, problema de otimização multiobjetivo minimização do NPV_C e minimização do LPS , caso Vila Campinas.	202
Figura 50. Fronteira de Pareto determinística e probabilística, problema de otimização multiobjetivo minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.	204
Figura 51. Fronteira de Pareto determinística e probabilística, problema de otimização multiobjetivo minimização do NPV_C , minimização do LPS e minimização do $EMCO_2$, caso Vila Campinas.....	206
Figura 52. Projeções nos planos ortogonais da fronteira de Pareto determinística e probabilística, problema de otimização multiobjetivo minimização do NPV_C , minimização do LPS e minimização do $EMCO_2$, caso Vila Campinas.	207

LISTA DE TABELAS

Tabela 1.	Resultados da pesquisa bibliográfica (continua).	55
Tabela 1.	Resultados da pesquisa bibliográfica (continuação).....	56
Tabela 1.	Resultados da pesquisa bibliográfica (conclusão).	57
Tabela 2.	Indicadores mais comumente adotados como critério de otimização, de acordo com a pesquisa bibliográfica.....	59
Tabela 3.	Fatores utilizados para o cálculo das emissões no ciclo de vida do sistema híbrido.....	115
Tabela 4.	Combinação de tipo de representação de variáveis.	134
Tabela 5.	Parâmetros do AG mono-objetivo utilizados na resolução de problemas com restrições.	149
Tabela 6.	Configuração dos problemas de otimização mono-objetivo implementadas para comparação com o HOMER®.....	163
Tabela 7.	Parâmetros do AG mono-objetivo utilizados na simulação.	164
Tabela 8.	Resultados da otimização mono-objetivo, comparação dos resultados obtidos pelo método AG proposto e o software HOMER®.....	165
Tabela 9.	Configuração de maior complexidade dos problemas de otimização mono-objetivo para os casos estudados.	170
Tabela 10.	Resultados numéricos para a configuração de maior complexidade do problema de otimização mono-objetivo.	173
Tabela 11.	Configuração dos problemas de otimização multiobjetivo aplicados ao caso de estudo Vila Campinas.	178
Tabela 12.	Parâmetros do algoritmo NSGA-II utilizado nos problemas de otimização multiobjetivo para o caso de estudo Vila Campinas.....	179
Tabela 13.	Caraterísticas de 5 soluções de interesse da última geração no problema de otimização multiobjetivo, minimização do NPV_C e minimização do LPS , caso Vila Campinas.	184
Tabela 14.	Caraterísticas de 5 soluções não dominadas da última geração no problema de otimização multiobjetivo, minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.....	188
Tabela 15.	Caraterísticas de 4 soluções não dominadas da última geração no problema de otimização multiobjetivo, minimização do NPV_C , minimização do LPS e minimização do $EMCO_2$, caso Vila Campinas.	193

Tabela 16. Parâmetros utilizados na geração de cenários de incerteza para o caso de estudo Vila Campinas.	195
Tabela 17. Soluções determinísticas avaliadas probabilisticamente para cada configuração do problema de otimização multiobjetivo.	196
Tabela 18. Comparação entre soluções de interesse obtidas pelo algoritmo determinístico e probabilístico, problema de otimização multiobjetivo minimização do NPV_C e minimização do LPS , caso Vila Campinas.....	203
Tabela 19. Comparação entre soluções de interesse obtidas pelo algoritmo determinístico e probabilístico, problema de otimização multiobjetivo minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.	205
Tabela 20. Comparação entre soluções de interesse obtidas pelo algoritmo determinístico e probabilístico, problema de otimização multiobjetivo minimização do NPV_C , minimização do LPS e minimização do $EMCO_2$, caso Vila Campinas.	208

LISTA DE ABREVIATURAS E SIGLAS

Símbolo	Descrição	Unidade
AG	Algoritmo Genético	--
BT	Bateria	--
CC	Estratégia de operação Ciclo de Carga	--
CONV	Conversor	--
DG	Grupo Moto Gerador	--
DIC	Duração de interrupção individual por unidade consumidora	[interrupções/ano]
DMIC	Duração de interrupção contínua por unidade consumidora	[h]
FC	Célula de Combustível	--
FIC	Frequência de interrupção individual por unidade consumidora	[interrupções]
LCOE	Custo Nivelado de Energia (<i>Levelized Cost of Energy</i>)	[US\$/kWh]
LPS	Perda no fornecimento de energia à carga	[kW]
LPSP	Probabilidade de Perda no Fornecimento de Energia (<i>Loss of Power Supply Probability</i>)	[%]
MPPT	Seguidor do ponto de máxima potência (<i>Maximum Power Point Tracker</i>)	--
NOCT	Temperatura Nominal de Operação da Célula (<i>Normal Operating Cell Temperature</i>)	[°C]
NPV	Valor Presente Líquido (<i>Net Present Value</i>)	[US\$]
NSGA	<i>Nondominated Sorting Genetic Algorithm</i>	--
NSGA-II	<i>Nondominated Sorting Genetic Algorithm II</i>	--
PV	Sistema solar fotovoltaico / Geração solar fotovoltaica	--
SD	Estratégia de operação Seguimento da Demanda	--
SHGE	Sistema Híbrido de Geração de Energia	--
SMC	Simulação de Monte Carlo	--
WT	Gerador Eólico / turbina eólica / aerogerador	--
LHS	Hipercubo Latino (LHS – <i>Latin Hypercube Sampling</i>)	--
UD	estratégia programada definida pelo usuário	--

LISTA DE SÍMBOLOS

Símbolo	Descrição	Unidade
a	Fator de idealidade modificado	[V]
b	Fator de operador mutação não-uniforme	--
$BT_{autonomy}$	Autonomia do banco de baterias	[h]
c	Razão de capacidade do modelo de bateria KiBaM	--
$C_{bt_max_cap}$	Capacidade de corrente máxima da bateria	[Ah]
$chromLength$	Longitude do cromossomo do AG	--
C_{icap}	Investimento inicial	[US\$]
$C_{level,tot}$	Custo anual equivalente	[US\$/ano]
$C_{operating}$	Custos operativos	[US\$/ano]
C_p	Coeficiente de potência ou eficiência do rotor da WT	--
CO_{2-eq}	Dióxido de carbono equivalente	[kg]
$CRF(\cdot)$	Fator de recuperação de capital	--
(det.)	De carácter determinístico	--
DG_{oh}	Horas de operação do DG	[h/ano]
$diff\ 2Opt$	Diferença entre valor calculado e ótimo conhecido	--
DOD	Profundidade de descarga	[%]
$DownTime$	Estado de substituição/reparação do componente	--
d_r	Taxa de juros real	[%]
$(dT/dz)_{std}$	Gradiente térmica em condições padrão	[K/m]
Ec	Estratégia de operação do SHGE	--
Ec_{min}, Ec_{max}	Limites inferior e superior da estratégia de operação	--
$\tilde{E}(G)$	Estimativa do valor esperado	--
E_{load}	Energia demandada pela carga	[kWh/ano]
$EMCO_{2,adm}$	Quantidade máxima de CO_{2-eq} emitido na operação do SHGE	[kg/ano]
E_{tot_hps}	Energia total gerada pelo SHGE	[kWh]
F	Espaço de busca de soluções factíveis, $F \subseteq S$	--
F_0	Ordenada na origem da curva de consumo do DG	[L/h/kW]
F_1	Inclinação da curva de consumo do DG	[L/h/kW]
F_{c-g}	Fator de vista para o solo	--
F_{dg}	Consumo horário de combustível do DG	[L/h]

Símbolo	Descrição	Unidade
$F_{dg,adm}$	Quantidade máxima de consumo de combustível por ano	[L/ano]
f_{exess}	Razão entre o excesso de energia e o total de energia gerada pelo sistema	[%]
$f_{exess,adm}$	Valor admissível da energia excedente	[%]
$f_m(\vec{x})$	Função objetivo de ordem m	--
f_{ren}	Fração de energia renovável	[%]
$f_{ren,min}$	Valor mínimo da participação da geração renovável	[%]
$f(\vec{x})$	Função objetivo do problema de otimização	--
g	Aceleração da gravidade	[m/s ²]
$g_j(\vec{x})$	Função restrição de desigualdade de ordem j	--
h_1, h_2	Nível dos reservatórios carga disponível e limitada do modelo de bateria KiBaM	--
$h_k(\vec{x})$	Função restrição de igualdade de ordem k	--
I_0	Radiação solar extraterrestre horária	[W/m ²]
I_b	Radiação solar direta horária incidente numa superfície horizontal	[W/m ²]
I_d	Radiação solar difusa horária incidente numa superfície horizontal	[W/m ²]
I_H	Radiação solar global horária incidente numa superfície horizontal	[W/m ²]
I_L	Corrente fotogerada	[A]
I_{mp}	Corrente de potência máxima do módulo PV	[A]
I_o	Corrente de saturação reversa do diodo	[A]
I_{sc}	Corrente de curto circuito do módulo PV	[A]
$i(t)$	Corrente de descarga	[A]
I_T	Radiação solar global horária incidente numa superfície inclinada	[W/m ²]
$I_{T,b}$	Radiação solar direta horária incidente numa superfície inclinada	[W/m ²]
$I_{T,d}$	Radiação solar difusa incidente numa superfície inclinada	[W/m ²]
$I_{T,refl}$	Radiação solar refletida horária incidente numa superfície inclinada	[W/m ²]
J	Numero de restrições de desigualdade	--
k	Taxa de condutância do modelo de bateria KiBaM	[1/h]
K	Numero de restrições de igualdade	--
k_b	Constante de Boltzmann	[J/K]

Símbolo	Descrição	Unidade
k_T	Índice de claridade horário	--
L_{AC}	Carga AC	--
L_{mean}	Potência média demandada pela carga	[kW]
$LPSP_{adm}$	Valor admissível da LPSP	[%]
LT_{bt_exp}	Tempo de vida esperado de uma bateria	[ano]
LT_{bt_float}	Tempo de vida flutuante (<i>float life</i>) da bateria	[ano]
LT_{proj}	Tempo de duração do projeto	[ano]
M	Numero de objetivos	--
$maxGen$	Número máximo de gerações do AG	--
$MTBF_i$	Tempo médio entre falhas do componente i-ésimo	[h]
$MTTR_i$	Tempo médio para reparo do componente i-ésimo	[h]
n	Número de variáveis no problema de otimização	--
N_{best}	Melhores indivíduos da população	--
$N_{bt_p,min}, N_{bt_p,max}$	Quantidade mínima e máxima de baterias em paralelo	--
N_{bt_tot}	Quantidade total de baterias no banco de baterias	--
N_{bt_p}	Número de baterias em paralelo do banco de baterias	--
N_{bt_s}	Número de baterias em série do banco de baterias	--
N_{conv}	Número de conversores	--
$N_{conv,min}, N_{conv,max}$	Quantidade mínima e máxima de conversores	--
n_d	Fator de idealidade do diodo	--
N_{dg}	Número de moto geradores	--
$N_{dg,min}, N_{dg,max}$	Quantidade mínima e máxima de moto geradores	--
n_p	Número de soluções que dominam a solução p	--
N_{pop}	Tamanho da população	--
N_{pv}	Número de módulos fotovoltaicos	--
NPV_C	Valor Presente Líquido dos Custos (<i>Net Present Value of costs</i>)	[US\$]
$NPV_{C,adm}$	Valor admissível de NPV_C	[US\$]
$N_{pv,min}, N_{pv,max}$	Quantidade mínima e máxima de módulos fotovoltaicos	--
N_s	Número de células fotovoltaicas em série	--
N_{samp}	Número de amostras geradas aleatoriamente	--
N_{wt}	Número de turbinas eólicas	--

Símbolo	Descrição	Unidade
$N_{wt,min}, N_{wt,max}$	Quantidade mínima e máxima de turbinas eólicas	--
p	Pressão atmosférica	[Pa]
P^*	Conjunto de soluções ótimas de Pareto	--
p_0	Pressão nas condições padrão	[Pa]
P_{bt_need}	Potência requerida pela bateria ou fornecida à bateria que surge do balanço energético do sistema	[kW]
PCI_{comb}	Poder calorífico inferior do combustível	[MJ/kg]
P_{dg}	Potência gerada pelo DG	[kW]
P_{dg_min}	Potência mínima de operação do DG	[kW]
P_{dgr}	Potência nominal do DG	[kW]
PF^*	Imagem do conjunto ótimo de Pareto (fronteira de Pareto)	--
P_{gen}	Potência gerada instantânea	[kW]
P_{load}	Potência demandada pela carga	[kW]
p_m	Taxa ou probabilidade de mutação	[%]
P_{mp}	Potência máxima do módulo PV	[W]
$popSize$	Tamanho da população do AG	--
p_r	Taxa ou probabilidade de recombinação	[%]
P_{ren}	Potência gerada a partir de fontes renováveis	[kW]
(prob.)	De caráter probabilístico	--
P_t	População de pais utilizada no NSGA-II	--
P_{wt}	Potência mecânica obtida pelo rotor do aerogerador	[kW]
$P_{wt,r}$	Potência nominal da turbina eólica	[kW]
$P_{wt,corr}$	Potência turbina eólica corrigir em por altitude do local	[kW]
q	Carga eletrônica	[C]
Q_{bt}	Quantidade total de carga (energia) armazenada na bateria em qualquer intervalo de tempo	[kWh]
Q_{bt1}, Q_{bt2}	Quantidade de carga nos reservatório de carga disponível e limitada	[kWh]
q_{bt1}, q_{bt2}	Quantidade de carga nos reservatório de carga disponível e limitada, valores instantâneos	[kWh]
Q_{bt_max}	Capacidade de carga máxima do banco de baterias	[kWh]
Q_{bto}	Quantidade total de carga armazenada na bateria no início do intervalo de tempo	[kWh]
Q_{bt1o}	Carga disponível na bateria no início do intervalo de tempo	[kWh]
$Q_{bt_life_thr}$	Energia total ciclada até atingir a vida útil da bateria	[kWh]

Símbolo	Descrição	Unidade
Q_{bt_thr}	Energia total ciclada pela bateria por ano	[kWh/ano]
Q_t	População de filhos utilizada no NSGA-II	--
R	Constante dos gases	[J/kg·K]
r_b	Razão entre a radiação incidente numa superfície inclinada e a radiação incidente numa superfície horizontal na ausência da atmosfera da Terra	--
R_s	Resistência em série do circuito equivalente da célula	[Ω]
R_{sh}	Resistência em paralelo do circuito equivalente da célula	[Ω]
R_t	População combinada utilizada no NSGA-II	--
S	Espaço de busca das variáveis de decisão, $S \subseteq \Re^n$	--
SOC	Estado de Carga (<i>State of Charge</i>) das baterias	[%]
SOC_{min}	Mínimo estado de carga recomendável para a bateria	[%]
SOC_{sp}	Set point para o estado de carregamento máximo do banco de baterias	[%]
S_p	Conjunto das soluções que são dominadas pela solução p	--
S_r	Fator de seleção utilizado no operador Coello Coello e Montes	--
$strLength$	Número mínimo de bits do gene do AG	--
T	Período de tempo considerado para a análise	[h]
T_0	Temperatura nas condições padrão	[K]
T_a	Temperatura ambiente	[°C], [K]
T_{bt}	Modelo de bateria, BT	--
T_c	Temperatura da célula fotovoltaica em condições operacionais	[°C]
T_{conv}	Modelo de conversor, CONV	--
T_{dg}	Modelo de moto gerador DG	--
T_{pv}	Modelo de painel PV	--
T_{wt}	Modelo de turbina eólica, WT	--
U	Velocidade média do ar a montante das pás do rotor	[m/s]
u	Velocidade instantânea do vento à altura do rotor do aerogerador	[m/s]
U_{ci}	Velocidade de vento mínima para que o rotor comece gerar energia elétrica	[m/s]
U_{co}	Velocidade máxima de operação segura do aerogerador	[m/s]
U_0	Velocidade média do ar a jusante das pás do rotor	[m/s]
$UpTime$	Estado de operação do componente	--
U_r	Velocidade de vento na qual a turbina entrega a potência nominal	[m/s]

Símbolo	Descrição	Unidade
U_{ref}	Velocidade do vento à altura de referência	[m/s]
U_{rot}	Velocidade do vento à altura do rotor	[m/s]
V_{bt}	Tensão nominal de cada bateria individual	[V]
V_{dc}	Tensão do barramento de DC	[V]
$V(G)$	Variância da função teste	--
V_{mp}	Tensão de potência máxima do módulo PV	[V]
V_{oc}	Tensão de circuito aberto do módulo PV	[V]
$\vec{x}$	Vetor solução de dimensão n , $\vec{x} = (x_1, \dots, x_n) \in \Re^n$	--
x_i	Solução de ordem i , $x_i \in \vec{x}$	--
x_i^{lb}, x_i^{ub}	Limites inferior e superior da variável de decisão x_i	--
z_0	Comprimento de rugosidade superficial do terreno	[m]
z_h	Altitude sobre o nível do mar	[m]
z_{ref}	Altura de medição	[m]
z_{rot}	Altura do rotor do aerogerador	[m]

LISTA DE LETRAS GREGAS

Símbolo	Descrição	Unidade
α	Parâmetro do operador cruzamento BLX- α	--
α_w	Coeficiente de extrapolação da velocidade do vento	--
β	Ângulo de inclinação da superfície respeito da horizontal	[°]
β_c	Fator de convergência	--
$\cos \theta$	Cosseno do ângulo de incidência solar	--
$\cos \theta_z$	Cosseno do ângulo zenital	--
δ_d	Fator de perturbação diário	--
δ_h	Fator de perturbação horário	--
δ_{load}	Fator de perturbação método de perfil diário	--
Δt	Intervalo de cálculo	[h]
δ_t	Valor de tolerância para restrições de igualdade	--
$\varepsilon_j(\mu, \sigma)$	Conjunto discreto de amostras aleatórias	--
$\varphi_i(t)$	Fenômenos que variam com o tempo	--
$\varphi_l(t)$	Série horária de demanda energética	[kW]
$\varphi_s(t)$	Série horária de radiação solar	[kWh/m ²]
$\varphi_T(t)$	Série horária de temperatura ambiente	[°C]
$\varphi_w(t)$	Série horária de velocidade do vento	[m/s]
$\Phi_i(t)$	Histórico de estados de operação do componente	--
$\Phi_{j,k}^{conv}(t)$	Histórico de estados de operação do conversor	--
$\Phi_{j,k}^{dg}(t)$	Histórico de estados de operação do moto gerador	--
$\Phi_{j,k}^{pv}(t)$	Histórico de estados de operação do painel PV	--
$\Phi_{j,k}^{wt}(t)$	Histórico de estados de operação do aerogerador	--
λ_{f_i}	Taxa media de falha do componente i-ésimo	[1/h]
λ_{r_i}	Taxa media de reparo do componente i-ésimo	[1/h]
η_{dg}	Eficiência na conversão de energia do DG	[%]
ξ	Componente aleatória do sistema simulado	--
ρ	Massa específica do ar	[kg/m ³]
ρ_0	Massa específica do ar nas condições padrão	[kg/m ³]
ρ_{comb}	Massa específica do combustível	[kg/m ³]
ρ_g	Índice de refletividade ou albedo do solo	--
σ	Desvio padrão de uma variável	--
σ_{share}	Parâmetro de compartilhamento do NSGA	--
$\sigma_{day,noise}$	Desvio padrão do ruído diário	--

Símbolo	Descrição	Unidade
$\sigma_{hour,noise}$	Desvio padrão do ruído horário	--
$\theta_i(t)$	Parâmetro com incerteza da variável i-ésima	--
$\Theta_j(t)$	Matriz de resultados do balanço energético	--
$\theta_{j,k}^l(t)$	Parâmetro com incerteza da carga	[kW]
$\theta_{j,k}^s(t)$	Parâmetro com incerteza da radiação solar	[kWh/m ²]
$\theta_{j,k}^w(t)$	Parâmetro com incerteza da velocidade do vento	[m/s]
$\theta_{j,k}^T(t)$	Parâmetro com incerteza da temperatura	[°C]
μ	Média de uma variável	--
$\mu(Sol)^{Pareto(det.)}$	Média das soluções determinísticas simuladas probabilisticamente	--
Ψ	Operador utilizado para obter o valor determinístico de uma função probabilística	--

SUMÁRIO

Parte I – Introdução e Revisão da Literatura.....	29
1 INTRODUÇÃO	30
1.1 CONTEXTUALIZAÇÃO	30
1.2 CARATERIZAÇÃO DO PROBLEMA.....	32
1.3 OBJETIVO GERAL.....	34
1.4 OBJETIVOS ESPECÍFICOS	34
1.5 CONTRIBUIÇÕES E RELEVÂNCIA DA PESQUISA	34
1.6 ESTRUTURA DA TESE	35
2 REVISÃO DA LITERATURA SOBRE SIMULAÇÃO E OTIMIZAÇÃO DE SISTEMAS HÍBRIDOS DE GERAÇÃO DE ENERGIA.....	37
2.1 SIMULAÇÃO DE SISTEMAS HÍBRIDOS DE GERAÇÃO DE ENERGIA	37
2.2 OTIMIZAÇÃO DE SISTEMAS HÍBRIDOS DE GERAÇÃO DE ENERGIA.....	39
2.2.1 Abordagem analítica.....	40
2.2.2 Abordagem gráfica	42
2.2.3 Abordagem probabilística.....	43
2.2.4 Abordagem iterativa	44
2.2.5 Abordagem metaheurística	46
2.2.6 Abordagem híbrida.....	49
2.3 OTIMIZAÇÃO MULTIOBJETIVO APLICADA A SHGE	49
2.3.1 Abordagem das somas ponderadas	50
2.3.2 Abordagem ε -restrito.....	51
2.3.3 Abordagem de busca da fronteira de Pareto.....	52
2.4 CONCLUSÕES DA PESQUISA BIBLIOGRÁFICA	54
Parte II – Materiais e Métodos.....	60
3 OTIMIZAÇÃO BASEADA EM SIMULAÇÃO	61
3.1 ABORDAGEM DE OTIMIZAÇÃO DETERMINÍSTICA APLICADA AO PROBLEMA DE DIMENSIONAMENTO DE UM SHGE	63
3.2 ABORDAGEM DE OTIMIZAÇÃO PROBABILÍSTICA APLICADA AO PROBLEMA DE DIMENSIONAMENTO DE UM SHGE	67

3.2.1	Representação das incertezas.....	68
4	MÓDULO DE SIMULAÇÃO	76
4.1	MODELO DE GERADOR SOLAR FOTOVOLTAICO	78
4.1.1	Modelo de radiação solar incidente numa superfície inclinada	79
4.1.2	Modelos de módulo fotovoltaico	84
4.2	MODELO DE GERADOR EÓLICO	87
4.2.1	Extrapolação vertical da velocidade do vento	89
4.2.2	Curva de potência da turbina eólica	90
4.2.3	Variação da massa específica do ar em função da altitude.....	91
4.3	MODELO DO SISTEMA DE ARMAZENAMENTO.....	92
4.3.1	Modelos de bateria disponíveis na literatura	93
4.3.2	Modelo de capacidade da bateria	94
4.3.3	Modelo de vida útil da bateria	97
4.4	MODELO DO GRUPO MOTO GERADOR	99
4.4.1	Consumo de combustível e eficiência do grupo moto gerador	100
4.5	MODELO DO SISTEMA DE CONDICIONAMENTO DE POTÊNCIA	102
4.5.1	Controlador de carga.....	102
4.5.2	Seguidor de ponto de máxima potência	103
4.5.3	Inversor e retificador	103
4.6	CURVA DE CARGA E DEMANDA DE ENERGIA.....	105
4.6.1	Determinação da curva de carga	107
4.6.2	Modelo de geração de curvas de carga baseado em simulação de Monte Carlo	108
4.6.3	Modelo de geração da curva de carga baseado no perfil diário	109
4.7	ESTRATÉGIAS DE OPERAÇÃO DO SISTEMA HÍBRIDO.....	111
4.7.1	Tipos de estratégias de operação de SHGE	111
4.7.2	Estratégia de operação “Seguimento da Demanda”	112
4.7.3	Estratégia de operação “Ciclo de Carga”	112
4.7.4	Estratégia “Programada”	113
4.8	AVALIAÇÃO DO IMPACTO AMBIENTAL	113
4.9	MODELO DE ANÁLISE ECONÔMICA	115
4.9.1	Custo dos componentes do sistema.....	118
4.10	INTEGRAÇÃO DOS MODELOS.....	120

4.10.1	Índices de desempenho relacionados com a confiabilidade	121
4.10.2	Índices de desempenho relacionados à geração de energia do SHGE ...	122
4.10.3	Índices de desempenho relacionados ao moto gerador	122
4.10.4	Índices de desempenho relacionados ao sistema de armazenamento ...	123
4.10.5	Índices de desempenho relacionados com as emissões de gases poluentes	123
4.10.6	Exemplo de simulação	125
5	MÓDULO DE OTIMIZAÇÃO	129
5.1	ALGORITMOS GENÉTICOS APLICADOS A OTIMIZAÇÃO	130
5.2	DESCRIÇÃO DA GATOOLBOX.....	132
5.2.1	Módulo definição do problema de otimização	132
5.2.2	Módulo definição das variáveis	134
5.2.3	Módulo geração da população inicial.....	135
5.2.4	Módulo evolução	135
5.2.5	Tratamento de restrições.....	139
5.2.6	Otimização multiobjetivo	140
5.2.7	Computação paralela.....	146
5.3	AVALIAÇÃO DO DESEMPENHO DA GATOOLBOX.....	147
5.3.1	Problemas de otimização mono-objetivo sem restrições	148
5.3.2	Problemas de otimização mono-objetivo com restrições.....	148
5.3.3	Problemas de otimização multiobjetivo com restrições	150
	Parte III – Resultados, Discussões e Conclusões	151
6	OTIMIZAÇÃO BASEADA EM SIMULAÇÃO COM ALGORITMOS GENÉTICOS APLICADA AO PROBLEMA DE DIMENSIONAMENTO DE UM SHGE.....	152
6.1	CASOS DE ESTUDO	152
6.1.2	Componentes do SHGE	154
6.2	OTIMIZAÇÃO MONO-OBJETIVO DE UM SHGE.....	158
6.2.1	Vetor de Variáveis de Decisão do Problema de Otimização do SHGE..	158
6.2.2	Função Objetivo do Problema de Otimização Mono-objetivo do SHGE	159

6.2.3	Restrições do Problema de Otimização Mono-objetivo do SHGE	159
6.2.4	Resultados da otimização mono-objetivo, comparação do método proposto com a ferramenta de otimização HOMER®.....	161
6.2.5	Resultados da otimização mono-objetivo, problema de maior complexidade.....	169
6.3	OTIMIZAÇÃO MULTIOBJETIVO DE UM SHGE.....	177
6.3.1	Otimização multiobjetivo determinística: caso de estudo Vila Campinas	179
6.3.2	Otimização multiobjetivo probabilística: caso de estudo Vila Campinas	194
7	CONCLUSÕES E TRABALHOS FUTUROS	209
	REFERÊNCIAS	214
	APÊNDICE A – MÉTODO DE PRÉ-DIMENSIONAMENTO DOS COMPONENTES DO SHGE.....	234
	APÊNDICE B – REVISÃO BIBLIOGRÁFICA SOBRE EMISSÕES INDIRETAS.....	239
	APÊNDICE C – CÁLCULO DA QUANTIDADE DE POLUENTES POR LITRO DE COMBUSTÍVEL (ÓLEO DIESEL).....	244
	APÊNDICE D – CUSTOS ASSOCIADOS AOS COMPONENTES DO SHGE	248
	APÊNDICE E – EQUAÇÕES DO MODELO DE ANÁLISE ECONÔMICA.	253
	APÊNDICE F – ARQUIVO DE RESULTADOS FORNECIDO PELO ALGORITMO DE SIMULAÇÃO DE SHGE	258
	APÊNDICE G – AVALIAÇÃO DO DESEMPENHO DA GATOOBOX.....	260
	APÊNDICE H – CASOS DE ESTUDO.....	278
	APÊNDICE I – CARACTERÍSTICAS TÉCNICAS E ECONÔMICAS DOS COMPONENTES UTILIZADOS NAS SIMULAÇÕES DO SHGE.....	286

PARTE I – INTRODUÇÃO E REVISÃO DA LITERATURA

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

A energia é considerada um insumo fundamental nas atividades produtivas, tendo um importante papel no processo de desenvolvimento da humanidade. O acesso às formas modernas de energia, em particular a energia elétrica, traz uma série de benefícios sociais que melhoram a qualidade de vida da população, entre os quais se podem mencionar (REICHE; COVARRUBIAS; MARTINOT, 2000):

- Reduz a fome e melhora o acesso à água potável através de sistemas de conservação de alimentos e bombeamento de água.
- Fomenta a educação e diminui a marginalização através da luz artificial e de ferramentas de acesso à informação e comunicação.
- Melhora a igualdade de gênero, livrando às mulheres de tarefas de abastecimento de água e combustível.
- Reduz a mortalidade infantil e materna, bem como a incidência de doenças através da refrigeração de medicamentos e o acesso a modernos equipamentos médicos.
- Traz benefícios econômicos diretos e indiretos a partir do uso de eletricidade em atividades produtivas em áreas rurais, como irrigação de cultivos, conservação de alimentos, processamento da colheita e desenvolvimento de pequenas empresas, o que resulta num aumento de oportunidades de emprego para a população.

Apesar da importância do acesso à energia elétrica, ainda existe, em pleno século XXI, uma parte substancial da população mundial que não tem acesso à eletricidade. Segundo a *International Energy Agency* (NIEZ, 2010) essa parcela é de aproximadamente 22%, o equivalente a um total de 1,5 bilhões de pessoas. Deste contingente, 85% vivem em comunidades rurais situadas em regiões geograficamente isoladas, as quais, muitas vezes, são pouco povoadas ou representam uma demanda energética demasiado baixa para justificar a extensão da rede elétrica convencional.

Atualmente, a maior parte da população sem acesso à eletricidade se encontra nas regiões menos desenvolvidas do planeta, como a África e o sul da Ásia. No entanto, a América Latina não está isenta desta problemática. Países com grande extensão territorial como Argentina, Brasil e Peru possuem parte da sua população sem serviço elétrico. A busca

pela universalização do atendimento elétrico constitui um constante desafio para os governos desses países, os quais têm implantado medidas para alterar esse panorama.

O Brasil tem trabalhado largamente na expansão do acesso à energia elétrica a partir da Constituição de 1988, quando então o governo assumiu total responsabilidade para a distribuição do serviço elétrico como um serviço básico. Como consequência da forte vontade política e do financiamento suficiente, o Brasil passou de uma taxa de eletrificação de 79,9% em 1996, para 99,5% em 2012 (THE WORLD BANK, 2015). No entanto, nas zonas rurais a taxa de eletrificação cai para 88% (NIEZ, 2010). Os projetos que possibilitaram essa expansão do serviço são o programa Luz no Campo (2000-2003), seu sucessor o programa Luz para Todos e o PROINFA (Programa de Incentivo às Fontes Alternativas de Energia Elétrica).


São diversas as tecnologias de geração de energia com potencial para serem utilizadas em programas de eletrificação rural, cada uma com diferentes características técnicas, custos e qualidade do serviço oferecido, que as fazem mais ou menos adequadas para cada situação. Tradicionalmente, a expansão do atendimento elétrico ocorre basicamente através da extensão de linhas de transmissão pertencentes ao sistema interligado, ou através da geração térmica de pequeno, médio e, por vezes, até mesmo de grande porte. Usualmente, a geração térmica ocorre com a instalação de grupos geradores cujo combustível é de origem fóssil (óleo diesel e gasolina, principalmente). Porém, ao mesmo tempo em que a demanda cresce, também o consumo de combustíveis fósseis aumenta. Com o aumento do consumo de combustíveis fósseis, os custos de logística, transporte e armazenamento também se elevam, assim como os efeitos negativos que provoca a queima deste tipo de combustíveis no meio ambiente.

Tais soluções, entretanto, não constituem alternativas únicas. O crescente uso de sistemas autônomos baseado em energias renováveis se configura como uma das soluções viáveis aos problemas de eletrificação em regiões afastadas da rede elétrica. O abastecimento de energia de forma autônoma se refere ao fornecimento de eletricidade de forma independente da rede de distribuição interligada. Este tipo de fornecimento de energia é adequado para pequenas comunidades rurais, onde não se tem acesso à rede elétrica, ou em locais de difícil acesso que dependem principalmente da geração diesel.

Sistemas utilizando duas ou mais fontes de energias renováveis, para suprir uma variedade de diferentes cargas, são normalmente chamados de “Sistemas Híbridos de Geração de Energia” (SHGE) (THIBAUD; ROBERTS; PRADO, 2015). Tipicamente esses sistemas funcionam isoladamente, com diferentes formas de armazenamento energético, mas também podem ser utilizados conjuntamente com fontes convencionais de energia e/ou geração a

diesel, quando for o caso. Na Figura 1 se mostra uma configuração típica de um sistema híbrido autônomo solar-eólico-diesel com armazenamento em baterias.

Figura 1. Dimensionamento complexo de SHGE.



Fonte: produção do próprio autor

1.2 CARATERIZAÇÃO DO PROBLEMA

Os SHGEs, quando dimensionados de forma correta, apresentam menor custo de energia gerada, maior confiabilidade no fornecimento de energia, além de benefícios ambientais, comparados a sistemas baseados em uma única fonte renovável ou em fontes tradicionais de geração (motor de combustão interna e linhas de transmissão) (LUNA-RUBIO et al., 2012). Porém, o dimensionamento ótimo deste tipo de sistema apresenta-se como uma tarefa complexa.

O principal desafio em sistemas híbridos com fontes de energia renováveis é igualar de forma econômica a produção de energia com o consumo. Este fato, que é trivial em sistemas com fontes de geração despacháveis, torna-se crítico no projeto de sistemas com integração de renováveis. A complexidade do processo de dimensionamento pode-se entender melhor com o auxílio da Figura 1. A informação de entrada para a estimativa da produção energética das fontes renováveis é de caráter estocástico; as variáveis velocidade do vento, radiação solar e temperatura são intermitentes e apresentam incerteza na disponibilidade. Por outro lado, o gerador solar fotovoltaico (PV), a turbina eólica (WT), as baterias (BT) e o conversor (CONV) têm uma resposta altamente não linear, dificultando sua representação. Embora o motor gerador diesel (DG) apresente uma resposta aproximadamente linear do consumo de

combustível em função da potência entregue, a sua eficiência varia de forma não linear em relação ao estado de carga. A carga a ser atendida também apresenta um comportamento estocástico; apesar de que é possível estimar um perfil típico para um determinado tipo de consumidor, sendo que a demanda instantânea de energia é de caráter aleatória e depende dos hábitos de consumo dos moradores. Aliado ao comportamento aleatório das variáveis de entrada e à resposta não linear de alguns dos componentes, durante a operação do SHGE ocorre uma alta interação entre as variáveis do sistema, o que dificulta sua representação e simulação.

Variadas técnicas para o dimensionamento de SHGE tem sido propostas; no entanto, nota-se que não existe uma abordagem globalmente aceita para resolver o problema (KONDILI, 2013). O dimensionamento do SHGE é geralmente feito a partir de técnicas de otimização mono-objetivo, que procuram minimizar o custo total ao longo da vida útil do sistema, minimizar a energia não fornecida pelo sistema (maximizar a confiabilidade) ou minimizar as emissões de gases poluentes. Porém, com a otimização de apenas um critério, é necessário estabelecer limites para as outras variáveis. Por exemplo, no caso de se dimensionar o sistema objetivando minimizar o custo total, devem-se fixar limites para a máxima energia não fornecida por ano, o uso de combustível ou a máxima quantidade de emissões de gases poluentes do moto gerador (se for o caso). Este procedimento cria uma grande dependência do resultado final em relação aos limites pré-selecionados, podendo-se encontrar uma solução que difere da solução ótima. Contudo, já se tem aplicado métodos de otimização multiobjetivo em problemas de engenharia com resultados satisfatórios (COLLETTE; SIARRY, 2003).

Dada a complexidade dos problemas não lineares com grande número de variáveis inter-relacionadas, como é o caso do dimensionamento de SHGEs, é necessária a exploração de métodos de otimização diferentes dos métodos clássicos. Os algoritmos de otimização do tipo metaheurísticos, os quais utilizam somente o valor da função objetivo e das restrições para guiar o processo de busca, são uma boa opção.

O grupo dos métodos metaheurísticos apresenta um conjunto de técnicas de otimização adaptadas para lidar com problemas complexos e que apresentam a característica de explosão combinatória. Estes métodos apresentam características gerais que convergem para soluções ótimas ou quase ótimas. Estas técnicas vêm sendo aplicadas com sucesso para resolver muitos problemas no campo da engenharia. A principal vantagem em relação aos métodos determinísticos clássicos é a possibilidade de otimização de um grande número de variáveis em menor tempo de processamento. Dentro do conjunto de técnicas para resolver problemas

de otimização multiobjetivo, as técnicas metaheurísticas baseadas em população (p. ex. Algoritmos Genéticos, Colônia de Formigas, Enxame de Partículas) e as baseadas em trajetórias (p. ex. Busca Local, Busca Tabu) se apresentam como uma opção para resolver o problema.

1.3 OBJETIVO GERAL

O objetivo principal da presente tese de doutorado é desenvolver uma metodologia para o dimensionamento ótimo de Sistemas Híbridos de Geração de Energia solar-eólico-diesel-bateria utilizando como função de avaliação uma função multiobjectivo e considerando a presença de incertezas nas variáveis de entrada.

1.4 OBJETIVOS ESPECÍFICOS

Para cumprir com o objetivo principal, colocam-se uma série de objetivos específicos:

- Desenvolver um modelo de simulação de SHGE solar-eólico-diesel-bateria que permita estudar o comportamento dos componentes durante sua operação e fornecer indicadores de desempenho relacionados com aspectos técnicos, econômicos e ambientais. O modelo deve apresentar um bom compromisso entre precisão e custo computacional.
- Desenvolver um modelo de otimização baseado na metaheurística Algoritmos Genéticos capaz de resolver problemas complexos de otimização mono-objetivo e multiobjetivo. O modelo deve incluir diferentes operadores, de modo a possibilitar a exploração de diferentes configurações do Algoritmo Genético.
- Integrar os modelos de simulação e otimização numa única ferramenta de otimização de SHGE capaz de dimensionar de forma otimizada o sistema de acordo com vários objetivos conflitantes e considerando, dentro do processo de otimização, a presença de incertezas na disponibilidade dos recursos renováveis, na demanda de energia e na indisponibilidade dos componentes sujeitos a falha.

1.5 CONTRIBUIÇÕES E RELEVÂNCIA DA PESQUISA

Vários autores têm proposto metodologias de otimização de sistemas híbridos mono e multiobjectivos, por outro lado também se tem estudado largamente a influência de incertezas

no desempenho final deste tipo de sistemas. No entanto, a abordagem de otimização-baseada em simulação para o dimensionamento de SHGE avaliando vários objetivos conflitantes e considerando a presença de incertezas no processo de otimização tem sido pouco explorada, constituindo a principal contribuição da presente pesquisa.

Uma segunda contribuição relaciona-se com os objetivos específicos. Ao longo da presente pesquisa de doutorado foi desenvolvida uma *toolbox* de otimização baseado em AG. A *GAtoolbox*, desenvolvida no ambiente computacional Matlab®, constitui uma ferramenta de otimização de uso geral útil para resolver problemas mono e multiobjetivo, sendo que a integração do modelo de simulação com a *GAtoolbox* constitui uma ferramenta de otimização de SGHE. Ambas as ferramentas se encontram disponíveis para que qualquer um consulte, examine ou modifique o código para expandi-lo ou adapta-lo a outras necessidades. O leitor interessado em adquirir o código fonte em Matlab®, pode entrar em contato com o autor de presente trabalho.

1.6 ESTRUTURA DA TESE

O presente trabalho de pesquisa se estrutura em três partes principais, integradas pelos seguintes capítulos:

Parte I – Introdução e Revisão da Literatura

Capítulo 1: constituído pela presente introdução.

Capítulo 2: apresenta uma revisão bibliográfica focada na simulação e otimização de SHGE; os principais trabalhos publicados até o momento nesta área são apresentados e comentados, e formam a base de sustentação para a presente pesquisa científica.

Parte II – Materiais e Métodos

Capítulo 3: apresenta a base metodológica da presente pesquisa. Neste capítulo se expõe a abordagem de otimização baseada em simulação proposta para o dimensionamento de SHGE. São apresentados dois métodos, o primeiro é o método de otimização determinístico no qual o SHGE é dimensionado considerando os parâmetros de entrada constantes. Já o segundo método consiste numa otimização probabilística no qual se incorporam as incertezas inerentes às variáveis de entrada.

Capítulo 4: este capítulo descreve o módulo de simulação, encarregado de simular a operação do SHGE em diferentes condições operacionais. Expõem-se brevemente os modelos matemáticos adotados para cada componente do sistema, assim como as estratégias de operação disponíveis para gerenciar a o fluxo energético entre os componentes do sistema. Seguidamente são apresentados os modelos de análise econômica e de avaliação do impacto ambiental e finalmente expõe-se um exemplo de aplicação da ferramenta de simulação com dados reais.

Capítulo 5: descreve a *toolbox* de otimização baseada em AG desenvolvida no presente estudo. Começa apresentando os conceitos teóricos básicos dos Algoritmos Genéticos no contexto de otimização. Em seguida descreve-se a *toolbox* desenvolvida em Matlab® (*GAtoolbox*) para a resolução de problemas de otimização. Finalmente se apresentam os resultados da avaliação do desempenho da *GAtoolbox* na resolução de uma série de problemas teste, que representam problemas mono-objetivo e multiobjetivo puramente matemáticos, bem como problemas reais de engenharia.

Parte III – Resultados, Discussões e Conclusões

Capítulo 6: apresenta os resultados da implementação da abordagem de otimização baseado em simulação aplicada ao problema objeto do presente trabalho, o dimensionamento de um SHGE. Primeiramente são apresentados os casos de estudo utilizados para aplicar a metodologia proposta. Na sequência, se apresentam os resultados da otimização na configuração mono-objetivo. Os resultados obtido com o algoritmo desenvolvido são validados com a ferramenta de otimização comercial HOMER®. Finalmente se apresentam os resultados da aplicação da metodologia de otimização multiobjetivo determinística e probabilística. Neste último caso também se explora a influência das incertezas nas soluções obtidas com o algoritmo determinístico através da simulação probabilística das mesmas.

Capítulo 7: cita as conclusões finais do presente trabalho, assim como a proposta de futuros trabalhos de pesquisa.

2 REVISÃO DA LITERATURA SOBRE SIMULAÇÃO E OTIMIZAÇÃO DE SISTEMAS HÍBRIDOS DE GERAÇÃO DE ENERGIA

No presente capítulo apresenta-se uma revisão bibliográfica sobre Sistemas Híbridos de Geração de Energia (SHGE) baseados em fontes renováveis, particularmente no que se considera o objeto do presente trabalho, a simulação e otimização de um SHGE.

2.1 SIMULAÇÃO DE SISTEMAS HÍBRIDOS DE GERAÇÃO DE ENERGIA

Um dos primeiros trabalhos sobre simulação de SHGE foi apresentado por Manwell e McGowan em 1994 (MANWELL; MCGOWAN, 1994). Neste trabalho os autores apresentam pela primeira vez um modelo para simulação de sistemas híbridos eólico-diesel-bateria baseado na combinação de séries temporais e abordagem probabilística. Propõem um novo modelo para a simulação de baterias de chumbo-ácido chamado de *Kinetic Battery Model*, o qual permite uma maior flexibilidade na programação do algoritmo. Também são incorporadas três estratégias de controle para a simulação do sistema: a estratégia sem armazenamento; a estratégia seguimento da demanda; e a estratégia ciclo de carga. O modelo é implementado e os resultados validados com dados reais mostrando boa concordância com o desempenho do sistema eólico-diesel-bateria real. Pesquisas posteriores de Manwell e McGowan, realizada conjuntamente com experiências de campo (MCGOWAN; MANWELL, 1999; MCGOWAN et al., 1996) resultaram na criação do software de simulação chamado Hybrid2 (MANWELL et al., 2006).

Um sistema autônomo de geração de energia eólico-solar com armazenamento em baterias, gerador de *backup* e cargas dissipadoras é apresentado em Nehrir (2000). Os autores estudam o desempenho do sistema no que diz respeito à produção de energia, e a influência do dimensionamento dos componentes na análise econômica do sistema. Também propõem a utilização de um aquecedor de água como carga dissipadora, a fim de aproveitar o excesso de energia gerada pelo sistema. O pré-aquecimento da água para uso doméstico resulta em economia de combustível para aquecimento.

Em Wies et al. (2004) os autores analisam as vantagens econômicas e ambientais da incorporação de um gerador fotovoltaico num sistema diesel-bateria existente utilizado para o fornecimento de energia em comunidades isoladas. Na análise econômica, os autores estudam a redução nos custos de operação e manutenção, enquanto que na análise ambiental, é avaliada a emissão de poluentes tais como CO₂, material particulado (PM) e NO_x. O modelo é

implementado e simulado no ambiente computacional Matlab Simulink®. Os autores concluem que a integração de um gerador solar fotovoltaico no sistema autônomo diesel-bateria existente é viável; além disso, ao se considerar os custos externos associados à redução de emissão de poluentes, o tempo de retorno do investimento é consideravelmente reduzido.

Uma abordagem probabilística é apresentada por Tina, Gagliano e Raiti (2006) com objetivo de avaliar o desempenho em longo prazo de um sistema híbrido eólico-solar. Os autores propõem um modelo analítico do sistema no qual a convolução das funções densidade de probabilidade de potência eólica e solar são utilizadas para estimar a energia gerada pelo sistema. Para caracterizar o recurso eólico os autores utilizam a distribuição de probabilidade de Weibull, enquanto que a função densidade de probabilidade do índice de claridade proposta por Graham, Hollands e Unny (1988) é usada para modelar a variabilidade do recurso solar. Os autores estudam a relação entre o número de componentes e o ângulo de inclinação dos painéis fotovoltaicos, e comparam os resultados com um programa de simulação numérica baseada no método de Simulação de Monte Carlo desenvolvido pelos autores. A convergência do método numérico para o método analítico é testada através do cálculo do índice de confiabilidade energética. Pesquisas posteriores dos mesmos autores são apresentadas em (DILETTOSO et al., 2007; TINA; GAGLIANO, 2011).

Mais recentemente os autores Karlis e Papadopoulos (2013) desenvolveram um programa de computador que permite avaliar técnica e economicamente o desempenho de um sistema híbrido sob diferentes condições operacionais. O algoritmo baseia-se num procedimento sistemático para estudar a exequibilidade técnica e a viabilidade financeira de uma dada configuração de sistema híbrido. O modelo é validado com dados coletados num sistema real instalado na Grécia. Os resultados obtidos pelos autores mostram como os subsídios por parte do governo podem afetar a viabilidade financeira do sistema.

Outros autores que tem trabalhado amplamente na simulação e otimização de sistemas híbridos são Lujano-Rojas, Dufo-López e Bernal-Agustín. No trabalho (LUJANO-ROJAS; DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2013) esses autores propõem um modelo para simular a operação de um sistema solar-eólico-diesel-baterias baseado em análise probabilística e treinamento de Redes Neurais Artificiais (em inglês ANN). O modelo considera as incertezas associadas com os recursos solar e eólico, o preço do combustível, e a vida útil das baterias. A ANN é treinada utilizando dados de entrada derivados de modelos de geração sintética de dados meteorológicos e Simulação de Monte Carlo. Finalmente, o sistema híbrido é dimensionado pela incorporação da ANN num algoritmo de otimização mono-objetivo. Segundo os autores, a ANN é capaz de gerar os valores esperados de energia não suprida e

valor presente líquido do sistema, mostrando um baixo custo computacional para a simulação do desempenho do sistema híbrido em longo prazo.

2.2 OTIMIZAÇÃO DE SISTEMAS HÍBRIDOS DE GERAÇÃO DE ENERGIA


O adequado dimensionamento dos componentes de um SHGE é essencial para garantir sua viabilidade técnica e econômica. O problema de otimização de SHGEs consiste na escolha da "melhor" configuração dentre um conjunto de possíveis soluções (espaço de busca), envolvendo a escolha da função objetivo, a definição das restrições e a seleção de uma metodologia de otimização (LUNA-RUBIO et al., 2012). Este problema, tal como em muitos outros problemas de engenharia, pode ser representado como a combinação de três subproblemas os quais devem ser resolvidos simultaneamente, a fim de alcançar uma solução satisfatória (KALDELLIS, 2010):

- O problema de síntese, que consiste em definir o tipo de componentes que constituirá o SHGE.
- O problema de projeto, que consiste no dimensionamento dos componentes do sistema.
- O problema de operação, que consiste em definir uma estratégia de operação que cumpra com as restrições definidas pelo propósito final do sistema.

O problema de otimização de SHGEs compreende um grande número de variáveis de decisão, sendo que a quantidade de simulações necessárias para encontrar uma boa solução é geralmente elevada, assim como o custo computacional requerido. Portanto, é de fundamental importância para os projetistas encontrar uma técnica de otimização para o dimensionamento do sistema de forma rápida e com a precisão desejada (ZHOU et al., 2010).

Várias abordagens para o dimensionamento otimizado de SHGE têm sido propostas nos últimos anos e uma maneira de classificá-las é apresentada na Figura 2. Nas seções seguintes, é apresentada uma revisão de trabalhos que utilizam essas abordagens.

Figura 2. Classificação de abordagens para otimização de SHGE.



Fonte: produção do próprio autor

2.2.1 Abordagem analítica

Nesta abordagem o SHGE é representado por meio de modelos matemáticos que descrevem o sistema em termos da sua factibilidade (UPADHYAY; SHARMA, 2014). Através da implementação computacional dos modelos matemáticos é possível avaliar o desempenho do sistema para diferentes configurações e cenários de operação. A melhor configuração do sistema de energia híbrido pode ser determinada a partir de indicadores de desempenho relacionados com aspectos de confiabilidade, econômicos e ambientais. Para aplicar esta metodologia é necessário obter séries temporais de longo prazo das variáveis meteorológicas e da carga, as quais nem sempre estão disponíveis (LUNA-RUBIO et al., 2012). Constitui a primeira técnica utilizada para o dimensionamento de sistemas híbridos.

No trabalho de Protogeropoulos, Brinkworth e Marshall (1997) os autores propõem uma metodologia analítica para o dimensionamento de um sistema híbrido eólico-solar com baterias considerando dois possíveis cenários de operação. O primeiro cenário utiliza os valores médios mensais dos recursos renováveis, enquanto que no segundo cenário consideram-se os "piores" meses de disponibilidade dos recursos renováveis. Variando sistematicamente a fração de renováveis (tamanho relativo dos componentes do sistema), os autores conseguem identificar as configurações ótimas tecnicamente viáveis. O custo global das diferentes configurações encontradas na primeira etapa é calculado e junto com as características técnicas de cada configuração os autores escolhem a melhor opção.

Em Celik (2002b) o autor aborda a otimização técnico-econômica de um sistema eólico-solar-bateria. Os cálculos são realizados numa base mensal. A procura da melhor configuração se baseia na determinação de uma série de fatores técnicos como a razão entre a geração de energia e a carga, a razão entre a energia armazenada e a carga, e o preço da energia gerada. O autor conclui que a configuração híbrida proporciona um melhor

desempenho em relação a qualquer outra configuração com apenas geração solar ou eólica, considerando o mesmo custo. Também observa que a capacidade de armazenamento do banco de baterias tem um impacto importante nos sistemas compostos por apenas geração solar ou eólica.

Dois trabalhos similares publicados (DIAF et al., 2007; 2008) propõem uma metodologia para o dimensionamento de sistemas híbridos solar-eólica-bateria autônomos. A metodologia visa minimizar do Custo Nivelado de Energia (em inglês *Levelized Cost of Energy – LCOE*) enquanto se atendem os requisitos de confiabilidade, representados pelo índice de Probabilidade de Perda no Fornecimento de Energia (em inglês *Loss of Power Supply Probability – LPSP*). As variáveis de decisão são o número de turbinas eólicas, o número de módulos fotovoltaicos e capacidade do banco de baterias. As diferentes possíveis configuração, que atendem a confiabilidade desejada são apresentadas pelos autores em gráficos de *trade-off* entre duas variáveis de interesse. Após a simulação do sistema em diferentes condições operação, os autores concluem que a configuração híbrida é melhor em relação à configuração de apenas geração fotovoltaica ou eólica, resultando em menor *LCOE* para um dado valor de *LPSP*. Também observam que para garantir a máxima confiabilidade, *i.e.*, *LPSP* igual a zero, o excedente de energia pode resultar em até 75% da produção de energia. Os autores propõem o uso de uma fonte de geração despachável¹ para reduzir o excesso de energia.

Numa série de três artigos os autores Gupta, Saini e Sharma (2008a, 2008b, 2008c) apresentam a modelagem, otimização e implementação de um sistema híbrido de geração de energia autônomo composto por micro hidrelétrica, geração fotovoltaica, armazenamento em baterias, moto gerador de *backup* funcionando a diesel, biogás e biomassa (lenha), e cargas dissipadoras. A otimização é realizada por meio de programação linear inteira mista com o objetivo de minimizar o custo de produção de energia. Os autores propõem ainda uma estratégia de operação combinada para reduzir a participação do gerador diesel. Conclui-se que a metodologia proposta resulta uma boa opção para o dimensionamento de SHGE autônomos.

Em Dufo-López, Bernal-Agustín e Mendoza (2009) os autores propõem a incorporação da produção de hidrogênio num sistema híbrido solar-eólico conectado à rede. Analisam-se dois possíveis cenários: um sistema solar-eólico que gera energia para venda diretamente à rede; um sistema solar-eólico que gera energia para ser vendida diretamente à rede e produz

¹ Fonte despachável é aquela em que há controle dos momentos de geração, independentemente das condições climáticas locais.

hidrogênio através de um eletrolizador seja para venda ou para armazenamento e posterior uso em célula de combustível. Também é realizada uma análise de sensibilidade para estudar o efeito da velocidade média do vento e do preço dos componentes no Valor Presente Líquido (em inglês *Net Present Value* – NPV) do sistema. Os autores concluem que perante a eficiência atual dos componentes (eletrolizador e células de combustível) e do cenário de incentivos econômicos disponível na Espanha (em 2009), a produção intermitente de hidrogênio é apenas economicamente atrativa em lugares com boa disponibilidade de vento, onde o hidrogênio pode ser vendido a um preço mínimo de 10 €/kg.

Em 2011 os autores Ekren e Ekren (2011) apresentaram uma interessante abordagem onde a teoria de Projeto de Experimentos (em inglês *Design of Experiments* – DOE) é empregada para o dimensionamento otimizado de um sistema autônomo híbrido eólico-solar-bateria. Os autores empregam o método da Superfície de Resposta para identificar a melhor combinação das variáveis de projeto (área de varredura do aerogerador, área do arranjo fotovoltaico, e capacidade do banco de baterias) que minimiza o custo total do sistema híbrido. Também propõem um método probabilístico para gerar sinteticamente dados meteorológicos e de carga a partir de funções de distribuições de probabilidades horárias e simulação Monte Carlo. Os resultados são comparados com a técnica de otimização OptQuest incluído no software ARENA®. Os autores observam que os resultados obtidos com o método OptQuest são melhores que os obtidos com o método da Superfície de Resposta, embora o primeiro método resultasse em tempos de simulação elevados.

2.2.2 Abordagem gráfica

Essa é uma metodologia simples na qual apenas duas variáveis de decisão de cada vez podem ser consideradas no processo de otimização (ZHOU et al., 2010), por exemplo, número de baterias e número de módulos fotovoltaicos, ou número de turbinas e número de módulos fotovoltaicos. É geralmente utilizada para se obter resultados preliminares.

No artigo Borowy e Salameh (1996) os autores utilizam uma técnica de otimização gráfica para o dimensionamento de um sistema híbrido solar-eólico-bateria. O sistema é simulado com base numa série temporal histórica de dados meteorológicos de radiação solar e vento registrada por um período de 30 anos. A carga a ser atendida pelo sistema corresponde a uma casa típica da cidade de Massachusetts. Para uma determinada carga e um valor de *LPSP* desejado, os autores encontram a melhor combinação de módulos fotovoltaicos e turbinas eólicas ou número de baterias e módulos fotovoltaicos com o menor custo total.

Apenas dois parâmetros por vez podem ser otimizados, os restantes devem ser predefinidos. Apesar dessa desvantagem, os autores Borowy e Salameh (1996) concluem que é uma técnica simples e que permite obter resultados prévios com rapidez.

Uma técnica gráfica simples para dimensionamento de sistemas solar-eólico a partir de dados meteorológicos em base mensal é apresentada por Markvart (1997). Considerando a variação sazonal dos recursos renováveis, o autor constrói uma série de curvas de dimensionamento em função da área de varredura da turbina eólica e a área do arranjo fotovoltaico. Também são construídos gráficos do custo do sistema em função da combinação de componentes. Os autores concluem que a configuração híbrida eólica-solar é melhor em termos de custo, devido ao fato de que o SHGE permite garantir uma maior confiabilidade no fornecimento de energia à carga.

2.2.3 Abordagem probabilística

A abordagem probabilística é uma metodologia pouco explorada na qual se considera a natureza estocástica dos recursos renováveis, e, em alguns casos, da carga a ser fornecida (ZHOU et al., 2010). A grande vantagem dessa abordagem é que permite criar modelos de risco pela combinação dos modelos estocásticos dos recursos e/ou demanda (CHAUHAN; SAINI, 2014; LUNA-RUBIO et al., 2012).

Karaki, Chedid e Ramadan (1999) propõem uma metodologia probabilística para modelar e simular o funcionamento de um sistema autônomo híbrido eólico-solar com armazenamento de energia em baterias. Através da abordagem probabilística representam o comportamento dos recursos solar e eólico e também modelam a probabilidade de falha dos equipamentos. A combinação destes modelos com o modelo de demanda permite a avaliação do sistema híbrido em condições operacionais reais. Os autores estimam também o limite máximo de armazenamento necessário considerando os ciclos de carga e descarga do banco de baterias.

Karki e Billinton (2001) apresentam um estudo interessante em que é avaliada a confiabilidade de um sistema eólico-solar-diesel para fornecimento de comunidades isoladas. Geram-se séries sintéticas de dados meteorológicos a fim de considerar a natureza estocástica dos recursos renováveis. Os autores utilizam o método proposto por Graham e Hollands (1990) e Hollands, D'andrea e Morrison (1989) para gerar dados de radiação solar e temperatura, respectivamente. Entretanto um modelo auto-regressivo de médias móveis (ARMA) é proposto para gerar a série temporal de velocidades do vento. Além disso, a

técnica de simulação de Monte Carlo é utilizada para gerar um histórico de operação de cada unidade geradora através da simulação dos tempos de funcionamento e reparo de cada uma delas. O resultado obtido pelos autores é um conjunto de curvas de confiabilidade e consumo de combustível para diferentes configurações do sistema híbrido. A informação gerada pode ser utilizada como ferramenta de planejamento energético para avaliar os efeitos da incorporação de energias renováveis nos sistemas elétricos.

Dilettoso et al. (2007) utilizam a abordagem probabilística proposta por Tina e Gagliano (2011) para otimizar um SHGE solar-eólico conectado à rede. Os autores propõem como método de otimização as metaheurísticas Exame de Partículas (em inglês *Particle Swarm* – PSO) e Algoritmos Genéticos (AG). Duas funções objetivo, o Índice de Confiabilidade Energético e a Taxa Interna de Retorno, são transformadas numa única função objetivo de minimização utilizando a lógica difusa. As variáveis de projeto escolhidas são ângulo de inclinação e a área do gerador fotovoltaico e a potência nominal do aerogerador. Segundo os autores, a metodologia proposta mostra bons resultados implicando baixo custo computacional.

Bashir e Sadeh (2012a) desenvolveram um algoritmo de otimização para determinar a potência de um SHGE autônomo eólico-solar-bateria considerando as incertezas na velocidade do vento e na radiação solar. Para isso, são empregados 32 anos de dados meteorológicos para criar funções densidade de probabilidade da velocidade do vento e da radiação solar, sendo o método de simulação de Monte Carlo utilizado para representar sua natureza estocástica. A otimização é feita por meio do método Enxame de Partículas (PSO), sendo que a função objetivo é o Valor Presente Líquido do sistema calculado durante o período de vida do projeto. Os autores concluem que o custo final do sistema é inferior quando consideradas as incertezas dos recursos renováveis para o mesmo nível de confiabilidade.

2.2.4 Abordagem iterativa

Na abordagem iterativa, o dimensionamento do SHGE é realizado por meio de um processo recursivo interrompido quando se atinge a melhor configuração que atende as especificações do projeto (LUNA-RUBIO et al., 2012). Em outras palavras, a melhor solução é obtida procurando todas as possíveis soluções no espaço de busca até atingir o mínimo/máximo valor da função objetivo (VENKATARAMAN, 2002). Nesta abordagem, a função objetivo está geralmente relacionada com variáveis de confiabilidade (*i.e.*, Perda no

Fornecimento de Energia) ou variáveis econômicas (*i.e.* Valor presente Líquido ou Custo Nivelado de Energia) (CHAUHAN; SAINI, 2014).

Yang, Lin e Zhou (2007) desenvolveram o modelo *Hybrid Solar-Wind System Sizing Optimization* (HSWSO) para otimizar o dimensionamento dos diferentes componentes de sistemas de geração híbridos solar-eólica com armazenamento em banco de baterias. O modelo compõe-se de três partes: o modelo dos componentes do sistema; o modelo técnico baseado no indicador Probabilidade de Perda no Fornecimento de Energia (*LPSP*); e o modelo econômico baseado no conceito de Custo Nivelado de Energia (*LCE*). Pela combinação destes três modelos os autores variam o número de componentes numa abordagem iterativa até atingir a configuração ótima de SHGE em termos de *LPSP*. O modelo é implementado para dimensionar um sistema híbrido para o fornecimento elétrico de uma estação de comunicação na província de Guangdong na China.

Em Ashok (2007) é proposto um método de otimização iterativo para dimensionar um SHGE na Índia. A otimização tem como objetivo minimizar o Custo de Ciclo de Vida (em inglês *Life Cycle Cost –LCC*) do sistema, garantindo a confiabilidade do fornecimento de energia. Diferentes estratégias de operação são estudadas pelos autores a fim de obter a configuração ótima. As fontes renováveis consideradas são: micro hidrelétrica, eólica e solar fotovoltaica além de geração diesel como *backup* e baterias para armazenamento de energia. A metodologia de otimização é aplicada para dimensionar um sistema numa aldeia agrícola típica da Índia, concluindo que um sistema com 100% de geração renovável composto por micro hidrelétrica, eólica e baterias é a configuração ideal. O SHGE é capaz de fornecer 24 horas de abastecimento elétrico para a aldeia, sem a necessidade de geradores diesel.

Uma abordagem determinística baseada no algoritmo *Dividing RECTangles* (DIRECT) é proposta por Zhang, Barakat e Yassine (2012) para o dimensionamento de um sistema eólico-solar-diesel-bateria. As variáveis de decisão adotadas são o modelo de módulos fotovoltaicos, a área do arranjo fotovoltaico, o número de aerogeradores, a altura dos aerogeradores, o número de baterias e as horas de funcionamento do gerador diesel. A função objetivo é o custo de investimento inicial do sistema. A metodologia é implementada num estudo de caso de uma comunidade isolada de aproximadamente 150 prédios residenciais localizada na França. Os resultados alcançados pelos autores mostram que o sistema híbrido solar-eólico-diesel-bateria é a combinação ótima com melhor custo-benefício para atender a demanda de energia elétrica da comunidade.

Engin (2013) implementa uma metodologia de dimensionamento para projetar um sistema autônomo eólico-solar-bateria. O procedimento simula a operação do sistema e avalia

seu desempenho para diferentes configurações cumprindo as restrições técnicas impostas pelos autores. As variáveis de decisão são o modelo e número de componentes, e a função objetivo é o Custo do Ciclo de Vida (em inglês *Life Cycle Cost* – LCC) do sistema, a qual foi minimizada. O algoritmo é implementado em Matlab®, e a partir de uma técnica iterativa simples obtém-se os valores ótimos das variáveis de decisão. O modelo é validado com medições derivadas de um sistema real em operação.

No trabalho apresentado por Zhang et al. (2013) propõe-se um algoritmo para o dimensionamento de um sistema solar-diesel-bateria baseado na otimização da estratégia de operação. O método combina uma abordagem iterativa com um método de busca aleatória. A função objetivo é o Custo da Energia, o qual é minimizado considerando o custo de capital inicial, o custo de combustível, os custos extras derivados das emissões de CO₂ e os custos de manutenção. O algoritmo utiliza a *toolbox* de otimização de Matlab® para resolver o problema com programação linear. Observa-se que o método de dimensionamento proposto por Zhang et al. (2013) reduz significativamente o esforço computacional.

No trabalho apresentado por Kaabeche e Ibtouen (2014), sugere-se um modelo de otimização com base numa abordagem iterativa para dimensionar as capacidades dos componentes de um sistema autônomo híbrido solar-eólico-diesel-bateria para fornecimento de uma carga com uma confiabilidade de 100%. O modelo avalia aspectos técnicos através de indicadores como o Déficit Total de Energia e aspectos econômicos através do Valor Presente Líquido e do Custo da Energia. Os autores implementam o algoritmo num estudo de caso na Argélia, concluindo que a configuração solar-eólico-diesel-baterias é economicamente mais viável em relação à configuração solar-eólico-baterias ou considerando a configuração com apenas geração diesel.

2.2.5 Abordagem metaheurística

As metaheurísticas são uma família de algoritmos de otimização global amplamente utilizadas no campo da engenharia nas últimas décadas. Esses algoritmos são especialmente adequados para a resolução de problemas nos quais o conjunto de soluções é demasiado grande para ser completamente amostrado. Baseadas em mínimas informações iniciais sobre as características do problema, essas técnicas são capazes de encontrar boas soluções em menores tempos de processamento do que outras abordagens de otimização tradicionais (BLUM; ROLI, 2003). A maioria das metaheurísticas incorpora alguma forma de otimização estocástica e são inspirados na natureza (YANG, 2010).

Dadas as características do problema de otimização de SHGE (explosão combinatória, alta interação entre as variáveis de decisão, existência de aleatoriedade), as técnicas metaheurísticas apresentam-se como uma ferramenta especialmente adequada para o tratamento deste tipo de problema. Isto se justifica pela grande quantidade de trabalhos publicados nas últimas décadas que propõem variadas metaheurísticas para a otimização de SHGE. Dentre as metaheurísticas mais utilizadas se encontram: Algoritmos Genéticos (*Genetic Algorithms*), a Programação Evolucionária (*Evolutionary Programming*), Otimização por Enxame de Partículas (*Particle Swarm Optimization*), Otimização por Colônia de Formigas (*Ant Colony Optimization*), Busca Tabu (*Tabu Search*), Recozimento Simulado (*Simulated Annealing*), Busca Local Estocástica (*Stochastic Local Search*), *Harmony Search*, entre outras.

No trabalho apresentado por Bourouni, Ben M'barek e Al Taei (2011) estuda-se um sistema híbrido solar-eólico-bateria acoplado a um sistema de dessalinização por osmose reversa. Os autores propõem o uso de um Algoritmo Genético para otimizar o dimensionamento do sistema. O algoritmo permite obter a configuração ideal de componentes que minimiza o Valor Presente Líquido da produção de água. A metodologia é validada com medições realizadas num sistema real localizado na Tunísia, revelando boa correspondência entre os valores medidos e calculados.

Diferentes tecnologias de bateria (lítio-íon, chumbo-ácido e redox ao vanádio) para serem usadas em um sistema híbrido autônomo solar-eólico-diesel são avaliadas por Merei, Berger e Sauer (2013). Com o objetivo de utilizar as diferentes tecnologias de baterias em simultâneo os autores propõem uma estratégia de gestão das baterias. A otimização é feita em função da minimização do custo global do sistema variando a potência dos componentes. Como algoritmo de otimização é utilizado o Algoritmo Genético disponível na *optimtool* do Matlab®. A metodologia é implementada em dois locais com diferentes disponibilidades de radiação solar, na Síria e na Alemanha. Os resultados demonstram que a combinação de mais de uma tecnologia de bateria em um mesmo sistema não é adequado, sendo que as baterias de redox ao vanádio constituem a melhor opção.

Ismail, Moghavvemi e Mahlia (2014) também utilizam uma versão do Algoritmo Genético para otimizar o dimensionamento de um sistema híbrido solar-bateria com uma microturbina ou gerador a diesel como geração de *backup*. O vetor decisão compreende as variáveis: tipo e número de painéis PV, tipo e número de baterias, tipo e número de microturbinas, tipo de montagem do arranjo PV e o ângulo de inclinação e azimute do arranjo PV. A função de otimização adotada é o Custo da Energia, também incorporando os custos

externos de emissão de gases poluentes (CO_2 , NO_x , SO_x) no cálculo do custo. Os autores concluem que o uso de microturbinas de ciclo térmico como fonte de geração despachável é técnica e economicamente viável. No entanto, a disponibilidade limitada no mercado de pequenas microturbinas em potências menores a 25 kW torna difícil a sua implementação.

Paliwal, Patidar e Nema (2014) propõe-se uma abordagem metaheurística para determinar a combinação ótima de recursos renováveis num sistema autônomo eólico-solar-diesel-bateria. O procedimento leva em conta critérios econômicos, através do cálculo do Custo Nivelado da Energia; critérios técnicos, através da estimativa de índices de confiabilidade; e critérios sociais, através da consideração dos custos sociais obtidos através das emissões de CO_2 . Também são incorporadas as incertezas associadas aos recursos renováveis. A otimização é realizada por meio de uma versão modificada do método Exame de Partículas (PSO) a fim de melhorar seu desempenho. Os autores concluem que a combinação de diferentes fontes de energia fornece uma solução economicamente mais viável para as condições testadas.

Em outro estudo, Maleki e Askarzadeh (2014) avaliam o desempenho de quatro metaheurísticas para a otimização de sistemas híbridos eólico-solar-bateria-célula de combustível. As metaheurísticas testadas são Enxame de Partículas, Busca Tabu, Recozimento Simulado e *Harmony Search*. A função objetivo a ser minimizada é o custo anual total do sistema, e as restrições se relacionam com o estado de carga das baterias e os limites máximos e mínimos dos componentes. Os resultados demonstram a robustez do algoritmo Enxame de Partículas; a classificação geral quanto à capacidade dos algoritmos em resolver o problema de otimização é Enxame de Partículas > Busca Tabu > *Harmony Search* > Recozimento Simulado. Por outro lado, o custo computacional do algoritmo Busca Tabu resultou menor do que a dos outros algoritmos. No que diz respeito à configuração do sistema, a opção de armazenamento de energia em baterias resulta a opção economicamente melhor do que o sistema com armazenamento com base no hidrogênio gerador a partir de eletrolisação.

Num estudo similar apresentado também por Maleki e Pourfayaz (2015), três metaheurísticas "tradicionais" (Enxame de Partículas, Busca Tabu e Recozimento Simulado) são comparadas com quatro algoritmos propostos recentemente, *Improved Harmony Search* (IHS), *Improved Harmony Search-based Simulated Annealing* (IHSBSA), e *Artificial Bee Swarm Optimization* (ABSO). Os algoritmos são implementados para dimensionar um sistema híbrido solar-eólico-bateria que é otimizado em termos do custo anual total. Neste

estudo, os autores observam que a nova abordagem ABSO se desempenha melhor do que os outros algoritmos, tanto em termos de robustez como em velocidade de cálculo.

2.2.6 Abordagem híbrida

Na abordagem híbrida combinam-se duas ou mais técnicas diferentes com o intuito de aproveitar as melhores características de cada uma delas (UPADHYAY; SHARMA, 2014). É prática comum combinar uma metaheurística com outras abordagens de otimização tradicionais (TALBI, 2009).

Lagorse, Paire e Miraoui (2009) combinam dois métodos de otimização para dimensionar um sistema de iluminação pública composto por painéis PV, baterias e células de combustível. Os autores implementam um Algoritmo Genético junto com um método de otimização linear, o algoritmo Simplex. O Algoritmo Genético é utilizado para se obter uma tendência nos resultados, e o algoritmo Simplex é empregado na sequência para completar a otimização a partir dos resultados do Algoritmo Genético. O objetivo da otimização é minimizar o custo total do sistema. Os autores concluem que o uso de células de combustível com painéis solares permite que o sistema de iluminação pública autônomo possa ser usado em regiões distantes do equador o ano todo.

Por exemplo, Katsigiannis, Georgilakis e Karapidakis (2010a) propõem a utilização do Algoritmo Genético multiobjetivo NSGA-II em combinação com um procedimento de busca local para resolver o problema de otimização de dimensionamento de um sistema eólico-solar-diesel com duas diferentes tecnologias de armazenamento de energia: baterias de chumbo-ácido e armazenamento de hidrogênio. Os objetivos da otimização são o custo da energia e as emissões de gases de efeito estufa com base na Análise do Ciclo de Vida dos componentes do sistema. De acordo com os autores, a implementação do algoritmo de busca local melhora o número e a qualidade das soluções de Pareto. No entanto, o tempo de processamento aumenta quando o método de busca local é incorporado. Os resultados também indicam que as baterias são a melhor opção em relação ao hidrogênio em termos econômicos e ambientais.

2.3 OTIMIZAÇÃO MULTIOBJETIVO APLICADA A SHGE

O problema de otimização de SHGE é intrinsecamente multiobjetivo já que é preciso considerar vários critérios conflitantes para que o sistema seja capaz de fornecer de maneira

adequada às necessidades energéticas da carga. Existem várias abordagens a serem satisfeitas na hora de resolver problemas multiobjectivo. Várias técnicas têm sido implementadas por diferentes autores no problema específico de dimensionamento de SHGEs. Algumas destas técnicas são apresentadas a seguir:

2.3.1 Abordagem das somas ponderadas

Em Saif et al. (2010), o problema de otimização de um sistema híbrido eólico-solar-diesel-bateria é formulado como um modelo de programação linear com dois objetivos: minimizar o custo total do sistema e minimizar as emissões de CO₂ do Ciclo de Vida do sistema. Os dois objetivos são agregados em uma única função objetivo utilizando um fator de peso para controlar a prioridade dos objetivos. O sistema deve cumprir a restrição relacionada com o nível máximo de carga não servida. Finalmente, aplicando a metodologia proposta, os autores constroem a fronteira de Pareto com as melhores soluções de *trade-off* entre os objetivos impostos. Os autores concluem que há uma necessidade de se considerar as emissões indiretas (derivadas do ciclo de vida dos componentes) quando se comparam diferentes fontes de geração, a fim de se obter uma estimativa real do impacto sobre o meio ambiente.

Em outro trabalho, Mohamed e Koivo (2011) combinam um Algoritmo Genético simples com uma abordagem de somas ponderadas para a otimização de uma micro rede. Os autores agregam num único objetivo o custo de operação do sistema e as emissões de poluentes, enquanto são impostas algumas restrições de confiabilidade. A metodologia permite obter uma solução única, em vez de um conjunto de soluções não dominadas. Apesar de a metodologia ser simples, é preciso fazer várias suposições para implementá-la. Os autores não informam o valor dos pesos utilizados na otimização e a metodologia não foi validada.

Em Fu, Yang e Zou (2011), os autores propõem um algoritmo que combina lógica difusa com somas ponderadas para dimensionar um pequeno sistema de geração híbrido eólico-solar-hidro para fornecimento em uma área rural. São considerados quatro objetivos de otimização relacionados com confiabilidade, custo, complementariedade entre geração e demanda e benefícios ambientais. A metodologia é testada e comparada com um método baseado em Algoritmos Genéticos apresentando grande similaridade entre os resultados. Observa-se que o custo anual obtido com o método de lógica difusa e somas ponderadas resulta inferior, uma vez que incorpora os benefícios ambientais da utilização de energias renováveis.

2.3.2 Abordagem ε -restrito

Maheri (2014) apresenta uma metodologia para otimizar o dimensionamento de um sistema híbrido eólico-solar-diesel considerando dois objetivos conflitantes, o custo e a confiabilidade. Também são consideradas incertezas na carga e nos recursos renováveis. O problema multiobjetivo é reformulado com um problema mono-objetivo transformando todos os objetivos menos um em restrições (abordagem ε -restrito), a fim de reduzir o tempo computacional requerido para os cálculos. O autor desenvolve um Algoritmo Genético para realizar a otimização que incorpora um operador de mutação dinâmica. Esse operador utiliza altas taxas de mutação nas primeiras gerações, a fim de aumentar o comportamento exploratório do Algoritmo Genético, e uma vez que o algoritmo identifica o conjunto de soluções não dominadas, a taxa de mutação é reduzida. Os resultados demonstram que um método determinístico pode levar a soluções que implicam o sobre dimensionamento do sistema, no entanto, uma abordagem probabilística permite obter soluções mais reais para o problema de otimização do SHGE.

Outra metaheurística, o método de Otimização por Enxame de Partículas (PSO) é utilizada por Sharafi e Elmekkawy (2014) numa abordagem de otimização baseada em simulação para dimensionar um sistema híbrido autônomo, incluindo vários geradores (eólico, solar e diesel) e duas tecnologias de armazenamento de energia (baterias e tanque de hidrogênio). Os autores Sharafi e Elmekkawy (2014) utilizam a abordagem de otimização multiobjetivo ε -restrito adotando como função objetivo o custo total do sistema, enquanto as emissões de CO₂ e a Probabilidade de Perda de Carga (*Loss of Load Probability*) são incorporadas como restrições limitadas por fatores ε_i . A metodologia é implementada para dimensionar um sistema para fornecimento de energia numa área rural da Espanha. Os resultados são comparados com outra abordagem chamada de *Strength Pareto Evolutionary Algorithm* (SPEA) chegando a resultados semelhantes em dois dos cenários analisados. Entretanto, no terceiro cenário avaliado, a metodologia proposta apresentou um melhor desempenho. Os autores também elaboram uma análise de sensibilidade para investigar a influência de certos parâmetros no desempenho do modelo desenvolvido, mostrando sua dependência com relação aos valores ε_i adotados.

Em Yazdanpanah (2014), um método de avaliação por correspondência (em inglês *Match Evaluation Method*) é desenvolvido para dimensionar um SHGE com o objetivo final de minimizar o custo total do sistema. Outros três critérios também são considerados, dois deles relacionados com a taxa de correspondência de eletricidade, o coeficiente de correlação

e o coeficiente de desigualdade, e um relacionado com o custo do sistema. Para realizar a otimização implementa-se um algoritmo de Enxame de Partículas Multiobjetivo (MOPSO) e as soluções encontradas são validadas com o algoritmo NSGA-II (DEB et al., 2002). Os autores concluem que ambos os algoritmos são capazes de atingir a solução global, embora o MOPSO apresenta menor tempo de processamento do que NSGA-II para o mesmo número de gerações.

2.3.3 Abordagem de busca da fronteira de Pareto

Esta abordagem trata os objetivos individualmente aplicando alguma metodologia de busca especialmente desenvolvida para identificar o conjunto de soluções não dominadas que conformam a fronteira de Pareto. Nos últimos anos este tipo de abordagem tem sido amplamente utilizado devido ao desenvolvimento de diferentes metaheurísticas que possibilitam a busca de soluções não dominadas em tempos de processamento menores.

Um dos primeiros grupos de pesquisa, e talvez o mais produtivo, em trabalhar com técnicas de otimização multiobjetivo (baseadas em Algoritmos Genéticos) para o dimensionamento do SHGE é Dufo-López e colaboradores da Universidade de Zaragoza, Espanha. Este grupo de pesquisa têm publicado vários trabalhos na área (BERNAL-AGUSTÍN; DUFO-LÓPEZ; RIVAS-ASCASO, 2006; BERNAL-AGUSTÍN; DUFO-LÓPEZ, 2009; DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2008; DUFO-LÓPEZ et al., 2011) e ainda desenvolveram um software de otimização chamado HOGA (DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2015), que utiliza técnicas metaheurísticas multiobjetivo para a otimização de SHGE.

No primeiro trabalho publicado, Bernal-Agustín, Dufo-López e Rivas-Ascaso (2006), abordam o problema de dimensionamento de um sistema eólico-solar-diesel-bateria utilizando a metaheurística multiobjetivo chamada *Strength Pareto Evolutionary Algorithm* (SPEA). O problema é formulado como biobjetivo: minimização do custo ao longo da vida útil do projeto e minimização das emissões de poluentes, garantindo ao mesmo tempo a confiabilidade no fornecimento de energia elétrica. A estratégia de controle é simultaneamente otimizada dentro do algoritmo. O vetor de variáveis de decisão inclui o número e o tipo de componentes, a estratégia de controle e o *set point* do estado de carga das baterias. Ao finalizar a simulação, o algoritmo fornece uma série de soluções não dominadas das quais o projetista pode selecionar a que melhor satisfaz as suas necessidades. Os autores não apresentam nenhum critério de seleção da solução final.

Em trabalhos posteriores Dufo-López e colaboradores continuam trabalhando com as metaheurísticas de otimização multiobjetivo aplicadas ao projeto de SHGEs. Em (DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2008) os autores utilizam o mesmo algoritmo (SPEA) para o mesmo problema, porém adicionando um maior número de variáveis de otimização. Os autores empregam um Algoritmo Genético secundário para otimizar a estratégia de controle. Além disso, adicionam um terceiro objetivo, a carga não fornecida e uma opção diferente de geração de energia, uma célula de combustível alimentada com hidrogênio produzido a partir do excedente de energia. Assim, o problema torna-se tri-objetivo. Em outro trabalho Bernal-Agustín e Dufo-López (2009) trabalham com o mesmo sistema, mas, neste caso, os autores propõem um novo algoritmo de operação para o SHGE. A estratégia proposta baseia-se na estimativa de um valor de potência limite, a qual indica o valor de energia para a qual a energia fornecida pelas baterias é economicamente igual a energia fornecida pelo gerador a diesel. Finalmente, em Dufo-López et al. (2011) os autores dimensionam um sistema eólico-solar-diesel-bateria usando o software HOGA desenvolvido por Dufo-López e Bernal-Agustín (2015). Neste trabalho, os objetivos a serem otimizados são o Custo Nivelado de Energia e as emissões de CO₂ no Ciclo de Vida Equivalente dos componentes do sistema. Conclui-se que quase todas as soluções não dominadas da fronteira de Pareto incluem um gerador a diesel, quando as emissões CO₂ produzidas durante as etapas de fabricação, transporte e disposição final dos painéis PV, das turbinas eólicas e as baterias são consideradas.

Novas metaheurísticas são constantemente propostas para resolver o problema de otimização multiobjetivo de um SHGE. Como é o caso do trabalho de Nasiraghdam e Jadid (2012), onde é implementado o algoritmo multiobjetivo de Colônia de Abelhas Artificial (*Multi-objective Artificial Bee Colony* – MOABC). O MOABC, que é inspirado no comportamento social das abelhas, é utilizado para dimensionar um sistema híbrido eólico-solar-célula de combustível conectado à rede. Quatro objetivos são considerados: minimização da perda no fornecimento de energia, maximização do índice de estabilidade de tensão, minimização do custo do sistema e minimização das emissões de poluentes. As variáveis de decisão são o estado das chaves no barramento e a energia gerada pelo sistema híbrido. O algoritmo é implementado e seu desempenho comparado com outras metaheurísticas, o NSGA-II e MOPSO. Verifica-se que o algoritmo MOABC apresenta um desempenho melhor em termos de diversidade e distribuição das soluções de Pareto com relação às outras metaheurísticas.

Num trabalho apresentado recentemente, Bilil, Aniba e Maaroufi (2014) utilizam o Algoritmo Genético multiobjetivo NSGA-II para dimensionar um sistema híbrido composto

de geração eólica e solar. Neste caso, os autores propõem duas funções objetivo; a primeira é o custo do sistema que leva em consideração os custos de operação, manutenção e reposição. O segundo objetivo é um índice de confiabilidade chamado de disparidade de carga/energia renovável. Além disso, os autores propõem o uso de um fator de penalidade a fim de priorizar as soluções que geram a quantidade de energia estritamente necessária sobre as que geram excesso de energia. Os resultados permitem concluir que o fator de penalidade proposto é de grande utilidade para ser usado no dimensionamento de SHGE.

2.4 CONCLUSÕES DA PESQUISA BIBLIOGRÁFICA

A Tabela 1 mostra um resumo da pesquisa bibliográfica realizada sobre artigos que abordam o tema de otimização de SHGE. Pode-se observar que quase a totalidade dos sistemas considera a geração solar fotovoltaica (PV) e a eólica (WT) como principais fontes geradoras de origem renovável. A geração de *backup* é quase exclusivamente realizada através de moto geradores funcionando a óleo diesel (DG), porém alguns trabalhos avaliam a possibilidade de empregar motores movidos a biodiesel ou gás de síntese. A geração a partir de micro centrais hidrelétricas (hidro) é considerada em alguns trabalhos, porém é mais específica para certas regiões onde o recurso se encontra disponível. Poucos trabalhos avaliam a possibilidade de incluir microturbinas a gás entre as fontes geradoras, sendo esta uma tecnologia ainda onerosa.

Com relação ao armazenamento de energia, as baterias eletroquímicas (BT) constituem a tecnologia de armazenamento por excelência, dado que é uma tecnologia amplamente desenvolvida e de baixo custo. No entanto, nos últimos anos o armazenamento de energia em tanques de hidrogênio produzido por eletrolizadores para seu posterior uso em células de combustível (FC) tem sido incluído em alguns trabalhos. Porém, o custo de geração e armazenamento de hidrogênio ainda limita sua aplicação. Outras tecnologias como armazenamento térmico ou bombeamento de água são estudadas em alguns trabalhos específicos.

Em relação à configuração do sistema, a grande maioria dos trabalhos se foca no estudo de sistemas autônomos, *i.e.* isolados da rede. Porém, a tendência de integração das fontes renováveis na rede elétrica a partir do conceito de *smart grid* tem salientado a produção de trabalhos que avaliam sistemas conectados à rede, tanto em sistema interligados como em miniredes.

Tabela 1. Resultados da pesquisa bibliográfica (continua).

Referência	Componentes							Autônomo	Conectado à rede	Simulação	Otimização
	Ano	PV	WT	FC	DG	BT	Outros				
(ABOUZHR; RAMAKUMAR, 1991)	1991	●				●		●		●	
(MANWELL; DENG; MCGOWAN, 1994)	1994		●		●	●		●		●	
(MCGOWAN et al., 1996)	1996	●	●		●	●		●		●	
(CHEDID; SALIBA, 1996)	1996	●	●		●	●		●			●
(BOROWY; SALAMEH, 1996)	1996	●	●			●		●			●
(PROTOGEROPOULOS; BRINKWORTH; MARSHALL, 1997)	1997	●	●			●		●			●
(MARKVART, 1997)	1997	●	●					●			●
(SEELING-HOCHMUTH, 1997)	1997	●	●		●	●		●			●
(KELLOGG et al., 1998)	1998	●	●			●		●	●		●
(MCGOWAN; MANWELL, 1999)	1999	●	●		●	●		●		●	
(KARAKI; CHEDID; RAMADAN, 1999)	1999	●	●			●		●		●	
(NEHRIR, 2000)	2000	●	●		●	●		●		●	
(KARKI; BILLINTON, 2001)	2001	●	●		●			●		●	
(CELIK, 2002a)	2002	●	●			●		●			●
(AI et al., 2003)	2003	●	●			●		●			●
(YANG; LU; BURNETT, 2003)	2003	●	●			●		●			●
(WIES et al., 2004)	2004	●			●	●		●			
(XU et al., 2005)	2005	●	●			●	carga dissipadora	●			●
(SHAHIRINIA; TAFRESHI, 2005)	2005	●	●		●	●		●			●
(DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2005)	2005	●			●	●		●			●
(PELET; FAVRAT; LEYLAND, 2005)	2005	●			●		armazenamento térmico, ciclo ranking orgânico, torre resfriamento de água, coletor solar		●		●
(CHEDID; KARAKI; RIFAI, 2005)	2005	●	●		●	●		●			●
(TINA; GAGLIANO; RAITI, 2006)	2006	●	●					●	●		
(NELSON; NEHRIR; WANG, 2006)	2006	●	●	●		●	eletrolizador	●	●		●
(KALDELLIS; KONDILI; FILIOS, 2006)	2006		●		●	●		●			●
(KOUTROULIS et al., 2006)	2006	●	●			●		●			●
(BERNAL-AGUSTÍN; DUFO-LÓPEZ; RIVAS-ASCASO, 2006)	2006	●	●		●	●		●			●
(DILETTOSO et al., 2007)	2007	●	●						●		●
(DIAF et al., 2007)	2007	●	●			●		●			●
(ASHOK, 2007)	2007	●	●		●	●	hidro	●			●
(YANG; LU; ZHOU, 2007)	2007	●	●			●		●			●
(DUFO-LÓPEZ; BERNAL-AGUSTÍN; CONTRERAS, 2007)	2007	●	●	●	●	●	eletrolizador, tanque H ₂	●			●

Tabela 1. Resultados da pesquisa bibliográfica (continuação).

Referência	Componentes							Autônomo	Conectado à rede	Simulação	Otimização
	Ano	PV	WT	FC	DG	BT	Outros				
(SENJYU et al., 2007)	2007	●	●		●	●		●			●
(SHI; ZHU; CAO, 2007)	2007	●	●			●		●			
(EKREN; EKREN, 2008)	2008	●	●			●		●			●
(DIAF et al., 2008)	2008	●	●			●		●			●
(GUPTA; SAINI; SHARMA, 2008b)	2008	●			●	●	biomassa, biogás, hidro	●			●
(DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2008)	2008	●	●	●	●	●	tanque H ₂	●			●
(SHI et al., 2008)	2008	●	●			●		●			
(DUFO-LÓPEZ; BERNAL-AGUSTÍN; MENDOZA, 2009)	2009	●	●	●			eletrolizador		●		●
(MONDOL; YOHANIS; NORTON, 2009)	2009	●							●		
(KALDELLIS; ZAFIRAKIS; KONDILI, 2009)	2009	●				●		●			●
(YANG; WEI; CHENGZHI, 2009)	2009	●	●			●	carga dissipadora	●			●
(HAKIMI; MOGHADDAS-TAFRESHI, 2009)	2009		●	●			eletrolizador, reformador, reator anaeróbico, tanque H ₂	●			●
(SINGH, 2009)	2009	●	●			●			●		●
(LAGORSE; PAIRE; MIRAOU, 2009)	2009	●		●		●	tanque H ₂	●			●
(BERNAL-AGUSTÍN; DUFO-LÓPEZ, 2009)	2009	●	●	●	●	●	tanque H ₂	●			●
(SILVA; NAKATA, 2009)	2009	●	●		●		hidro, combustão biomassa, gasificação biomassa	●			●
(KHATOD; PANT; SHARMA, 2010)	2010	●	●		●			●			●
(ZENG et al., 2010)	2010	●	●			●		●			●
(MASOUM; BADEJANI; KALANTAR, 2010)	2010	●	●			●			●		●
(KATSIGIANNIS; GEORGILAKIS; KARAPIDAKIS, 2010b)	2010	●	●	●	●	●	biodiesel	●			●
(KATSIGIANNIS; GEORGILAKIS; KARAPIDAKIS, 2010a)	2010	●	●	●	●	●	tanque H ₂	●			●
(ZENG et al., 2010)	2010	●	●			●		●			●
(SAIF et al., 2010)	2010	●	●		●	●		●			●
(TINA; GAGLIANO, 2011)	2011	●	●						●	●	
(EKREN; EKREN, 2011)	2011	●	●			●		●			●
(JAHANBANI; RIAHY, 2011)	2011	●	●			●		●			●
(BOUROUNI; BEN M'BAREK; AL TAE, 2011)	2011	●	●			●	dessalinização por osmose inversa	●			●
(DUFO-LÓPEZ et al., 2011)	2011	●	●		●	●		●			●
(MOHAMED; KOIVO, 2011)	2011	●	●		●	●	microturbina		●		●

Tabela 1. Resultados da pesquisa bibliográfica (conclusão).


Referência	Componentes							Autônomo	Conectado à rede	Simulação	Otimização
	Ano	PV	WT	FC	DG	BT	Outros				
(FU; YANG; ZOU, 2011)	2011	●	●			●	hidro	●			
(BASHIR; SADEH, 2012b)	2012	●	●			●		●			●
(ZHANG; BARAKAT; YASSINE, 2012)	2012	●	●		●	●		●			●
(MOSTOFI; SHAYEGHI, 2012)	2012	●	●	●		●	hidro, eletrolizador	●			●
(BASHIR; SADEH, 2012b)	2012	●	●			●	maremotriz	●			●
(GUPTA; SAINI; SHARMA, 2008a, 2008c)	2012	●	●		●	●		●			●
(NASIRAGHDAM; JADID, 2012)	2012	●	●	●					●		●
(LI; WEI; XIANG, 2012)	2012	●	●			●		●			●
(KATSIGIANNIS et al., 2012)	2012	●	●		●	●		●			●
(KARLIS; PAPADOPOULOS, 2013)	2013	●	●			●			●	●	
(LUJANO-ROJAS; DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2013)	2013	●	●		●	●			●	●	
(ZHANG et al., 2013)	2013	●			●	●		●			●
(ENGİN, 2013)	2013	●	●			●		●			●
(MEREI; BERGER; SAUER, 2013)	2013	●	●		●	●		●			●
(CHEN, 2013)	2013	●	●		●	●		●			●
(ABUL'WAFA, 2013)	2013	●	●		●			●			●
(KAABECHE; IBTIOUEN, 2014)	2014	●	●		●	●		●			●
(PALIWAL; PATIDAR; NEMA, 2014)	2014	●	●		●	●		●			●
(MALEKI; ASKARZADEH, 2014)	2014	●	●	●		●		●			●
(ISMAIL; MOGHAVVEMI; MAHLIA, 2014)	2014	●			●	●	microturbina	●			●
(MAHERI, 2014)	2014	●	●		●			●			●
(BILIL; ANIBA; MAAROUFI, 2014)	2014	●	●					●			●
(SHARAFI; ELMEKKAWY, 2014)	2014	●	●	●	●	●	tanque H ₂ , eletrolizador	●			●
(YAZDANPANA, 2014)	2014	●	●			●		●			●
(AL-SHAMMA'A; KHALED, 2014)	2014	●	●		●	●					●
(ARUN; KUMARAVEL; SELVAN, 2014)	2014	●	●		●	●			●		●
(MALEKI; POURFAYAZ, 2015)	2015	●	●			●		●			●
(MAKHLOUFI, 2015)	2015	●				●		●			●
(KAMJOO et al., 2015)	2015	●	●			●		●			●
(CLARKE; AL-ABDELI; KOTHAPALLI, 2015)	2015	●		●		●	dessalinização	●			●
(KO et al., 2015)	2015	●					coletor solar, rede elétrica, rede de gás		●		●

PV gerador solar fotovoltaico, WT turbina eólica, FC célula de combustível, DG moto gerador, BT bateria

Fonte: produção do próprio autor

Com relação à otimização de SHGE pode-se concluir que a grande maioria dos estudos dimensionam o sistema considerando um ou dois critérios (1 e 2 objetivos) como pode ser observado na Figura 3. No entanto, com a crescente utilização de técnicas metaheurísticas que permitem avaliar problemas de otimização multiobjetivo de forma mais eficiente, cada vez mais são apresentados trabalhos nos quais se otimizam mais de dois critérios conflitantes de forma simultânea. Em relação aos critérios de otimização, observa-se que a abordagem mais utilizada é otimizar o dimensionamento do sistema sob o ponto de vista econômico, colocando outros critérios secundários, geralmente relacionado com a confiabilidade e aspectos ambientais, em forma de restrição. Já em relação à otimização multiobjetivo, os critérios mais empregados em conjunto são o econômico e o ambiental ou o econômico e a confiabilidade. Outros critérios, tais como aspectos social e geográfico, são pouco utilizados em estudos de dimensionamento de SHGE, contudo são mais empregados em estudos de planejamento energético.

Figura 3. Número de objetivos considerados e critérios de otimização mais empregados, de acordo com a pesquisa bibliográfica.



Fonte: produção do próprio autor

A Tabela 2 apresenta os indicadores relacionados com cada critério de otimização mais utilizados para direcionar a busca das soluções ótimas. Pode-se observar que os indicadores mais empregados para avaliar a confiabilidade se relacionam com a energia não fornecida. Os indicadores mais amplamente empregados para avaliar o aspecto econômico são o Valor Presente Líquido do sistema, o Custo do kWh gerado e o Custo de Capital inicial. Já, os indicadores empregados para avaliar o impacto ambiental do sistema estão geralmente relacionados com as emissões de CO₂, o poluente mais importante relacionado à quantidade de emissões em motores de combustão interna.

Tabela 2. Indicadores mais comumente adotados como critério de otimização, de acordo com a pesquisa bibliográfica.

Confiabilidade	# trabalhos	Porcentagem
Energia não Fornecida	4	33,3%
Índice de Confiabilidade Energético	2	16,7%
Probabilidade de Perda no Fornecimento de Energia	2	16,7%
Nível de Confiança, inclui:		
• Energia não Fornecida	1	8,3%
• Tempo de Duração de Falha		
• Tempo máximo entre falhas sucessivas		
Probabilidade de estado de risco (<i>Risk State Probability</i>)	1	8,3%
Probabilidade de estado saudável (<i>Healthy State Probability</i>)		
Índice de disparidade energia renovável-carga	1	8,3%
Método de avaliação por correspondência, inclui:		
• Coeficiente de desigualdade	1	8,3%
• Coeficiente de correlação		
Econômicos		
Valor Presente Líquido	17	22,7%
Custo da Energia	15	20,0%
Custo de Capital Inicial do Sistema	14	18,7%
Custo Nivelado da Energia	6	8,0%
Custo Anualizado do Sistema	5	6,7%
Custo de Capital Inicial e O&M	7	9,3%
Custo do Ciclo de Vida do Sistema	5	6,7%
Custos de Operação	4	5,3%
Tempo de <i>payback</i> da energia	1	1,3%
Taxa interna de Retorno do Investimento	1	1,3%
Ambientais		
Emissões acumuladas de CO ₂	9	60,0%
Emissões de CO ₂ no Ciclo de Vida do Sistema	2	13,3%
Emissões acumuladas de CO ₂ , SO ₂ e NO _x	2	13,3%
Emissões de CO ₂ equivalente para a rede elétrica e gás natural	1	6,7%
Custo Social das emissões de CO ₂	1	6,7%
Qualidade de Energia		
Índice de estabilidade de energia	1	100%
Geográficos		
Restrição de uso de áreas protegidas	1	100%
Sociais		
Potencial de geração de emprego	1	100%

Fonte: produção do próprio autor

PARTE II – MATERIAIS E MÉTODOS

3 OTIMIZAÇÃO BASEADA EM SIMULAÇÃO

A simulação pode ser utilizada como uma ferramenta eficaz de análise para avaliar sistemas nos quais a complexidade ou a existência de incertezas fazem a modelagem matemática convencional impraticável. Por outro lado, as técnicas de otimização precisam de uma representação matemática explícita do sistema, a fim de serem aplicadas. Deste modo, a implementação conjunta dos modelos de simulação e técnicas de otimização em uma abordagem de otimização baseada em simulação permite superar essas limitações (SHARAFI; ELMEKKAWY, 2014).

A técnica de otimização baseada em simulação tem provado ser uma ferramenta poderosa para resolver problemas de otimização que surgem de sistemas reais complexos em diferentes áreas de atuação, como logística, finanças, engenharia, design, medicina, entre outras (GENG, 1996). O principal objetivo da otimização baseada em simulação é determinar o valor ótimo de um conjunto de parâmetros que resultam no melhor desempenho de um determinado sistema (WANG; SHI, 2013; YANG; KOZIEL; LEIFSSON, 2014).

Um problema de otimização² baseado em simulação define-se como (WANG; SHI, 2013):

$$\min / \max_{\vec{x} \in F} f(\vec{x}) \quad (3.1)$$

sendo $f(\cdot)$ a função objetivo, $\vec{x}$ um vetor n-dimensional de todas as variáveis de decisão, e F o espaço de soluções factíveis.

No contexto de problemas de otimização baseados em simulação, a função objetivo, $f(\vec{x})$, é derivada de simulação experimental. Devido à complexidade da simulação, desconhece-se a forma da função objetivo, sendo, portanto, impossível obter uma expressão analítica da mesma (GOSAVI, 2015). Por conseguinte, a função objetivo deve ser obtida a partir da informação derivada das simulações (*outputs*):

$$f(\vec{x}, \xi) = \Psi \left[L(\vec{x}, \xi) \right] \quad (3.2)$$

$\vec{x} \in F, \xi \in \Xi$

onde $\xi \in \Xi$ representa a característica aleatória do sistema simulado, e $L(\vec{x}, \xi)$ é o valor de desempenho derivado dos *outputs* das simulações.

Os principais desafios na resolução de problemas baseados em simulação são:


² No presente trabalho, o significado de otimização refere-se à otimização paramétrica, na qual a solução é um conjunto estático de parâmetros para todos os estados do sistema (GOSAVI, 2015).

- i) Não existe uma expressão analítica da função objetivo $f(\bar{x})$, e ainda o espaço de soluções viáveis F pode não ser explicitamente definido.
- ii) Em algumas situações, a presença de aleatoriedade no sistema faz com que seja difícil estimar o valor da função objetivo em apenas uma única simulação.
- iii) Na maioria dos casos, devido à complexidade do modelo, a simulação do mesmo implica um custo computacional elevado.

Várias abordagens para a otimização baseada em simulação podem ser encontradas na literatura (APRIL et al., 2003; HRČKA; VAŽAN; ŠUTOVÁ, 2014; WANG; SHI, 2013; YANG; KOZIEL; LEIFSSON, 2013, 2014). Uma forma de classificá-las é como segue (APRIL et al., 2003):

- **Abordagens clássicas para otimização baseada em simulação:** dentro deste grupo encontram-se as abordagens baseadas em gradiente, metodologia da superfície de resposta, busca aleatória, entre outros.
- **Abordagens metaheurísticas para otimização baseada em simulação:** nesta abordagem o modelo de simulação é considerado como uma caixa preta que avalia os sinais de entrada para fornecer uma resposta. Isto é, uma série de parâmetros de entrada são fornecidos à caixa preta (*inputs*), o modelo de simulação fornece um *feedback* ou uma série de respostas (*outputs*), as quais são utilizadas para guiar o processo de busca da metaheurística. Uma descrição gráfica desta abordagem mostra-se na Figura 4.

Figura 4. Representação gráfica da abordagem metaheurística para otimização baseada em simulação.



Fonte: (FU, 2002).

O presente trabalho foca-se na abordagem metaheurística aplicada à otimização baseada em simulação. Particularmente, emprega-se a metaheurística Algoritmos Genéticos (AG) para projetar de forma otimizada um sistema híbrido de geração de energia baseado em fontes renováveis. São propostos dois métodos: primeiro propõe-se um método de otimização determinístico no qual o SHGE é dimensionado considerando os parâmetros de entrada constantes; o segundo método consiste numa otimização probabilística no qual se incorporam as incertezas inerentes às variáveis de entrada.

3.1 ABORDAGEM DE OTIMIZAÇÃO DETERMINISTICA APLICADA AO PROBLEMA DE DIMENSIONAMENTO DE UM SHGE

A abordagem de otimização determinística é, de longe, o método mais amplamente utilizado. Consiste em resolver o problema de otimização dado pela equação $\min / \max_{\bar{x} \in F, \xi \in \Xi} \Psi[L(\bar{x}, \xi)]$ desconsiderando a presença de incertezas nas variáveis, i.e. $\xi = 0$.

Portanto, o problema se reduz a $\min / \max_{\bar{x} \in F} f(\bar{x})$. O algoritmo de otimização determinístico aplicado ao problema de dimensionamento de um SHGE proposto no presente trabalho se apresenta na Figura 5. O algoritmo consta de dois módulos básicos, o módulo de otimização e o módulo de simulação. O módulo de otimização tem como função básica a busca da configuração ótima do SHGE dentro do universo de possíveis soluções, o mecanismo de busca se baseia na metaheurística de AG. Já o módulo de simulação tem a função de fornecer as informações relacionadas com o desempenho do SHGE, as quais são necessárias para guiar o processo de busca. No decorrer da simulação os dois módulos interagem continuamente trocando informações.

O funcionamento do algoritmo de otimização determinístico descreve-se a seguir:

① Início

Para iniciar a simulação precisam-se fornecer as informações relacionadas com as características técnicas e econômicas dos possíveis componentes que constituíram o SHGE, assim como as características dos recursos renováveis disponíveis no local e da carga a ser atendida. Também é preciso fornecer os parâmetros do algoritmo AG, i.e. tamanho da população, taxa de cruzamento, taxa de mutação, critério de parada, entre outros.

② Pré-dimensionamento

A definição do intervalo de variação das variáveis de decisão é um passo importante antes de começar as simulações. Uma boa escolha dos limites máximo e mínimo para as variáveis de projeto permite reduzir o espaço de busca e, portanto, diminuir o tempo de simulação do algoritmo de otimização. Para tal fim, utiliza-se um método de pré-dimensionamento (PINHO et al., 2008) que permite calcular de forma rápida os valores máximos das variáveis N_{wt} , N_{pv} , N_{dg} , N_{bt_p} e N_{conv} . Conhecendo a disponibilidade de recursos renováveis e as características da carga, este método permite estimar a quantidade máxima de um determinado modelo de componente gerador (N_{wt} , N_{pv} , N_{dg}) necessária para suprir a totalidade da carga apenas com este componente; caso exista a opção de mais de um modelo de componente, adota-se o limite máximo considerando o equipamento de menor capacidade. De forma similar define-se o limite máximo da variável N_{bt_p} como sendo a quantidade máxima de baterias necessárias para suprir a totalidade da carga durante um determinado período de autonomia. Finalmente, o número máximo de N_{conv} define-se como a quantidade máxima de um determinado modelo de conversor para alocar a carga pico. Esta metodologia, apesar de simples, auxilia ao usuário na escolha dos limites do intervalo de variação das variáveis de projeto. No Apêndice A se apresenta a metodologia de pré-dimensionamento utilizada de forma mais detalhada.

③ Geração da população inicial

As variáveis de decisão são o número de componentes ($N_{wt}, N_{pv}, N_{dg}, N_{bt_p}, N_{conv}$), o tipo (modelo) de componente ($T_{wt}, T_{pv}, T_{dg}, T_{bt}, T_{conv}$), e a estratégia de operação do SHGE (Ec). Assim o vetor de decisão compõe-se por uma combinação específica dessas variáveis. O primeiro passo do algoritmo consiste em gerar *popSize* indivíduos de forma aleatória os quais constituem a população inicial $\vec{x}_j$. Cada indivíduo (solução) representa uma possível configuração do SHGE. A população de indivíduos gerada pelo módulo de otimização constitui a informação de *input* para o módulo de simulação.

④ Simulação do sistema

No módulo de simulação executa-se um ano completo de operação do SHGE com a configuração de componentes e estratégia de controle definida para cada indivíduo da população $\vec{x}_j$. Em cada intervalo de simulação efetua-se um balanço de energia entre as

fontes geradoras e os sumidouros de energia. Considera-se que os parâmetros não variam dentro do intervalo de simulação, que no presente estudo é $\Delta t = 1$ hora.

⑤ Cálculo dos indicadores de desempenho

São avaliadas as funções objetivo e as restrições de operação impostas pelo usuário. O resultado é uma série de indicadores de desempenho que caracterizam a operação do SHGE. Essas informações constituem o *output* do módulo de simulação, o qual é enviado de volta para o módulo de otimização.

⑥ Avaliação da população e seleção

A viabilidade de cada solução é verificada de acordo com as restrições impostas para o sistema, cada indivíduo é atribuído com um valor de aptidão em função do valor das funções objetivo e da quantidade de restrições violadas. Os melhores indivíduos (os mais aptos) são selecionados para passar à próxima geração.

⑦ Avaliação do critério de parada

Verifica-se o critério de parada do algoritmo; caso não for satisfeito, a população é submetida ao processo de evolução.

⑧ Geração de uma nova população


Através da aplicação dos operadores recombinação e mutação gera-se uma nova população de indivíduos, preferivelmente melhores do que os indivíduos da geração anterior. Uma vez que a população é atualizada com os novos indivíduos, esta é enviada de volta para o módulo de simulação para avaliar as funções objetivo e as restrições e mais uma vez os resultados retornam ao módulo de otimização.

⑨ Fim

Os passos ④ a ⑧ são repetido até satisfazer o critério de parada. No final da simulação, o algoritmo fornece a melhor solução, correspondente à configuração ótima de SHGE, ou para o caso multiobjetivo, o conjunto de soluções ótimas de Pareto.

O abordagem de otimização mostrada na Figura 5 denomina-se determinística já que o módulo de simulação que ele incorpora é de caráter determinístico, isto é, para as mesmas condições de entrada, ele produzirá a mesma saída. Assim, quando dois indivíduos que representam a mesma configuração de SHGE são avaliados no módulo de simulação, os resultados são os mesmos, i.e. ambas as configurações possuem o mesmo valor da função objetivo e dos indicadores de desempenho. O determinismo deriva do fato que os parâmetros de entrada do módulo de simulação permanecem invariáveis durante o processo de otimização. Esta característica constitui a principal diferença em relação ao segundo método proposto, denominado de método otimização probabilístico, o qual se explica a seguir.

Figura 5. Fluxograma da abordagem de otimização determinística para o problema de dimensionamento de um SHGE.



Fonte: produção do próprio autor

3.2 ABORDAGEM DE OTIMIZAÇÃO PROBABILÍSTICA APLICADA AO PROBLEMA DE DIMENSIONAMENTO DE UM SHGE

A presença de incertezas relacionadas com a natureza estocástica dos recursos renováveis, a demanda de energia e a falha dos componentes do sistema representa uma complicação adicional no processo de simulação e otimização de SHGE.

O problema de otimização probabilística consiste em resolver $\min_{\vec{x} \in F, \xi \in \Xi} / \max \Psi[L(\vec{x}, \xi)]$ sendo que neste caso a presença de incertezas faz que a função objetivo tenha uma natureza estocástica induzida por ξ . O operador Ψ aplicado a $L(\vec{x}, \xi)$ permite obter um valor determinístico da função para poder ser avaliada pelo algoritmo de otimização. Existem diferentes abordagens para definir esse operador, no presente trabalho adota-se o método denominado minimax (PETRONE et al., 2013), no qual o problema de otimização formula-se como:

$$\min_F \left[\sup_{\Xi} f_1(\vec{x}, \xi), \sup_{\Xi} f_2(\vec{x}, \xi), \dots, \sup_{\Xi} f_m(\vec{x}, \xi) \right]^T \quad (3.3)$$

Através desta transformação procura-se projetar o sistema considerando o pior cenário de operação. Apesar de conservador, este método se considera adequado para o dimensionamento de SHGE autônomos.

Várias fontes de incerteza estão presentes num sistema real, no caso de sistemas de geração baseados em fontes renováveis, estas podem ser classificadas em função da sua origem como: *a)* incertezas inerentes ao modelo; *b)* incertezas inerentes ao sistema; *c)* incertezas externas e *d)* incertezas discretas (GIANNAKOUDIS et al., 2010; IERAPETRITOU; ACEVEDO; PISTIKOPOULOS, 1996).

No presente trabalho são consideradas incertezas externas relacionadas com a disponibilidade dos recursos renováveis e da demanda de energia a ser atendida pelo SHGE, e incertezas discretas relacionadas com a indisponibilidade operacional dos componentes do SHGE sujeitos a falha.

A variabilidade dos valores médios de radiação solar, velocidade do vento e curva de carga é fundamental devido a sua influência sobre o desempenho do SHGE. Variações nestes parâmetros afetam diretamente os indicadores de desempenho relacionados com a energia não suprida, o custo total do sistema, o consumo de combustível, entre outros. O desempenho de um sistema de geração projetado a partir de informação meteorológica e de carga específica, será ótimo apenas para a faixa de variação dos dados de entrada considerados. No entanto,

espera-se que o sistema não consiga atender de forma eficiente eventuais picos de energia ou interrupções no fornecimento devido a flutuações nas condições climáticas ou eventos de consumo imprevisíveis, a menos que estas incertezas sejam consideradas durante o projeto do sistema. É aqui a necessidade de incorporar as incertezas na disponibilidade dos recursos renováveis e na demanda no processo de dimensionamento do SHGE.

De forma similar a taxa de indisponibilidade operacional dos componentes do SHGE influencia no seu desempenho final. No caso de SHGE autônomos, a confiabilidade dos componentes que o compõem torna-se fundamental devido a que não há *backup* da rede para suprir situações de indisponibilidade das fontes geradoras. Assim, para se realizar uma avaliação realista do desempenho do SHGE deve-se incluir necessariamente uma análise de indisponibilidade dos componentes do sistema.

3.2.1 Representação das incertezas

A representação de incertezas de forma estocástica é comumente feita por meio de funções distribuição de probabilidade, as quais definem o intervalo de variação dos parâmetros, assim como a probabilidade de ocorrência de cada valor dentro do intervalo considerado (GOSAVI, 2015). Uma vez definidas as funções de probabilidade apropriadas para cada variável, deve-se adotar um método de amostragem para gerar uma série de valores aleatórios de cada variável para simular o sistema de forma iterativa. Em função do tipo de incerteza, é definido um método de representação.

a) Incertezas externas

A série temporal $\varphi_i(t)$ representa os fenômenos que variam com o tempo, velocidade do vento ($i = w$), radiação solar ($i = s$), temperatura ambiente ($i = T$) e demanda energética ($i = l$), derivados de observações históricas ou de dados experimentais. As variações relacionadas com o comportamento típico do fenômeno real presentes em $\varphi_i(t)$ podem ser aproximadas através da incorporação de um modelo de incerteza estocástica. O desvio do parâmetro representado com relação ao valor observado ou medido, $\varphi_i(t)$, pode ser gerado pela incorporação de uma função densidade de probabilidade no processo de predição de novas séries a partir da série original. Uma função densidade de probabilidade com média μ e desvio padrão σ é uma função contínua que pode ser representada por um conjunto discreto de amostras geradas de forma aleatória $\varepsilon_j(\mu, \sigma)$. Esses valores amostrais associados aos

valores da série $\varphi_i(t)$ representam o parâmetro com incerteza $\theta_i(t)$, como mostra a equação (3.4):

$$\theta_i(t) = \varphi_i(t) \pm |\varepsilon_j(\mu, \sigma)| \quad (3.4)$$


Observa-se que o mesmo valor $\varepsilon_j(\mu, \sigma)$ gerado de forma aleatória é associado ao parâmetro $\varphi_i(t)$ para toda a série temporal, resultando que as novas séries, $\theta_i(t)$, obtidas a partir da série original encontram-se deslocadas na mesma direção. Pode-se melhorar o algoritmo considerando diferentes funções distribuição de probabilidade para cada intervalo de simulação, porém seria preciso de séries temporais históricas com maior resolução para definir as distribuições de probabilidade em intervalos de tempo menores (por exemplo, horários), as quais nem sempre se encontram disponíveis. No entanto, a variação interanual dos valores médios das variáveis velocidade do vento, radiação solar, temperatura e demanda de energia da carga podem ser geralmente representadas por uma função distribuição de probabilidade normal ou Gaussiana (DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2015; MALKAWI; AUGENBROE, 2004). Desta forma, de posse dos valores médios e do desvio padrão dos valores médios anuais destas variáveis, pode-se realizar uma análise probabilística fazendo uso de um método de amostragem adequado para gerar diferentes cenários de disponibilidade dos recursos renováveis e da carga. O método de amostragem adotado no presente trabalho é o método de Hipercubo Latino (LHS – *Latin Hypercube Sampling*)³ (apud (HELTON; DAVIS, 2000) p. 16). Foi escolhido este procedimento de amostragem aleatório estratificado pelo fato de garantir uma boa diversidade de amostras em uma menor quantidade de iterações quando comparado com o método de Monte Carlo (HELTON; DAVIS, 2000).

Na Figura 6 se expõe a representação gráfica do processo de geração de cenários de disponibilidade dos recursos renováveis e da carga incorporando as incertezas. A informação de entrada é a série horária das variáveis a serem amostradas (velocidade do vento, radiação solar, temperatura ambiente e carga), as médias e desvio padrão anuais dessas variáveis (σ_i, μ_i) e o número de amostras requerido (N_{smp}) . Quando o SHGE é simulado probabilisticamente nestas condições, o resultado é uma série de curvas de probabilidade relacionadas aos indicadores de desempenho do sistema. Ressalta-se que dado que a variável temperatura ambiente está intimamente relacionada com a variável radiação solar, considera-se a correlação entre ambas na hora de gerar as amostras.

³ McKay, M.D., R.J. Beckman, and W.J. Conover. 1979. **A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code**, Technometrics. Vol. 21, no. 2, 239-245.

Figura 6. Método de geração de amostras para a simulação probabilística do SHGE.

Distribuições de probabilidade




Geração de amostras

$$\begin{aligned}\theta_j^s(t) &= \varphi_s(t) \pm |\varepsilon_j(\mu_s, \sigma_s)| \\ \theta_j^w(t) &= \varphi_w(t) \pm |\varepsilon_j(\mu_w, \sigma_w)| \\ \theta_j^T(t) &= \varphi_T(t) \pm |\varepsilon_j(\mu_T, \sigma_T)| \\ \theta_j^l(t) &= \varphi_l(t) \pm |\varepsilon_j(\mu_l, \sigma_l)|\end{aligned}$$

$$t = 1, \dots, 8760$$

$$j = 1, \dots, N_{\text{sam}}$$

Cenários de incerteza



b) Incertezas discretas

As incertezas discretas estão relacionadas com a indisponibilidade dos componentes do SHGE sujeitos a falha. Portanto, é preciso gerar históricos de indisponibilidade dos componentes para simular o sistema em diferentes condições operacionais. A técnica de simulação de Monte Carlo cronológica é especialmente útil para este propósito. Este processo consiste em gerar amostras a partir das distribuições de probabilidade associadas aos tempos de operação e de reparação/substituição (estado de falha) dos componentes (BILLINTON; LI, 1994). Gera-se em primeira instância o histórico de operação dos componentes individuais para em seguida gerar o histórico de operação do subsistema agregando os históricos individuais. Por exemplo, o histórico de operação do subsistema eólico compõe-se do histórico de operação dos aerogeradores individuais, o histórico de operação do subsistema moto gerador é o somatório dos históricos dos geradores diesel individuais, e assim por diante. O método de geração de históricos de operação pode-se resumir nos seguintes passos:

- 1) Especifica-se a estado inicial do componente. Cada componente pode ser encontrado em estado de operação (*UpTime*) ou em processo de substituição/reparação (*DownTime*). No presente trabalho assume-se que todos os componentes estão disponíveis (*UpTime*) no instante inicial.
- 2) Sorteia-se o tempo de duração do estado atual do componente. Para isto se considera que o tempo de operação segue uma distribuição exponencial, hipótese válida para tempos de operação de equipamentos na região de vida útil (BILLINTON; ALLAN, 1992). Assume-se que o tempo de falha também segue uma distribuição exponencial. Os tempos de funcionamento e reparo para o componente i -ésimo são sorteados como segue:

$$\begin{aligned} UpTime_i &= -MTBF_i \times \ln(U_i) \\ DownTime_i &= -MTTR_i \times \ln(U_i) \end{aligned} \quad (3.5)$$


na qual $MTBF_i = 1/\lambda_{fi}$ é o tempo médio entre falhas, $MTTR_i = 1/\lambda_{ri}$ é o tempo médio para reparo, λ_{fi} é a taxa média de falha, λ_{ri} é a taxa média de reparo e U_i é um número pseudoaleatório com distribuição uniforme entre [0,1].

- 3) Repete-se o passo 2) para cada intervalo de tempo do período considerado, neste caso 8760 horas por ano, registrando a duração dos estados do componente. O resultado é um histórico de estados de operação do componente durante o período apurado, $\Phi_i(t)$.

- 4) O histórico de operação cronológico do subsistema obtém-se pela combinação dos históricos de operação dos i componentes do subsistema $\Phi = \sum_t^T \Phi_i(t)$.

A Figura 7 ilustra o processo de geração de histórico de operação de um sistema formado por dois componentes iguais. No presente trabalho considera-se que os componentes sujeitos à falha no SHGE são o aerogerador, o painel fotovoltaico, o moto gerador e o conversor de energia.


Figura 7. Exemplo de histórico de operação do sistema gerado pela simulação de Monte Carlo cronológica.



Fonte: produção do próprio autor

Considerando os conceitos de quantificação das incertezas apresentados anteriormente, propõe-se o método de otimização probabilístico que se ilustra na Figura 8. Esta nova abordagem surge da modificação da abordagem determinística mostrada na Figura 5 para incorporar as incertezas no processo de otimização do SHGE. Assim, a principal diferença do algoritmo probabilístico com relação ao algoritmo determinístico é a inclusão do módulo incertezas mostrado na Figura 8.

Figura 8. Fluxograma da abordagem de otimização probabilística para o problema de dimensionamento de um SHGE.



A seguir se descrevem brevemente as etapas do algoritmo probabilístico, destacando apenas as diferenças com o algoritmo determinístico:

① Início

Idem passo ① do algoritmo determinístico.

② Pré-dimensionamento

Idem passo ② do algoritmo determinístico (ver Apêndice A).

③ Geração da população inicial

Idem passo ③ do algoritmo determinístico.

④ Representação das incertezas

Para cada indivíduo da população inicial $\bar{x}_j$ geram-se N_{smp} amostras dos cenários de disponibilidade dos recursos renováveis e da demanda de energia da carga $\theta_{j,k}^w(t), \theta_{j,k}^s(t), \theta_{j,k}^T(t), \theta_{j,k}^l(t)$, utilizando o método apresentado na seção 3.2.1 a). Da mesma forma, geram-se N_{smp} históricos de operação dos componentes do SHGE sujeitos a falha, o aerogerador $\Phi_{j,k}^{wt}(t)$, os painéis fotovoltaicos $\Phi_{j,k}^{pv}(t)$, o moto gerador $\Phi_{j,k}^{dg}(t)$ e o conversor $\Phi_{j,k}^{conv}(t)$, com o método apresentado em 3.2.1.b).

⑤ Simulação dos sistemas

Cada indivíduo da população é simulado N_{smp} vezes a partir dos cenários de incerteza gerados no passo ④. No total são realizadas $popSize \times N_{smp}$ simulações do SHGE em cada geração do algoritmo AG. Assim, para cada indivíduo da população obtém-se uma matriz de resultados do balanço energético, $\Theta_j(t)$, de dimensão $8760 \times N_{smp}$.

⑥ Cálculo dos indicadores de desempenho probabilísticos

Os indicadores de desempenho avaliados sobre $\Theta_j(t)$ resultam num conjunto de indicadores estocásticos, isto é, uma distribuição de probabilidade para cada indicador de desempenho computado. Neste ponto se aplica o método minimax apresentado na equação (3.3) para se obter um valor determinístico das funções objetivo que são utilizadas pelo AG na comparação das diferentes configurações.

⑦ Avaliação da população e seleção

Idem passo ⑥ do algoritmo determinístico.

⑧ Avaliação do critério de parada

Idem passo ⑦ do algoritmo determinístico.

⑨ Geração de uma nova população

Idem passo ⑧ do algoritmo determinístico.

⑩ Fim

No final da simulação o algoritmo fornece um conjunto de soluções ótimas que podem ser consideradas “robustas” já que foram obtidas incorporando condições de incerteza.

Nos seguintes capítulos 4 e 5 apresentam-se as características dos módulos de simulação e otimização que formam parte do algoritmo de otimização proposto para o dimensionamento de SHGE.

No capítulo 6, apresentam-se os resultados da implementação do algoritmo proposto para o dimensionamento de um SHGE. Na seção 6.1, são apresentados os casos de estudo utilizados para aplicar a metodologia proposta, o sistema híbrido solar-diesel da Vila Campinas e o sistema híbrido solar-eólico-diesel da Vila São Tomé. Na sequência, na seção 6.2, se apresentam os resultados da otimização mono-objetivo para ambos os casos de estudo. Primeiramente se faz uma validação do algoritmo mono-objetivo proposto com a ferramenta de otimização comercial HOMER®, com base numa configuração de problema de otimização mono-objetivo de menor complexidade. Na sequência, estuda-se um problema de maior complexidade, no qual se aumenta o espaço de busca. Na seção 6.3, apresentam-se os resultados da aplicação da metodologia de otimização multiobjetivo determinística e probabilística, utilizando como caso de estudo a Vila Campinas. Inicialmente, na seção 6.3.1, resolve-se o problema de otimização multiobjetivo determinístico para três configurações de problema de otimização, minimização do custo e maximização da confiabilidade; minimização do custo e minimização das emissões de poluentes; e minimização do custo, maximização da confiabilidade e minimização das emissões de poluentes. Seguidamente, na seção 6.3.2.1 explora-se a influência das incertezas nas soluções obtidas com o algoritmo determinístico, através da simulação probabilística das mesmas. Finalmente, na seção 6.3.2.2, implementa-se a abordagem de otimização probabilística para as três configurações de problema de otimização estudadas anteriormente, neste caso as incertezas são consideradas no processo de otimização.

4 MÓDULO DE SIMULAÇÃO


A escolha de um modelo quantitativo válido e com a precisão desejada para calcular as respostas de interesse constitui um componente fundamental no processo de otimização baseado em simulação (PARKINSON; BALLING; HEDENGREN, 2013). No algoritmo proposto no presente trabalho isto é feito pelo Módulo de Simulação, o qual tem a função básica de simular a operação do SHGE em diferentes condições operacionais, fornecendo as informações necessárias para guiar o algoritmo de otimização na busca da solução ótima (ver Figura 5 no capítulo 0).

O sistema híbrido estudado no presente trabalho se apresenta na Figura 9. Trata-se de uma configuração que incorpora como fontes geradoras de origem renovável aerogeradores e painéis fotovoltaicos, possui um sistema de armazenamento de energia (banco de baterias) e ainda um sistema gerador de *backup* constituído por um grupo moto gerador diesel. Essa configuração denomina-se tipo paralelo, na qual uma ou mais fontes podem suprir a carga AC através do sincronismo entre inversor e grupo gerador conectado ao barramento AC. Supõe-se que o sistema conta um inversor de tensão bidirecional, chamado aqui de conversor, o qual permite a transferência de potência em ambos os sentidos. Quando o conversor opera como inversor transforma tensão DC-AC e quando o conversor opera como retificador transforma tensão AC-DC.

Cada componente do SHGE deve ser modelado matematicamente e analisado de forma a atender as necessidades de fornecimento da carga dentro das especificações requeridas, sendo que o desempenho individual de cada componente afeta o desempenho global do sistema (PAUDEL, 2011). Assim, foi desenvolvida uma ferramenta de simulação de sistemas híbridos para ser incorporada no algoritmo de otimização. Esta ferramenta, a qual foi implantada no ambiente computacional Matlab®, incorpora uma série de modelos matemáticos utilizados para simular a operação dos diversos componentes que podem formar parte do SHGE.

Nas seguintes seções se expõem brevemente os modelos matemáticos incorporados na ferramenta de simulação.

Figura 9. Configuração de SHGE estudada no presente trabalho.



Fonte: produção do próprio autor


4.1 MODELO DE GERADOR SOLAR FOTOVOLTAICO

O dispositivo responsável pela conversão da luz incidente em eletricidade é chamado de célula fotovoltaica. Uma célula fotovoltaica é basicamente um diodo semicondutor cuja junção *pn* é exposto à luz (VILLALVA; GAZOLI; FILHO, 2009). Desde a década de 1960, uma ampla gama de materiais semicondutores tem sido empregada na fabricação de células solares, no entanto, as células solares de silício cristalino, monocristalino (m-Si) e policristalino (p-Si), atualmente dominam o mercado mundial, respondendo com quase 90% do mesmo em 2013 (FRAUNHOFER INSTITUTE FOR SOLAR ENERGY SYSTEMS ISE, 2014). No presente trabalho centrou-se na tecnologia de silício, portanto, ao longo do texto, ao se referir à painel fotovoltaico, considera-se constituído por células de silício. Para atingir níveis de tensão úteis para aplicações práticas, as células solares devem ser ligadas em série, geralmente de 30 a 36 células, constituindo assim um módulo fotovoltaico. Por sua vez, a associação série-paralelo de módulos fotovoltaicos constitui um arranjo fotovoltaico (KALOGIROU, 2009; PINHO et al., 2008). Um sistema gerador fotovoltaico é constituído pelo arranjo de painéis fotovoltaicos e os componentes auxiliares de condicionamento de potência, inversor e seguidor de ponto de máxima potência (MPPT). Na presente seção denomina-se gerador solar fotovoltaico apenas ao arranjo de painéis. O modelo de inversor é apresentado separadamente na seção 4.5, o MPPT não é modelado explicitamente, contudo incorpora-se sua eficiência no fator de perda do modelo do gerador fotovoltaico.

No sentido mais simples, o modelo de gerador solar fotovoltaico (PV) pode ser dividido em dois submodelos básicos: a) modelo de radiação, o qual estima a radiação solar incidente no plano do arranjo fotovoltaico e; b) modelo de módulo PV, o qual calcula a energia elétrica gerada pelo sistema fotovoltaico a partir da radiação solar incidente.

Na Figura 10 se apresenta um diagrama esquemático do modelo de gerador solar fotovoltaico no qual se destacam quatro blocos, o primeiro e o último correspondem às informações de entradas relacionadas com as variáveis meteorológicas e ao resultado do modelo (a energia gerada pelo sistema PV), respectivamente. Já os blocos intermediários são o modelo de radiação e o modelo de módulo fotovoltaico. Nas seguintes seções se expõem os modelos matemáticos adotados para estes blocos.

Figura 10. Representação gráfica do modelo de gerador solar fotovoltaico implementado.




Fonte: produção do próprio autor

4.1.1 Modelo de radiação solar incidente numa superfície inclinada

Na maioria dos casos, a informação disponível para utilizar como dado de entrada para os modelos de gerador solar PV é a radiação solar global no plano horizontal (I_H), que é a quantidade total de radiação solar incidente sobre uma superfície horizontal situada no plano da Terra. No entanto, a potência de saída do gerador solar PV depende da quantidade de radiação solar que incide sobre a superfície do painel, o qual, em geral, se encontra inclinado certo ângulo (β) em relação à horizontal, visando maximizar a captação de energia. Assim, para simular a operação de um sistema solar PV, deve-se calcular a radiação solar global incidente sobre a superfície do arranjo para cada intervalo de tempo de simulação (LAMBERT; GILMAN; LILIENTHAL, 2006). Dado que o presente trabalho foca-se na simulação de um sistema em uma base de tempo horária, o procedimento de cálculo apresentado a seguir refere-se à estimativa da radiação solar horária incidente numa superfície inclinada.

O processo de cálculo da radiação solar global no plano inclinado (I_T) a partir da radiação solar global no plano horizontal (I_H) envolve uma série de etapas, as quais se apresentam na Figura 11 e se descrevem a seguir.

Figura 11. Processo de cálculo da radiação solar global incidente numa superfície inclinada.



Fonte: produção do próprio autor

Etapa ①

Calcula-se a radiação solar extraterrestre (I_0) a partir da data (dia do ano) e da latitude e longitude do local. O cálculo de I_0 é um procedimento amplamente estudado, em função da precisão requerida pode-se adotar algum dos modelos disponíveis na literatura. No presente trabalho, adota-se o método disponível em (DUFFIE; BECKMAN, 2013).

Etapa ②

Uma vez estimado o valor de I_0 computa-se o índice de claridade (k_T), que é a razão entre a radiação solar global no plano horizontal e a radiação solar extraterrestre $k_T = I_H / I_0$.

Etapa ③

O índice de claridade é utilizado para determinar a componente difusa da radiação solar horizontal (I_d). Vários modelos têm sido desenvolvidos para estabelecer uma correlação empírica entre as variáveis k_T e I_d (ERBS; KLEIN; DUFFIE, 1982; HOLLANDS, 1971; MUNEEER; SALUJA, 1985; REINDL; KLEIN; DUFFIE, 1990). No entanto, a relação mais amplamente utilizada para o cálculo em base horária é a correlação de Erbs et al. (1982), a qual se define conforme equação (4.1):

$$\frac{I_d}{I_H} = \begin{cases} 1,0 - 0,09k_T & \text{para } k_T \leq 0,22 \\ 0,9511 - 0,1604k_T + 4,388k_T^2 - 16,638k_T^3 + 12,336k_T^4 & \text{para } 0,22 < k_T \leq 0,80 \\ 0,165 & \text{para } k_T > 0,8 \end{cases} \quad (4.1)$$

Etapa ④

Calcula-se a componente direta da radiação solar global no plano horizontal (I_b) conforme equação (4.2). Esta relação é válida apenas na hipótese que sobre uma superfície horizontal a radiação solar refletida é desprezível (MANWELL et al., 2006).

$$I_b = I_H - I_d \quad (4.2)$$

Neste ponto, conta-se com todas as parcelas da radiação solar incidente numa superfície horizontal, com base nessas informações as seguintes etapas consistem em determinar a radiação solar incidente numa superfície inclinada a partir das suas componentes direta, refletida e difusa.

Etapa ⑤

O cálculo da radiação solar direta incidente numa superfície inclinada ($I_{T,b}$) considera cálculos puramente geométricos (DEMAIN; JOURNÉE; BERTRAND, 2013), conforme equação (4.3):

$$I_{T,b} = I_b r_b = I_b \frac{\cos \theta}{\cos \theta_z} \quad (4.3)$$

na qual r_b é um fator de correção devido à mudança no ângulo de incidência dos raios solares sobre a superfície inclinada. Define-se como a razão entre a radiação incidente numa superfície inclinada e a radiação incidente numa superfície horizontal na ausência da atmosfera da Terra (IQBAL, 1983).

Etapa ⑥

Calcula-se a componente de radiação solar refletida numa superfície inclinada. A abordagem mais amplamente utilizada consiste em supor que o processo de reflexão do solo é isotrópico, como proposto por Liu e Jordan em 1963 (BENGHANEM, 2011; DEMAIN; JOURNÉE; BERTRAND, 2013; MEHLERI et al., 2010). Nesse caso, a radiação refletida do solo sobre uma superfície inclinada ($I_{T,refl}$) é composta pelo albedo do solo (ρ_g) e um fator “de vista” para o solo (F_{c-g}), definido como a razão entre a radiação incidente na superfície inclinada sobre a radiação refletida pelo solo, conforme a equação (4.4) (IQBAL, 1983):

$$I_{T,refl} = I_H \rho_g \underbrace{\left(\frac{1 - \cos \beta}{2} \right)}_{F_{c-g}} \quad (4.4)$$

Etapa ⑦

Em geral, todos os modelos para estimar a radiação solar numa superfície inclinada estimam as parcelas de radiação direta e refletida do modo como apresentado nas etapas ⑤ e ⑥. Onde os modelos diferem é no tratamento da radiação difusa ($I_{T,d}$). Existem duas abordagens que permitem classificar os métodos em: modelos de céu isotrópico e modelos de céu anisotrópico (JAKHRANI et al., 2013). Os modelos do primeiro grupo assumem que a radiação difusa é uniformemente distribuída no hemisfério celeste, a partir dessa hipótese a radiação difusa é a mesma independentemente da orientação da superfície e depende exclusivamente da fração do hemisfério solar vista pela superfície (BENGHANEM, 2011). Em contrapartida, os modelos de céu anisotrópico consideram a anisotropia da radiação difusa na região do horizonte e na região circumsolar (JAKHRANI et al., 2013; YATES; HIBBERD, 2010).

A partir de uma pesquisa bibliográfica, na qual foram revisados 35 artigos, observou-se que os modelos mais empregados para o cálculo da radiação solar difusa numa superfície inclinada são os seguintes:

Modelos de céu isotrópico

- Modelo de Liu e Jordan (LIU; JORDAN, 1963).
- Modelo de Koronakis (KORONAKIS, 1986).

Modelos de céu anisotrópico

- Modelo HDKR (DUFFIE; BECKMAN, 2013)
- Modelo de Perez et al. (PEREZ et al., 1990).

Para maiores detalhes sobre a formulação matemática desses modelos, o leitor pode-se referir ao artigo *Simulation and Validation of Photovoltaic System Performance Models* apresentado pelo autor no congresso XI CLAGTEE em 2015 (ROBERTS et al., 2015).

Etapa ⑧

Finalmente, em posse de todas as parcelas de radiação solar incidente numa superfície inclinada, é possível calcular a radiação solar global incidente numa superfície inclinada pela soma das parcelas direta, difusa e refletida segundo a equação (4.5), concluindo assim o processo de cálculo. Este procedimento é repetido para cada intervalo de tempo durante a simulação do sistema.

$$I_T = I_{T,b} + I_{T,refl} + I_{T,d} \quad (4.5)$$

No total, são quatro os modelos para estimar a radiação solar numa superfície inclinada que estão disponíveis na ferramenta de simulação computacional desenvolvida no presente estudo; cada um incorpora um modelo diferente de radiação solar difusa (Etapa ⑦). Com o intuito de avaliar seu desempenho foi realizada uma validação dos modelos com dados experimentais derivados de medições de campo realizadas num sistema fotovoltaico em operação localizado na Universidade Otto-von-Güericke (OvGU), na Alemanha. Este estudo foi apresentado no congresso XI CLAGTEE em 2015, maiores informações podem-se obter no artigo (ROBERTS et al., 2015).

Os resultados deste estudo indicam que todos os modelos apresentam um erro médio absoluto menor de 9,2% em relação aos valores experimentais. No entanto, o modelo de céu anisotrópico HDKR proposto por Duffie e Beckman (2013) resulta o mais "preciso" em termos de estimação da radiação solar incidente anual, apresentando um erro médio absoluto de 8,029%. Em seguida se situam o modelo de Koronakis (1986), o modelo de Liu Jordan (1963) e o modelo Perez et al. (1990). Dado os melhores resultados obtidos pelo modelo

HDKR (DUFFIE; BECKMAN, 2013), este será o modelo padrão utilizado nas simulações do SHGE.

4.1.2 Modelos de módulo fotovoltaico

Uma vez conhecida a radiação solar incidente, é preciso estimar a potência gerada pelas células, módulos ou arranjos fotovoltaicos. Inúmeros modelos de variada complexidade têm sido desenvolvidos com este fim (KLISE; STEIN, 2009). Esses modelos podem ser classificados em modelos de potência e modelos baseados no circuito elétrico equivalente (DJAMILA; ERNEST, 2012). Na seguinte seção se apresentam os cinco modelos estudados, dois modelos de potência e três modelos baseados no circuito elétrico equivalente.


4.1.2.1 Modelos de Potência

Essa classe de modelos (GERGAUD; MULTON; BEN AHMED, 2002; JONES; UNDERWOOD, 2002; PATEL, 1999) é baseada na representação simplificada do ponto de eficiência máxima do módulo fotovoltaico. Estimam a potência fornecida pelo módulo fotovoltaico apenas no Ponto de Máxima Potência (em inglês *Maximum Power Point* – MPP), ver Figura 12. A aplicação destes modelos supõe a utilização de um sistema seguidor de ponto de máxima potência, que é um sistema eletrônico que altera o ponto de funcionamento eletrônico dos painéis, para que estes sejam capazes de fornecer a potência máxima em todo momento.

Os dois modelos de potência incorporados na ferramenta de simulação são:

- Modelo proposto no software HOMER® (LILIENTHAL; LAMBERT; GILMAN, 2004).
- Modelo proposto no software RETScreen®, baseado no modelo de Evans (1981).

Figura 12. Curva característica I-V e curva P-V para um módulo de 110 Wp na qual se destacam os pontos característicos.



Fonte: produção do próprio autor

4.1.2.2 Modelos Baseados no Circuito Elétrico Equivalente

Os modelos de potência são capazes de estimar a potência fornecida pelos módulos fotovoltaicos apenas no seu ponto de máxima de potência. Porém, quando é necessário determinar a corrente ou tensão em qualquer ponto de operação do módulo, é necessário recorrer a outros modelos (SIDDIQUI; ABIDO, 2013). Várias abordagens tem sido propostas para representar a totalidade da curva característica I-V de um módulo fotovoltaicos (ver Figura 12), desde método de interpolação (MARION; RUMMEL; ANDERBERG, 2004) até métodos empíricos (KING; BOYSON; KRATOCHVILL, 2004). No entanto, a abordagem mais utilizada é a de representar a célula solar por meio de um circuito elétrico equivalente composto por uma fonte de corrente, um ou dois diodos e combinações de resistências em série e em paralelo. A revisão da literatura realizada revelou que o modelo de circuito equivalente com um diodo é o mais amplamente utilizado para aplicações de engenharia, uma vez que oferece um bom compromisso entre simplicidade e precisão (MA; YANG; LU, 2014; VILLALVA; GAZOLI; FILHO, 2009). Assim sendo, os modelos estudados são deste tipo. A equação característica (4.6) define a resposta I-V para este tipo de modelo:

$$I = I_L - I_D - I_{sh} = I_L - I_o \left[\exp \left(\frac{V + IR_s}{n_d V_t} \right) - 1 \right] - \frac{V + IR_s}{R_{sh}} \quad (4.6)$$

Para caracterizar completamente a equação (4.6), cinco parâmetros devem ser determinados:

I_L : a corrente fotogerada [A].

I_o : a corrente de saturação reversa do diodo [A].

R_s : a resistência série [Ω].

R_{sh} : a resistência em paralelo [Ω].

a : fator de idealidade modificado, que é definido como: $a = n_d k_b T_c N_s / q$.

sendo,

n_d : fator de idealidade do diodo.

k_b : constante de Boltzmann, ($1,381 \times 10^{-23}$ J/K).

T_c : temperatura da célula [$^{\circ}\text{C}$].

N_s : número de células solar em série.

q : carga eletrônica, ($1,605 \times 10^{-19}$ C).

O método empregado para determinar os cinco parâmetros I_L , I_o , R_s , R_{sh} e a é o que diferencia os diferentes modelos disponíveis na literatura. Os três modelos estudados no presente trabalho baseiam-se numa abordagem analítico-iterativa para determinar os parâmetros da equação característica, porém diferem nas considerações assumidas; estes são:

- Modelo de De Soto, Klein e Beckman (DE SOTO; KLEIN; BECKMAN, 2006; DUFFIE; BECKMAN, 2013).
- Modelo de Villalva, Gazoli e Ruppert Filho (VILLALVA; GAZOLI; FILHO, 2009; VILLALVA; GAZOLI, 2009).
- Modelo de Walker (WALKER, 2001).

No total, os modelos de módulo fotovoltaico implementados na ferramenta de simulação são 5, os 2 modelos de potência e os 3 modelos de circuito equivalente. O autor do presente trabalho fez uma validação dos modelos aqui apresentados utilizando dados experimentais medidos num sistema fotovoltaico real. Os resultados desta pesquisa foram publicados em forma detalhada em Roberts et al. (2015). As conclusões mais importantes se expõem a seguir.

- Todos os modelos avaliados estimam a energia gerada pelo sistema fotovoltaico com um erro médio relativo menor de 6% e um erro médio absoluto de 10%. Este nível de incerteza resulta aceitável para modelos empregados em estudos de viabilidade (LEE; FREARSON; RODDEN, 2011).
- O modelo de De Soto et al. (2006) apresentou o melhor desempenho com um erro médio relativo de -0,7% e um erro médio absoluto de 8,1%.
- Os modelos de HOMER® (2004), De Soto et al. (2006) e Villalva et al. (2009) tendem a subestimar a produção energética, enquanto que Walker (2001) e Evans (1981) a sobre estimam.
- Os modelos de circuito equivalente apresentam uma precisão maior em relação aos modelos de potência. No entanto, estes últimos apresentam um custo computacional menor, requerendo apenas 10% do tempo gasto pelos modelos de circuito equivalente para completar a mesma simulação.

Dado que a abordagem de otimização baseada em simulação proposta no presente trabalho implica simular o SHGE de forma iterativa, é preciso que os modelos matemáticos dos componentes incorporados na ferramenta de simulação apresentem um bom compromisso entre precisão e custo computacional. Conforme este quesito, adota-se como modelo de módulo fotovoltaico padrão para as simulações do SHGE, o modelo de potência proposto por HOMER® (2004).

4.2 MODELO DE GERADOR EÓLICO

O aproveitamento da energia contida no vento data de milhares de anos, moinhos de vento para moagem de grãos e bombeamento de água e embarcações à vela são usados desde o século V antes de Cristo (a.c.). Mais recentemente, no fim do século XIX, surgiu a primeira aplicação de energia eólica para produção direta de eletricidade, através do advento da primeira turbina eólica, também conhecida como aerogerador (BURTON et al., 2011).

Segundo considerações de Lu et al. (2009), o recurso eólico a nível mundial se estima em $6,95 \times 10^{17}$ kWh/ano, o que equivale a quase 36 vezes o consumo mundial de eletricidade. Verifica-se que o potencial de aproveitamento desta forma de geração de energia é enorme, ainda mais sabendo que as estimações feitas por (LU; MCELROY; KIVILUOMA, 2009) consideram apenas o potencial eólico *on-shore* (em terra).

O componente responsável pela transformação da energia cinética dos ventos em energia elétrica é denominado de gerador eólico, turbina eólica ou simplesmente aerogerador.


Pás aerodinâmicas “captam” o vento, fazendo seu eixo girar, transformando a energia cinética do vento em energia mecânica. O eixo está acoplado a um gerador elétrico, que transforma a energia mecânica em energia elétrica.

A grande maioria das máquinas comercialmente disponíveis atualmente corresponde a turbinas de tipo eixo horizontal com três pás, pois se apresentam como a alternativa economicamente mais viável em relação à fabricação, montagem e controle de velocidade (BANSAL; BHATTI; KOTHARI, 2002).

A potência das turbinas varia desde pequenas máquinas de poucos watts até vários milhões de watts. Segundo a sua potência, as turbinas eólicas podem ser classificadas em (KALDELLIS, 2010): pequeno porte (< 10 kW), médio porte ($10 - 250$ kW) e grande porte (> 250 kW). O presente trabalho foca-se em aplicações que envolvem sistemas híbridos de geração energia para fornecimento de comunidades remotas. Neste tipo de sistemas encontram sua aplicação os aerogeradores de pequeno e médio porte e, portanto, somente este tipo de máquina será discutido.

O modelo adotado para estimar a geração de energia da turbina eólica compõe-se de três blocos de cálculo, como se mostra na Figura 13. O primeiro bloco tem a finalidade de extrapolar a velocidade do vento à altura do rotor da turbina; o segundo bloco permite estimar a potência entregue pela turbina eólica a partir da velocidade do vento extrapolada; finalmente o terceiro bloco insere uma correção em função da altitude do local de instalação do aerogerador. Nas seguintes seções se expõem brevemente os modelos matemáticos inseridos em cada um destes blocos.

Figura 13. Representação gráfica do modelo de gerador eólico implementado.



Fonte: produção do próprio autor

4.2.1 Extrapolção vertical da velocidade do vento

O perfil de velocidade do vento varia com a altura, ao nível do solo a presença de obstáculos como vegetação, edificações e fenômenos topográficos tendem a reduzir a velocidade do vento. Este fenômeno é denominado de cisalhamento do vento ou simplesmente gradiente do vento (MANWELL; MCGOWAN; ROGERS, 2009a).

O gradiente do vento influencia a estimativa do potencial eólico disponível num local assim como o cálculo da energia gerada pelas turbinas eólicas. Portanto, caso as medições meteorológicas do vento sejam realizadas a uma altura diferente daquela na qual será posicionado a centro do rotor da turbina, as velocidades deverão ser corrigidas para a altura do rotor da turbina.

Para terrenos relativamente homogêneos, o cálculo da velocidade do vento à altura do rotor (U_{rot}) é geralmente realizado utilizando um dos seguintes modelos matemáticos derivados da teoria de camada limite de mecânica dos fluidos.

a) Modelo exponencial:

Este modelo assume que a variação da velocidade do vento com altura é representada pela equação (4.7) (MANWELL; MCGOWAN; ROGERS, 2009a; NAWRI et al., 2014; PATEL, 1999).

$$\frac{U_{rot}}{U_{ref}} = \left(\frac{z_{rot}}{z_{ref}} \right)^{\alpha_w} \quad (4.7)$$

sendo,

U_{rot} : velocidade do vento à altura do rotor da turbina eólica [m/s].

U_{ref} : velocidade do vento à altura de referência (medição) [m/s].

z_{rot} : altura do rotor da turbina eólica [m].

z_{ref} : altura de medição da velocidade do vento [m].

α_w : coeficiente de extrapolação derivado de relações empíricas que dependente da rugosidade do terreno.

O coeficiente α é um parâmetro adimensional que depende de variáveis como elevação, hora do dia, época do ano, características do terreno, temperatura, velocidade do vento entre outros. Na ausência de outras informações um valor de $\alpha = 1/7$ é aceitável, porém na prática esse valor pode variar largamente. Valores típicos de α para diferentes tipos de terreno podem ser consultados em Manwell McGowan; Rogers (2009a) e Nawri et al. (2014).

b) Modelo logarítmico:

O modelo logarítmico supõe que o perfil do vento é proporcional ao logaritmo da altura acima do solo de acordo com a equação (4.8):

$$\frac{U_{rot}}{U_{ref}} = \frac{\ln(z_{rot}/z_0)}{\ln(z_{ref}/z_0)} \quad (4.8)$$

sendo,

z_0 : comprimento de rugosidade superficial do terreno [m].

Na prática, o modelo de extrapolação logarítmico tende a ser menos conservador na estimativa da velocidade do vento em relação ao modelo exponencial. Portanto, adota-se este último como método padrão para extrapolação da velocidade do vento na ferramenta de simulação de SHGE desenvolvida.

4.2.2 Curva de potência da turbina eólica

Para estimar a energia gerada por uma turbina eólica é preciso conhecer apenas alguns parâmetros, sendo o principal sua curva de potência. A curva de potência de um aerogerador indica a potência fornecida pela turbina em função da velocidade de vento disponível. A vantagem de trabalhar com a curva de potência do aerogerador é que ao se estimar a energia gerada, incorpora-se tanto a eficiência dos componentes elétricos (gerador) como dos componentes mecânicos (caixa multiplicadora e rotor) (MUKUND, 2006).

Normalmente os fabricantes fornecem a curva do aerogerador para intervalos discretos de velocidade do vento. Para utilizar esta informação em simulações é preciso de um modelo matemático que, a partir dos dados informados pelo fabricante, permita estimar a potência entregue pelo aerogerador em qualquer intervalo de velocidade do vento.

O modelo adotado no presente estudo foi proposto por Hocaoglu, Gerek e Kurban (2009) e é apresentado na equação (4.9). Este modelo consegue representar a curva potência do aerogerador com boa exatidão dado que emprega funções de interpolação para ajustar uma curva aos dados fornecidos pelo fabricante. É de simples implementação computacional e permite aumentar a sua precisão em função do número de interpolações utilizadas.

$$P_{wt}(u) = \begin{cases} 0 & u \leq U_{ci} \text{ ou } u \geq U_{co} \\ a_1 u^3 + b_1 u^2 + c_1 u + d_1 & U_{ci} < u < U_1 \\ a_2 u^3 + b_2 u^2 + c_2 u + d_2 & U_1 < u < U_2 \\ \dots & \\ a_n u^3 + b_n u^2 + c_n u + d_n & U_{n-1} < u < U_n \\ P_{wt,r} & U_r < u < U_{co} \end{cases} \quad (4.9)$$

sendo,

- P_{wt} : potência instantânea gerada pela turbina eólica [kW].
- u : velocidade instantânea do vento [m/s].
- a, b e c : coeficientes do polinômio de interpolação.
- n : número de interpolações utilizadas para aproximar a curva do aerogerador.
- $P_{wt,r}$: potência nominal da turbina eólica [kW].
- U_{ci} : velocidade do vento mínima [m/s].
- U_r : velocidade do vento nominal [m/s].
- U_{co} : velocidade de corte [m/s].

4.2.3 Variação da massa específica do ar em função da altitude

A altitude com relação ao nível médio do mar afeta diretamente a massa específica do ar (ρ). Por sua vez a produção energética da turbina eólica fica representada como $P_{wt} = \frac{1}{2} \rho U^3 C_p$, sendo C_p o coeficiente de potência que diz respeito a eficiência da turbina eólica na conversão de energia cinética em mecânica. A partir dessa equação fica evidente que há uma relação direta entre a massa específica do ar e a energia gerada pela turbina eólica. A curva de potência fornecida pelo fabricante é apenas válida na condição padrão na qual foi

medida (nível do mar e 15°C). Portanto, é preciso corrigir a estimativa do valor de potência gerada pela turbina eólica em função das condições do local de instalação.

A equação (4.10) representa a razão entre a massa específica do ar em condições padrão (ρ_0) e massa específica real do ar nas condições do local (ρ) (LAMBERT; GILMAN; LILIENTHAL, 2006):

$$\frac{\rho}{\rho_0} = \left[1 - \frac{\left(\frac{dT_a}{dz} \right)_{std} \cdot z_h}{T_0} \right]^{g \left[R \left(\frac{dT_a}{dz} \right)_{std} \right]^{-1}} \left(\frac{T_0}{T_0 - \left(\frac{dT_a}{dz} \right)_{std} \cdot z_h} \right) \quad (4.10)$$

sendo,

$\left(\frac{dT_a}{dz} \right)_{std}$: gradiente térmico, em condições padrão é igual a 0,0066 K/m.

z_h : altitude do local [m s.n.m.].

T_a : temperatura ambiente [K].

T_0 : temperatura nas condições padrão [288,16 K].

R : constante dos gases [287 J/kgK].

g : gravidade [9,81 m/s²].

Com a equação (4.10) pode-se estimar a massa específica real do ar nas condições do local a partir do conhecimento da altitude e a temperatura ambiente.

Finalmente, é possível corrigir a potência gerada pela turbina eólica em função da altitude do local de instalação com a equação (4.11):

$$P_{wt,corr} = P_{wt} \left(\frac{\rho}{\rho_0} \right) \quad (4.11)$$

4.3 MODELO DO SISTEMA DE ARMAZENAMENTO

A natureza intermitente e imprevisível das fontes de energia renováveis faz com que a sua integração nos sistemas elétricos de potência seja um verdadeiro desafio. Devido ao comportamento aleatório das fontes de energia renováveis, tais como a solar fotovoltaica e a eólica, elas não podem atuar como geração de base. Adicionalmente podem provocar problemas de instabilidade, harmônicos e flutuação de tensão (*flickers*) no sistema elétrico (KALDELLIS; ZAFIRAKIS; KONDILI, 2009). No entanto, os efeitos dessa característica

aleatória dos recursos renováveis podem ser mitigados através da utilização de sistemas de armazenamento de energia, quando corretamente dimensionados.

O principal desafio em sistemas com grande participação de energias renováveis é igualar de forma econômica a produção de energia com o consumo. Este fato que é trivial em sistemas com fontes de geração despacháveis, torna-se crítico no projeto de um sistema com integração de renováveis. Devido à intermitência na produção energética destas fontes é necessário um sistema que permita armazenar energia nos momentos de excesso de geração para ser utilizada nos momentos em que a demanda é maior que a energia disponível (KLISE; STEIN, 2009).

Os sistemas de armazenamento mais comumente utilizados em sistemas autônomos de geração de energia são as baterias eletroquímicas, armazenamento bombeado, sistemas de ar comprimido e volantes (*flywheels*). No entanto, as baterias eletroquímicas, em particular as de chumbo-ácido, têm-se consagrado como o elemento acumulador ideal em sistemas baseados em energias renováveis (KALDELLIS, 2010; PINHO, 2008). O grande número de modelos diferentes de baterias existentes no mercado, cada uma com suas próprias características especiais, cobre uma vasta gama de aplicações, tanto para qualidade de aplicações de energia como para a gestão energética. É por isso que no presente trabalho adota-se como sistema de armazenamento do SHGE, baterias eletroquímicas de chumbo-ácido. Nas seguintes seções se apresenta o modelo de bateria incorporado na ferramenta de simulação de SHGE.


4.3.1 Modelos de bateria disponíveis na literatura

Com o intuito de identificar o modelo de bateria mais adequado para ser utilizado na simulação do SHGE, realizou-se uma revisão bibliográfica na literatura específica (BINDNER et al., 2005; CHAPMAN, 1987; DIORIO et al., 2015; KLISE; STEIN, 2009; MANWELL; MCGOWAN, 1993; ROSS, 2001, 2007; URBINA et al., 1998). Observa-se que em função da aplicação e as informações disponíveis, os modelos de bateria incluem algum dos seguintes submodelos: *a)* modelo de desempenho ou capacidade; *b)* modelo de tensão; *c)* modelo térmico e *d)* modelo de vida útil. Estes quatro submodelos podem ser implementados de forma independente ou podem também ser integrados num único modelo, de modo a simular detalhadamente todas as características da bateria.

Dado que a abordagem de otimização baseada em simulação proposta no presente trabalho implica simular o funcionamento do SHGE iterativamente, procurou-se um modelo de bateria com um bom compromisso entre precisão e custo computacional. Além disso, as

informações de entrada requeridas para rodar o modelo devem ser mínima, de preferência informações disponíveis na folha de especificações do fabricante. Tomando em contas estas considerações, o modelo de bateria escolhido inclui um submodelo de capacidade e um submodelo de vida útil, como se pode observar na Figura 14. Assim configurado, o modelo de bateria fornece as informações de interesse para a simulação do SHGE, isto é, o estado de carga da bateria em cada intervalo de simulação, e uma estimativa do tempo de vida do componente.

Figura 14. Representação gráfica do modelo de bateria implementado.



Fonte: produção do próprio autor

A seguir se apresentam brevemente os fundamentos dos submodelos de capacidade e de vida útil que compõem o modelo de bateria incorporado na ferramenta de simulação.


4.3.2 Modelo de capacidade da bateria

Os modelos de capacidade tem a finalidade de representar uma das grandezas mais importantes a ser avaliada numa bateria, o estado de carga (SOC – em inglês *State of Charge*), em função da potência de carga/descarga, da eficiência de carga/descarga, do histórico de estados de carregamento, entre outros fatores.

O modelo de capacidade adotado denomina-se *Kinetic Battery Model* (KiBaM). Este modelo, adequado para baterias de chumbo-ácido, foi desenvolvido por Manwell e McGowan (1993). O nome do modelo deriva dos conceitos de cinética eletroquímica nos quais se baseia.

O modelo KiBaM representa a carga da bateria através de uma analogia com um sistema equivalente de dois reservatórios (ver Figura 15). O primeiro reservatório, denominado de carga disponível (*available charge*), representa a carga (energia) da bateria imediatamente disponível para a conversão em energia eléctrica DC. O segundo reservatório, denominado de carga limitada (*bound charge*), representa a energia quimicamente armazenada que só fornece elétrons para o reservatório de carga disponível (JONGERDEN; HAVERKORT, 2009).

Figura 15. Ilustração do modelo equivalente de dois reservatório utilizado pelo KiBaM para representar o estado de carga da bateria.



Fonte: (MANWELL; MCGOWAN, 1993)

O KiBaM funciona do seguinte modo. Quando uma carga é conectada aos terminais da bateria, ela fornece certa quantidade de corrente eléctrica, $i(t)$, reduzindo a carga disponível e aumentando a diferença de nível entre os dois reservatórios ($h_2 - h_1$). Quando a carga é desconectada, se estabelece um fluxo de carga (elétrons) do reservatório de carga limitada para o reservatório de carga disponível até que ambos os níveis h_1 e h_2 se igualem.

Durante os períodos em que a bateria não é utilizada, uma maior quantidade de energia se torna disponível para seu uso imediato, sendo que a bateria é capaz de fornecer energia por um tempo mais prolongado do que no caso de uma carga ser aplicada de forma continua. Através desta abordagem, o modelo KiBaM representa o efeito de recuperação da bateria

durante os períodos de não utilização. Além disso, também é considerado o efeito da taxa máxima de descarga, pois, para uma corrente de descarga maior a carga disponível será drenada mais rapidamente e, portanto, há menos tempo disponível para equilibrar as alturas dos reservatórios (*i.e.* converter energia química em energia disponível). Deste modo, uma parte da carga da bateria não será utilizada, resultando numa capacidade efetiva menor (JONGERDEN; HAVERKORT, 2008).

Definindo as alturas de ambos os reservatórios como $h_1 = q_{bt1}/c$ e $h_2 = q_{bt2}/(1-c)$, a variação de carga em ambas os tanques é dada pelo sistema de equações diferenciais (4.12):

$$\begin{cases} \frac{dq_{bt1}}{dt} = -i(t) + k(h_2 - h_1) \\ \frac{dq_{bt2}}{dt} = -k(h_2 - h_1) \end{cases} \quad (4.12)$$

sendo,

- c : razão de capacidade, que representa a razão entre o volume da carga disponível e o volume conjunto de ambos os reservatórios.
- $q_{bt1}(t)$: quantidade de carga no reservatório de carga disponível [kWh].
- $q_{bt2}(t)$: quantidade de carga no reservatório de carga limitada [kWh].
- $i(t)$: corrente de descarga [A].
- k : taxa de condutância, taxa na qual a carga flui entre os dois reservatórios; representa a velocidade a qual a bateria pode converter energia química em energia imediatamente disponível [1/h].

Resolvendo o sistema de equações diferenciais (4.12) obtêm-se as equações da quantidade de carga disponível (4.13) e limitada (4.14) no final de cada intervalo de simulação:

$$Q_{bt1} = Q_{bt1o} e^{-kt} + \frac{(Q_{bto} \cdot k \cdot c - P_{bt_need}) \cdot (1 - e^{-kt})}{k} - \frac{P_{bt_need} \cdot c \cdot (kt - 1 + e^{-kt})}{k} \quad (4.13)$$

$$Q_{bt2} = Q_{bt2o} e^{-kt} + Q_{bto} (1 - c) (1 - e^{-kt}) - \frac{P_{bt_need} \cdot (1 - c) \cdot (kt - 1 + e^{-kt})}{k} \quad (4.14)$$

sendo,

- Q_{bt1} : carga disponível ao final do intervalo de tempo [kWh].
- Q_{bt1o} : carga disponível na bateria no início do intervalo de tempo [kWh].

- Q_{bt2} : carga limitada ao final do intervalo de tempo [kWh].
- Q_{bt20} : carga limitada no início do intervalo de tempo [kWh].
- Q_{bto} : quantidade total de carga armazenada na bateria no início do intervalo de cálculo [kWh].
- P_{bt_need} : potência requerida pela bateria ou fornecida à bateria que surge do balanço energético do sistema [kW].

A quantidade total de carga (energia) armazenada na bateria em qualquer intervalo de tempo (Q_{bt}) resulta da soma da carga disponível (Q_{bt1}) e a carga limitada (Q_{bt2}), segundo a equação (4.15):

$$Q_{bt} = Q_{bt1} + Q_{bt2} \quad (4.15)$$

O conceito aqui apresentado pode ser estendido para um banco de baterias, isto é um arranjo de N_{bt_s} baterias em série, conectadas em N_{bt_p} cadeias em paralelo, resultando numa quantidade total de baterias igual a $N_{bt_s} \cdot N_{bt_p}$. Neste caso, a carga máxima que o banco de baterias pode armazenar é dada pela equação (4.16):

$$Q_{bt_max} = C_{bt_max_cap} \cdot N_{bt_s} \cdot N_{bt_p} \cdot V_{dc} \quad (4.16)$$

sendo,

- $C_{bt_max_cap}$: capacidade de corrente máxima da bateria [Ah].
- V_{dc} : tensão do barramento de DC [V], a qual é definida pelo número de baterias em série, $V_{dc} = N_{bt_s} \cdot V_{bt}$
- V_{bt} : tensão nominal de cada bateria individual [V].

4.3.3 Modelo de vida útil da bateria

As baterias eletroquímicas têm uma vida útil definida por um tempo de calendário (quantidade máxima de anos de operação) e pelo histórico de ciclos carregamento/descarregamento. Os modelos de vida útil contabilizam os ciclos de carga/descarga das baterias a fim de prever o tempo de reposição.

O modelo de vida útil da bateria adotado no presente estudo é baseado na abordagem de Fluxo-Ah (*Ah-throughput*). Esta abordagem foca exclusivamente no fator de “stress” relacionado com o fluxo de Ampère-hora (Ah) ao qual a bateria é submetida. Assume que a quantidade de energia que pode ser ciclada⁴ pela bateria até atingir sua vida útil é fixa, independente da profundidade de descarga dos ciclos individuais ou de qualquer outro parâmetro que pode influenciar o modo em que a energia é carregada ou descarregada (BINDNER et al., 2005). A principal vantagem deste método é a sua simplicidade, em particular no que diz respeito à modelagem e programação computacional. Como desvantagem pode-se mencionar que o modelo não é capaz de representar a degradação da bateria quando ela opera além da vida útil especificada pelo fabricante.

Finalmente, para estimar a vida útil de uma bateria de chumbo-ácido considera-se a mesma esgotada no momento em que atinge seu tempo de calendário (morre por causa da idade) ou quando atinge a quantidade máxima de ciclos de carga/descarga (morre por causa do uso). O tempo de calendário é definido pelo tempo de vida flutuante (*float life*), o qual se refere ao máximo tempo de operação esperado do equipamento independente do uso que tenha, este valor é especificado pelo fabricante (WOODBANK COMMUNICATIONS LTD., 2015). A partir dessas considerações, o tempo de vida esperado de uma bateria, LT_{bt_exp} , calcula-se com a equação (4.17):

$$LT_{bt_exp} = MIN \left(\frac{N_{bt_tot} \cdot Q_{bt_life_thr}}{Q_{bt_thr}}, LT_{bt_float} \right) \quad (4.17)$$

sendo,

N_{bt_tot} : quantidade total de baterias no banco de baterias, $N_{bt_s} \cdot N_{bt_p}$.

$Q_{bt_life_thr}$: energia total ciclada até atingir a vida útil de uma única bateria [kWh].

Q_{bt_thr} : energia total ciclada pela bateria por ano [kWh/ano].

LT_{bt_float} : tempo de vida flutuante (*float life*) [ano].

A metodologia para estimar a energia total ciclada até atingir a vida útil da bateria ($Q_{bt_life_thr}$) pode ser consultado na referência (BINDNER et al., 2005).

⁴ Processo que consiste em descarregar a energia da bateria, e em seguida recarregá-la.

4.4 MODELO DO GRUPO MOTO GERADOR

O grupo moto gerador transforma a energia térmica, proveniente da combustão, em energia elétrica. Ele é formado basicamente por uma máquina térmica acoplada mecanicamente a um gerador elétrico. O combustível mais comumente utilizado neste tipo de aplicação é o óleo diesel. No entanto, outros combustíveis possíveis de serem utilizados são a gasolina, o álcool, o gás natural e a biomassa. Independente do combustível, a máquina responsável pelo processo completo de geração, desde o térmico até a geração de eletricidade, é geralmente denominada de grupo moto gerador, a seguir refere-se a este componente com a sigla DG.

Em tempos passados, o atendimento de locais isolados era quase exclusivamente realizado com DG a gasolina ou a diesel com potências variando desde alguns quilowatts até 1 MW. Mais recentemente, as microturbinas têm entrado no mercado da geração autônoma, com potências que variam desde 25 até 250 kW. Também, às células de combustível estão sendo consideradas como alternativa para no futuro (MALEKI; ASKARZADEH, 2014).

A característica de gerar energia independentemente das condições climáticas e a capacidade de apresentar uma rápida resposta ante as flutuações da carga, fazem do DG um componente importante em sistemas autônomos onde a confiabilidade é prioridade.

Quando empregado em combinação com fontes de geração renovável, os DG atuam como *backup* de energia nos momentos em que a geração renovável é insuficiente. Nestes casos o DG opera apenas em situações onde há indisponibilidade de energia renovável gerada ou armazenada (bateria) e devem ser dimensionados para suprir a carga durante o período em que a demanda excede à geração. Em contrapartida, em situações onde o gerador alimenta diretamente o banco de baterias através da utilização de um retificador, sua potência nominal deve ser especificada para que ele opere com fator de carregamento ótimo, pois nessas condições o gerador apresenta máxima eficiência (PINHO et al., 2008).

Estudo aponta que a combinação de fontes renovável e grupo moto gerador em uma configuração de sistema híbrido reduz o tamanho do sistema de acumulação (bateria) e melhora o desempenho do sistema enquanto a sua confiabilidade (BARLEY; WINN, 1996; MARKVART, 2000).

O modelo adotado para simular a operação do grupo moto gerador é constituído por dois submodelos, o primeiro estima o consumo de combustível do equipamento, entanto que o segundo calcula a sua eficiência. A seguir se expõem seus fundamentos.

4.4.1 Consumo de combustível e eficiência do grupo moto gerador

Para grupos moto geradores constituídos de motores a combustão interna de velocidade constante, a taxa de consumo de combustível pode ser aproximada por uma função de primeira ordem com coeficientes constantes. Deste modo, através de uma equação empírica que represente esta relação, pode-se estimar o consumo de combustível do DG em função da potência demandada.

O modelo mais amplamente utilizado para geradores diesel é apresentado pela função linear apresentada na equação (4.18) (LAMBERT; GILMAN; LILIENTHAL, 2006):

$$F_{dg} = F_0 \cdot P_{dgr} + F_1 \cdot P_{dg} \quad (4.18)$$

sendo,

F_{dg} : consumo horário de combustível do DG [L/h].

P_{dgr} : potência nominal do DG [kW].

P_{dg} : potência instantânea fornecida pelo DG [kW].

F_0 : ordenada na origem da curva de consumo do gerador [L/h/kW_{nominal}].

F_1 : inclinação da curva de consumo do gerador [L/h/kW].

Segundo Sarei e Ohlin⁵ (1989) (*apud* (ARUN; KUMARAVEL; SELVAN, 2014) p. 81) para o valor dos coeficientes F_0 e F_1 pode-se adotar como sendo $F_0 = 0,084$ e $F_1 = 0,246$. Assim, a equação do consumo instantâneo de combustível do DG fica definida como (4.19):

$$F_{dg} = 0,084 \cdot P_{dgr} + 0,246 \cdot P_{dg} \quad (4.19)$$

Apesar do consumo de combustível do DG variar linearmente com a potência gerada, a sua eficiência apresenta um comportamento não linear. Sabe-se que em um gerador diesel típico o funcionamento em capacidade menor que a sua potência nominal diminui a eficiência do equipamento, aumentando o consumo de combustível em relação à potência gerada. Sendo assim, precisa-se de uma relação que permita estimar a eficiência do DG para ser utilizada como indicador de desempenho do SHGE.

A relação adotada para estimar a eficiência do gerador diesel, isto é, a razão entre a energia elétrica entregue pelo gerador para cada litro de combustível consumido, se mostra na equação (4.20):

⁵SKARSTEIN O., UHLEN K. **Design considerations with respect to long-term diesel saving in wind/diesel plants**. Wind Engineering. vol. 13, Nº 2, pp. 72-87, 1989 *apud* HAUSCHILD, 2006.

$$\eta_{dg} = \frac{3,6 \cdot P_{dg}}{\rho_{comb} \left(\frac{0,084 \cdot P_{dgr} + 0,246 \cdot P_{dg}}{1000} \right) \cdot PCI_{comb}} \quad (4.20)$$

sendo,

η_{dg} : eficiência na conversão de energia do DG.


ρ_{comb} : massa específica do combustível [kg/m³].

PCI_{comb} : poder calorífico inferior do combustível [MJ/kg].

3,6 : fator de conversão de unidades derivado de 1 kWh = 3,6 MJ.

Na Figura 16 se apresenta a curva de consumo de combustível e a correspondente curva de eficiência de um gerador diesel de potência nominal $P_{dgr} = 75$ kW, em função do estado de carga do equipamento. A máxima eficiência se dá para estados de carga maiores que 80% da potência nominal, em contrapartida para estados de carga próximos do mínimo recomendado de 20%, a eficiência do DG cai significativamente. É por isto que se recomenda dimensionar o DG e definir uma estratégia de operação do SHGE de modo que o motor gerador opere em condições próximas à potência nominal. Desta forma se reduz o consumo de combustível do equipamento e, portanto, o custo da energia gerada pelo sistema (BARLEY; WINN, 1996).

Figura 16. Curva de consumo de combustível e eficiência de um moto gerador diesel de 75 kW.




Fonte: produção do próprio autor

4.5 MODELO DO SISTEMA DE CONDICIONAMENTO DE POTÊNCIA

O sistema de condicionamento de potência é composto por equipamentos cuja função principal é gerenciar o controle geração/consumo visando ao aproveitamento ótimo dos recursos, aliado à qualidade e continuidade na entrega da energia ao usuário. Como pode se observar na Figura 17, o sistema de condicionamento constitui o elo de ligação entre todos os componentes, sendo o “cérebro” do sistema. Dentre os mais importantes equipamentos deste subsistema estão o controlador de carga, inversor de tensão, retificador e seguidor de ponto de máxima potência. A ligação desses componentes de acordo com a configuração de SHGE adotada no presente trabalho é mostrada na Figura 9, no início de capítulo. Os equipamentos que compõem o sistema de condicionamento de potência assim com as considerações para sua modelagem são descritos a seguir.

Figura 17. Diagrama em blocos dos subsistemas que compõem um SHGE.



Fonte: adaptado de (PINHO, 2008)

4.5.1 Controlador de carga

Os controladores de carga, também conhecidos como reguladores de carga, gerenciador de carga ou regulador de tensão, são dispositivos eletrônicos que apresentam como função básica o controle dos níveis de carga e descarga das baterias. Situações de sobrecarga e descarga profunda contribuem fortemente para a redução da vida útil da bateria. Nesse sentido, o controlador tem a função de desconectar a geração quando a bateria atingir um nível máximo pré-determinado de tensão, e desconectar a carga quando a bateria atingir um nível mínimo de carga (PINHO; GALDINO, 2014).

No algoritmo de simulação de SHGE desenvolvido no presente trabalho, o controle do estado de carga das baterias é gerenciado pelo algoritmo de controle definido pela estratégia de operação do sistema, a qual será introduzida na seção 4.7. Portanto, o controlador de carga não é representado explicitamente com um modelo matemático, considerando sua eficiência de 100%.

4.5.2 Seguidor de ponto de máxima potência

O seguidor do ponto de máxima potência (em inglês *Maximum Power Point Tracker* – MPPT) é um conversor DC-DC que altera o ponto de funcionamento eletrônico dos painéis, para que estes sejam capazes de fornecer a potência máxima em todo momento (KHADER; ABU-AISHEH, 2010).

Com exceção de sistemas fotovoltaicos autônomos de pequena potência com armazenamento em baterias (< 1 kW), atualmente todos os sistemas fotovoltaicos incorporam um MPPT, pois este equipamento aumenta a eficiência do sistema e portanto, minimiza o período de retorno do investimento inicial do sistema (BHANDARI et al., 2014). No presente trabalho, supõe-se que o gerador solar fotovoltaico incorporado no SHGE possui um MPPT. Apesar que a maioria dos modernos dispositivos MPPT possuem uma alta eficiência, em torno de 94-97% (BHANDARI et al., 2014), esta fonte de perda não pode ser desconsiderada quando o sistema PV é simulado ao longo da vida útil. Portanto, na ferramenta de simulação desenvolvida considera-se a eficiência do MPPT embutida no fator de redução de potência do gerador solar fotovoltaico, o qual pondera as diferentes fontes de perda não dependentes da temperatura.

4.5.3 Inversor e retificador

Em sistemas híbridos nos quais interagem fontes geradoras e cargas em corrente contínua (DC) e corrente alternada (AC), é preciso de um dispositivo capaz de fazer a conversão de tensão e corrente contínua em tensão e corrente alternada, e vice versa.

O dispositivo encarregado de converter potência DC em potência AC com a frequência e tensão ou corrente de saída desejada é denominado de inversor o conversor DC/AC. A tensão de saída tem uma forma de onda periódica a qual, em função do método de inversão, pode-se aproximar mais ou menos a uma onda senoidal. Já o dispositivo capaz de converter tensão alternada em contínua denomina-se de retificador ou conversor AC/DC. Estes

dispositivos costuma-se inserir um filtro capacitivo após o retificador para eliminar a ondulação da saída DC.

No presente trabalho supõe-se que o sistema incorpora um inversor bidirecional ou simplesmente conversor, como mostrado na Figura 9 no começo do capítulo. Este dispositivo pode atuar como retificador (AC-DC) quando há necessidade de carregar o banco de baterias, ou pode atuar como inversor (DC-AC) para alimentação da carga. Considerando esta hipótese, é necessário apenas modelar um único componente, neste caso o conversor. Assume-se também que a eficiência de retificação é a mesma que a de inversão. A seguir se apresenta o modelo de conversores incorporado na ferramenta de simulação.

4.5.3.1 Modelo de conversor

A característica mais importante a ser representada num conversor é sua eficiência, a qual indica a fração da potência de entrada transferida para a saída. Existem diversas abordagens para representar a eficiência dos conversores, sendo a mais comumente adotada a de considerar este parâmetro constante, isto é, assumir que a eficiência do conversor varia linearmente com a potência de operação (KING; BOYSON; KRATOCHVILL, 2004). Esta abordagem, apesar de simples, não representa o real funcionamento do dispositivo, já que a eficiência do conversor depende do nível de tensão de entrada e do estado de carga ao qual o equipamento é submetido (DRIESSE; JAIN; HARRISON, 2008). Assim, outras abordagens têm sido propostas para representar o real comportamento dos conversores, desde aproximações simples da eficiência com base em informações fornecidas pelo fabricante (DOBOS, 2014; DRIESSE; JAIN; HARRISON, 2008; GERGAUD; MULTON; BEN AHMED, 2002; MANWELL et al., 2006; NOTTON; LAZAROV; STOYANOV, 2010), equações empiricamente derivadas (CENTENO GONZALEZ et al., 2013; KING et al., 2007), até abordagens analíticas mais complexas baseadas no modelo de impedância do conversor para simular sua resposta em frequência (APRILIA et al., 2012).


No presente trabalho, procurou-se um modelo que consiga representar a operação real do conversor com relativa precisão, de simples programação computacional e com mínima informação de entrada, tipicamente informações encontradas na folha de especificações do fabricante. A partir de uma pesquisa bibliográfica foram identificados quatro modelos de conversor com as características desejadas:

- Modelo de Manwell et al. (2006).
- Modelo de King et al. (2007).

- Modelo de Notton et al. (2010).
- Modelo de Dobos (2014).

Com o intuito de avaliar o desempenho dos quatro modelos de conversor, foi realizada uma validação dos mesmos utilizando dados experimentais medidos num sistema real em operação. Na Figura 18 se mostra o ajuste dos modelos de inversor testados em relação aos dados experimentais. O modelo de Notton et al. (2010) apresentou o melhor desempenho em termos de erro médio absoluto (1,99%) e erro médio relativo (-0,09%). Além de ser adaptável para diferentes formatos de curva de inversor e requerer mínima informação de entrada para sua aplicação. Portanto, conclui-se que este modelo de conversor é o mais adequado para ser incorporado na ferramenta de simulação de SHGE.

Figura 18. Comparação dos modelos de inversor com resultados experimentais.



Fonte: produção do próprio autor

4.6 CURVA DE CARGA E DEMANDA DE ENERGIA

O consumo de energia é a potência elétrica que uma carga consome num determinado período de tempo, medida em kWh. A carga a ser atendida por um sistema de geração pode


ser representada por uma curva de demanda (ou curva de carga), que é uma representação da demanda em função do tempo para um dado período (COTRIM, 2003).

Cada tipo de consumidor apresenta um tipo de curva de demanda padrão, sendo que o formato destas curvas depende dos hábitos de consumo da população que compõe a demanda. Exemplos típicos de curvas são as de consumidor residencial, comercial e industrial. Porém, o presente estudo se foca em consumidores com hábitos diferentes dos urbanos, os denominados consumidores rurais isolados, nos quais a quantidade de equipamentos elétricos utilizados é reduzida, tipicamente aqueles necessários para cobrir as necessidades básicas.

Nesta categoria de consumidores, as cargas do tipo residencial (televisores, refrigeradores, ferro de passar, lâmpadas incandescentes e fluorescentes) são parte predominante da demanda total de eletricidade da comunidade. Dentre as cargas tipicamente residenciais, os eletrodomésticos correspondem ao maior percentual, representando mais de 70% do consumo total (OLIVEIRA BARBOSA; PINHO, 2008).

O perfil de consumo típico de uma comunidade rural isolada do Estado do Pará se mostra na Figura 19. O consumo médio diário é de 1,88 kWh/dia, apresentando uma demanda pico de 4,75 kW às 21:00h. Neste tipo de consumidores, a demanda máxima ocorre sempre nas primeiras horas do anoitecer (entre 19:00h e 22:00h), devido a entradas de cargas comumente usadas nesse período (lâmpadas e televisão, por exemplo). Enquanto que menores demandas ocorrem durante o resto do dia, devido à saída dos usuários de suas residências em direção ao campo para trabalhar. No período da manhã pode-se observar um pico de demanda de menor magnitude, o qual pode variar em função da região onde se situa a comunidade. Este aumento na carga se deve principalmente à necessidade de iluminação e, em regiões mais frias, o uso de aquecedores pode também ser necessário logo no início da manhã.

Figura 19. Curva de carga para um dia típico de consumidor rural isolado do Estado do Pará.



Fonte: (PINHO et al., 2008)

4.6.1 Determinação da curva de carga

O conhecimento das características da carga, especialmente a carga de pico, que um SHGE deve atender é muito importante, pois tem grande influência no dimensionamento e no desempenho final da instalação. Uma imprecisa estimativa da curva de carga pode levar a um pobre desempenho do SHGE em relação à confiabilidade, ou ainda resultar no sobre dimensionamento do sistema. Portanto, deve-se fazer uma adequada caracterização da carga antes de começar o processo de dimensionamento do SHGE.

A abordagem mais amplamente utilizada na literatura para efetuar o dimensionamento ou análise de desempenho de sistemas híbridos é utilizar informação de consumo elétrico real, isto é, curvas de consumo típicas derivadas de medições de campo (ASHOK, 2007; BOROWY; SALAMEH, 1996; CHEDID; SALIBA, 1996; DIAF et al., 2008; DUFO-LÓPEZ et al., 2011; HABIB et al., 1999). As vantagens de se trabalhar com dados de medição são a maior precisão das informações de consumo real da unidade consumidora e a capacidade de incorporar variações sazonais no consumo, o que leva a uma melhor estimativa da energia a ser suprida pelo sistema de geração. No entanto, medições de consumo elétrico registrada por um período considerável de tempo nem sempre estão disponíveis, especialmente no caso de

localidades isoladas. Caso se necessitar avaliar o desempenho do sistema em diferentes cenários de consumo, novas medições devem ser realizadas.

É por essas razões que a ferramenta de simulação de SHGE incorpora dois modelos para a geração sintética de curvas de carga. Estes modelos permitem, a partir do conhecimento das características da carga, gerar históricos de consumo variáveis no tempo para serem utilizados na simulação do SHGE. A seguir se apresentam brevemente os fundamentos destes dois métodos considerados.

4.6.2 Modelo de geração de curvas de carga baseado em simulação de Monte Carlo

Este modelo foi proposto pelo autor da presente pesquisa em Roberts (2012), e apresentado em Cassula et al. (2013), para maiores informações consultar essas referências.

O algoritmo baseia-se no conceito de “curva de probabilidade de uso do equipamento”, que representa, em forma de probabilidade, os hábitos de consumo energético dos moradores de um determinado local. Estas curvas de probabilidade são utilizadas para determinar o estado (ligado/desligado) dos aparelhos elétricos que compõem a carga em cada intervalo de simulação. O método de simulação Monte Carlo Sequencial é utilizado para representar as variações estocásticas no processo de geração das curvas de carga (ROBERTS, 2012).

Inicialmente devem-se conhecer os equipamentos que compõem uma residência típica, bem como suas probabilidades de estarem ligados em uma determinada hora do dia. Estes dados são geralmente obtidos através de pesquisa de campo. Para cada hora, o algoritmo gera um número pseudoaleatório e compara com a probabilidade do equipamento estar funcionando. Por exemplo, a probabilidade da TV estar funcionando das 17 as 18 horas é de 0,7. Caso o número sorteado seja menor que 0,7, considera-se a TV “ligada”, caso contrário, considera-se “desligada”. Este procedimento é repetido para cada equipamento e para cada hora do dia. O resultado é uma curva de carga horária que contém a informação dos hábitos de consumo dos moradores da unidade consumidora.

O algoritmo ainda considera a possibilidade de mais de uma residência, onde os sorteios são realizados de maneira independente. Ao somar o histórico de estados ligado/desligado dos equipamentos em uma determinada hora, nas diferentes residências, se obtém a demanda total do sistema nesta hora. O modelo tem a capacidade de representar variações sazonais, diferenciando verão de inverno, e dias de semana e final de semana.

A principal vantagem deste método é a capacidade de gerar curvas de consumo elétrico com grande precisão, as quais incorporam a informação sobre os hábitos de consumo dos

moradores. Por outro lado, precisam-se como informação de entrada as curva de probabilidade dos equipamentos presentes no local de estudo. Esta informação nem sempre está disponível, podendo ser estimada através do conhecimento dos hábitos de consumo dos moradores. Também é importante mencionar que o custo computacional do método se incrementa na medida em que aumenta o número de unidades consumidoras e aparelhos elétricos considerados. Esta característica, comum aos métodos baseados na simulação Monte Carlo, pode condicionar sua aplicação em modelos que requerem grande número de simulações.

4.6.3 Modelo de geração da curva de carga baseado no perfil diário

Este método é baseado na abordagem proposta por (LAMBERT; GILMAN; LILIENTHAL, 2006). De modo breve, o algoritmo inicia replicando um perfil diário de demanda elétrica durante o período de simulação (365 dias), em seguida adicionam-se perturbações em base horária e diária para simular a aleatoriedade do consumo elétrico. Isto é feito multiplicando os valores horários pelo fator δ_{load} dado pela equação (4.21):

$$\delta_{load} = 1 + \delta_d + \delta_h \quad (4.21)$$

sendo,

δ_d :é o fator de perturbação diário $\delta_d \sim U(0, \sigma_{day, noise})$, sorteado uma vez por dia a partir de uma distribuição normal de média zero e desvio padrão igual ao valor de ruído diário especificado.

δ_h :é o fator de perturbação horário $\delta_h \sim U(0, \sigma_{hour, noise})$, sorteado uma vez por hora a partir de uma distribuição normal de média zero e desvio padrão igual ao valor de ruído horário especificado.


Finalmente, tem a opção de especificar um fator de escala para introduzir variações no perfil entre dias da semana e dias de fim de semana, e entre os diferentes meses do ano.

As principais vantagens do método são a simplicidade e a mínima informação de entrada requerida para sua aplicação. Como desvantagens pode-se mencionar que o formato final da curva de carga gerada depende fortemente dos fatores de ruído horários e diários especificados pelo usuário, os quais muitas vezes são difíceis de determinar. Por outro lado, o método não contempla a opção de especificar diferentes tipos unidades consumidoras.

Para ilustrar com um exemplo, a Figura 20 mostra as curvas de carga geradas com os métodos apresentados, durante um período de 10 dias. A Figura 20(a) corresponde ao perfil

gerado com o método baseado em Simulação Monte Carlo. As Figura 20(b) e Figura 20(c) foram geradas com o método baseado no perfil diário, adotando diferentes fatores de ruído diário e horário. No método baseado na curva diária é preciso ajustar os valores do ruído para considerar a aleatoriedade de um perfil real, já no método baseado em Simulação Monte Carlo, essa informação é inserida por meio das curvas de probabilidade de uso dos equipamentos.

Figura 20. Perfis de consumo gerados com os métodos de geração sintética de curvas de carga.



Fonte: produção do próprio autor

4.7 ESTRATÉGIAS DE OPERAÇÃO DO SISTEMA HÍBRIDO

A estratégia de operação (ou controle) visa gerenciar a operação dos componentes de um sistema através da avaliação de informações de entrada relacionadas com seu desempenho (*feedback*). Na operação de um sistema híbrido podem-se diferenciar dois níveis de controle (GUPTA; SAINI; SHARMA, 2008c):

- Controle dinâmico, relacionado com o controle da frequência e níveis de tensão do sistema.
- Estratégia de operação, que considera o fluxo de energia entre os diferentes componentes que compõem o sistema.

No presente trabalho, aborda-se apenas o nível de controle relacionado com a estratégia de operação, a qual se define a seguir.

A estratégia de operação é um algoritmo de controle que administra a interação entre os diferentes componentes do sistema. Em cada intervalo de simulação a estratégia de operação avalia as informações de entrada, como a disponibilidade de recursos renováveis, a demanda da carga e o estado de carregamento do sistema de armazenamento. Em seguida, toma decisões sobre o fluxo de energia no sistema, determinando que componentes devem entrar em operação, quais devem ser desconectados, onde deve ser armazenada a energia excedente, e, se preciso, acionar as cargas dissipadoras, visando otimizar o desempenho do sistema (DUFO-LÓPEZ; BERNAL-AGUSTÍN; CONTRERAS, 2007; GUPTA; SAINI; SHARMA, 2008c).

4.7.1 Tipos de estratégias de operação de SHGE

Os sistemas híbridos autônomos integrados apenas por fontes de geração renováveis utilizam estratégias de operação governadas estritamente pelo estado de carga do sistema de acumulação. Isto é, a geração será desconectada da bateria devido a uma situação de carga plena do banco de baterias ou a carga deve ser desconectada devido a uma situação de máxima profundidade de descarga do sistema acumulação (BLASQUES MACEDO, 2005).

Sistemas híbridos que integram fontes renováveis e grupos moto geradores atuando como *backup* incorporam estratégias de operação, também conhecidas como estratégias de despacho (*dispatch strategy*), que visam otimizar a entrada em operação do grupo gerador. Em outras palavras, a estratégia de despacho responde à pergunta “quando” e “como” o grupo gerador deve ser conectado ao sistema (PINHO et al., 2008).

Dentre a grande quantidade de estratégias possíveis de ser utilizadas num SHGE com geração de *backup* há duas que são mais frequentemente citadas na literatura (BARLEY; WINN, 1996; BARLEY et al., 1995; BLASQUES MACEDO, 2005; DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2005; HAUSCHILD, 2006; PINHO et al., 2008), a estratégia de “Seguimento da Demanda” (*Load Following*) e a estratégia de “Ciclo de Carga” (*Cycle Charge*). Trabalhos anteriores têm concluído que a melhor destas duas estratégias, para uma dada configuração de SHGE, resulta praticamente tão rentável quanto uma estratégia preditiva ideal, a qual pressupõe o perfeito conhecimento de futuras condições de demanda e de disponibilidade de recursos renováveis (KATSIGIANNIS et al., 2012).

Na ferramenta de simulação de SHGE aqui desenvolvida, são incorporadas três estratégias de operação, a estratégia Seguimento da Demanda, a estratégia Ciclo de Carga, e mais uma estratégia definida pelo usuário. A escolha da estratégia de operação mais adequada para uma dada configuração de SHGE constitui uma variável de otimização. A seguir se apresentam as estratégias de operação disponíveis na ferramenta de simulação.

4.7.2 Estratégia de operação “Seguimento da Demanda”

Na estratégia denominada de “Seguimento da Demanda” (SD) as baterias são carregadas apenas com as fontes renováveis. Caso a energia gerada pelas renováveis não seja suficiente, o DG é acionado para fornecer apenas a energia faltante para suprir à demanda, sem gerar potência adicional para carregar às baterias. No entanto, se a potência mínima de operação do DG é especificada como diferente de zero (no intuito de evitar que o DG opere em baixa condição de carga), pode-se ter a situação em que a potência requerida do DG seja menor que a potência mínima de operação, assim o excesso de energia é enviado às baterias (BARLEY; WINN, 1996). Se o ponto de operação mínimo do DG é zero, as baterias serão carregadas exclusivamente com a energia originada de fontes renováveis.

A estratégia SD tende a ser mais adequada para sistemas com grande participação de fontes renováveis, onde a geração renovável pode, por alguns momentos, exceder a carga (KATSIGIANNIS et al., 2012).

4.7.3 Estratégia de operação “Ciclo de Carga”

A estratégia de operação “Ciclo de Carga” (CC) difere da estratégia SD pois quando as fontes renováveis e as baterias não conseguem fornecer a demanda total, o DG entra em

operação a potência nominal, atendendo a carga e carregando as baterias com a energia excedente. Na estratégia CC deve-se definir um *set point* para o estado de carregamento máximo do banco de baterias, SOC_{sp} . Assim, o DG continuará a funcionar até o banco de baterias atingir o SOC_{sp} . No caso da potência nominal do DG resultar maior que a demanda da carga mais a potência máxima que as baterias podem absorver, ele fornecerá apenas a potência necessária para garantir a carga e carregar o banco de baterias, evitando o excesso de energia.

A estratégia CC tende a ser adequada em sistemas com pouca ou nenhuma geração renovável (KATSIGIANNIS et al., 2012).

4.7.4 Estratégia “Programada”

A estratégia programada definida pelo usuário (UD) permite planificar o funcionamento do DG. Durante certos períodos de tempo o DG pode ser forçado a operar ou a permanecer inativo de acordo com o programa pré-selecionado pelo usuário. Podem-se tratar os dias de semana e os dias de final de semana de forma diferenciada. Esta estratégia pode ser implantada em conjunto com as estratégias SD e CC. Isto é, nos momentos em que o DG está operativo, este é gerenciado por alguma destas estratégias. Uma estratégia do tipo UD é necessária em situações onde há restrições para a operação do DG, por exemplo, durante certos períodos do dia pode ser necessário focar a parada do DG para evitar ruídos molestos ou emissão de gases de escape.

4.8 AVALIAÇÃO DO IMPACTO AMBIENTAL

Todos os sistemas de geração de energia, incluindo as chamadas energias renováveis, emitem gases do efeito estufa⁶ (em inglês *Green House Gas* – GHG) e contribuem para as mudanças climáticas antropogênicas. Uma correta avaliação do impacto ambiental de uma determinada tecnologia de geração de energia envolve a quantificação das emissões GHG ao longo de todas as etapas do ciclo de vida da tecnologia, assim como do combustível que ela utiliza (WEISSER, 2007). A quantificação precisa das emissões GHG não é uma tarefa simples já que depende de muitos fatores como do tipo de tecnologia e os requerimentos

⁶ São substâncias gasosas que absorvem parte da radiação infravermelha, emitida principalmente pela superfície terrestre, e dificultam seu escape para o espaço. Isso impede que ocorra uma perda demasiada de calor para o espaço, mantendo a Terra aquecida.

energéticos ao longo do seu ciclo de vida, das características da matriz energética da região, das condições de disponibilidade dos recursos naturais, assim como da vida útil dos equipamentos (PENG; LU; YANG, 2013).

A metodologia mais amplamente utilizada para a análise do impacto ambiental é denominada de Avaliação do Ciclo de Vida (em inglês *Life Cycle Analysis* – LCA), que consiste na análise do berço ao túmulo do processo em estudo. O principal indicador utilizado no LCA para avaliar o impacto ambiental de diferentes tecnologias de geração de energia é o Potencial de Aquecimento Global (em inglês *Global Warming Potential* - GWP) (SILVEIRA et al., 2014). Este indicador, expresso em $\text{kgCO}_{2\text{-eq}}/\text{kWh}$ ⁷, representa quanto determinada quantidade de gases de efeito estufa contribui para o aquecimento global.

O indicador GWP calculado através da metodologia de LCA considera não apenas as emissões derivadas da construção, operação e desmantelamento dos componentes, mas também os impactos ambientais associados a todos os processos relevantes a montante e a jusante dentro da cadeia energética que acontece durante o ciclo de vida dos equipamentos que compõem o sistema (i.e., painéis fotovoltaicos, estrutura de suporte, turbinas eólicas, moto gerador diesel, baterias e conversor). As emissões geradas durante a operação do sistema são denominadas de emissões diretas, enquanto que as emissões geradas durante as etapas de fabricação, transporte e disposição final dos componentes são denominadas de emissões indiretas (DUFO-LÓPEZ et al., 2011; SAIF et al., 2010). No caso da configuração de SHGE estudada no presente trabalho (ver Figura 9), apenas são consideradas as emissões diretas geradas pela combustão do óleo diesel no grupo moto gerador. O restante dos componentes não geram poluentes durante sua operação, no entanto contribuem com emissões indiretas.

A ferramenta de simulação de SHGE desenvolvida permite calcular as emissões no ciclo de vida do sistema, considerando a contribuição das emissões diretas e indiretas de todos os componentes. Assim, a quantidade de $\text{CO}_{2\text{-eq}}$ gerado durante a operação do SHGE pode ser adotada como critério de otimização.

Para aplicar o método de estimação das emissões no ciclo de vida do SHGE é preciso fornecer um fator de emissão para cada componente, o qual é geralmente expresso em termos de sua potência nominal ou energia gerada. Com o intuito de definir estes fatores de emissão, foi feita uma pesquisa bibliográfica. Os resultados completos desta pesquisa se mostram no Apêndice B, no entanto, na Tabela 3, se mostram os valores de fatores de emissão adotados

⁷ $\text{CO}_{2\text{-eq}}$ refere-se à equivalência em dióxido de carbono, medida que expressa a quantidade de gases de efeito estufa (GHG) em termos equivalentes da quantidade de dióxido de carbono (CO_2).

nas simulações do SHGE. Além do fator de emissão para cada componente, foi considerado o fator de emissão para o combustível, o qual representa as emissões no processo de fabricação e transporte do combustível utilizado pelo moto gerador, neste caso óleo diesel.

Tabela 3. Fatores utilizados para o cálculo das emissões no ciclo de vida do sistema híbrido.

Componente	Fator de emissão indireta	Unidade	Fator de emissão direta	Unidade
Turbina eólica	0,02	kgCO _{2-eq} /kWh	n/a	
Painel fotovoltaico	0,059	kgCO _{2-eq} /kWh	n/a	
Conversor	42,835	kgCO _{2-eq} /kW	n/a	
Bateria	59,42	kgCO _{2-eq} /kWh ⁽¹⁾	n/a	
Óleo diesel	0,530	kgCO _{2-eq} /L	n/a	
Moto gerador	454,293	kgCO _{2-eq} /kW	2,64	kgCO _{2-eq} /L ⁽²⁾

⁽¹⁾ kWh refere-se neste caso à capacidade energética máxima da bateria.

⁽²⁾ O cálculo do fator de emissões diretas do moto gerador é apresentado no Apêndice C.

Fonte: produção do próprio autor

4.9 MODELO DE ANÁLISE ECONÔMICA

A análise econômica desempenha um papel fundamental no processo de dimensionamento de um sistema energético, pois juntamente com a análise técnica fornecem as informações necessárias para tomar a decisão em relação à configuração final do sistema (GUPTA; KUMAR; BANSAL, 2012; JAMIL; KIRMANI; RIZWAN, 2012; KAABECHE; IBTIOUEN, 2014; KARLIS; PAPADOPOULOS, 2013; KATSIGIANNIS; GEORGILAKIS; KARAPIDAKIS, 2010a; MOHAMED; KOIVO, 2011). Uma análise completa de um novo projeto de investimento considera a avaliação dos custos ao longo da vida do projeto, tomando em conta os custos diretos, os custos indiretos e gerais, impostos e retornos sobre o investimento, além de quaisquer externalidades, como possíveis impactos ambientais, que são importantes para a tomada decisão. A finalidade e a abrangência da análise irão definir o nível de detalhe e os indicadores econômicos mais apropriados para ser usados no estudo.

Vários indicadores econômicos podem ser utilizados para realizar a avaliação de investimentos na área de energia. A revisão bibliográfica realizada no capítulo 0 mostrou que os indicadores mais citados são o Valor Presente Líquido, o Custo da Energia e o Custo de Capital Inicial do Sistema (ver Tabela 2). No presente trabalho, o problema consiste em selecionar uma configuração de SHGE dentre um conjunto de alternativas mutuamente exclusivas que têm como objetivo a prestação do mesmo serviço, ou seja, o fornecimento de

energia elétrica a uma demanda específica. Dado que a escolha de uma alternativa exclui o aproveitamento das vantagens das outras, a maioria dos indicadores econômicos não é aplicável, uma vez que falham ao representar a diferença nas características dos investimentos (p. ex. Taxa Interna de Retorno do Investimento, Taxa Interna de Retorno Modificada, *Payback*, Relação Custo-benefício). Por estas razões, Short e Packey (1995) recomendam empregar o Valor Presente Líquido, *NPV* (do inglês *Net Present Value*), como principal parâmetro econômico na hora de avaliar uma decisão de investimento no qual é necessário selecionar uma opção a partir de um conjunto de alternativas mutuamente exclusivas.

Valor Presente Líquido (*NPV*)

O *NPV* está relacionado com a metodologia de análise de Custos do Ciclo de Vida (do inglês *Life Cycle Cost Analysis*), que é um método comumente usado para a avaliação econômica com base nos princípios do valor temporal do dinheiro (MANWELL; MCGOWAN; ROGERS, 2009b). A metodologia de análise de Custos do Ciclo de Vida, como seu nome indica, é comumente aplicada a alternativas que têm estimativas de custos que abrangem o período de vida do sistema inteiro. Isso significa que os custos desde as primeiras fases do projeto até a fase final são estimados considerando o valor temporal do dinheiro. O melhor equilíbrio entre os custos incorridos ao longo do projeto é obtido quando o custo total do ciclo de vida é minimizado.

Na avaliação de sistemas de geração de energia baseado em fontes renováveis, esta metodologia se apresenta especialmente apropriada, uma vez que este tipo de sistema se caracteriza por possuir altos investimentos iniciais, tempos de vida longos e baixos custos de operação e manutenção (MANWELL, 2004). Todas as despesas e receitas contempladas pela análise de ciclo de vida resumem-se no cálculo de um único valor, o Valor Presente Líquido, *NPV*, que considera a depreciação, os impostos e o valor temporal do dinheiro (AGAJELU et al., 2013). Deste modo, o *NPV* pode ser utilizado como parâmetro de comparação de diferentes alternativas de SHGE, inclusive em sistemas que integrem fontes convencionais.

No presente trabalho utiliza-se como principal parâmetro de avaliação econômica, o Valor Presente Líquido dos custos (NPV_C), de acordo com o qual a melhor alternativa dentre todas as possíveis é aquela com o menor NPV_C . O NPV_C contempla os custos de investimento inicial, os custos de substituição dos componentes, os custos de operação e manutenção do sistema, o custo do combustível, e, se for aplicável, o custo de compra de energia à rede e despesas adicionais derivadas de penalidades pela emissão de poluentes (LAMBERT; GILMAN; LILIENTHAL, 2006). As receitas incluem os lucros da venda de energia à rede,

além de qualquer valor residual que ocorre no final da vida útil do projeto. O NPV_C , em US\$, è calculado por meio da equação (4.22):

$$NPV_C = \frac{C_{level,tot}}{CRF(d_r, LT_{proj})} \quad (4.22)$$

sendo,

$C_{level,tot}$: custo anual equivalente⁸; representa a soma dos custos anualizados de todos os componentes do sistema, mais outros custos anualizados [US\$/ano].

$CRF(\cdot)$: fator de recuperação de capital; relação utilizada para calcular o valor presente de uma série uniforme de pagamentos anuais (anuidade).

d_r : taxa de juros real [%].

LT_{proj} : tempo de duração do projeto [ano].

Custo Nivelado de Energia (*LCOE*)

É considerada uma boa prática a utilização de mais de um critério para avaliar a viabilidade econômica de um projeto. Sendo assim, como segundo indicador econômico, adota-se o Custo Nivelado de Energia *LCOE* (do inglês *Levelized Cost of Energy*), critério utilizado especificamente na avaliação de plantas de energia. O *LCOE* è equivalente ao preço médio que os consumidores de energia elétrica deveriam pagar ao fornecedor para que o investidor possa recuperar o seu investimento a um mínimo de lucratividade pré-definida. Em outras palavras, è o custo médio que, se atribuído a cada unidade de energia produzida por um sistema durante um determinado período de análise, se iguala ao Custo Total do Ciclo de Vida do projeto quando levado ao ano base (NEVES JÚNIOR, 2010).

O *LCOE*, em US\$/kWh, calcula-se como a razão entre o custo anual equivalente do sistema e a energia gerada pelo sistema efetivamente utilizada para fornecer à carga, de acordo com a equação (4.23):

$$LCOE = \frac{C_{level,tot}}{E_{load} - LPS} \quad (4.23)$$

sendo,

E_{load} : energia demanda pela carga [kWh].

LPS : energia não suprida [kWh].


⁸O custo anual equivalente resulta da transformação do fluxo de todos os custos do projeto num fluxo anual uniforme.

Todas as equações do método de análise econômica podem ser encontradas no Apêndice E.

4.9.1 Custo dos componentes do sistema

Dado que o dimensionamento final do SHGE depende fortemente do custo dos componentes que o compõem, foi necessário realizar uma pesquisa de preços no mercado local para definir esses valores. O custo específico dos componentes do SHGE (aerogeradores, painéis fotovoltaicos, moto geradores, baterias, inversores) depende da sua capacidade e é geralmente representado como uma função de potência (KALDELLIS, 2010; NOTTON; MUSELLI; POGGI, 1998). A partir de dados informados por diferentes fornecedores no mercado brasileiro e obtidos de outros trabalhos de pesquisa, foi possível encontrar a função potência do custo específico para cada componente, as quais se mostram na Figura 21. Estes custos são utilizados nas simulações do SHGE. Maiores informações sobre os custos associados aos componentes do SHGE podem-se consultar no Apêndice D.

Figura 21. Custos específicos dos componentes no mercado brasileiro para (a) aerogerador, (b) painéis fotovoltaicos, (c) moto gerador diesel, (d) bateria, (e) inversor.



Fonte: elaborado pelo autor

4.10 INTEGRAÇÃO DOS MODELOS

Uma vez adotados todos submodelos para representar a operação dos diferentes componentes do SHGE, é preciso integrá-los na ferramenta de simulação de SHGE. A estrutura geral do algoritmo de simulação de SHGE desenvolvida no presente estudo é apresentada na Figura 22. O algoritmo é dividido em três módulos com funções específicas:

- **Módulo de Projeto:** aqui são definidas todas as informações relativas ao projeto em questão. Devem ser definidas as informações relativas à carga e à disponibilidade dos recursos renováveis; o tipo e número de componentes que integrarão o sistema assim como as suas características técnicas; a estratégia de operação que gerenciará o sistema; os parâmetros para a análise econômica e; se for preciso os parâmetros para a análise probabilística.
- **Módulo de Simulação:** este módulo integra todos os submodelos apresentados nas seções anteriores e tem a função de simular o funcionamento do SHGE durante um ano de operação. Inicia-se pela geração do perfil de carga o qual é dado de entrada para o módulo energético. No módulo energético, faz-se um balanço energético para cada intervalo de simulação, o qual, no presente estudo, foi definido como $\Delta t = 1$ hora⁹. Ao final de cada intervalo de simulação (Δt), a soma de geração e consumo deve ser zero, já considerando as perdas e o excesso/déficit de energia, quando for o caso. Dado que o intervalo de simulação é 1 hora, o valor de potência é igual ao valor de energia em cada intervalo. Os resultados da simulação energética são enviados ao módulo de análise econômica.
- **Módulo de Resultados:** uma vez finalizada a simulação do sistema, é preciso avaliar o desempenho do SHGE. Isto é feito através do cálculo de uma série de índices relacionados com diferentes aspectos da operação do sistema. Estes índices servem como meio de verificação do desempenho global do sistema, e dos subsistemas que o compõem. A seguir se definem os índices de maior interesse, já que são empregados pelo módulo de otimização de SHGE.

⁹ O intervalo de simulação recomendado varia entre 5 minutos e 2 horas, sendo que para simulações em longo prazo, um intervalo de simulação de uma hora é o mais empregado (MANWELL et al., 2006).

4.10.1 Índices de desempenho relacionados com a confiabilidade

a) Probabilidade de Perda no Fornecimento de Energia (*LPSP*): define-se como a razão entre a energia não fornecida e a energia demandada pela carga no período de tempo considerado (AI et al., 2003; BOROWY; SALAMEH, 1996; DIAF et al., 2008):

$$LPSP = \frac{\sum_{t=1}^T LPS(t) \Delta t}{\sum_{t=1}^T P_{load}(t) \Delta t} \quad (4.24)$$

sendo,

$LPS(t)$: perda no fornecimento de energia à carga [kW].

$P_{load}(t)$: potência demandada pela carga no tempo t [kW].

T : período de tempo considerado para a análise, no presente caso 8760 horas.

Δt : intervalo de cálculo ($\Delta t = 1$ h).

a) Duração de Interrupção Individual por Unidade Consumidora (*DIC*): intervalo de tempo no qual, no período de observação, em cada unidade consumidora ocorreu descontinuidade da distribuição de energia elétrica.

$$DIC = \sum_{i=1}^{N_{int}} t_{int}(i) \quad (4.25)$$

sendo,

N_{int} : número de interrupções da unidade consumidora considerada, no período de apuração (8760 h = 1 ano).

$t_{int}(i)$: tempo de duração da interrupção da unidade consumidora considerada, no período de apuração [horas].

b) Duração Máxima de Interrupção Contínua por Unidade Consumidora (*DMIC*): tempo máximo de interrupção contínua, da distribuição de energia elétrica, para uma unidade consumidora qualquer [horas]. Através dessa duração pode-se avaliar a ultrapassagem em relação a um determinado padrão.

$$DMIC = \max [t_{int}(i)]_{i=0}^T \quad (4.26)$$

c) Frequência de Interrupção Individual por Unidade Consumidora (*FIC*): número de interrupções ocorridas, no período de observação, em cada unidade consumidora.

$$FIC = N_{int} \quad (4.27)$$

4.10.2 Índices de desempenho relacionados à geração de energia do SHGE

a) Razão de Excesso de Energia (f_{exe}): durante a operação do SHGE a energia gerada pelas fontes renováveis pode resultar maior ou menor que a demanda da carga. Caso a geração seja maior que a energia demandada, o sistema pode optar por carregar as baterias (dependo da estratégia de operação selecionada) até as baterias atingirem seu máximo estado de carga. Neste ponto, se ainda há disponibilidade de energia renovável, o sistema de controle interrompe o carregamento das baterias resultando num excesso de potência não utilizada pelo sistema. Pode-se definir então a razão entre o excesso de energia e o total de energia gerada pelo sistema durante o período de avaliação com a equação (4.28):

$$f_{excess} = \frac{\sum_{t=1}^T [P_{gen}(t) - P_{load}(t)] \cdot \Delta t}{\sum_{t=1}^T [P_{gen}(t)] \cdot \Delta t} \quad (4.28)$$

sendo,

P_{gen} : potência total gerada pelo SHGE [kW].

b) Fração de Energia gerada pelas Fontes Renováveis (f_{ren}): razão de energia renovável em relação ao total de energia gerada pelo SHGE, definindo com a equação (4.29):

$$f_{ren} = \frac{\sum_{t=1}^T [P_{pv}(t) + P_{wt}(t)] \cdot \Delta t}{\sum_{t=1}^T [P_{pv}(t) + P_{wt}(t) + P_{dg}(t)] \cdot \Delta t} \quad (4.29)$$

4.10.3 Índices de desempenho relacionados ao moto gerador

a) Consumo total de combustível do DG (F_{dg}): consumo total de combustível durante o período de análise.

$$F_{dg_tot} = \sum_{t=1}^T F_{dg}(t) \quad (4.30)$$

b) Horas de operação do DG (DG_{oh}): quantidade de horas que o DG operou com potência superior à mínima potência de operação.

$$DG_{oh} = \sum_{t=1}^T \phi_{dg} \quad (4.31)$$

sendo,

$$\phi_{dg}(t) = \begin{cases} 1 & \text{se } P_{dg}(t) > P_{dg_min} \\ 0 & \text{caso contrário} \end{cases} \quad (4.32)$$

4.10.4 Índices de desempenho relacionados ao sistema de armazenamento

a) Estado de carga (SOC): nível de carregamento do banco de baterias em relação à sua capacidade máxima, definido pela equação (4.33):

$$SOC(t) = \frac{Q_{bt}(t)}{Q_{bt_max}} \quad (4.33)$$

b) Tempo de vida esperado de uma bateria (LT_{bt_exp}): expectativa da vida útil (número de anos) do banco de baterias até a substituição. Este valor é calculado utilizando a equação (4.17) apresentada na seção 4.3.3.

c) Autonomia do banco de baterias ($BT_{autonomy}$): razão entre a capacidade do banco de baterias e a potência média demandada pela carga por dia.

$$BT_{autonomy} = \frac{N_{bt_tot} V_{bt} Q_{bt_max} (1 - SOC_{min}) \cdot 24 \left[\frac{h}{dia} \right]}{L_{mean_day}} \quad (4.34)$$


4.10.5 Índices de desempenho relacionados com as emissões de gases poluentes

a) Fator de emissão ($EMCO_2$): quantidade de gases poluentes gerados pelo SHGE, considera as emissões diretas, geradas durante a operação do sistema, e as emissões indiretas (geradas durante o ciclo de vida dos componentes do sistema. Calcula-se segundo a equação (4.35):

$$EMCO_2 = \sum_{i=1}^T F_{dg} \cdot ef_{CO_2,dg} + \sum_{j=1}^{N_{comp}} E_{comp,j} \cdot ief_{CO_2,j} \quad (4.35)$$

sendo F_{dg} o consumo de combustível do DG, $ef_{CO_2,dg}$ o fator de emissão direta do DG, N_{comp} o número de componentes do SHGE, $E_{comp,j}$ a energia gerada ou potência nominal do componente j -ésimo e $ief_{CO_2,j}$ o fator de emissão indireta do componente j -ésimo.

Figura 22. Estrutura geral do algoritmo de simulação do SHGE.



Fonte: elaborado pelo autor

4.10.6 Exemplo de simulação


Para ilustrar com um exemplo o funcionamento da ferramenta de simulação, são apresentados a seguir os resultados da aplicação do algoritmo em um SHGE composto por: 150 kWp de geração solar fotovoltaica, 3x16 kW de geração diesel, 855,6 kWh de armazenamento em baterias e 35 kW de capacidade do conversor. O sistema foi dimensionado para o fornecimento de uma carga com um consumo diário de 475 kWh e opera segundo a estratégia de operação seguimento da demanda.

A ferramenta fornece, ao finalizar a simulação, os resultados horários derivados do balanço energético. Isto é, uma série horária de 8760 valores de todas as variáveis de interesse, como são a potência demanda pela carga, a potência instantânea gerada pelas fontes, o estado de carregamento das baterias, energia não fornecida, entre outros. Na Figura 23 se expõe o gráfico horário da simulação do sistema durante um período de 10 dias no mês de março. Escolheu-se esse período para mostrar com maior detalhe o funcionamento do algoritmo de balanço de energia. Observa-se que há uma sequência de 6 dias de baixa radiação solar e, portanto, a produção do sistema fotovoltaico (P_{pv} na Figura 23) resulta baixa nesse período. Como consequência, o banco de baterias atinge seu estado mínimo de carregamento de 30% (SOC na Figura 23) não conseguindo suprir a carga. Assim, precisa-se acionar a geração diesel de *backup* (P_{dg} na Figura 23) para suprir o déficit de energia da carga (P_{load} na Figura 23). Na parte inferior da Figura 23 observa-se que há momentos nos quais os dois moto geradores (DG 1 e DG 2) não conseguem suprir a carga e, portanto, deve entrar em operação o terceiro moto gerador (DG 3). Dado que o sistema opera de acordo com a estratégia seguimento da demanda, as baterias são apenas carregadas com a geração renovável. O moto gerador opera apenas à mínima potência necessária para fornecer o faltante de energia (acima da sua potência mínima de operação). Deste modo, as baterias só começam a aumentar seu nível de carregamento uma vez que o período de baixa radiação finaliza. Uma vez que as baterias atingem seu nível máximo de carregamento, o gerador diesel é acionado apenas para suprir o pico de consumo nos período de maior demanda ocorridos no final da tarde.

Além dos resultados horários, a ferramenta de simulação fornece um arquivo de texto com todos os indicadores de desempenho calculados com base na simulação realizada. O arquivo correspondente ao presente exemplo se mostra no Apêndice F.



Finalmente, a ferramenta de simulação também fornece resultados gráficos relacionados com a análise econômica. Na Figura 24(a) se apresenta a estrutura de custos de cada componente do sistema avaliado no presente exemplo, em valor presente, para cada componente do sistema. Observa-se que o investimento inicial representa a maior parcela dos custos para a geração renovável de tipo solar fotovoltaica (PV na Figura 24(a)); ao contrário do que acontece com o moto gerador (DG na Figura 24(a)), onde a maior parcela corresponde ao combustível e em menor medida o custo de O&M, sendo que o custo de investimento inicial é quase desprezível na estrutura de custos deste equipamento. As baterias (BT na Figura 24(a)), também implicam em um elevado custo de investimento inicial. Existe ainda uma reposição deste componente durante a vida útil de sistema, portanto ao custo de investimento inicial adiciona-se o custo de uma substituição das baterias. Finalmente, na Figura 24(b) se mostra a participação dos custos de cada equipamento no NPV_C total do sistema. Observa-se que a maior parcela corresponde ao custo do subsistema fotovoltaico, sendo que o custo de investimento inicial mais o custo de O&M do sistema PV representam 33,5% do NPV_C do sistema híbrido. O banco de baterias (BT) é o segundo maior custo neste caso, representando 27,12% do NPV_C . Os custos associados ao moto gerador (DG) representam apenas o 7,72% do NPV_C , no entanto quando se adiciona o custo do combustível, esta parcela aumenta para 26,59%.

Figura 23. Resultados horários da simulação de um sistema solar-diesel-bateria durante 10 dias de operação.



Fonte: produção do próprio autor

Figura 24. Resultados gráficos da análise econômica para o SHGE simulado no exemplo; (a) balanço dos custos de cada componente e, (b) participação dos custos de cada componente no custo nivelado total do sistema.



Fonte: produção do próprio autor

5 MÓDULO DE OTIMIZAÇÃO

A metodologia proposta no presente estudo utiliza a metaheurística Algoritmos Genéticos (AG) como método de otimização para resolver o problema de dimensionamento de sistemas híbridos de geração de energia baseados em fontes renováveis. Como mostra a Figura 5 no capítulo 0, o módulo de otimização da ferramenta desenvolvida incorpora um algoritmo AG que, a partir das informações fornecidas pelo módulo de simulação, procura a melhor configuração de SHGE que otimize os critérios definidos pelo usuário.

Para tal fim, foi desenvolvida uma *toolbox* em Matlab® (*GAtoolbox*) que implementa um algoritmo de otimização baseado em AG. A *GAtoolbox* utiliza funções da linguagem computacional Matlab® para constituir uma ferramenta versátil que permite a implementação de um amplo leque de configurações de AG. A *GAtoolbox* foi concebida como uma ferramenta de otimização de uso geral, a qual pode ser utilizada para resolver problemas de otimização global mono e multiobjetivo, com e sem restrições. Durante o decorrer da presente pesquisa de doutorado utilizou-se a *GAtoolbox* para estudar o funcionamento dos AG, tendo constituído uma ferramenta fundamental para avaliar o desempenho de diferentes configurações de AG e ganhar um maior conhecimento sobre sua operação. Permitiu testar diferentes tipos de codificação das variáveis, diversos operadores e critérios de finalização e experimentar a influência dos parâmetros do algoritmo no desempenho do AG na resolução de problemas de otimização. Finalmente a *GAtoolbox* foi integrada na ferramenta de otimização baseada em simulação para resolver o problema de dimensionamento do SHGE.

O presente capítulo tem como objetivo principal descrever a *toolbox* de Matlab® desenvolvida. Primeiramente, na seção 5.1, se apresentam de maneira sucinta os conceitos teóricos básicos dos Algoritmos Genéticos. Na seção 5.2 descreve-se a estrutura geral da *GAtoolbox*. Os operadores implementados nas diferentes etapas do algoritmo AG mono-objetivo são apresentados de forma breve, dado que não é o objetivo principal deste trabalho (para maiores informações consultar as bibliografias indicadas). No entanto, o algoritmo multiobjetivo incorporado na *GAtoolbox* é descrito com maior detalhe dado que é o foco do presente estudo. Finalmente, na seção 5.3 aplica-se a *GAtoolbox* para a resolução de problemas teste com o intuito de avaliar seu desempenho.

5.1 ALGORITMOS GENÉTICOS APLICADOS A OTIMIZAÇÃO

Os Algoritmos Genéticos (AGs) são algoritmos probabilísticos que formam parte dos Algoritmos Evolucionários (BÄCK; SCHWEFEL, 1992; BÄCK, 1996), família de modelos computacionais inspirados no processo de evolução natural.


Os AGs foram concebidos em 1960 pelo americano John Holland (1992a), com o objetivo inicial de estudar os fenômenos relacionados à adaptação das espécies e da seleção natural que ocorre na natureza, bem como desenvolver uma maneira de incorporar estes conceitos aos computadores (MITCHELL, 1998). Em 1975, Holland publicou *Adaptation in Natural and Artificial Systems*, ponto inicial dos Algoritmos Genéticos. David E. Goldberg (1989), aluno de Holland, nos anos 80 obteve seu primeiro sucesso em aplicação industrial com AGs. Desde então os AGs são utilizados para solucionar problemas de otimização e aprendizado de máquinas.

Assim como no processo evolutivo das espécies, os AGs manipulam uma população de indivíduos, cada um com um valor de aptidão (*fitness*) associado, para uma nova geração de indivíduos, utilizando os princípios Darwinianos de reprodução e sobrevivência dos mais aptos, realizando operações genéticas de seleção, recombinação e mutação. Cada indivíduo da população representa uma possível solução; portanto, basicamente o que o AG faz é buscar dentre o conjunto de soluções do espaço de busca, sempre em direção do ótimo global, o indivíduo de maior aptidão (ZITZLER; LAUMANN; BLEULER, 2004). O princípio funcional do AG em sua configuração mais simples é representado na Figura 25. As etapas mais importantes do algoritmo são a geração da população inicial de soluções, a avaliação da função aptidão e a geração de novas populações através da aplicação dos operadores genéticos.

As principais diferenças dos AGs com relação aos métodos clássicos de otimização podem se resumir nos seguintes pontos (SIVANANDAM; DEEPA, 2007):

- Trabalham com representações das possíveis soluções no formato de um código genético, em lugar de com o valor real das soluções.
- Realizam buscas simultâneas no espaço de possíveis soluções através de uma população de indivíduos.
- Utilizam apenas o valor da função a otimizar (função aptidão), não necessitando das derivadas ou outra informação adicional. Isto permite resolver problemas com pouco conhecimento prévio.
- Utilizam regras de transição probabilísticas, em lugar de determinísticas.

Figura 25. Diagrama de funcionamento do Algoritmo Genético simples



Fonte: (CAO; WU, 1999).

A crescente popularidade, e consequente empregabilidade dos AG, pode ser atribuída a sua robustez e eficiência quando utilizados na resolução de problemas mais complexos, nos quais, muitos métodos clássicos da programação matemática falham (DEB, 2014).

Um método de otimização para ser considerado eficiente deve fazer uso equilibrado de dois processos: intensificação da busca em uma região promissória do espaço de soluções (exploração) e diversificação do processo de busca pela solução (exploração) (MITCHELL, 1998). Embora nos AGs, assim como em todos os métodos metaheurísticos, encontrar a melhor configuração do algoritmo que permita o balanceamento entre estes dois processos não é trivial, tem-se demonstrado que a técnica de otimização via AGs comporta-se de maneira adequada para uma grande variedade de problemas (BÄCK; FOGEL; MICHALEWICZ, 2000a; GOLDBERG, 1989).

Apesar das vantagens em relação aos métodos clássicos, os AGs têm algumas desvantagens relacionadas principalmente à escolha dos parâmetros dos operadores, os quais devem ser avaliados cuidadosamente; caso contrário pode comprometer a capacidade do algoritmo para encontrar soluções ótimas, assim como dificultar sua convergência, levando a tempos de processamento inviáveis (BASTOS, 2004). Apesar destas desvantagens, os AGs continuam sendo um dos métodos de otimização metaheurística mais utilizados no campo da engenharia (AKACHUKWU et al., 2014).

5.2 DESCRIÇÃO DA GATOOLBOX

A *GAtoolbox* conta com quatro módulos principais, como se mostra na Figura 26: Definição do problema de Otimização, Definição das variáveis, Geração da população inicial e Evolução. Estes módulos interagem trocando informações que possibilitam o funcionamento do algoritmo. Dentro de cada módulo há uma série de sub-rotinas com tarefas específicas. Cada uma dessas sub-rotinas pode ser executada por diferentes operadores disponíveis na *GAtoolbox*. Desta forma o AG pode adotar diferentes configurações segundo os operadores escolhidos pelo usuário.

5.2.1 Módulo definição do problema de otimização


O primeiro passo no processo de otimização consiste em caracterizar o problema. Assim, considerando a definição geral de um problema de otimização (SIMON, 2013):

$$\begin{aligned}
 &\text{Minimizar} && f_m(\vec{x}) && m=1,2,\dots,M \\
 &\text{sujeito a} && g_j(\vec{x}) \geq 0 && j=1,2,\dots,J \\
 & && h_k(\vec{x}) = 0 && k=1,2,\dots,K \\
 & && x_i^{lb} \leq x_i \leq x_i^{ub} && i=1,2,\dots,n \\
 & && \vec{x} \in S
 \end{aligned} \tag{5.1}$$

Devem-se fornecer as seguintes informações:

Função/ões objetivo $\Rightarrow$	$f_m(\vec{x})$	$f_m(\vec{x}) = (f_1(\vec{x}), f_2(\vec{x}), \dots, f_M(\vec{x}))^T$
Número de objetivos $\Rightarrow$	m	$m=1,2,\dots,M$
Número de variáveis $\Rightarrow$	n	$\vec{x} = (x_1, \dots, x_n) \in \Re^n$
Restrições de desigualdade $\Rightarrow$	$g_j(\vec{x}) \geq 0$	$j=1,2,\dots,J$
Restrições de igualdade $\Rightarrow$	$h_k(\vec{x}) = 0$	$k=1,2,\dots,K$
Intervalo de variação das variáveis $\Rightarrow$	$[x_i^{lb}, x_i^{ub}]$	$x_i^{lb} \leq x_i \leq x_i^{ub} ; i=1,2,\dots,n$

Por definição, o algoritmo implementado na *GAtoolbox* minimiza a função objetivo, ou seja, resolve o problema da forma $\min f(x)$. No entanto, para resolver um problema de maximização basta aplicar a propriedade $\max \{f(x) : x \in S\} = -\min \{-f(x) : x \in S\}$ (HORST; PARDALOS; NGUYEN, 2000).

Figura 26. Estrutura operacional da *GAtoolbox*.

Fonte: produção do próprio autor

5.2.2 Módulo definição das variáveis

Antes de começar com a simulação, é preciso definir o tipo e a representação das variáveis que serão utilizadas pelo algoritmo. Tipicamente a escolha do tipo de variável no espaço de busca real depende do problema em questão, podendo ser decimal real, decimal inteira ou mista. O AG pode trabalhar diretamente com as variáveis reais ou pode trabalhar com as variáveis em forma codificada, p. ex. código binário, código *gray*, entre outros. Desta forma, em função do tipo de variável definida pelo problema e o tipo de representação utilizada pelo AG, definida pelo usuário, haverá ou não necessidade de decodificação para passar do espaço de trabalho real para o espaço de trabalho do AG, como se pode ver na Tabela 4. A *GAtoolbox* permite apenas a codificação das variáveis em formato binário.

Tabela 4. Combinação de tipo de representação de variáveis.

Formato	Espaço de trabalho do AG	Espaço de trabalho real	Necessidade de decodificação?
0	binário	real decimal	Sim
1	binário	inteiro decimal	Sim
2	real decimal	real decimal	Não
3	inteiro decimal	inteiro decimal	Não

Fonte: produção do próprio autor

Para trabalhar com variáveis inteiras adota-se um método de truncamento para produzir números inteiros a partir de variáveis reais, desta forma utilizam-se os mesmo operadores para ambos os tipos de variáveis. O método de truncamento adotado foi proposto por Deep et al. (2009), e é definido pela equação (5.2):

$$\bar{x}_i = \begin{cases} x_i & \text{se } x_i \in \mathbb{Z} \\ \lfloor x_i \rfloor & \text{se } r \geq 0,5 \\ \lceil x_i \rceil & \text{se } r < 0,5 \end{cases} \quad (5.2)$$

sendo,

x_i : variável real decimal.

$\bar{x}_i$: variável real inteira, obtida pelo processo de truncamento.

r : número aleatório $r \sim U(0,1)$.

$\lfloor x_i \rfloor$: indica o número arredondado para o inteiro menor.

$\lceil x_i \rceil$: indica o número arredondado para o inteiro maior.

5.2.3 Módulo geração da população inicial

Neste módulo gera-se a primeira população de indivíduos em função do tipo de variável previamente definida e a faixa de variação das variáveis. A *GAtoolbox* cria a primeira população de indivíduos de forma aleatória.

Caso a representação das variáveis seja binária, gera-se uma matriz composta por $\{0,1\}$ de dimensão $pop = N_{pop} \times chromLength$; sendo N_{pop} o tamanho da população (definida pelo usuário) e $chromLength = strLength \times n$ é a longitude do cromossomo, isto é, o número de variáveis, n , vezes o número de bits de cada gene, $strLength$. O número mínimo de bits do gene ($strLength$) depende da precisão requerida para representar a variável.

Caso a representação das variáveis seja real, inicia-se a primeira geração de indivíduos de forma aleatória, no intervalo definido pelos limites superior e inferior de cada variável e de dimensão $pop = N_{pop} \times n$.

Caso o usuário precise replicar a simulação partindo da mesma população, a *GAtoolbox* tem a opção de especificar a população para iniciar o algoritmo.

5.2.4 Módulo evolução

Este módulo é o encarregado de aplicar os operadores de evolução à população de indivíduos, compõe-se das seguintes sub-rotinas.

5.2.4.1 Seleção

A sub-rotina de seleção é o primeiro operador que se aplica para selecionar bons indivíduos da população para formar uma população intermediária (*mating pool*). A partir desta população intermediária será aplicado o próximo operador de cruzamento. O processo de seleção segue os seguintes passos (DEB, 2004):

i) Atribuir um valor de aptidão (*fitness*) a cada indivíduo. Na *GAtoolbox* isto pode ser feito por meio dos seguintes métodos (CHIPPERFIELD; FLEMING; FONSECA, 1994; SUMATHI; HAMSAPRIYA; SUREKHA, 2008):

- Ranking linear (*linear ranking*).
- Ranking não-linear (*non-linear ranking*).

ii) Em função do seu valor de aptidão, selecionar os bons (geralmente acima da média) indivíduos para formar parte da população intermediária. Os operadores disponíveis para fazer isto são:

- Método da roleta (*roulette wheel method*) (HOLLAND, 1992).
- Amostragem universal estocástica (*stochastic universal sampling*) (BAKER, 1987).
- Seleção por torneio (*tournament method*) (GOLDBERG; DEB, 1991).
- Ranking geométrico normalizado (*normalized geometric method*) (MICHALEWICZ, 1996).

iii) Eliminar os indivíduos ruins para que as cópias dos bons indivíduos sejam inseridas.

5.2.4.2 Recombinação

O operador seleção não gera novos indivíduos, mas apenas gera múltiplas cópias dos bons indivíduos em detrimento dos ruins. Portanto, é necessário aplicar o operador de recombinação para gerar novos indivíduos e assim diversificar a população (processo de exploração). Isto é feito a partir da combinação do material genético de dois indivíduos (os progenitores), para criar dois novos indivíduos (filhos), com a esperança de que sejam mais aptos (CHIPPERFIELD; FLEMING; FONSECA, 1994). O operador recombinação é aplicado de forma probabilística em função da taxa de recombinação, p_r , a qual geralmente varia entre 0,5 e 1,0 (EIBEN; SMITH, 2003). O tipo de operador de recombinação utilizado pelo *GAtoolbox* depende da representação das variáveis adotada. Os operadores disponíveis são:

- Todas as representações
 - Recombinação discreta (também chamada de cruzamento uniforme) (MÜHLENBEIN; SCHLIERKAMP-VOOSEN, 1993).
- Representação binária, real e inteira
 - Cruzamento em um ponto (GOLDBERG, 1989; HOLLAND, 1992).
 - Cruzamento em dois ou múltiplos pontos (GOLDBERG, 1989; HOLLAND, 1992).
 - Cruzamento aleatório (*shuffle crossover*) (CARUANA; ESHELMANN; SCHAFFER, 1989).
- Representação real e inteira
 - BLX- α (*blend recombination*) (ESHELMAN; SCHAFFER, 1993).

- Recombinação linear (*line recombination*) (MÜHLENBEIN; SCHLIERKAMP-VOOSEN, 1995).
- Recombinação aritmética (*arithmetic recombination*) (EIBEN; SMITH, 2003; HOUCK et al., 1995; MICHALEWICZ, 1996).
- BLX-0.0 (*flat recombination*) (RADCLIFFE, 1991).
- Recombinação intermediária (*intermediate recombination*) (MÜHLENBEIN; SCHLIERKAMP-VOOSEN, 1993).

5.2.4.3 Mutação

A aplicação recursiva dos operadores de seleção e recombinação pode levar à perda de informação genética potencialmente importante. É por este motivo que se faz necessário aplicar um operador que promova a diversidade da população (processo de exploração), de modo a não ficar preso num ótimo local (BASTOS, 2004; WHITLEY, 1994). Isto é feito através do operador mutação, o qual altera de forma aleatória a informação genética dos indivíduos da população. O processo de mutação é controlado por uma probabilidade ou taxa de mutação, p_m . Quando o AG é configurado para trabalhar com codificação binária, utiliza-se uma taxa p_m baixa [0,001, 0,01]. Já para codificação real, recomenda-se um valor de $p_m = 1/n$, sendo n o número de variáveis (BÄCK; FOGEL; MICHALEWICZ, 2000b). O tipo de operador de mutação utilizado pelo *GAtoolbox* depende da representação das variáveis utilizada. Os operadores disponíveis são:

- Representação binária
 - Mutação binária (*binary mutation*) (GOLDBERG, 1989; HOLLAND, 1992).
- Representação real e inteira
 - Mutação breeder (*breeder mutation*) (MÜHLENBEIN; SCHLIERKAMP-VOOSEN, 1993; MÜHLENBEIN, 1994).
 - Mutação boundary (*boundary mutation*) (HOUCK et al., 1995; MICHALEWICZ; JANIOW, 1993; SUMATHI; HAMSAPRIYA; SUREKHA, 2008).
 - Mutação uniforme (*uniform mutation*) (HOUCK et al., 1995).
 - Mutação multi-uniforme (*multi-uniform mutation*) (JOINES; KING; CULBRETH, 2012).
 - Mutação não-uniforme (*non-uniform mutation*) (MICHALEWICZ, 1996).

- Mutação multi-não-uniforme (*multi-non-uniform mutation*) (JOINES; KING; CULBRETH, 2012).

5.2.4.4 Critério de parada

Se o AG é corretamente aplicado, a população evoluirá em sucessivas gerações de forma que a aptidão média de todos os indivíduos da população, assim como a aptidão do melhor indivíduo irá se aprimorar em direção ao ótimo global. Sendo assim, pode-se dizer que o algoritmo converge para a solução ótima (DE JONG, 1975). Sabendo então que as sucessivas populações continuam a melhorar, é preciso definir um critério para dar por finalizado o algoritmo.

O trabalho publicado por Jain, Pohlheim e Wegener (2001) avalia os critérios de parada mais amplamente utilizados e faz recomendações sobre sua utilização. Baseando-se nesse estudo, os critérios de parada disponíveis na *GAtoolbox* são:

- Tempo máximo e máximo número de gerações (MILTON, 2009).
- Diferença mínima com relação ao ótimo conhecido (*hitting bound*) (JAIN; POHLHEIM; WEGENER, 2001).
- Diferença entre as médias (*running mean*) (JAIN; POHLHEIM; WEGENER, 2001).
- Desvio padrão dos objetivos (EIBEN; SMITH, 2003).
- Melhor-pior (*best-worst*) (JAIN; POHLHEIM; WEGENER, 2001).
- Phi (VÖSSNER, 1997).

5.2.4.5 Reinservação

Caso o critério de parada não for cumprido, a população será submetida a um novo processo de evolução. Portanto, é preciso inserir os novos indivíduos gerados na população original. O critério mais simples é gerar a mesma quantidade de filhos que de pais, e substituir a população completa. No entanto, pode-se gerar uma quantidade de filhos menor que o tamanho da população original, nesta situação devem-se estabelecer regras para definir quais pais serão substituídos. Caso sejam gerados mais filhos que o tamanho da população, devem ser escolhidos os indivíduos que sobreviverão para a próxima geração. Na *GAtoolbox*, estão disponíveis dois métodos de reinservação:

- Reinservação uniforme (*uniform reinsertion*) (SARMADY, 2007).
- *Worst and fitness-based reinsertion* (POHLHEIM, 2006).

5.2.5 Tratamento de restrições

Em geral, as restrições são parte integral da formulação de qualquer problema de otimização, daí a importância de adotar um método eficiente para o tratamento de restrições compatível com os AG.

Na definição do problema de otimização mostrada na equação (5.1), $\vec{x} \in F \subseteq S$, sendo $S \subseteq \mathbb{R}^n$ o espaço de busca das variáveis de decisão ($\vec{x}$) e o conjunto $F \subseteq S$ define um espaço de busca de soluções factíveis (BÄCK; FOGEL; MICHALEWICZ, 2000a). Devido à forma complexa que podem adotar as restrições, a relação entre a região factível (F) e o espaço de busca (S) pode resultar complexa (XINJIE; MITSUO, 2010).

O tratamento de restrições de igualdade $h_k(\vec{x}) = 0$ constituem, muitas vezes, a parte mais difícil nos problemas de otimização com restrições, dado que fazem da região F significativamente menor em relação ao espaço S . Portanto, é prática comum “relaxar” as restrições de igualdade transformando-as em restrições de desigualdade, segunda a equação (5.3):

$$g_{k+J} \equiv \delta_t - |h_k(\vec{x})| \geq 0 \quad (5.3)$$

sendo δ_t um valor de tolerância, ou seja, um valor muito pequeno definido pelo usuário¹⁰. Este procedimento leva o número de restrições de desigualdade para $m = J + K$.

Os AG possuem uma grande vantagem para lidar com problemas de otimização com restrição, pois trabalham com uma população de indivíduos entre os quais pode haver soluções factíveis ou não factíveis, que permitem promover a busca de soluções em diferentes regiões. Esta propriedade, denominada paralelismo implícito, é especialmente útil nos casos em que as regiões factíveis são desconectadas ou descontínuas (XINJIE; MITSUO, 2010).

Muitas técnicas de tratamento de restrições para ser utilizadas com Algoritmos Evolutivos têm sido propostas na literatura, como exposto nos trabalhos de (COELLO COELLO, 1999; MICHALEWICZ, 1995).

O método adotado na *GAtoolbox* para o tratamento de restrições é o baseado em regras de dominância (MICHALEWICZ; SCHOENAUER, 1996). Esta abordagem tem a vantagem de requerer poucos parâmetros para sua aplicação, fazendo-a especialmente atrativa para ser utilizada com AG, os quais já possuem uma série de parâmetros que devem ser definidos para o correto funcionamento do algoritmo. Os métodos de tratamento de restrições disponíveis na *GAtoolbox* são:

¹⁰ $\delta_t = 0,001$ ou $\delta_t = 0,0001$ são valores comumente adotados (XINJIE; MITSUO, 2010).

- Método de Deb (2000).
- Método de Coello Coello e Montes (2002a).

A lógica de operação de ambos os métodos é muito similar, no entanto onde eles se diferenciam é na forma que é efetuada a seleção por torneio para escolher a solução dominante entre duas concorrentes.

5.2.6 Otimização multiobjetivo


A resolução de problemas multiobjetivo requer de uma abordagem diferente com relação ao caso mono-objetivo. Assignar um valor de aptidão para os indivíduos da população não é tarefa trivial quando há mais de um objetivo conflitante. Portanto, utilizam-se AGs específicos para a resolução de problemas multiobjetivo. A *GAtoolbox* incorpora o algoritmo denominado *Nondominated Sorting Genetic Algorithm II* (NSGA-II) para tal fim. A seguir apresentam-se alguns conceitos básicos e definições próprias da otimização multiobjetivo, necessárias para entender a operação do algoritmo NSGA-II, apresentado na sequência.

5.2.6.1 Diferenças entre otimização mono-objetivo e multiobjetivo

A principal diferença da otimização multiobjetivo com relação à otimização mono-objetivo consiste na inexistência de uma única solução ótima, mas sim um conjunto de soluções eficientes em que nenhuma solução é melhor que as demais em relação a todos os objetivos, já que o *trade-off* (compromisso) entre os objetivos conflitantes é importante (DEB, 2004). Assim, o conceito de otimização em um cenário multiobjetivo consiste em escolher, num conjunto de soluções em que os valores dos objetivos não podem ser melhorados simultaneamente (conjunto de soluções ótimas de Pareto), a melhor solução segundo critérios de tomada de decisão de um agente decisor (SARENI; ROBOAM; RE, 2005). Essa diferença, comparada com a abordagem mono-objetivo, se mostra na Figura 27.

O bloco de tomada de decisão, que ocorre de forma explícita na otimização multiobjetivo como indicado na Figura 27, é o que representa essa intervenção do agente decisor, o qual pode introduzir suas preferências ou prioridades em diferentes fases do processo de otimização. Neste contexto surge uma possível classificação dos métodos de otimização multiobjetivo (DEB, 2014; SARENI; ROBOAM; RE, 2005): i) métodos *a-priori*, ii) métodos progressivos, e iii) métodos *a-posteriori*.

Figura 27. Diferença em as abordagens de otimização mono e multiobjectivo.



Fonte: adaptado de (MACIEL SILVA, 2012)

O algoritmo de otimização multiobjetivo incorporado na *GAtoolbox* enquadra-se dentro de grupo de métodos *a-posteriori*. Nesta abordagem o processo de decisão é feito após o processo de busca de soluções. Ao final do processo de busca tem-se um conjunto de soluções ótimas de Pareto, a partir do qual o decisor deve selecionar uma solução que representa a solução adequada (solução final) (SARENI; ROBOAM; RE, 2005).

5.2.6.2 Conceitos de dominância de Pareto

A seguir se apresentam algumas definições importantes utilizadas na otimização multiobjetivo, para problemas de minimização; para problemas de maximização são análogas.

Definição 1: Dominância de Pareto (*Pareto Dominance*)

Tomando duas soluções factíveis quaisquer $x_1, x_2 \in S$ diz-se que x_1 domina x_2 , se as condições abaixo são verdadeiras:

- i) A solução x_1 não é pior que a solução x_2 em relação a todos os objetivos, ou

$$f_m(x_1) \leq f_m(x_2) \quad \forall m \in \{1, 2, \dots, M\}.$$

- ii) A solução x_1 é estritamente melhor do que x_2 em pelo menos um objetivo, ou $f_m(x_1) < f_m(x_2)$ em pelo menos um $m \in \{1, 2, \dots, M\}$.

Em outras palavras, x_1 é pelo menos igual que x_2 em todos os objetivos, e x_1 é melhor que x_2 em pelo um objetivo. Em otimização multiobjetivo usa-se a notação $x_1 \preceq x_2$ para indicar que x_1 domina x_2 . Caso a solução x_1 é estritamente melhor que x_2 em todos os objetivos, diz-se que x_1 domina fortemente x_2 , ou $x_1 \prec x_2$.

É importante observar que apesar da dominância ser definida no espaço das variáveis de decisão, a comparação entre as duas soluções é realizada no espaço das funções objetivo (S), ou seja, o critério de dominância é verificado utilizando-se os resultados da avaliação de cada um dos objetivos.

Definição 2: Soluções ótimas de Pareto (*Pareto Optimality*)

Uma solução $x \in F$, é ótimo de Pareto se e somente se não há $x' \in F$ tal que x' domine x ($F \subseteq S$, sendo S o espaço de busca e F a região factível). Uma solução ótima de Pareto também pode ser denominada como solução não dominada, eficiente ou não inferior.

Definição 3: Conjunto ótimo de Pareto (*Pareto Optimal Set*)

O conjunto de soluções que são não dominadas sobre todo o espaço de busca S , são chamadas de conjunto ótimo de Pareto (P^*).

$$P^* := \{x \in S \mid \neg \exists x' \in S : x' \preceq x\} \quad (5.4)$$

Definição 4: Fronteira de Pareto (*Pareto Front*)

A imagem do conjunto ótimo de Pareto no espaço dos objetivos é denominada fronteira de Pareto (PF^*).

$$PF^* := \{u = f(x) \mid x \in P^*\} \quad (5.5)$$


Para ilustrar os conceitos de dominância de Pareto, na Figura 28 se apresenta um conjunto de possíveis soluções para o caso de um problema de otimização multiobjetivo de minimização considerando dois objetivos (f_1 e f_2). As soluções A, B, C, D, E e F são soluções não dominadas dado que não existe nenhuma outra solução que resulte em valores das funções objetivo menores aos destas, ou seja, cumprem com a Definição 2. Estas soluções

constituem a fronteira de Pareto (Definição 3) sendo as melhores soluções que o algoritmo de otimização multiobjetivo pode encontrar.

As soluções 1, 2, 3 e 4 são soluções dominadas, já que existe alguma outra solução com pelo menos um valor das funções objetivo de menor valor. No entanto, dentro do conjunto de soluções dominadas, podem-se definir diferentes níveis em função do grau de dominância que apresentam. Caso uma solução seja dominada apenas por outra solução, pode-se denominar de solução dominada de primeiro grau, caso seja dominada por duas soluções, pode-se denominar de solução dominada de segundo grau, e assim por diante. Por exemplo, observando a Figura 28, a solução 1 é dominada pelas soluções B e C, então diz-se que a solução 1 é de segundo grau. A solução 4 é dominada pelas soluções B, C, D, 1 e 2, portanto, diz-se que a solução 4 é de quinto grau.

O grau de dominância é utilizado por alguns dos algoritmos de otimização multiobjetivo para definir a aptidão (*fitness*) de cada solução (JUSTESEN, 2009). As soluções não dominadas possuirão maior aptidão que as dominadas; as soluções dominadas de primeiro grau possuirão maior aptidão que as de segundo grau e assim por diante.

Figura 28. Representação de várias soluções num problema de otimização com dois objetivos (f_1 e f_2) a ser minimizados.



Fonte: produção do próprio autor

5.2.6.3 Algoritmo de otimização multiobjetivo NSGA-II

Srinivas e Deb (1994) propuseram em 1994 o algoritmo de otimização multiobjetivo NSGA (*Nondominated Sorting Genetic Algorithm*), com o objetivo de se trabalhar o conceito de dominância e manutenção da diversidade da população simultaneamente seguindo a ideia inicial de Goldberg (1989). No entanto, ao longo dos anos surgiram várias críticas ao NSGA evidenciando sua inferioridade frente a outros algoritmos contemporâneos como o MOGA (*Multi-Objective Genetic Algorithm*) (FONSECA; FLEMING, 1993) e o NPGA (*Niched-Pareto Genetic Algorithm*) (HORN; NAFPLIOTIS; GOLDBERG, 1994). Dentre as críticas recebidas, destacam-se (DEB et al., 2002):

- 1) A alta complexidade computacional na classificação dos indivíduos não-dominados da população.
- 2) Falta de elitismo, mecanismo que assegura a supervivência do melhor indivíduo na seguinte geração, evitando a perda de boas soluções quando estas são encontradas.
- 3) Necessidade de especificar o parâmetro de compartilhamento, σ_{share} , utilizado no mecanismo para assegurar a diversidade da população.

Tendo em vistas essas críticas, os autores Deb et al. (2002) propuseram uma versão melhorada do NSGA, denominada de NSGA-II¹¹, o qual incorpora três mecanismos que visam contornar as limitações do NSGA, estes são:


- a) **Elitismo:** o algoritmo trabalha com uma população combinada (R_t) formada pela população de pais (P_t) e de filhos (Q_t), $R_t = P_t \cup Q_t$. Pais e filhos competem de acordo com as regras de dominância, assegurando assim o elitismo.
- b) **Fast Nondominated Sorting (FNS):** mecanismo de classificação de indivíduos da população em diferentes níveis segundo a dominância de Pareto. Este novo procedimento de classificação caracteriza-se por sua simplicidade e eficiência computacional, reduzindo assim a complexidade do algoritmo (DEB, 2004).
- c) **Crowding Distance Assignment (CDA):** mecanismo “livre de parâmetros” que visa manter a diversidade da população. O mecanismo baseia-se na estimação da densidade de soluções em torno de uma solução de referência por meio de um índice (*crowding distance*). Este índice é utilizado para modificar a aptidão das soluções visando priorizar as soluções mais distantes respeito da solução de referência.

¹¹As diferenças entre o NSGA e o NSGA-II são tão significativas que são considerados como dois algoritmos completamente diferentes por vários pesquisadores.

O procedimento do NSGA-II é ilustrado na Figura 29. O algoritmo NSGA-II começa gerando uma população inicial aleatória P_t de dimensão N_{pop} , e por meio dos operadores genéticos de seleção, recombinação e mutação gera-se uma população de filhos Q_t também de tamanho N_{pop} . Em seguida as duas populações são combinadas para formar uma população $R_t = P_t \cup Q_t$ de tamanho $2 \cdot N_{pop}$. A nova população é classificada de acordo com o critério de dominância usando o mecanismo FNS, e a nova população começa a ser preenchida com os indivíduos de R_t com menor índice de classificação i_{rank} , iniciando pelas soluções dominantes da fronteira 1 e assim por diante. Se a última fronteira a ter seus indivíduos acrescentados na nova população P_{t+1} tiver uma quantidade de soluções que, somada àsquelas já acrescentadas, ultrapassa o tamanho N_{pop} da população P_{t+1} , os indivíduos excedentes são rejeitados segundo o critério de diversidade imposto pelo mecanismo CDA, ou seja, aqueles com maior valor do índice de concentração são os escolhidos para compor P_{t+1} .

Finalmente a nova população P_{t+1} de tamanho $N_{P_{t+1}} = N_{pop}$ é submetida à seleção, recombinação e mutação para gerar a população de filhos Q_{t+1} começando assim uma nova geração. Esse processo é repetido até que o critério de parada seja satisfeito.

Figura 29. Procedimento do algoritmo de otimização multiobjectivo NSGA-II.



Fonte: adaptado de (DEB et al., 2002)

5.2.7 Computação paralela

Com objetivo de reduzir o tempo computacional na execução do algoritmo de otimização baseado na metaheurística AG empregou-se a computação paralela, que é uma técnica de programação utilizada para aumentar o desempenho computacional de tarefas muito extensas e independentes (GONÇALVES MACHADO, 2014).

O Matlab® *Parallel Computing Toolbox* (PCT) permite ao usuário resolver problemas intensivos computacionalmente e com grande volume de dados em computadores multiprocessados e multinúcleo. A biblioteca PCT do Matlab® possibilita executar uma tarefa em paralelo no ambiente de trabalho de uma máquina, usando até oito núcleos para auxiliar o programa principal (LUSZCZEK, 2008).

Para paralelizar um algoritmo utiliza-se a função *parfor* (*parallel for-loops*) do Matlab®. As iterações de *loops parfor* são executadas em *workers* do Matlab®, que são executados nos núcleos do processador. Cada núcleo pode hospedar um *work* (MATHWORKS, 2016). O resultado da execução de um *loop parfor* em Matlab® é o mesmo que o de um *loop for* padrão (não paralelizado). No entanto, devido ao fato de a presença de vários núcleos efetuarem cálculos computacionais simultaneamente no mesmo ciclo, um ciclo *parfor* pode fornecer um desempenho significativamente melhor do que seu análogo *loop for* (MATHWORKS, 2016).

O *loop parfor* é útil em situações onde é necessário executar cálculos simples em muitas iterações de um *loop*, por exemplo, uma simulação de Monte Carlo. No entanto, o uso do *parfor* também tem suas limitações. Se há dependência entre as iterações do *loop*, não se pode usar um *loop parfor*.


A ferramenta de otimização *GAtoolbox* desenvolvida no presente estudo incorpora a possibilidade de computação paralela através do uso da função *parfor*. No entanto, devido à limitação mencionada no parágrafo anterior sobre a necessidade de independência entre iterações *loop*, o paralelismo aplica-se apenas para um processo de cálculo por vez. Portanto, se a otimização do SHGE realiza-se considerando a existência de incertezas, o paralelismo se aplica ao algoritmo de simulação probabilística (computacionalmente mais intensivo), porém não à otimização. No caso em que se desconsideram as incertezas, o paralelismo aplica-se ao algoritmo de otimização. Isto é feito automaticamente pela *GAtoolbox* uma vez definidas as condições do problema.

5.3 AVALIAÇÃO DO DESEMPENHO DA GATOOLBOX

A avaliação do desempenho de um algoritmo de otimização depende de muitos fatores, como mostrado na Figura 30. Assim, torna-se impossível avaliar exaustivamente um algoritmo considerando todos estes fatores envolvidos. No entanto, antes de implementar o algoritmo desenvolvido no problema específico de estudo, é recomendável realizar uma avaliação preliminar de acordo com as necessidades, ou seja, considerando a aplicação do algoritmo.

Nesta seção apresentam-se as principais conclusões obtidas da avaliação do desempenho do AG implementado na *GAtoolbox* para a resolução de diferentes tipos de problemas de otimização. Com o intuito de avaliar diferentes aspectos do algoritmo, foram realizados experimentos em três etapas, considerando em cada etapa problemas teste com características diferentes. Os resultados completos com relação a todos os problemas teste avaliados podem-se encontrar no Apêndice G, no entanto a seguir se expõem os pontos principais.

Figura 30. Avaliação do desempenho do AG.



Fonte: adaptado de (BLASCO FERRAGUD, 2012)

5.3.1 Problemas de otimização mono-objetivo sem restrições

Os objetivos desta etapa foram comparar o desempenho das duas opções de codificações de variáveis disponíveis na *GAtoolbox*, a codificação binária e a codificação real, e explorar as diferentes combinações de operadores de recombinação e mutação disponíveis na *GAtoolbox*, visando identificar a configuração do AG com melhor desempenho.

Para tal fim foram realizados experimentos utilizando duas funções teste para problemas de otimização sem restrições especialmente projetadas para avaliar diferentes características dos algoritmos de otimização, i.e. velocidade de convergência, precisão, e robustez. As funções adotadas são a função de Michalewicz e a função de Schwefel (HAINES; MILLS; FILLIBEN, 2014), considerando ambas com dimensão $n = 2$.

No total foram testadas 40 configurações do AG, estas configurações surgem da combinação dos dois tipos de codificação (binária e real) e dos tipos diferentes de operadores de recombinação e mutação disponíveis na *GAtoolbox*. No intuito de avaliar especificamente estes aspectos, o resto dos parâmetros do AG, como o método de atribuição de aptidão e o método de seleção, foram fixados. Todas as configurações do AG foram executadas 20 vezes a partir de populações iniciais geradas aleatoriamente, avaliando três critérios de desempenho: i) percentagem de sucesso na resolução do problema; ii) tempo de execução e; iii) numero de funções avaliadas. Os resultados se mostram na Tabela G.3 e Tabela G.4 do Apêndice G.

As três configurações do AG que apresentaram melhor desempenho são:

#	Codificação	Operador cruzamento	Operador mutação
1	Codificação real	BLX- α ($\alpha = 0,5$)	Não-uniforme (b = 5)
2	Codificação real	Intermediária	Não-uniforme (b = 5)
3	Codificação real	BLX- α ($\alpha = 0,5$)	Uniforme

Estes resultados são coincidentes com o estudo de Herrera, Lozano e Verdegay (1998) no qual os autores observam que a configuração de AG com codificação real, operador de recombinação BLX- α ($\alpha = 0,5$) e operador de mutação não-uniforme apresenta melhores resultados. A partir desta conclusão, adota-se a configuração de AG codificação real+BLX- α +Não-uniforme, como padrão na *GAtoolbox*.

5.3.2 Problemas de otimização mono-objetivo com restrições

Nos experimentos realizados nesta etapa visou-se avaliar o desempenho dos dois métodos de tratamento de restrições disponíveis na *GAtoolbox*, os quais foram apresentados

na seção 5.2.5. Para tal fim foram empregados 5 problemas amplamente adotados na literatura para testar o desempenho de algoritmos de otimização na resolução de problemas com restrições. Destes problemas, 3 correspondem a formulações matemáticas especialmente desenvolvidas para avaliar métodos de tratamento de restrições, os outros 2 são problemas clássicos de engenharia encontrados na literatura.

Com base nos resultados obtidos na etapa anterior, adota-se a configuração de AG mostrada na Tabela 5, dado que apresentou os melhores resultados.

Tabela 5. Parâmetros do AG mono-objetivo utilizados na resolução de problemas com restrições.

Operador	Método	Parâmetro
Codificação	--	real
Tamanho da população	--	$N_{pop} = 10 \times n$
Estratégia de reinserção	Melhores “ N_{best} ” indivíduos	$N_{best} = N_{pop}$
Critério de parada	– Diferença mínima com relação ao ótimo conhecido	$diff\ 2Opt = 1 \times 10^{-3}$
	– Número máximo de gerações	$maxGen = 5000$
Operador de recombinação	BLX- α	$\alpha = 0,5$
Probabilidade de recombinação	--	$p_r = 0,9$
Operador de mutação	Não-uniforme	$b = 5$
Probabilidade de mutação	--	$p_m = 0,2$

Fonte: produção do próprio autor

Os dois métodos de tratamento de restrições incorporados na *GAtoolbox* se diferenciam no mecanismos para promover a diversidade de soluções. O método proposto por Deb (2000) emprega o mecanismo de nichos (*niching*), já o método de Coello Coello e Montes (2002a) utiliza um fator de seleção, S_r , para controlar probabilisticamente a quantidade de indivíduos que passarão pelo processo de seleção. A fim de testar o desempenho destas duas abordagens, os problemas teste foram resolvidos com os métodos de tratamento de restrições configurados como segue:

- Método de Deb (2000) com e sem mecanismo de nichos.
- Método de Coello Coello e Montes (2002a), com $S_r = 0,7$ e $S_r = 0,8$.

Para todos os problemas, executou-se o algoritmo de otimização 20 vezes com diferentes populações iniciais geradas aleatoriamente. Os resultados se mostram no Apêndice G, seção G.2.

Com base nos resultados obtidos observou-se que, embora todas as configurações de AG testadas conseguiram encontrar a solução ótima, o método de tratamento de restrições proposto por Coello Coello e Montes (2002a) mostrou um melhor desempenho em relação ao

método de Deb (2000), tanto em termos de convergência para ótimo global como em tempo de processamento. Portanto, o método de tratamento de restrições proposto por Coello Coello e Montes (2002a) é adotado como padrão na *GAtoolbox* para resolução de problemas de otimização mono-objetivo com restrições.

5.3.3 Problemas de otimização multiobjetivo com restrições

Nesta etapa foi avaliado o desempenho do algoritmo de otimização multiobjetivo incorporado na *GAtoolbox*, o NSGA-II. Para isto foram utilizados cinco problemas de otimização tomados da literatura, quatro problemas que consideram dois objetivos, e um problema que considera três objetivos conflitantes. A definição dos problemas pode-se encontrar no Apêndice G.

Todos os problemas foram resolvidos com um tamanho de população igual a $N_{pop} = 100$. Foi utilizada a configuração de AG com codificação real das variáveis, operador de recombinação BLX- α com $\alpha = 0,5$, e operador de mutação não-uniforme com $b = 5$. A taxa de recombinação é igual a $p_r = 0,9$ e a taxa de mutação é igual a $p_m = 1/n$. O critério de parada é o máximo número de gerações, $maxGen = 200$.

Para todos os problemas, executou-se o algoritmo de otimização 10 vezes com diferentes populações iniciais geradas aleatoriamente. Os resultados se mostram no Apêndice G, seção G.3.

A partir dos resultados obtidos, pode-se concluir que o algoritmo de otimização multiobjetivo NSGA-II incorporado na *GAtoolbox* é adequado para a resolução não apenas de problemas relativamente simples, com espaços de busca convexos e restrições simples, mas também para problemas mais complexos, com espaços de busca côncavos, não contínuos e com restrições mais difíceis de cumprir, e com maior número de objetivos.

Portanto, o algoritmo NSGA-II (DEB et al., 2002) configurado com os parâmetros mostradas acima é adotado como padrão na *GAtoolbox* para resolução de problemas de multiobjetivo.

PARTE III – RESULTADOS, DISCUSSÕES E CONCLUSÕES

6 OTIMIZAÇÃO BASEADA EM SIMULAÇÃO COM ALGORITMOS GENÉTICOS APLICADA AO PROBLEMA DE DIMENSIONAMENTO DE UM SHGE

No presente capítulo apresentam-se os resultados da implementação da metodologia proposta para o dimensionamento de um SHGE considerando diferentes cenários de operação. Primeiramente, na seção 6.1, se expõem os casos de estudo utilizados para avaliar o desempenho do método de dimensionamento proposto, na seção 6.2 se apresentam os resultados da otimização na configuração mono-objetivo, já na seção 6.3 se apresentam os resultados da otimização multiobjetivo determinística e probabilística.

6.1 CASOS DE ESTUDO

Com objetivo de implementar a metodologia proposta em diferentes cenários de disponibilidade de recursos renováveis e condições de demanda foram adotados dois casos de estudo dos quais se teve acesso às informações necessárias para implementar as simulações; informação meteorológicas, dados de consumo elétrico e características dos componentes. Os casos de estudo adotados correspondem a sistemas de geração de energia reais. A seguir se apresenta brevemente cada um dos casos de estudo; no Apêndice H pode-se encontrar informação técnica mais detalhada sobre os sistemas na sua configuração atual, assim como sobre os dados meteorológicos utilizados nas simulações.

Caso (A) - Sistema Híbrido da Vila Campinas

Vila Campinas está localizada às margens do Rio Manacapuru, nas coordenadas geográficas 3°17' S de latitude e 61°5' W de longitude, e aproximadamente a 53 km em linha reta da sede de seu município, Manacapuru, distante 80 km de Manaus, capital do Estado de Amazonas (ver Figura H.1 no Apêndice H). Seu acesso é somente por via fluvial, barcos de linha oriundos de Manacapuru levam em média seis horas de trajeto até a Vila, porém barcos de motor de popa reduzem o tempo para três horas (CARTAXO FERREIRA, 2000).

A população da região da Vila Campinas é distribuída pelos habitantes que se concentram na Vila, cerca de 1010, e pelos habitantes dispersos em seus arredores, em torno de 1000. A exploração dos recursos naturais é a base econômica, pois representa os poucos meios de trabalho existentes. A pesca é a principal fonte de renda da população e quase a totalidade da agricultura praticada é de subsistência (CARTAXO FERREIRA, 2000).

Atualmente o sistema de geração consiste num sistema híbrido solar-diesel com armazenamento em baterias que fornece energia para 120 unidades consumidoras, 16 horas por dia. Existe o projeto de ampliação do serviço para 24 horas por dia, porém ainda não foi implementado. Na Figura 31(a) se apresenta o perfil de carga de um dia típico da Vila Campinas, a configuração atual e a curva estimada considerando a expansão da geração para 24 horas por dia, segundo estimações de Cartaxo Ferreira (2000). No primeiro caso o consumo médio diário é 369,6 kWh, já no segundo caso consumo diário aumenta para 475,2 kWh.

Para realizar a simulação do sistema é necessário dados horários de consumo elétrico. No entanto, a única informação disponível é o perfil diário mostrado na Figura 31(a). Assim, foi aplicado o modelo de geração de séries sintéticas de curvas de carga a partir do perfil diário apresentado no capítulo 4, seção 4.6.3 (ver Figura 33). Considerando fatores de ruído horário e diário de 15% e um fator de escala de fim de semana de 1,1 obtém-se a série de 8760 valores horários de consumo elétrico da Vila Campinas. O perfil anual de demanda para a Vila Campinas tem as seguintes características: consumo diário médio de 474,88 kWh, demanda média de 19,79 kW, demanda máxima de 43,30 kW e fator de carga de 0,46.

A Figura 32(a) mostra a disponibilidade de recursos renováveis em forma de médias mensais das variáveis velocidade do vento, radiação solar global no plano horizontal e temperatura para a região da Vila Campinas.

Caso (B) - Sistema Híbrido da Vila São Tomé

A Vila de São Tomé está localizada no litoral do município de Maracanã, estado de Pará, nas coordenadas geográficas 0°44'24''S de latitude e 47°28'59''W de longitude. Localiza-se aproximadamente 2 km em linha reta da cidade de Maracanã a qual se encontra a 171 km da capital do Estado, Belém (ver Figura H.1 no Apêndice H). Pode-se chegar à Vila por via fluvial desde Maracanã ou por estrada em condições precárias.

Atualmente o fornecimento elétrico das 67 unidades consumidoras da Vila São Tomé é feito com um sistema híbrido solar-eólico-diesel com armazenamento em baterias, o sistema opera 24 horas por dia. Na Figura 31 (b) se mostra o perfil de carga de um dia típico da Vila São Tomé, que foi estimado pelo grupo de pesquisa GEDAE (Grupo de Estudos e Desenvolvimento de Alternativas Energéticas) da Universidade Federal do Pará (UFPA) a partir de medições de campo (OLIVEIRA BARBOSA, 2006).

A série anual de dados horários de carga para São Tomé foi gerada com o modelo de geração de séries sintéticas de curvas de carga a partir do perfil diário apresentado no capítulo


4, seção 4.6.3 (ver Figura 33). Considerou-se um fatores de ruído horário e diário de 15% e um fator de escala de fim de semana de 1,1. O perfil anual de demanda resultante para a Vila São Tomé tem as seguintes características: consumo médio diário de 55,54 kWh, demanda média de 2,31 kW, demanda máxima de 6,02 kW e fator de carga de 0,38.

Na Figura 32(b) mostra-se a disponibilidade de recursos renováveis em forma de médias mensais das variáveis velocidade do vento, radiação solar global no plano horizontal e temperatura para a região da Vila São Tomé.

6.1.2 Componentes do SHGE


As características técnicas e econômicas dos componentes considerados para as simulações são apresentados no Apêndice I. Dentre os modelos considerados encontra-se o modelo de componente utilizado no sistema real dos casos de estudo da Vila Campinas e Vila São Tomé. Para alguns componentes não foi possível obter as especificações técnicas, no entanto, foi adotado um componente com características similares. As características técnicas e preços de todos os equipamentos foram consultados no mercado nacional brasileiro, sendo que o preço final do componente foi calculado a partir das equações de potência derivadas dos gráficos de custo específico apresentados no capítulo 4, seção 4.9.1.

Figura 31. Perfil de consumo de um dia típico para o caso de (a) Vila Campinas, (b) Vila São Tomé.




Fonte: produção do próprio autor

Figura 32. Valores mensais das variáveis meteorológicas velocidade do vento, radiação solar e temperatura para o caso de (a) Vila Campinas, (b) Vila São Tomé.



Fonte: produção do próprio autor

Figura 33. Geração de séries sintéticas de dados horários de carga para a Vila Campinas e a Vila São Tomé.



Fonte: produção do próprio autor

6.2 OTIMIZAÇÃO MONO-OBJETIVO DE UM SHGE

No caso da otimização mono-objetivo, a configuração de SHGE é otimizada em relação a um único critério (objetivo), enquanto que uma série de restrições devem ser satisfeitas. Segundo a definição geral de um problema de otimização com restrições:

$$\begin{aligned} \text{Minimizar:} \quad & f(\vec{x}) \\ \text{Sujeito a:} \quad & g_j(\vec{x}) \geq 0, \quad j = 1, \dots, J + K \\ & x_i^{lb} \leq x_i \leq x_i^{ub}, \quad i = 1, \dots, n \end{aligned} \quad (6.1)$$

sendo $\vec{x}$ é o vetor de variáveis de decisão de dimensão n ou vetor de variáveis de projeto, $f(\vec{x})$ é a função objetivo a ser minimizada, $g_j(\vec{x})$ são as funções de restrição representadas por J desigualdades e K igualdades, e $[x_i^{lb}, x_i^{ub}]$ estabelece o intervalo de valores que as variáveis de decisão podem adotar. A seguir definem-se cada um destes componentes para o problema particular da otimização do SHGE.

6.2.1 Vetor de Variáveis de Decisão do Problema de Otimização do SHGE

As variáveis de decisão são o número de componentes, o modelo de componente e a estratégia de operação. Neste caso estuda-se um sistema do tipo solar-eólico-moto gerador com armazenamento de energia em baterias eletroquímicas, portanto o vetor de decisão $\vec{x}$ resulta de dimensão $n = 11$:

$$\vec{x} = [x_i]^T = [N_{wt}, T_{wt}, N_{pv}, T_{pv}, N_{dg}, T_{dg}, N_{bt_p}, T_{bt}, N_{conv}, T_{conv}, Ec]^T \quad (6.2)$$

sendo N_{wt} é número de turbinas eólicas, T_{wt} é o modelo de turbina eólica, N_{pv} é o número de módulos fotovoltaicos, T_{pv} é o modelo de módulo fotovoltaicos, N_{dg} é o número de moto geradores, T_{dg} é o modelo de moto gerador, N_{bt_p} é o número de baterias em paralelo no banco de baterias (o número de baterias em série fica definido pela tensão do barramento DC), T_{bt} é o modelo de baterias, N_{conv} é o número de conversores (inversores bidirecionais), T_{conv} é o modelo de conversores e Ec é a estratégia de operação do sistema híbrido. Assim sendo, as variáveis de decisão podem adotar apenas valores inteiros, logo $\vec{x} \in \mathbb{Z}$.

Há a possibilidade de reduzir a dimensão do vetor de decisão caso se fixem as variáveis relacionadas com o modelo de componente e a estratégia de operação, assim a dimensão do vetor pode variar entre $n = 5$ e $n = 11$ segundo a configuração do problema.

6.2.2 Função Objetivo do Problema de Otimização Mono-objetivo do SHGE

Adota-se como o critério a ser minimizado, *i.e.* função objetivo, o Valor Presente Líquido dos Custos (*Net Present Value of Costs* - NPV_C) calculado sobre o tempo de vida do projeto. O conceito e o método de cálculo do NPV_C foi apresentado na seção 4.9, assim utiliza-se a equação (4.22) para seu cálculo.

6.2.3 Restrições do Problema de Otimização Mono-objetivo do SHGE

Além da função objetivo, existem outros critérios que devem ser atendidos pelo SHGE. Estes critérios são definidos através das funções de restrição, que representam os limites dentro dos quais o sistema deve operar (restrições de desigualdade), ou certos valores que devem ser satisfeitos (restrições de igualdade). No problema de otimização do SHGE são definidas um total de 18 restrições, 7 funções de restrições relacionadas com indicadores de desempenho do SHGE mais as 11 restrições das variáveis de projeto:

- a) Restrição relacionada com a confiabilidade:** a primeira restrição que o sistema deve atender está relacionada com a capacidade do SHGE para atender a demanda. Assim, a Probabilidade de Perda de Fornecimento de Energia (*Loss of Power Supply Probability* - $LPSP$) deve resultar inferior a um valor pré-estabelecido (admissível) dado pelo equação (6.3):

$$LPSP \leq LPSP_{adm} \quad (6.3)$$

- b) Restrições relacionadas com a geração de energia:** podem-se especificar duas restrições, uma relacionada à participação da geração renovável no sistema e outra relativa à quantidade de energia excedente. Assim, essas duas restrições assumem a forma das equações (6.4) e (6.5):

$$f_{ren} \geq f_{ren,min} \quad (6.4)$$

$$f_{exess} \leq f_{exess,adm} \quad (6.5)$$

- c) Restrição relacionada com o consumo de combustível:** em certas situações, a quantidade de combustível disponível para a operação do grupo moto gerador de *backup* pode ser limitada por questões de logística e ambientais. Portanto, pode-se especificar um limite máximo de consumo de combustível para o grupo moto gerador em L/ano. Assim sendo, define-se tal restrição através da equação (6.6):

$$F_{dg} \leq F_{dg,adm} \quad (6.6)$$

d) Restrição relacionada com a emissão de poluentes: pode-se especificar um limite para a quantidade de poluentes gerados pelo SHGE (emissões diretas e indiretas), na forma da equação (6.7):

$$EMCO_2 \leq EMCO_{2,adm} \quad (6.7)$$

e) Restrição relacionada com o sistema de armazenamento: em função de prolongar a vida útil das baterias é recomendável não descarregá-las mais do que o limite imposto pelo SOC_{min} . Do mesmo modo, o limite máximo de carregamento é definido pelo SOC_{max} . Assim, para cada intervalo de simulação deve-se verificar que seja respeitada a condição dada pela equação (6.8):

$$SOC_{min} \leq SOC(t) \leq SOC_{max} \quad (6.8)$$

f) Restrições relacionadas com o custo do projeto: pode-se fixar um valor máximo admissível para o valor presente líquido do projeto, definido pela equação (6.9):

$$NPV_C \leq NPV_{C,adm} \quad (6.9)$$

g) Restrições relacionadas com as variáveis de projeto: os limites superior e inferior que definem o espaço de busca, isto é, os possíveis valores que as variáveis de projeto podem adotar, também devem ser especificados segundo a equação (6.10):

$$g_j(\vec{x}) = \begin{cases} N_{wt,min} \leq N_{wt} \leq N_{wt,max} \\ T_{wt,min} \leq T_{wt} \leq T_{wt,max} \\ N_{pv,min} \leq N_{pv} \leq N_{pv,max} \\ T_{pv,min} \leq T_{pv} \leq T_{pv,max} \\ N_{dg,min} \leq N_{dg} \leq N_{dg,max} \\ T_{dg,min} \leq T_{dg} \leq T_{dg,max} \\ N_{bt_p,min} \leq N_{bt_p} \leq N_{bt_p,max} \\ T_{bt,min} \leq T_{bt} \leq T_{bt,max} \\ N_{conv,min} \leq N_{conv} \leq N_{conv,max} \\ T_{conv,min} \leq T_{conv} \leq T_{conv,max} \\ Ec_{min} \leq Ec \leq Ec_{max} \end{cases} \quad (6.10)$$

sendo $N_{i,min}$ e $N_{i,max}$ os limites inferior e superior do número de componentes i , $T_{i,min}$ e $T_{i,max}$ definem os limites inferior e superior dos modelos disponíveis para o componente i , Ec_{min} e Ec_{max} definem as possíveis estratégias de operação para gerenciar o SHGE.

6.2.4 Resultados da otimização mono-objetivo, comparação do método proposto com a ferramenta de otimização HOMER®

Nesta seção o algoritmo de otimização mono-objetivo desenvolvido no presente estudo é comparado com a ferramenta de otimização comercial HOMER®, Modelo Híbrido de Otimização para Fontes Renováveis de Energia (do inglês *Hybrid Optimization Model for Electric Renewables*), desenvolvido pelo *National Renewable Energy Laboratory* (NREL) dos Estados Unidos (HOMER ENERGY LLC. BOULDER COLORADO, 2015).

O software HOMER® é uma das ferramentas de simulação e otimização de sistemas híbridos mais amplamente utilizada na atualidade, devido principalmente à sua simplicidade de utilização e porque oferece uma versão livre com poucas restrições de utilização (SINHA; CHANDEL, 2014). Este software, desenvolvido na linguagem computacional C++, apresenta uma série de vantagens que permite realizar rápidos estudos de pré-factibilidade, estudar a influência dos parâmetros por meio de análise de sensibilidade e avaliar os resultados através de um amplo leque de gráficos e tabelas. No entanto, possui uma série de limitações que são:

- O HOMER® permite apenas a otimização do sistema considerando um único objetivo, a minimização do Valor Presente Líquido do sistema. Permite a opção de penalizar as emissões de poluentes e a energia não fornecida à carga, transformando o problema de otimização multiobjetivo num problema mono-objetivo com penalização, porém não é possível dimensionar o sistema considerando vários objetivos conflitantes de forma independente.
- A técnica de otimização utilizada pelo HOMER® baseia-se no método de Busca Exaustiva, a qual consiste em avaliar todas as possíveis combinações das variáveis discretas (VENKATARAMAN, 2002). Dado que HOMER® não utiliza qualquer técnica de enumeração parcial, o resultado é obtido uma vez que são avaliadas todas as possíveis combinações de componentes e estratégias de operação para o SHGE. Embora esta técnica assegure que o resultado obtido corresponde com o ótimo global, em situações onde o usuário requer avaliar um grande número de componentes e estratégias de operação, o tempo computacional requerido pode resultar excessivo, como será demonstrado a seguir.
- O HOMER® não permite considerar a profundidade de descarga máxima (DOD) do banco de baterias como variável de otimização, sendo que este parâmetro influencia consideravelmente a vida útil das baterias.

- O inversor é modelado com eficiência constante e independente da potência entregue, aproximação que pode influenciar o resultado final da otimização.
- O HOMER® não possui nenhum mecanismo para auxiliar ao usuário na escolha dos limites do intervalo de variação das variáveis de projeto.
- O HOMER® desconsidera variações dos parâmetros entre intervalos de simulação menores que uma hora, e adota a tensão do barramento DC fixa.

Na Tabela 6 se mostra a configuração do problema de otimização implementada para comparação com o HOMER®. As seguintes considerações foram adotadas nesta configuração:

- a) Para o caso de estudo (A) da Vila Campinas adotou-se um possível modelo para cada componente, os quais se correspondem com o modelo de componente do sistema real em operação; e quatro possíveis estratégias de operação (Ec), a estratégia Seguimento da Demanda (SD), a estratégia Ciclo de Carga (CC) e mais duas estratégias que surgem da combinação das anteriores com a estratégia programada definida pelo usuário (DU). Neste caso a estratégia DU consiste em forçar a operação do moto gerador diesel entre às 06:00 h e 24:00 h, o resto do tempo o moto gerador não se encontra disponível para fornecimento da carga.
- b) No caso de estudo (B) da Vila São Tomé considerou-se dois possíveis modelos de aerogerador e dois possíveis modelos de bateria, para o resto dos componentes se considera apenas um modelo que se corresponde com o equipamento instalado no sistema real em operação.

O número máximo de combinações possíveis de componentes e estratégias de operação calcula-se como $N_{wt} \times T_{wt} \times N_{pv} \times T_{pv} \times N_{dg} \times T_{dg} \times N_{bt_p} \times T_{bt} \times N_{conv} \times T_{conv} \times Ec$; no Caso (A) este valor resultou em $1,31 \times 10^8$ e no Caso (B) em $1,40 \times 10^7$. Cabe aclarar que para as simulações realizadas no HOMER® limitou-se a quantidade de possíveis combinações para alguns componentes e estratégias de operação de modo a evitar tempos de simulação excessivos, assim o número total de possíveis combinações resulta menor para o HOMER®, como pode ser visto na Tabela 6.

Tabela 6. Configuração dos problemas de otimização mono-objetivo implementadas para comparação com o HOMER®.

Caso (A) – Vila Campinas		Caso (B) – Vila São Tomé		
	AG	HOMER®	AG	HOMER®
$\left[N_{wt,min}, N_{wt,max}\right]$	[0,55]	[0,55]	[0,15]	[0,15]
T_{wt}	6 kW	6 kW	{1; 6} kW	{1; 6} kW
$\left[N_{pv,min}, N_{pv,max}\right]$	[0,2400]	[0,2400]	[0,200]	[0,200]
T_{pv}	0,64 kWp	0,64 kWp	0,8 kWp	0,8 kWp
$\left[N_{dg,min}, N_{dg,max}\right]$	[0,2]	[0,2]	[0,2]	[0,2]
T_{dg}	48 kW	48 kW	16 kW	16 kW
$\left[N_{bt_p,min}, N_{bt_p,max}\right]$	[0,26]	[0,26]	[0,120]	[0:10:120]
T_{bt}	198 kWh	198 kWh	{198; 3565} kWh	{198; 3565} kWh
$\left[N_{conv,min}, N_{conv,max}\right]$	[0,2]	[0,2]	[0,2]	[0,2]
T_{conv}	50 kW	50 kW	15 kW	15 kW
Ec	{SD; CC; DU+SD; DU+CC}	{SD; CC}	{SD; CC}	{SD; CC}
# de combinações	1,31x10 ⁸	1,47x10 ⁶	1,40x10 ⁷	5,01x10 ⁶
Função objetivo		NPV _C (US\$)		
$LPSP_{adm}$	(%)	0,0		
$f_{ren,min}$	(%)	0,0		
$f_{exess,adm}$	(%)	100		
$F_{dg,adm}$	(L/ano)	Inf		
$EMCO_{2,adm}$	(t/ano)	Inf		
$NPV_{C,adm}$	(US\$)	Inf		

Fonte: produção do próprio autor

No Apêndice I se apresentam as características técnicas e econômicas dos componentes utilizadas como dado de entrada para as simulações. Outros dados de entrada do modelo são o horizonte de análise (vida útil do projeto), considerado em 20 anos; e a taxa de juros real $d_r = 4,8\%$ a.a., calculada a partir de uma taxa de juros nominal $d_n = 10\%$ a.a. e uma taxa de inflação $i_r = 5\%$ a.a.

Define-se o intervalo de variação das variáveis de decisão utilizando o método de pré-dimensionamento apresentado no capítulo 4 (ver Apêndice A), resultando nos intervalos mostrados na Tabela 6.

Em ambos os casos definiu-se a restrição de máxima confiabilidade, i.e. $LPSP_{adm} = 0\%$, já o resto das restrições são mais “relaxadas”.

Baseado nas experimentações realizadas no capítulo 5 com os problemas teste definiu-se a configuração de parâmetros do AG apresentada na Tabela 7.

Tabela 7. Parâmetros do AG mono-objetivo utilizados na simulação.

Operador	Método	Parâmetro
Tamanho da população	--	$N_{pop} = 50$
Função de aptidão	Método de Coello Coello e Montes	$S_r = 0,8$
Método de seleção	Torneio binário	Tamanho do torneio = 2
Estratégia de reinserção	Melhores “ N_{best} ” indivíduos	$N_{best} = N_{pop}$
Critério de parada	Número máximo de gerações	$maxGen = 40$
Operador de recombinação	BLX- α	$\alpha = 0,5$
Probabilidade de recombinação	--	$p_r = 0,9$
Operador de mutação	Não-uniforme	$b = 5$
Probabilidade de mutação	--	$p_m = 1/n$
Computação paralela	não	

Fonte: produção do próprio autor

Todas as simulações da otimização mono-objetivo foram realizadas num computador equipado com Windows 7, 64 Bits, processador Intel Core i7 2,5GHz e memória RAM de 8GB. Os resultados das simulações se mostram na Tabela 8. Pode-se observar que em ambos os casos estudados o algoritmo AG proposto atingiu o ótimo global, conferindo este resultado com a configuração encontrada pelo HOMER®. Pequenas diferenças em alguns dos indicadores se devem ao funcionamento interno de ambos os algoritmos; apesar de utilizar os mesmo modelos matemáticos, existem considerações ou simplificações que levam a resultados levemente discrepantes. Por exemplo, no Caso (A) há uma diferença no consumo anual de óleo diesel do DG, sendo que em ambos os casos as horas de operação resultam iguais, essa diferença influencia no valor do preço final da energia, $LCOE$, e no NPV_C . No Caso (B), a solução do HOMER® inclui 119 painéis fotovoltaicos de 0,08 kWp, sendo que o AG opta por 112, implicando uma leve diferença nas horas de operação do DG (para compensar a menor geração solar). Isto se deve porque o algoritmo do HOMER® considera soluções viáveis àquelas que cumprem com as restrições dentro de um valor de tolerância. A solução do HOMER® com 119 painéis fotovoltaicos resulta num valor de $LPSP = 4,42 \times 10^{-9}\%$, se bem pequeno, que pode ser considerada desprezível, no entanto o algoritmo AG desconsidera essa configuração por não cumprir com a restrição $LPSP_{adm} = 0\%$.

Tabela 8. Resultados da otimização mono-objetivo, comparação dos resultados obtidos pelo método AG proposto e o software HOMER®.

	Caso (A) - Campinas		Caso (B) - São Tomé	
	AG ⁽¹⁾	HOMER	AG ⁽¹⁾	HOMER
Potência do WT (kW)	0,00	0,00	6kW (1x6kW)	6kW (1x6kW)
Potência do PV (kW)	0,00	0,00	8,96kWp (112x0,08kWp)	9,52kWp (119x0,08kWp)
Potência do DG (kW)	48kW (1x48kW)	48kW (1x48kW)	16kW (1x16kW)	16kW (1x16kW)
Capacidade do banco BT (kWh)	0,00	0,00	47,52 (1x20 bat., 198Ah, 12V)	47,52 (1x20 bat., 198Ah, 12V)
Potência do CONV (kW)	0,00	0,00	15kW (1x15kW)	15kW (1x15kW)
Estratégia operação	SD	SD	SD	SD
Probabilidade de Perda de Energia <i>LPSP</i> (%)	0,00	0,00	0,00	4,42x10 ⁻⁹
Excesso de energia <i>f_{excess}</i> (%)	0,64	0,65	20,85	20,63
Fração de energia renovável <i>f_{ren}</i> (%)	0,0	0,0	94,9	95,24
Horas de operação do DG <i>H_{dg}</i> (h/ano)	8760	8760	297,00	277,00
Combustível consumido pelo DG <i>F_{dg}</i> (L/ano)	79517,42	80047,00	750,58	699,00
Investimento inicial <i>C_{icap}</i> (US\$)	74.566,40	74.566,00	137.204,02	137.645,00
Custos operativos ⁽²⁾ <i>C_{operating}</i> (US\$/ano)	76.059,32	74.200,00	4.488,10	4.576,00
Custo nivelado de energia <i>LCOE</i> (US\$/kWh)	0,46	0,50	0,75	0,76
Valor presente líquido <i>NPV_C</i> (US\$)	1.041.865,08	1.018.206,00	194.282,80	195.838,00
Combinações avaliadas (#)	2000	822526	2000	588776
Combinações avaliadas (%)	0,002	55,97	0,01	11,75
Tempo de simulação (min)	18,72	190	18,93	111

⁽¹⁾Melhor valor de 4 simulações.⁽²⁾O custo operativo do sistema é o valor presente da soma do custo anual de O&M, o custo do combustível, o custo anualizado de reposição menos o valor residual.

Fonte: produção do próprio autor


Observa-se que o valor presente líquido (NPV_C) para o sistema do Caso (A) resulta elevado em relação ao valor do investimento inicial, custos operativos e de combustível. Este resultado se deve a que o DG opera de forma contínua durante as 8760 horas do ano, portanto, devido a que se considerou uma vida útil de 10000 horas para este componente, este deve ser substituído praticamente uma vez por ano. Assim, os custos de reposição do DG levam a aumentar o valor do NPV_C final.

A principal vantagem do método baseado em AG é a menor quantidade de vezes que a função objetivo tem que ser avaliada para atingir a solução ótima. No presente problema, onde a avaliação da função objetivo tem um custo computacional relativamente elevado, dado que é preciso simular a operação do SHGE por 8760 horas, essa vantagem fica evidente. Em ambos os casos o algoritmo AG atingiu o ótimo global em 40 gerações, com uma população de 50 indivíduos, isto equivale a 2000 avaliações da função objetivo. Assim, o AG precisou avaliar 0,002% do total de possíveis combinações no Caso (A) e 0,01% no Caso (B). Em contrapartida, o algoritmo HOMER® precisou avaliar 55,97% e 11,75% nos Casos (A) e (B), respectivamente. Neste ponto cabe esclarecer que o HOMER® não precisou avaliar o 100% das possíveis soluções, pois o algoritmo conta com um mecanismo para desconsiderar soluções inviáveis antes de serem simuladas; o algoritmo rejeita soluções que não possuem conversor, soluções com uma quantidade excessiva de conversores além de outras soluções que não cumprem com restrições que podem ser verificadas antes da simulação, reduzindo a quantidade de funções avaliadas e o tempo de processamento. A diferença na quantidade de avaliações da função objetivo se faz evidente no tempo computacional gasto por cada algoritmo, no caso (A) o AG precisou de 10% do tempo gasto pelo algoritmo HOMER®, e no caso (B) o AG precisou de 17% do tempo.

Na Figura 34 mostra-se o gráfico de evolução do melhor resultado da função objetivo (NPV_C) e o valor médio da função objetivo da população do AG para ambos os casos estudados. Observa-se que o algoritmo AG converge rapidamente para o valor final, sendo que no Caso (A), Figura 34(a), a partir da geração número 27 a função objetivo não apresenta variação (os valores da função objetivo do melhor indivíduo e a média da população coincidem). No Caso (B), Figura 34(b), isto acontece a partir da geração 24. Deve-se esclarecer que a velocidade de convergência depende das características da primeira geração, caso o algoritmo gere uma primeira geração com algum indivíduo perto do ótimo, este irá demorar menos tempo para atingir o ótimo global. No entanto, se a primeira geração não fornece indivíduos perto da região factível, o algoritmo irá gastar mais tempo para convergir.

A configuração do problema de otimização estudada nesta seção é relativamente simples pelos seguintes motivos: otimização mono-objetivo, espaço de busca limitado de forma intencional para evitar tempos de processamento demasiadamente elevados quando utilizado o método de busca exaustiva e restrições não muito restritas. No entanto, permite evidenciar as vantagens da abordagem de otimização baseada em simulação com AG proposta no presente trabalho em relação ao método de busca exaustiva implementado no software HOMER®. Na seguinte seção implementa-se o algoritmo proposto para os mesmos casos de estudo, porém aumentando a complexidade do problema.

Figura 34. Evolução da função objetivo NPV_C e média da população para a configuração de menor complexidade do problema de otimização mono-objetivo, (a) Vila Campinas e (b) Vila São Tomé.



Fonte: produção do próprio autor

6.2.5 Resultados da otimização mono-objetivo, problema de maior complexidade

Nesta segunda configuração do problema de otimização mono-objetivo consideram-se 4 possíveis modelos para cada componente do SHGE e 4 possíveis estratégias de operação, desta forma amplia-se o espaço de busca e, portanto, a complexidade do problema aumenta.

Na Tabela 9 se mostra a configuração do problema de otimização estudada na presente seção para os dois casos de estudo avaliados. As seguintes considerações foram adotadas:

- a) Para ambos os casos além dos componentes instalados no sistema real, consideram-se mais 3 modelos para cada componente. Também foram consideradas quatro possíveis estratégias de operação, a estratégia SD, a estratégia CC e mais duas estratégias DU. No Caso (A) (Vila Campinas) a estratégia DU consiste em permitir a operação do moto gerador diesel entre às 06:00h e 24:00h, o resto do tempo o moto gerador não se encontra disponível para fornecimento da carga. No Caso (B) (Vila São Tomé) o grupo moto gerador se encontra disponível entre às 18:00h e 24:00h.
- b) Em ambos os casos considera-se que o SHGE pode contar com um grupo moto gerador de potência nominal menor que a potência pico da carga.
- c) O resto das restrições se expõem na Tabela 9.

Os parâmetros do AG são os mesmos que na configuração estudada na seção 6.2.4 já apresentados na Tabela 5, com a exceção do tamanho da população, que aumentou para $N_{pop} = 100$ indivíduos com o intuito de ampliar a cobertura do espaço de busca.

Nesta configuração do problema não foi possível comparar os resultados do algoritmo AG com o HOMER®, por duas razões. Primeiramente o HOMER® apresenta limitações para a entrada de diferentes marcas/modelos de equipamentos. Podem ser simulados simultaneamente no máximo 10 diferentes tipos de baterias e grupos moto geradores, e 2 diferentes tipos de aerogeradores. Os módulos fotovoltaicos e os inversores, por sua vez, são inseridos por faixa de potência e não por marca/modelo. Por outro lado, o tempo de processamento que requereria o HOMER® para resolver este problema seria proibitivo. Considerando que o algoritmo de busca exaustiva do HOMER® precise avaliar 50% do máximo número de combinações possíveis para cada caso (ver Tabela 9), e sabendo que o algoritmo HOMER® realiza aproximadamente 88 avaliações da função objetivo por segundo, o tempo necessário para resolver o problema do Caso (A) resultaria em aproximadamente 600 anos, e para o Caso (B) seria de 3 anos, evidenciando a ineficiência do método neste tipo de problema de explosão combinatória.

Tabela 9. Configuração de maior complexidade dos problemas de otimização mono-objetivo para os casos estudados.


	Caso (A) – Vila Campinas	Caso (B) – Vila São Tomé
$[N_{wt,min}, N_{wt,max}]$	[0,250]	[0,15]
T_{wt}	{1; 6; 7; 10} kW	{1; 6*; 7; 10} kW
$[N_{pv,min}, N_{pv,max}]$	[0,2400]	[0,400]
T_{pv}	{0,064*; 0,08; 0,11; 0,12} kWp	{0,04; 0,08*; 0,11; 0,12} kWp
$[N_{dg,min}, N_{dg,max}]$	[0,6]	[0,3]
T_{dg}	{2,8; 10; 16; 48*} kW	{2,8; 4; 7; 16*} kW
$[N_{bt_p,min}, N_{bt_p,max}]$	[0,30]	[0,4]
T_{bt}	{198*; 226; 1192; 3565} kWh	{198*; 226; 1192; 3565} kWh
$[N_{conv,min}, N_{conv,max}]$	[0,5]	[0,2]
T_{conv}	{5; 7; 17; 50*} kW	{5; 7; 7; 15*} kW
Ec	{SD; CC; DU+SD; DU+CC}	{SD; CC; DU+SD; DU+CC}
# de combinações	$3,21 \times 10^{12}$	$7,83 \times 10^9$
Função objetivo	NPV_C (US\$)	
$LPSP_{adm}$ (%)	0,0	
$f_{ren,min}$ (%)	0,0	
$f_{exess,adm}$ (%)	100	
$F_{dg,adm}$ (L/ano)	Inf	
$EM_{CO_2,adm}$ (t/ano)	Inf	
$NPV_{C,adm}$ (US\$)	Inf	

*Componentes instalados no sistema real em operação.

Fonte: produção do próprio autor

Os gráficos de evolução da função objetivo e da média da população se mostram na Figura 35. Observa-se que o algoritmo AG converge rapidamente para o valor final, em ambos os casos, a partir da geração número 36 a função objetivo não apresenta variação convergindo todos os indivíduos da população para a solução final. Cabe esclarecer que foram realizadas quatro simulações para cada caso de estudo obtendo-se em todas elas o mesmo resultado.

Figura 35. Evolução da função objetivo NPV_C e média da população para a configuração de maior complexidade do problema de otimização mono-objetivo, (a) Vila Campinas e (b) Vila São Tomé.



Fonte: produção do próprio autor

Na Tabela 10 se expõem os resultados numéricos obtidos pelo algoritmo para a segunda configuração do problema de otimização mono-objetivo (de maior complexidade). A primeira observação a partir dos resultados mostrados na Tabela 10 é que em ambos os casos o algoritmo AG encontrou uma configuração de SHGE com menor custo com relação aos resultados da configuração do problema estudada na seção 6.2.4 (Tabela 8). Isto é, a partir da consideração de outros modelos para cada componente, o algoritmo achou uma configuração com menor NPV_C . No Caso (A) (Vila Campinas), o algoritmo opta pelo hibridismo, passando de um sistema diesel para um sistema solar-diesel-bateria, obtendo uma diminuição no NPV_C de 23%. No Caso (B) (Vila São Tomé), também o algoritmo opta por um sistema solar-diesel-bateria, sendo que na seção 6.2.4 (Tabela 8) o sistema era eólico-solar-diesel-bateria. Nesta segunda configuração a potência do arranjo fotovoltaico resulta maior, diminui a potência do moto gerador e aumenta a capacidade do banco de baterias, obtendo deste modo uma redução do NPV_C de 17%.

Em ambos os casos o sistema híbrido definido pelo algoritmo AG não inclui aerogeradores, isto se deve porque o recurso eólico em ambos locais é relativamente baixo, sobre tudo no Caso (A) (Vila Campinas). Em contrapartida, o recurso solar apresenta um nível excelente ao longo de todo o ano, não existindo praticamente variação sazonal do recurso (ver gráficos sazonais no Apêndice H). Outro fator importante é a queda que têm experimentado os preços dos painéis fotovoltaicos nos últimos anos, aliado ao menor custo de operação e manutenção (O&M) requerido por este tipo de fonte de geração em comparação ao sistema eólico, faz com que a opção de hibridismo solar-diesel-baterias seja a mais atrativa para os casos avaliados.

Outra constatação interessante pode ser feita a partir da configuração de sistema híbrido proposta pelo algoritmo AG para o Caso (B). Na configuração mostrada na Tabela 10 observa-se que o sistema conta com um moto gerador de 2,8 kW de potência nominal, menor que a potência pico da carga de 6,02 kW. Em compensação, a capacidade do banco de baterias permite uma autonomia de mais de 3 dias frente à falta de geração. Esta configuração é apenas possível devido à consideração b) estabelecida no início da simulação, a partir da qual se permite um sistema com moto gerador de potência menor à potência pico da carga. Caso o projetista opte por uma situação mais conservadora, basta com especificar uma potência mínima para o moto gerador igual à potência máxima da carga.

Tabela 10. Resultados numéricos para a configuração de maior complexidade do problema de otimização mono-objetivo.

	Caso (A) – Vila Campinas AG ⁽¹⁾	Caso (B) – Vila São Tomé AG ⁽¹⁾
Potência do WT (kW)	0,00	0,00
Potência do PV (kWp)	149,40 (1245x0,12 kWp)	18,72 (156x0,12 kWp)
Potência do DG (kW)	48,00 (3x16 kW)	2,80 (1x2,8 kW)
Capacidade do banco BT (kWh)	855,60 (120x1 bat. 3565Ah, 2V)	286,08 (120x1 bat. 1192 Ah, 2V)
Potência do CONV (kW)	35,00 (7x5 kW)	5,00 (1x5 kW)
Estratégia operação	SD	SD
Energia consumida pela carga (kWh/ano)	178253,48	20272,83
Energia não suprida, <i>LPSP</i> (kWh/ano)	0,00	0,00
Probabilidade de Perda de Energia, <i>LPSP</i> (%)	0,00	0,00
Excesso de energia, f_{exess} (%)	4,33	5,32
Fração de energia renovável, f_{ren} (%)	86,24	99,66
Vida útil das BT, LT_{bt_exp} (ano)	10,56	20,00
Autonomia do sistema, BTB_{aut} (dia)	1,23	3,61
Horas de operação do DG, H_{dg} (h/ano)	1797,00	105,00
Combustível consumido pelo DG, F_{dg} (L/ano)	11263,85	46,48
Emissões no ciclo de vida, $EMCO_2$ (tCO2-eq/ano)	29,76	0,14
Investimento inicial, C_{icap} (US\$)	524.288,75	140.584,12
Custos operativos, $C_{operating}$ (US\$/ano)	20.281,88	1.656,83
Custo nivelado de energia, $LCOE$ (US\$/kWh)	0,345	0,627
Valor presente líquido, NPV_C (US\$)	782.227,44	161.655,13
Combinações avaliadas (#)	5000	5000
Combinações avaliadas (%)	$1,56 \times 10^{-7}$	$6,39 \times 10^{-5}$
Tempo de simulação (min)	49,62	39,78

⁽¹⁾Melhor valor de 4 simulações.


Fonte: produção do próprio autor

Também cabe um comentário a respeito da quantidade de conversores da configuração do sistema para o Caso (A). O algoritmo AG indica o uso de 7 unidades do conversor de menor potência, de 5 kW, o qual é coerente na visão do algoritmo, pois este conversor apresenta a melhor relação custo/eficiência entre todos os modelos disponíveis. Porém, tecnicamente pode resultar mais viável instalar 3 conversores de 17 kW ou mesmo um de 50 kW. Esta situação pode ser evitada se define-se a quantidade máxima de conversores a partir do modelo de maior capacidade, em lugar de considerar o modelo de menor potência nominal, como foi feito nesta simulação.

A Figura 36 mostra contribuição de cada componente gerador na produção mensal para os dois casos estudados. Observa-se que em ambos os casos o sistema fotovoltaico (PV na Figura 36) fornece mais de 80% da potência demandada pela carga durante todos os meses do ano. O uso do moto gerador diesel (DG na Figura 36) fica reservado para fornecer a carga em períodos de falta de geração renovável e baixo estado de carregamento das baterias, segundo a estratégia de operação escolhida pelo algoritmo.


Finalmente, na Figura 37 se mostra a participação dos custos de cada equipamento no NPV_C total do sistema. Observa-se que no sistema da Vila Campinas, Figura 37(a), a maior parcela corresponde ao custo do subsistema fotovoltaico (PV), sendo que o custo de investimento inicial mais o custo de O&M do sistema PV representam 33,5% do NPV_C do sistema híbrido. O banco de baterias é o segundo maior custo neste caso, representando 27,12% do NPV_C . Os custos associados ao moto gerador representam apenas o 7,72% do NPV_C , no entanto quando se adiciona o custo do combustível, esta parcela aumenta para 26,59%. No caso do sistema da Vila São Tomé, observa-se que o custo relacionado com materiais elétricos e construção, serviços e acessórios englobados na categoria “Outros” na Figura 37(b) representa a maior parcela com 38,47%; lembrando que estes custos correspondem ao sistema real em operação, reportados por Oliveira Barbosa e Pinho (OLIVEIRA BARBOSA; PINHO, 2007). As baterias e o subsistema fotovoltaico representam quase o 60% do NPV_C no sistema da Vila São Tomé, sendo que apenas o banco de baterias representa 37,49% do custo total, evidenciado a importância que tem o sistema de armazenamento em sistemas de geração autônomos.

Figura 36. Participação de cada componente na geração mensal para os casos de estudo (a) Vila Campinas e (b) Vila São Tomé.



Fonte: produção do próprio autor

Figura 37. Participação dos custos de cada componente no custo nivelado total do sistema, casos de estudo Vila Campinas (a) e Vila São Tomé (b).



Fonte: produção do próprio autor

6.3 OTIMIZAÇÃO MULTIOBJETIVO DE UM SHGE

Nesta seção é aplicada a abordagem de otimização baseada em simulação com AG para o caso de otimização multiobjetivo. Deste modo, o SHGE é otimizado com relação a dois ou mais critérios principais ou funções objetivo, enquanto que uma série de critérios secundários (restrições) são satisfeitos. São avaliadas as duas propostas de otimização-multiobjetivo apresentadas no capítulo 0, a otimização determinística e a otimização probabilística; nesta última o SHGE é dimensionado incorporando as incertezas na disponibilidade dos recursos renováveis, na demanda de energia e na indisponibilidade dos componentes do sistema (ocorrência de falhas).

A metodologia foi aplicada para o caso de estudo da Vila Campinas, já apresentado na seção 6.1. As simulações foram realizadas utilizando os dados meteorológicos e dados de consumo expostos no Apêndice H e as características técnicas e econômicas dos componentes apresentadas no Apêndice I. São estudadas três configurações do problema de otimização multiobjetivo: problema de minimização do custo e maximização da confiabilidade $\min f_m(NPV_C, LPS)$; problema de minimização do custo e minimização das emissões de poluentes $\min f_m(NPV_C, EMCO_2)$; e problema de minimização do custo, maximização da confiabilidade e minimização das emissões de poluentes $\min f_m(NPV_C, LPS, EMCO_2)$. A configuração das variáveis de otimização e das restrições para as três configurações de problema de otimização estudadas se mostra na Tabela 11.

A quantidade de combinações possíveis de componentes e estratégias de operação resulta igual a $N_{wt} \times T_{wt} \times N_{pv} \times T_{pv} \times N_{dg} \times T_{dg} \times N_{bt-p} \times T_{bt} \times N_{conv} \times T_{conv} \times Ec = 1,43 \times 10^{13}$. O algoritmo multiobjetivo desenvolvido, configurado com os parâmetros mostrados na Tabela 12, precisou de $200(\text{gerações}) \times 100(\text{indivíduos por geração}) = 20000$ avaliações da função objetivo para atingir a solução final, isto equivale a $1,4 \times 10^{-7}\%$ do total de combinações possíveis. O tempo de simulação resultou, em média, 65 minutos utilizando um computador equipado com Windows 7, 64 Bits, processador AMD FX™-8150 com processador de 8 núcleos 3,6GHz e memória RAM de 16 GB. Neste caso foi utilizada a função de computação paralela incorporada na *GAtoolbox* para diminuir o tempo de simulação. Todas as simulações foram replicadas 4 vezes obtendo-se os mesmos resultados.

Tabela 11. Configuração dos problemas de otimização multiobjetivo aplicados ao caso de estudo Vila Campinas.

$\min f_m(NPV_C, LPS) \quad \min f_m(NPV_C, EMCO_2) \quad \min f_m(NPV_C, LPS, EMCO_2)$				
Número de componentes considerados				
$[N_{wt,min}, N_{wt,max}]$		[0,250]		
$[N_{pv,min}, N_{pv,max}]$		[0,2400]		
$[N_{dg,min}, N_{dg,max}]$		[0,16]		
$[N_{bt_p,min}, N_{bt_p,max}]$		[0,30]		
$[N_{conv,min}, N_{conv,max}]$		[0,10]		
Modelos de componentes considerados				
T_{wt}		{1; 6; 7; 10} kW		
T_{pv}		{0,064; 0,08; 0,11; 0,12} kWp		
T_{dg}		{2,8; 10; 16; 48} kW		
T_{bt}		{198; 226; 1192; 3565} kWh		
T_{conv}		{5; 7; 17; 50} kW		
Estratégias de operação consideradas				
Ec		{SD; CC; DU+SD; DU+CC}		
Número total de combinações possíveis		$1,43 \times 10^{13}$		
Objetivos considerados				
NPV_C	(US\$)	●	●	●
LPS	(kWh/ano)	●		●
$EMCO_2$	(tCO ₂ -eq/ano)		●	●
Restrições				
$LPSP_{adm}$	(%)	5,0	0,0	5,0
$f_{ren,min}$	(%)	0,0	0,0	0,0
$f_{exess,adm}$	(%)	100	100	100
$F_{dg,adm}$	(L/ano)	Inf	Inf	Inf
$EMCO_{2,adm}$	(t/ano)	Inf	Inf	Inf
$NPV_{C,adm}$	(US\$)	Inf	Inf	Inf

Fonte: produção do próprio autor

Tabela 12. Parâmetros do algoritmo NSGA-II utilizado nos problemas de otimização multiobjetivo para o caso de estudo Vila Campinas.

Operador	Método	Parâmetro
Tamanho da população	--	$N_{pop} = 100$
Tratamento de restrições	Método de dominância	$niching = \text{sim}$
Método de seleção	Torneio binário	Tamanho do torneio = 2
Estratégia de reinserção	Melhores " N_{best} " indivíduos	$N_{best} = N_{pop}$
Critério de parada	Número máximo de gerações	$maxGen = 200$
Operador de recombinação	BLX- α	$\alpha = 0,5$
Probabilidade de recombinação	--	$p_r = 0,9$
Operador de mutação	Não-uniforme	$b = 5$
Probabilidade de mutação	--	$p_m = 1/n$

Fonte: produção do próprio autor

6.3.1 Otimização multiobjetivo determinística: caso de estudo Vila Campinas

6.3.1.1 Minimização do Custo e Maximização da Confiabilidade

Nesta seção dimensiona-se o SHGE considerando dois objetivos conflitantes, procura-se minimizar o Valor Presente Líquido dos Custos (*Net Present Value of Costs* – NPV_C) e maximizar a confiabilidade no fornecimento de energia através da minimização da Energia não Suprida (*Loss of Power Supply* – LPS). Deste modo, o problema de otimização multiobjetivo se define como mostra a equação (6.11):

$$\begin{aligned}
 \text{Minimizar:} \quad & f_m(NPV_C, LPS) & m = 1, 2 \\
 \text{Sujeito a:} \quad & g_1(\vec{x}) \equiv LPSP \leq LPSP_{adm} \\
 & g_2(\vec{x}) \equiv f_{exess} \leq f_{exess,adm} \\
 & g_3(\vec{x}) \equiv f_{ren,min} \leq f_{ren} \\
 & g_4(\vec{x}) \equiv F_{dg} \leq F_{dg,adm} \\
 & g_5(\vec{x}) \equiv EMCO_2 \leq EMCO_{2,adm} \\
 & g_6(\vec{x}) \equiv NPV_C \leq NPV_{C,adm} \\
 & N_{j,min} \leq N_{ji} \leq N_{j,max} & j = wt, pv, dg, bt, conv \\
 & T_{j,min} \leq T_{ji} \leq T_{j,max} & i = 1, ..., popSize \\
 & Ec_{min} \leq Ec \leq Ec_{max}
 \end{aligned} \tag{6.11}$$

A evolução da fronteira de Pareto do problema de otimização multiobjetivo NPV_C vs LSP é apresentada na Figura 38, mostra-se a população de soluções nas gerações 25, 50, 75, 100, 150 e 200. O eixo horizontal corresponde ao primeiro objetivo, o Valor Presente Líquido dos Custos (NPV_C), enquanto que o eixo vertical à esquerda corresponde ao segundo objetivo, a Energia não Suprida (LPS). Também, num segundo eixo vertical à direita mostra-se a Probabilidade de Perda de Energia ($LPSP$), calculada como

$$LPSP = \sum_{t=1}^T LPS(t) \Delta t / \sum_{t=1}^T P_{load}(t) \Delta t .$$

Observa-se que a partir da geração 100 todas as soluções se encontram situadas na fronteira final, não se percebendo variação na distribuição das soluções até a geração 200.

Na Figura 39 mostram-se as soluções não dominadas da última geração (200) distribuídas na fronteira de Pareto. Na mesma Figura 39 destacam-se 8 soluções com marcador de bolinha cheio, mostra-se ainda a solução obtida na seção 6.2.5 com o algoritmo AG mono-objetivo (marcador tipo cruz), também para o caso de Vila Campinas. A solução mais superior à esquerda do gráfico (Sol 1 na Figura 39), corresponde à solução de menor custo e maior energia não suprida (menor confiabilidade), enquanto que a solução mais inferior à direita do gráfico (Sol 8 na Figura 39) corresponde à solução de maior custo e menor energia não suprida (maior confiabilidade). Estas soluções se denominam de soluções extremas, pois definem os limites da fronteira de Pareto. A solução extrema 8 coincide com a solução do problema mono-objetivo, dado que é a configuração de menor custo com $LPSP = 0\%$, restrição imposta na configuração do problema mono-objetivo (ver Tabela 10, na seção 6.2.5).

Observam-se ainda duas descontinuidades que dividem a fronteira final de Pareto em três partes. A primeira descontinuidade se define entre as soluções 3 e 4; ambas apresentam praticamente o mesmo NPV_C , porém a confiabilidade é de $LPSP = 2,84\%$ e $LPSP = 2,10\%$, respectivamente. O mesmo acontece entre as soluções 6 e 7, que definem os extremos da segunda descontinuidade, neste caso a diferença na confiabilidade entre as duas soluções é maior, $LPSP = 1,23\%$ e $LPSP = 0,04\%$, respectivamente, sendo o NPV_C praticamente o mesmo para ambas estas soluções. Estas descontinuidades na fronteira de Pareto se devem à característica discreta das variáveis de otimização.

Num problema de otimização onde dois objetivos conflitantes são minimizados simultaneamente a fronteira de Pareto adota um formato convexo sendo que a região de maior arqueamento da curva é denominada de joelho da fronteira de Pareto. As soluções situadas na região do joelho da fronteira de Pareto são as mais interessantes para o tomador de decisão, já

que representam o melhor compromisso entre os valores das funções objetivo (BECHIKH; SAID; GHÉDIRA, 2011). Na fronteira de Pareto mostrada na Figura 39 podem-se se identificar 3 joelhos, um para cada seção da fronteira definida entre as descontinuidades antes mencionadas. Portanto, se pode identificar uma solução que maximize o compromisso entre os objetivos em cada seção da fronteira; a solução 2 situa-se no joelho da primeira seção da fronteira, a solução 5 situa-se no joelho da segunda seção da fronteira e a solução 7 é a solução de maior compromisso da terceira seção da fronteira. Também a solução 7 é a configuração de maior compromisso com relação à fronteira completa.

Na Tabela 13 apresentam-se as características das soluções de interesse 1, 2, 5, 7 e 8 que compõem a fronteira de Pareto final.

Em todas as soluções, o algoritmo opta por não incluir aerogeradores no sistema, evidenciando que o potencial eólico na região não é técnica e economicamente viável para seu uso na geração de energia. Em contrapartida a potência fotovoltaica instalada é elevada em todas as soluções, o bom potencial do recurso existente no local aliado ao custo relativo dessa tecnologia faz com que a opção de incluir geração fotovoltaica resulte atrativa. No entanto, para cumprir com a restrição de máxima energia não suprida ($LPSP_{adm} \leq 5\%$), o sistema deve contar com uma fonte de geração de *backup*, assim todas as soluções incluem pelo menos um moto gerador na sua configuração. Em todas as soluções o banco de baterias resultou igual, tanto na quantidade de baterias quanto no modelo do componente. A capacidade do banco de baterias assim dimensionado fornece uma autonomia de 29,43 horas ao sistema. Observa-se ainda na Tabela 13 que a vida útil das baterias resulta similar para as 5 soluções selecionadas, evidenciando que o uso das baterias é praticamente o mesmo em todas as configurações.


Em todas as soluções o algoritmo optou pela estratégia de operação Seguimento da Demanda (SD). Esta estratégia se mostra adequada para sistemas com grande participação de fontes renováveis, como é o caso das soluções mostradas na Tabela 13, nas quais a fração de energia renovável resulta superior a 80% em todos os casos.

Com à confiabilidade, os indicadores DIC, DMIC e FIC permitem avaliar o desempenho dos sistemas geradores quanto à continuidade do fornecimento elétrico. A Aneel, como órgão regulador no Brasil, faz um acompanhamento contínuo da continuidade do fornecimento de energia elétrica nas distintas regiões do país. Os resultados deste controle são públicos através do relatório de indicadores de continuidade do fornecimento (ANEEL - AGENCIA NACIONAL DE ENERGIA ELÉTRICA, 2016). Segundo este relatório, para consumidores não urbanos na região da Vila Campinas, o valor do DIC é de 100 horas,

enquanto que o FIC é de 92 interrupções por ano. Considerando estes valores, apenas as soluções 7 e 8 cumprem com o padrão de confiabilidade requerido para a região de estudo.


O custo para atingir o maior nível de confiabilidade ($LPSP = 0\%$) é igual à diferença do NPV_C entre as soluções 1 e 8, isto é, $US\$782.278,25 - US\$715.096,44 = US\$67.181,81$. O que implica um aumento no NPV_C do sistema de 9,39%, devido principalmente ao aumento do investimento inicial de 8,1%.

Figura 38. Evolução da fronteira de Pareto para o problema de otimização multiobjetivo, minimização do NPV_C e minimização do LPS , caso Vila Campinas.



Fonte: produção do próprio autor

Figura 39. Fronteira de Pareto da última geração para o problema de otimização multiobjetivo, minimização do NPV_C e minimização do LPS , caso Vila Campinas.



Fonte: produção do próprio autor

Tabela 13. Características de 5 soluções de interesse da última geração no problema de otimização multiobjetivo, minimização do NPV_C e minimização do LPS , caso Vila Campinas.

	Sol 1 (menor custo e maior energia não suprida)	Sol 2	Sol 5	Sol 7	Sol 8 (maior custo e menor energia não suprida)
Potência do WT (kW)	0,00	0,00	0,00	0,00	0,00
Potência do PV (kW)	131,64 (1097x0,12 kW)	145,44 (1212x0,12 kW)	139,44 (1162x0,12 kW)	138,12 (1151x0,12 kW)	150,00 (1250x0,12 kW)
Potência do DG (kW)	16,00 (1x16 kW)	16,00 (1x16 kW)	20,00 (2x10 kW)	32,00 (2x16 kW)	48,00 (3x16 kW)
Capacidade do banco BT (kWh)	855,60 (1x120 bat., 3565 Ah, 2V)	855,60 (1x120 bat., 3565 Ah, 2V)	855,60 (1x120 bat., 3565 Ah, 2V)	855,60 (1x120 bat., 3565 Ah, 2V)	855,60 (1x120 bat., 3565 Ah, 2V)
Potência do CONV (kW)	35,00 (7x5 kW)	35,00 (7x5 kW)	35,00 (7x5 kW)	35,00 (7x5 kW)	35,00 (7x5 kW)
Estratégia operação	SD	SD	SD	SD	SD
Energia consumida pela carga (kWh/ano)	178253,48	178253,48	178253,48	178253,48	178253,48
Probabilidade de Perda de Energia, LPSP (%)	4,99	3,86	1,84	0,04	0,00
Duração de interrupção individual, DIC (h/ano)	1481,00	1153,00	831,00	35,00	0,00
Duração máxima de interrupção contínua, DMIC (h)	15,00	15,00	13,00	3,00	0,00
Frequência de interrupção individual, FIC (int/ano)	188,00	151,00	204,00	27,00	0,00
Excesso de energia, EXE (%)	0,64	3,43	1,88	1,59	4,48
Fração de energia renovável, RF (%)	83,75	87,97	84,61	82,68	86,42
Vida útil das BT (ano)	11,90	10,86	11,25	11,21	10,53
Horas de operação do DG (h/ano)	2450,00	1926,00	2139,00	2170,00	1781,00
Combustível consumido (L/ano)	11283,56	8809,65	11100,42	13608,75	11142,73
Emissões no ciclo de vida (tCO _{2-eq} /ano)	29,80	23,28	29,32	35,93	29,44
Investimento inicial (US\$)	486.001,34	511.762,55	502.120,52	497.584,52	525.408,80
Custos operativos (US\$/ano)	18.013,89	16.740,46	19.036,02	20.517,97	20.197,81
Custo Nivelado de Energia, LCOE (US\$/kWh)	0,332	0,333	0,334	0,335	0,345
Valor Presente Líquido, NPV_C (US\$)	715.096,44	724.662,51	744.214,71	758.525,67	782.278,25

Fonte: produção do próprio autor

6.3.1.2 Minimização do Custo e Minimização das Emissões de CO₂ – Vila Campinas

Neste caso a otimização consiste em dimensionar o SHGE minimizando simultaneamente o Valor Presente Líquido dos Custos (NPV_C) e as Emissões do gás Poluente CO₂ ($EMCO_2$). Portanto, o problema multiobjetivo se define como mostra a equação (6.12):

$$\begin{aligned}
 \text{Minimizar: } & f_m(NPV_C, EMCO_2) & m = 1, 2 \\
 \text{Sujeito a: } & g_1(\vec{x}) \equiv LPSP \leq LPSP_{adm} \\
 & g_2(\vec{x}) \equiv f_{exess} \leq f_{exess,adm} \\
 & g_3(\vec{x}) \equiv f_{ren,min} \leq f_{ren} \\
 & g_4(\vec{x}) \equiv F_{dg} \leq F_{dg,adm} \\
 & g_5(\vec{x}) \equiv EMCO_2 \leq EMCO_{2,adm} \\
 & g_6(\vec{x}) \equiv NPV_C \leq NPV_{C,adm} \\
 & N_{j,min} \leq N_{ji} \leq N_{j,max} & j = wt, pv, dg, bt, conv \\
 & T_{j,min} \leq T_{ji} \leq T_{j,max} & i = 1, \dots, popSize \\
 & Ec_{min} \leq Ec \leq Ec_{max}
 \end{aligned} \tag{6.12}$$


Na Figura 40 mostra-se a evolução da população de soluções não dominadas nas gerações 10, 25, 50, 75, 100, 150 e 200. Verifica-se uma rápida convergência das soluções na fronteira de Pareto, sendo que a partir da geração 50 praticamente não se observam variações na disposição das soluções sobre a fronteira, a qual neste caso não apresenta descontinuidades. Na última geração (200), mostrada na Figura 41, observa-se uma boa distribuição das soluções ao longo da fronteira. Na mesma Figura 41 se destacam cinco soluções de interesse (marcador tipo bolinha cheio): a solução extrema 1 que prioriza minimizar o custo do sistema; a solução 3 que representa o maior compromisso entre o custo e as emissões, situada no joelho da fronteira de Pareto; a solução extrema 5 que prioriza a redução de emissões de poluentes; e mais duas soluções intermediárias entre os extremos da fronteira e o joelho, as soluções 2 a 4. Também na Figura 41 se mostra a solução do problema mono-objetivo obtida na seção 6.2.5 (marcador tipo cruz), a qual coincide com a solução extrema 1, uma vez que esta solução foi otimizada considerando apenas minimizar o custo do sistema independentemente dos objetivos conflitantes considerados neste caso (NPV_C e $EMCO_2$). As características das 5 soluções de interesse destacadas na Figura 41 são apresentadas na Tabela 14.

Dado que foi definida a restrição $LPSP_{adm} \leq 0\%$ todas as configurações da fronteira conseguem atender 100% da carga. Para satisfazer esta condição, as configurações 1, 2 e 3 optam pelo hibridismo solar-diesel, incorporando diferente fração de geração diesel e solar fotovoltaica. A solução 4 opta pelo hibridismo solar-eólica-diesel. Já a solução 5 inclui apenas geração renovável solar-eólica. Nesta última configuração observa-se que a potência instalada resulta excessiva, ainda mais no caso dos aerogeradores.

Nas soluções 1, 2 e 3 a inclusão de maior potência solar fotovoltaica e capacidade de armazenamento permite reduzir o tempo de operação do moto gerador e, portanto, diminuir o consumo de combustível e as emissões de poluentes. No entanto, o NPV_C do sistema aumenta aliado ao maior investimento inicial requerido. Uma redução de 98% nas emissões, de 29,44tCO_{2-eq}/ano na configuração 1 para 0,53tCO_{2-eq}/ano na configuração 3, equivale a um aumento de 60% no investimento inicial e um aumento de 25% no NPV_C . Já o custo de reduzir as emissões ao mínimo e fornecer a carga apenas com renováveis, resultando numa diferença de US\$3.978.892,70 - US\$787.024,13 = US\$3.191.868,57 entre as duas soluções extremas, a mais econômica e mais poluente (solução 1) e a mais onerosa e menos poluente (solução 5).


Cabe o comentário sobre as configurações 3 e 4, nas quais o algoritmo escolheu colocar dois moto geradores de 16 kW e um moto gerador de 2,8 kW, respectivamente. Observa-se que o tempo de operação dos equipamentos resulta muito baixo, 25 horas por ano para a solução 3 e apenas 3 horas para a solução 4. Evidentemente essas configurações são lógicas desde o ponto de vista do algoritmo, porém tecnicamente não são viáveis. Esta situação pode-se resolver impondo como restrição uma quantidade mínima de horas de operação para o moto gerador.

Figura 40. Evolução da fronteira de Pareto para o problema de otimização multiobjetivo, minimização do NPV_C e minimização das $EMCO_2$, caso Vila Campinas.



Fonte: produção do próprio autor

Figura 41. Fronteira de Pareto da última geração para o problema de otimização multiobjetivo, minimização do NPV_C e minimização das $EMCO_2$, caso Vila Campinas.



Fonte: produção do próprio autor

Tabela 14. Características de 5 soluções não dominadas da última geração no problema de otimização multiobjetivo, minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.

	Sol 1 (menor custo e maiores emissões)	Sol 2	Sol 3 (maior compromisso)	Sol 4	Sol 5 (maior custo e menores emissões)
Potência do WT (kW)	0,00	0,00	0,00	60,00 (10x6 kW)	532,00 (76x7 kW)
Potência do PV (kW)	150 (1250x0,12 kW)	161,4 (1345x0,12 kW)	253,92 (2116x0,12 kW)	288,00 (2400x0,12 kW)	216,26 (1966x0,12 kW)
Potência do DG (kW)	48,00 (3x16 kW)	48,00 (3x16 kW)	32,00 (2x16 kW)	2,80 (1x2,8 kW)	0,00
Capacidade do banco BT (kWh)	855,60 (1x120 bat., 3565 Ah, 2V)	1711,20 (2x120 bat., 3565 Ah, 2V)	1711,20 (2x120 bat., 3565 Ah, 2V)	1716,48 (6x120 bat., 1192 Ah, 2V)	858,24 (3x120 bat., 1192 Ah, 2V)
Potência do CONV (kW)	35,00 (5x7 kW)	35,00 (5x7 kW)	49 (7x7 kW)	42 (6x7 kW)	49 (7x7 kW)
Estratégia operação	SD	SD	SD	CC	SD
Energia consumida pela carga (kWh/ano)	178253,4834	178253,4834	178253,4834	178253,4834	178253,4834
Probabilidade de Perda de Energia, LPSP (%)	0,00	0,00	0,00	0,00	0,00
Duração de interrupção individual, DIC (h/ano)	0,00	0,00	0,00	0,00	0,00
Duração máxima de interrupção contínua, DMIC (h)	0,00	0,00	0,00	0,00	0,00
Frequência de interrupção individual, FIC (int/ano)	0,00	0,00	0,00	0,00	0,00
Excesso de energia, EXE (%)	4,48	2,49	32,67	46,17	63,16
Fração de energia renovável, RF (%)	86,42	93,32	99,87	99,99	100
Vida útil das BT (ano)	10,53	18,26	17,05	20,00	20,00
Horas de operação do DG (h/ano)	1781,00	959,00	25,00	3,00	--
Combustível consumido (L/ano)	11142,74	5552,11	154,61	1,46	--
Emissões no ciclo de vida (tCO_{2-eq}/ano)	29,44	14,75	0,53	0,12	0,07
Investimento inicial (US\$)	528.323,95	671.935,57	855.048,16	1.231.408,59	3.221.562,27
Custos operativos (US\$/ano)	20.341,76	11.435,05	8.923,21	18.777,46	59.549,38
Custo Nivelado de Energia, LCOE (US\$/kWh)	0,35	0,36	0,43	0,65	1,76
Valor Presente Líquido, NPV_C (US\$)	787.024,13	817.362,97	968.530,76	1.470.214,40	3.978.892,70

Fonte: produção do próprio autor

6.3.1.3 Minimização do Custo, Maximização da Confiabilidade e Minimização das Emissões de CO₂

Neste problema dimensiona-se o SHGE considerando três objetivos simultaneamente, isto é, minimizando o Valor Presente Líquido dos Custos (NPV_C), maximizar a Energia não Suprida (LPS) e minimizar as emissões de poluentes ($EMCO_2$). Desta forma o problema de otimização se define como mostra a equação (6.13):

$$\begin{aligned}
 \text{Minimizar: } & f_m(NPV_C, LPS, EMCO_2) & m = 1, 2, 3 \\
 \text{Sujeito a: } & g_1(\vec{x}) \equiv LPSP \leq LPSP_{adm} \\
 & g_2(\vec{x}) \equiv f_{exess} \leq f_{exess,adm} \\
 & g_3(\vec{x}) \equiv f_{ren,min} \leq f_{ren} \\
 & g_4(\vec{x}) \equiv F_{dg} \leq F_{dg,adm} \\
 & g_5(\vec{x}) \equiv EMCO_2 \leq EMCO_{2,adm} \\
 & g_6(\vec{x}) \equiv NPV_C \leq NPV_{C,adm} \\
 & N_{j,min} \leq N_{j,i} \leq N_{j,max} & j = wt, pv, dg, bt, conv \\
 & T_{j,min} \leq T_{j,i} \leq T_{j,max} & i = 1, \dots, popSize \\
 & Ec_{min} \leq Ec \leq Ec_{max}
 \end{aligned} \tag{6.13}$$


A evolução da fronteira de Pareto assim como a última geração (200) obtida pelo algoritmo de otimização expõem-se nas Figura 42 e Figura 43, respectivamente. O eixo “x” corresponde ao LPS , o eixo “y” ao NPV_C e o eixo “z” ao $EMCO_2$. A fronteira de Pareto se encontra dividida em duas partes, por um lado se agrupam as soluções que contemplam a inclusão de pelo menos um moto gerador de *backup* e por outro lado as soluções que têm diferente participação de renováveis e não incorporam geração diesel. Estas últimas possuem um nível de emissões muito baixo (apenas as emissões indiretas derivadas dos sistemas renováveis). Isto se pode observar melhor nas projeções nos planos ortogonais mostradas na Figura 44, em particular a Figura 44(a) a qual mostra a projeção no plano NPV_C vs $EMCO_2$.

Escolheram-se 4 soluções de interesse para uma análise mais aprofundado (ver Figura 43) cujas características se mostram na Tabela 15. As soluções 1, 2 e 3 são as soluções extremas da fronteira, a solução 1 é a de maior custo, a solução 2 é de menor confiabilidade (maior LSP) e a solução 3 corresponde com à configuração com maior nível de emissões. Já a solução 4 (joelho) é a configuração que maximiza o compromisso entre os três objetivos considerados. Esta última configuração constitui a de maior interesse para o tomador de

decisão. Percebe-se ainda que a solução 3 possui um custo similar à solução obtida com o algoritmo mono-objetivo obtida na seção 6.2.5 (marcador tipo cruz na Figura 43 e Figura 44), dado que esta solução corresponde com a configuração de menor custo da fronteira de Pareto final.


A configuração final do SHGE deve ser escolhida pelo tomar de decisão dentre as soluções que formam parte da fronteira de Pareto. Caso o agente decisor priorize a confiabilidade, apenas as soluções 3 e 4 cumprem com o padrão mínimo de confiabilidade imposto pela Aneel com relação aos indicadores FIC e DIC. A solução 3 apresenta um maior número de interrupções por ano com relação à solução 4, porém a duração dessas interrupções é menor, o que resulta numa menor energia não suprida (*LPS*). A maior confiabilidade desta configuração implica um maior uso do gerador diesel e, como consequência, um maior consumo de combustível. No entanto, o valor presente líquido da solução 3 se apresenta menor do que a solução 4, devido principalmente ao menor investimento inicial requerido. A solução 4, a de maior compromisso entre os objetivos, se apresenta com uma boa opção caso se priorize minimizar o uso de combustível mantendo os níveis de confiabilidade requeridos, no entanto a implantação desta configuração requer um investimento inicial quase o dobro em relação à solução 3 e um NPV_C 43,5% maior.

Figura 42. Evolução da fronteira de Pareto para o problema de otimização multiobjetivo, minimização do NPV_C , minimização do LPS e minimização das $EMCO_2$, caso Vila Campinas.




Fonte: produção do próprio autor

Figura 43. Fronteira de Pareto da última geração para o problema de otimização multiobjetivo, minimização do NPV_C , minimização do LPS e minimização das $EMCO_2$, caso Vila Campinas.



Fonte: produção do próprio autor

Figura 44. Projeções nos planos ortogonais das soluções da fronteira de Pareto para o problema de otimização multiobjetivo, minimização do NPV_c , minimização do LPS e minimização das $EMCO_2$, caso Vila Campinas.



Fonte: produção do próprio autor

Tabela 15. Características de 4 soluções não dominadas da última geração no problema de otimização multiobjetivo, minimização do NPV_C , minimização do LPS e minimização do $EMCO_2$, caso Vila Campinas.

	Sol 1 (maior custo)	Sol 2 (menor confiabilidade)	Sol 3 (maiores emissões)	Sol 4 (maior compromisso)
Potência do WT (kW)	1463,00 (209x7 kW)	798,00 (114x7 kW)	0,00	0,00
Potência do PV (kW)	125,82 (1966x0,064 kW)	98,11 (1523x0,064 kW)	138,12 (1151x0,12 kW)	185,04 (1542x0,12 kW)
Potência do DG (kW)	0,00	0,00	32,00 (2x16 kW)	10,00 (1x10 kW)
Capacidade do banco BT (kWh)	286,08 (1x120 bat., 1192 Ah, 2V)	286,08 (1x120 bat., 1192 Ah, 2V)	855,60 (1x120 bat., 3565 Ah, 2V)	3422,40 (4x120 bat., 3565 Ah, 2V)
Potência do CONV (kW)	49,00 (7x7 kW)	42,00 (6x7 kW)	35,00 (7x5 kW)	49,00 (7x7 kW)
Estratégia operação	SD	SD	SD	SD
Energia consumida pela carga (kWh/ano)	178253,48	178253,48	178253,48	178253,48
Probabilidade de Perda de Energia, LPSP (%)	3,12	5,00	0,04	0,13
Duração de interrupção individual, DIC (h/ano)	358,00	598,00	35,00	23,00
Duração máxima de interrupção contínua, DMIC (h)	11,00	15,00	3,00	12,00
Frequência de interrupção individual, FIC (int/ano)	81,00	117,00	27,00	3,00
Excesso de energia, EXE (%)	79,16	64,84	1,59	7,60
Fração de energia renovável, RF (%)	100,00	100,00	82,68	99,90
Vida útil das BT (ano)	12,62	10,15	11,21	20,00
Horas de operação do DG (h/ano)	0,00	0,00	2170,00	27,00
Combustível consumido (L/ano)	--	--	13608,75	83,29
Emissões no ciclo de vida (tCO_{2-eq}/ano)	0,04	0,03	35,93	0,41
Investimento inicial (US\$)	11.234.317,70	7.142.460,23	497.584,52	969.339,69
Custos operativos (US\$/ano)	166.791,03	98.635,43	20.517,97	9.375,67
Custo Nivelado de Energia, LCOE (US\$/kWh)	6,08	3,90	0,33	0,48
Valor Presente Líquido, NPV_C (US\$)	13.355.514,04	8.396.874,90	758.525,67	1.088.576,58

Fonte: produção do próprio autor

6.3.2 Otimização multiobjetivo probabilística: caso de estudo Vila Campinas

Nesta seção implementa-se a metodologia de otimização probabilística apresentada no capítulo 0. Primeiramente se investiga qual a influência das incertezas nas configurações do SHGE obtidas na seção 6.3.1 com o método de otimização determinística. Posteriormente, implementa-se o método de otimização probabilística, no qual o SHGE é dimensionado considerando as incertezas no processo de otimização.

6.3.2.1 Sensibilidade das Soluções Determinísticas da Fronteira de Pareto

As configurações do SHGE obtidas na seção anterior ficam definidas uma vez que o conjunto de condições de entrada é especificado. Dado que o algoritmo de simulação é do tipo determinístico, para as mesmas condições de entrada os resultados sempre serão os mesmos. No entanto, em sistemas reais existem incertezas inerentes às variáveis de entrada. Quando essas incertezas são inseridas nas simulações, os resultados são não determinísticos, devendo ser apresentados em forma de probabilidades ou como uma faixa de possíveis valores. A seguir avalia-se a influência das incertezas nas configurações obtidas pelo algoritmo determinístico na seção 6.3.1 para o caso de estudo da Vila Campinas. A abordagem utilizada consiste em simular os sistemas de forma iterativa introduzindo em cada iteração incertezas nas variáveis de entrada. As incertezas são geradas probabilisticamente através do método de amostragem LHS (*Latin Hypercube Sampling*) para a geração de cenários de disponibilidade dos recursos renováveis e da demanda da carga e Simulação Monte Carlo para a geração de históricos de operação dos componentes do sistema sujeitos a falha. A partir deste procedimento obtém-se uma série de resultados em forma de distribuição de probabilidade que permitem avaliar a resposta das configurações de SHGE obtidas pelo algoritmo determinístico sob a presença de incertezas. O número máximo de amostras definiu-se em $N_{smp} = 1000$ com base na velocidade de convergência dos indicadores de desempenho avaliados, i.e. NPV_C , LPS e $EMCO_2$. Observa-se que o LPS é o indicador que mais demora a convergir. Depois de realizar uma série de experimentações, observou-se que são necessárias aproximadamente 1000 simulações para o LPS atingir a convergência desejada definida pelo fator de convergência $\beta_c = 0,05$, segundo a equação (6.14) (LEITE; SCHMITT; CASSULA, 2005).

$$\beta_c = \sqrt{V[\tilde{E}(G)]} / \tilde{E}(G) \quad (6.14)$$

sendo, $V(G)$ a variância da função teste e $\tilde{E}(G)$ a estimativa do valor esperado.

Caso este limite definido por β_c for atingido em um número menor de amostras, a simulação é finalizada. O tempo de simulação probabilística das soluções determinísticas da fronteira de Pareto considerando 1000 amostras resultou, em média, de 15 minutos utilizando um computador equipado com Windows 7, 64 Bits, processador Intel Core i7 2,5GHz e memória RAM de 8 GB.

Como foi comentado no capítulo 3, as incertezas consideradas na simulação do SHGE têm a ver com a disponibilidade dos recursos renováveis (velocidade do vento, radiação solar e temperatura), a demanda de energia da carga e a indisponibilidade operacional dos componentes do sistema sujeitos a falha. Na Tabela 16, se apresentam os valores dos parâmetros utilizados pelo método de amostragem para a geração probabilística de cenários de operação do SHGE no caso de estudo da Vila Campinas.

Tabela 16. Parâmetros utilizados na geração de cenários de incerteza para o caso de estudo Vila Campinas.

	Valor	Unidade	Referência
Desvio padrão da média anual da velocidade do vento	0,15	m/s	[1]
Desvio padrão da média anual da radiação solar global	1,15	kWh/m ² /dia	[2]
Desvio padrão da média anual da temperatura ambiente	5,00	°C	[3]
Desvio padrão da média anual do consumo da carga	48,84	kWh/dia	[4]
Tempo médio entre falhas, turbina eólica	1920	h	
Tempo médio para reparo, turbina eólica	80	h	
Tempo médio entre falhas, painel fotovoltaico	2190	h	
Tempo médio para reparo, painel fotovoltaico	80	h	
Tempo médio entre falhas, moto gerador diesel	950	h	[5]
Tempo médio de reparo, moto gerador diesel	50	h	
Tempo médio entre falhas, conversor	87600	h	
Tempo médio de reparo, conversor	80	h	

[1] (DIAS, 2013)

[2] (MARTINS et al., 2007)

[3] (SILVA DE SOUSA et al., 2011)

[4] Estimado pelo autor.

[5] (KARKI; BILLINTON, 2001; KARKI; DHUNGANA; BILLINTON, 2013; KARKI et al., 2006)

Fonte: produção do próprio autor

Foi avaliada a variabilidade apenas das soluções de interesse para cada configuração do problema de otimização multiobjetivo, isto é, as soluções extremas e as soluções que maximizam o compromisso entre os objetivos. No entanto, o mesmo procedimento pode ser aplicado para qualquer solução da fronteira de Pareto determinística. Na Tabela 17 se

apresenta um resumo das soluções determinísticas que são avaliadas probabilisticamente (informações mais detalhadas já foram apresentadas nas Tabela 13, Tabela 14 e Tabela 15).

Tabela 17. Soluções determinísticas avaliadas probabilisticamente para cada configuração do problema de otimização multiobjetivo.

Problema de $\min f_m(NPV_C, LPS)$				
Solução	Caraterística da solução	NPV _C (US\$)	LPSP (%)	
Sol 1 (det.)	Extremo da fronteira de Pareto, maximiza o LPSP	715.096,44	4,99%	
Sol 2 (det.)	Maior compromisso entre objetivos do joelho 1 da fronteira de Pareto	724.662,51	3,86%	
Sol 5 (det.)	Maior compromisso entre objetivos do joelho 2 da fronteira de Pareto	744.214,71	1,84%	
Sol 7 (det.)	Maior compromisso entre objetivos do joelho 3 da fronteira de Pareto	758.525,67	0,04%	
Sol 8 (det.)	Extremo da fronteira de Pareto, maximiza o NPV _C	782.278,25	0,00%	
Problema de $\min f_m(NPV_C, EMCO_2)$				
Solução	Caraterística da solução	NPV _C (US\$)	EMCO ₂ (tCO ₂ -eq/ano)	
Sol 1 (det.)	Extremo da fronteira de Pareto, maximiza o EMCO ₂	787.024,00	29,4	
Sol 3 (det.)	Maior compromisso entre objetivos	968.531,00	0,5	
Sol 5 (det.)	Extremo da fronteira de Pareto, maximiza o NPV _C	3.978.890,00	0,1	
Problema de $\min f_m(NPV_C, LPS, EMCO_2)$				
Solução	Caraterística da solução	NPV _C (US\$)	LPSP (%)	EMCO ₂ (tCO ₂ -eq/ano)
Sol 1 (det.)	Extremo da fronteira de Pareto, maximiza o NPV _C	13.355.500,00	3,12%	0,04
Sol 2 (det.)	Extremo da fronteira de Pareto, maximiza o LPSP	8.396.870,00	5,00%	0,03
Sol 3 (det.)	Extremo da fronteira de Pareto, maximiza o EMCO ₂	758.526,00	0,04%	35,93
Sol 4 (det.)	Maior compromisso entre objetivos	1.088.580,00	0,13%	0,41

Fonte: produção do próprio autor


A variabilidade nas soluções determinísticas de interesse para a configuração do problema de otimização $\min f_m(NPV_C, LPS)$ como resultado da incorporação das incertezas se mostra na Figura 45. Na Figura 45, Sol (det.) são as soluções determinísticas obtidas com o algoritmo AG multiobjetivo, Sol (prob.) são as soluções obtidas aplicando a simulação probabilística às soluções determinísticas e, $\mu(Sol)^{Pareto(det.)}$ são as médias do conjunto de soluções probabilísticas. Observa-se que as soluções ótimas, em média, se deslocam com relação à fronteira de Pareto determinística quando são introduzidas incertezas no processo de simulação.

A influência das incertezas nos objetivos NPV_C e LPS pode ser diretamente avaliada pela dispersão da nuvem de pontos das soluções probabilísticas, Sol (prob.), na Figura 45. No entanto, uma representação mais clara da variabilidade pode-se obter a partir das curvas de densidade de probabilidade para o NPV_C e o LPS mostradas nas Figura 46(a) e Figura 46(b),

respectivamente. Observa-se na Figura 46(a) que a variabilidade do NPV_C é ampla para todas as soluções. Já com relação ao LPS , a variabilidade se apresenta maior para as soluções 1, 2 e 5, para a solução 7 é menor sendo que a solução 8 é praticamente insensível à presença das incertezas com relação ao LPS .


As soluções 1 e 2 apresentam uma menor dispersão com relação ao NPV_C e maior dispersão com relação ao LPS ; o contrário acontece com as soluções 7 e 8, as quais apresentam maior dispersão com relação a NPV_C e variação quase nenhuma com relação ao LPS . Isto se deve porque as configurações do SHGE correspondentes às soluções 7 e 8 incorporam mais de um moto gerador (ver Tabela 13), fazendo com que estas configurações sejam mais “robustas” perante eventuais variações na disponibilidade de recursos renováveis e na demanda da carga. No entanto, o NPV_C do sistema vê-se influenciada devido ao maior tempo de operação e maior consumo de combustível do moto gerador para suprir as variações nas condições operacionais. Por outro lado, as soluções 1 e 2 incorporam um moto gerador, e como consequência, são mais sensíveis às variações nas condições operacionais derivadas da incorporação das incertezas.

Figura 45. Variabilidade das soluções determinísticas sob a influência de incertezas, problema de otimização multiobjetivo minimização do NPV_C e minimização do LPS , caso Vila Campinas.



Fonte: produção do próprio autor

Figura 46. Funções densidade de probabilidade das soluções determinísticas sob a influência de incertezas, problema de otimização multiobjetivo minimização do NPV_C e minimização do LPS , caso Vila Campinas.




Fonte: produção do próprio autor

Nas distribuições de probabilidade da Figura 47(a) e Figura 47(b) mostra-se a variabilidade das soluções determinísticas de interesse para a configuração do problema de otimização $\min f_m(NPV_C, EMCO_2)$ como resultado da incorporação das incertezas.

Observa-se que as soluções 1 e 3 apresentam maior dispersão com relação ao NPV_C do que com relação ao $EMCO_2$. A maior variação dá-se na solução 1, com relação aos dois objetivos. O contrário acontece com a solução 5, a qual apresenta pouca dispersão com relação as dois objetivos (NPV_C e $EMCO_2$). Isto se deve porque a solução 5 é uma configuração de SHGE que considera apenas fontes renováveis (ver Tabela 14), portanto não gera emissões diretas de poluentes (apenas emissões indiretas) e os custos operativos das fontes renováveis tem pouca influência no NPV_C . Dado que a solução 3 é a configuração de SHGE de maior compromisso entre os objetivos considerados, apresenta relativamente pouca dispersão em relação a ambos os objetivos. Já a solução 1, a de menor NPV_C , apresenta uma dispersão elevada com relação ao $EMCO_2$, pois esta configuração incorpora três moto geradores que geram emissões diretas de poluentes durante sua operação variável.

Figura 47. Funções densidade de probabilidade das soluções determinísticas sob a influência de incertezas, problema de otimização multiobjetivo minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.




Fonte: produção do próprio autor

Na Figura 48 se mostra a variabilidade das soluções determinísticas de interesse para a configuração do problema de otimização $\min f_m(NPV_C, LPS, EMCO_2)$ como resultado da incorporação das incertezas. Observa-se na Figura 48(a) que todas as soluções são pouco sensíveis à presença de incertezas com relação ao NPV_C . Já as curvas de probabilidade do LPS mostradas na Figura 48(b) apresentam maior dispersão, a solução 3 é a mais robusta neste aspecto porque conta com dois moto geradores permitindo absorver as variações nas condições operacionais. As soluções 1 e 4 apresentam dispersão similar quanto à confiabilidade, sendo que a solução 2 é a que mais variação apresenta. Com relação às emissões, as soluções 1 e 2 apresentam pouca dispersão porque são configurações que contemplam apenas geração renovável (ver Tabela 15). Já a solução 4 apresenta uma grande dispersão em função do uso do gerador diesel para suprir as variações operacionais.

Os resultados apresentados anteriormente permitem evidenciar que as soluções determinísticas que compõem a fronteira de Pareto apresentam dispersão no valor dos objetivos ante a presença de eventuais incertezas nas variáveis de entrada. Como mostrado na Figura 45, a média das soluções avaliadas probabilisticamente afasta-se da fronteira de Pareto determinística, indicando que é necessário incorporar um método de quantificação de incertezas no processo de otimização para se obter soluções robustas em relação aos objetivos avaliados.

Figura 48. Funções densidade de probabilidade das soluções determinísticas sob a presença de incertezas, problema de otimização multiobjetivo, minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.



Fonte: produção do próprio autor

6.3.2.2 Otimização Considerando as Incertezas

A partir dos resultados da seção anterior fica evidente que é preciso uma metodologia de otimização que permita considerar as incertezas no processo de dimensionamento do SHGE. Assim, nesta seção se apresentam os resultados da implementação do método de otimização probabilístico apresentado na seção 3.2 para o caso de estudo da Vila Campinas.


As incertezas incorporadas no processo de otimização são as mesmas que foram utilizadas na seção 6.3.2.1, mostradas na Tabela 16, para a simulação probabilística das soluções de interesse obtidas com o algoritmo determinístico. O método de amostragem é o LHS (*Latin Hypercube Sampling*) para a geração de cenários de disponibilidade dos recursos renováveis e da demanda da carga e Simulação Monte Carlo para a geração de históricos de operação dos componentes do sistema sujeitos a falha. Dado que o método de otimização probabilístico aqui proposto implica um custo computacional elevado, a quantidade de amostras geradas para cada indivíduo deve ser limitado para evitar tempos de processamento excessivos. Adotou-se um tamanho de população $popSize = 100$ indivíduos, máximo número de gerações $maxGen = 200$, número de amostras $N_{samp} = 50$ e computação paralela. Assim configurado, o algoritmo de otimização multiobjetivo probabilístico precisa avaliar a função objetivo 1×10^6 vezes em cada simulação. Utilizando um computador equipado com Windows 7, 64 Bits, processador AMD FX™-8150 com processador de 8 núcleos 3,6GHz e memória RAM de 16 GB, o tempo médio de simulação foi de 15 horas para cada configuração do problema de otimização. Deste modo, a simulação probabilística das três configurações do problema de otimização $\min f_m(NPV_C, LPS)$, $\min f_m(NPV_C, EMCO_2)$ e $\min f_m(NPV_C, LPS, EMCO_2)$ para o caso de estudo da Vila Campinas requereu, em média, 45 horas de processamento.

A simulação probabilística é iniciada a partir da última geração obtida com o algoritmo determinístico, isto é, os indivíduos da fronteira de Pareto determinística constituem a primeira geração do algoritmo probabilístico. Desta forma é possível acelerar a convergência do algoritmo probabilístico e permite uma posterior comparação com as soluções do algoritmo determinístico.

Na Figura 49 se mostra o resultado da otimização probabilística aplicada ao problema $\min f_m(NPV_C, LPS)$ para o caso de estudo da Vila Campinas. Na mesma Figura 49 expõe-se a fronteira de Pareto determinística, obtida na seção 6.3.1, e a média das soluções determinísticas de interesse simuladas incorporando as incertezas, $\mu(x_i)^{Pareto(det.)}$. Observa-se que a fronteira de Pareto probabilística situa-se à direita das soluções médias, indicando que para se atingirem iguais níveis de confiabilidade, o SHGE possui valores mais elevados de NPV_C com relação às soluções médias, $\mu(x_i)^{Pareto(det.)}$, e como consequência também com relação às soluções determinísticas. Todas as soluções da fronteira de Pareto probabilística se encontram dentro da região fatível, limitada por $LPS = 5\%$, sendo que as soluções médias

situadas mais acima à esquerda do gráfico não cumprem com esta restrição. Este resultado ocorre porque o algoritmo de otimização probabilístico é mais conservador, em cada geração uma vez aplicado o método de amostragem nos indivíduos da população estes são submetidos ao processo de seleção, sendo que aqueles indivíduos que não cumprem com a restrição de LPS_{adm} serão assinalados com um valor de aptidão baixo e, eventualmente, eliminados na seguinte geração. Desta forma assegura-se que todos os indivíduos da fronteira de Pareto probabilística representam soluções fatíveis e robustas, pode-se dizer que ante os cenários de incerteza considerados, todas as configurações de SHGE conseguiram satisfazer as restrições impostas.

Figura 49. Fronteira de Pareto determinística e probabilística, problema de otimização multiobjetivo minimização do NPV_C e minimização do LPS , caso Vila Campinas.



Fonte: produção do próprio autor

Na Tabela 18 se faz uma comparação das características das soluções de interesse que formam parte da fronteira de Pareto determinística e probabilística. Observa-se que o algoritmo probabilístico opta por colocar maior geração diesel e eliminar as baterias nas soluções de menor custo e maior compromisso. Este resultado já era esperado, pois o gerador diesel constitui uma fonte de geração despachável que permite absorver eficazmente possíveis variações na demanda e na geração renovável. Para aumentar a confiabilidade ($LPSP = 0\%$) o

algoritmo probabilístico opta por adicionar 44,92 kW de potência geradora (um moto gerador de 16 kW e 241 painéis fotovoltaicos de 0,12 kW), esta configuração mais robusta equivale a um aumento no NPV_C de 16% em relação à solução equivalente determinística.

Tabela 18. Comparação entre soluções de interesse obtidas pelo algoritmo determinístico e probabilístico, problema de otimização multiobjetivo minimização do NPV_C e minimização do LPS, caso Vila Campinas.


	Solução de menor NPV_C e maior LPS		Solução de maior compromisso		Solução de maior NPV_C e menor LPS	
	(det.)	(prob.)	(det.)	(prob.)	(det.)	(prob.)
Potência do WT (kW)	0,00	0,00	0,00	0,00	0,00	0,00
Potência do PV (kW)	131,64 (1097x0,12 kW)	51,00 (425x0,12 kW)	138,12 (1151x0,12 kW)	52,08 (434x0,12 kW)	150,00 (1250x0,12 kW)	178,92 (1491x0,12 kW)
Potência do DG (kW)	16,00 (1x16 kW)	32,00 (2x16 kW)	32,00 (2x16 kW)	32,00 (2x16 kW)	48,00 (3x16 kW)	64,00 (4x16 kW)
Capacidade do banco BT (kWh)	855,60 (1x120 bat., 3565 Ah, 2V)	0,00	855,60 (1x120 bat., 3565 Ah, 2V)	0,00	855,60 (1x120 bat., 3565 Ah, 2V)	855,60 (1x120 bat., 3565 Ah, 2V)
Potência do CONV (kW)	35,00 (7x5 kW)	20,00 (4x5 kW)	35,00 (7x5 kW)	25,00 (5x5 kW)	35,00 (7x5 kW)	35,00 (7x5 kW)
Estratégia operação	SD	SD	SD	SD	SD	SD
Probabilidade de Perda de Energia, LPSP (%)	4,99	4,07	0,04	1,30	0,00	0,00
Valor Presente Líquido, NPV_C (US\$)	715.096,44	779.774,00	758.525,67	813.906,00	782.278,25	903.571,00

Fonte: produção do próprio autor

Na Figura 50 se mostra a fronteira de Pareto obtida com o algoritmo de otimização probabilístico aplicado ao problema $\min f_m(NPV_C, EMCO_2)$ para o caso de estudo da Vila Campinas. Também se mostra a fronteira de Pareto determinística e a média das soluções determinísticas simuladas incorporando as incertezas, denominadas de $\mu(x_i)^{Pareto(det.)}$. Observa-se que as duas fronteiras diferem, sobre tudo na região do joelho, onde se situam as soluções de maior compromisso entre os objetivos, e, portanto, as de maior interesse para o tomador de decisão. De modo comparativo, na Tabela 19 se apresentam as características das soluções de interesse obtidas pelos algoritmos determinístico e probabilístico. Novamente evidencia-se que o algoritmo probabilístico opta por adicionar mais geração diesel em relação à configuração determinística equivalente. Ambas as soluções de maior compromisso, a determinística e a probabilística, apresentam um nível de emissões baixo, apesar de incorporarem moto geradores diesel. Isto ocorre porque foi imposta a restrição de máxima

confiabilidade ($LPS_{adm} = 0\%$), e portanto o algoritmo opta por uma fonte despachável para garantir essa condição. É interessante notar que a solução probabilística que prioriza as emissões (menor $EMCO_2$), resultou num NPV_C menor em relação à solução determinística equivalente, já que ante um cenário de maior variabilidade das condições operacionais o algoritmo opta por diminuir a geração eólica e aumentar a geração diesel, diminuindo assim o investimento inicial do sistema.

Figura 50. Fronteira de Pareto determinística e probabilística, problema de otimização multiobjetivo minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.



Fonte: produção do próprio autor

Tabela 19. Comparação entre soluções de interesse obtidas pelo algoritmo determinístico e probabilístico, problema de otimização multiobjetivo minimização do NPV_C e minimização do $EMCO_2$, caso Vila Campinas.


	Solução de menor NPV_C e maior $EMCO_2$		Solução de maior compromisso		Solução de maior NPV_C e menor $EMCO_2$	
	(det.)	(prob.)	(det.)	(prob.)	(det.)	(prob.)
Potência do WT (kW)	0,00	0,00	0,00	0,00	532,00 (76x7 kW)	392,00 (56x7 kW)
Potência do PV (kW)	150,00 (1250x0,12 kW)	208,20 (1735x0,12 kW)	253,92 (2116x0,12 kW)	275,16 (2293x0,12 kW)	216,26 (1966x0,12 kW)	227,07 (1892x0,12 kW)
Potência do DG (kW)	48,00 (3x16 kW)	64,00 (4x16 kW)	32,00 (2x16 kW)	48,00 (3x16 kW)	0,00	16,00 (1x16 kW)
Capacidade do banco BT (kWh)	855,60 (1x120 bat., 3565 Ah, 2V)	855,60 (1x120 bat., 3565 Ah, 2V)	1711,20 (2x120 bat., 3565 Ah, 2V)	2566,80 (3x120 bat., 3565 Ah, 2V)	858,24 (3x120 bat., 1192 Ah, 2V)	2566,80 (3x120 bat., 3565 Ah, 2V)
Potência do CONV (kW)	35,00 (5x7 kW)	42,00 (6x7 kW)	49,00 (7x7 kW)	42,00 (6x7 kW)	49,00 (7x7 kW)	68,00 (4x17kW)
Estratégia operação	SD	SD	SD	SD	SD	SD
Emissões no ciclo de vida (tCO ₂ -eq/ano)	29,44	26,35	0,53	0,62	0,07	0,15
Valor Presente Líquido, NPV_C (US\$)	787.024,13	919.000,00	968.530,76	1.120.000,00	3.978.892,70	3.330.000,00

Fonte: produção do próprio autor

A Figura 51 mostra a fronteira de Pareto obtida pelos algoritmos de otimização determinístico e probabilístico para a configuração do problema $\min f_m(NPV_C, LPS, EMCO_2)$, assim como as soluções médias da simulação probabilística aplicada às soluções determinísticas (seção 6.3.2.1). Para maior clareza, na Figura 52, se mostram as projeções nos planos ortogonais do gráfico 3D da Figura 51. Já na Tabela 20 se mostra a comparação entre as soluções de interesse obtidas pelo algoritmo probabilístico e determinístico.


Observa-se que a solução de maior compromisso entre os três objetivos avaliados resulta, no caso probabilístico, 25% mais onerosa em termos de valor presente do que a solução determinística, pois incorpora quase 40% mais de potência geradora. No entanto, a solução probabilística de compromisso atinge um nível de confiabilidade ótimo com $LPSP = 0\%$.

Figura 51. Fronteira de Pareto determinística e probabilística, problema de otimização multiobjetivo minimização do NPV_C , minimização do LPS e minimização do $EMCO_2$, caso Vila Campinas.



Fonte: produção do próprio autor

Figura 52. Projeções nos planos ortogonais da fronteira de Pareto determinística e probabilística, problema de otimização multiobjetivo minimização do NPV_C , minimização do LPS e minimização do $EMCO_2$, caso Vila Campinas.



Fonte: produção do próprio autor

Tabela 20.Comparação entre soluções de interesse obtidas pelo algoritmo determinístico e probabilístico, problema de otimização multiobjetivo minimização do NPV_C , minimização do LPS e minimização do $EMCO_2$, caso Vila Campinas.

	Solução de maior NPV_C		Solução de maior LPS		Solução de maior $EMCO_2$		Solução de maior compromisso	
	(det.)	(prob.)	(det.)	(prob.)	(det.)	(prob.)	(det.)	(prob.)
Potência do WT (kW)	1463,00 (209x7 kW)	1001,00 (143x7 kW)	798,00 (114x7 kW)	462,00 (66x7 kW)	0,00	0,00	0,00	28,00 (4x7 kW)
Potência do PV (kW)	125,82 (1966x0,064 kW)	131,46 (2054x0,064 kW)	98,11 (1523x0,064 kW)	152,08 (1901x0,08 kW)	138,12 (1151x0,12 kW)	142,92 (1191x0,12 kW)	185,04 (1542x0,12 kW)	235,92 (1966x0,12 kW)
Potência do DG (kW)	0,00	0,00	0,00	0,00	32,00 (2x16 kW)	48,00 (3x16 kW)	10,00 (1x10 kW)	48,00 (3x16 kW)
Capacidade do banco BT (kWh)	286,08 (1x120 bat., 1192 Ah, 2V)	572,16 (2x120 bat., 1192 Ah, 2V)	286,08 (1x120 bat., 1192 Ah, 2V)	572,16 (2x120 bat., 1192 Ah, 2V)	855,60 (1x120 bat., 3565 Ah, 2V)	855,60 (1x120 bat., 3565 Ah, 2V)	3422,40 (4x120 bat., 3565 Ah, 2V)	3422,40 (4x120 bat., 3565 Ah, 2V)
Potência do CONV (kW)	49,00 (7x7 kW)	42,00 (6x7 kW)	42,00 (6x7 kW)	35,00 (5x7 kW)	35,00 (7x5 kW)	35,00 (7x5 kW)	49,00 (7x7 kW)	49,00 (7x7 kW)
Estratégia operação	SD	SD	SD	SD	SD	SD	SD	SD
Probabilidade de Perda de Energia, LPSP (%)	3,12	1,42 (-55%)	5,00	5,13 (+2,6)	0,04	0,00 (-100%)	0,13	0,00 (-100%)
Emissões no ciclo de vida (tCO _{2-eq} /ano)	0,04	0,05 (+25%)	0,03	0,04 (+33%)	35,93	69,61 (+94%)	0,41	0,71 (+73%)
Valor Presente Líquido, NPV_C (US\$)	13.355.514,04	10.800.000,00 (-20%)	8.396.874,90	3.420.000,00 (-59%)	758.525,67	913.000,00 (+21%)	1.088.576,58	1.360.000,00 (+25%)

Fonte: produção do próprio autor

7 CONCLUSÕES E TRABALHOS FUTUROS

No presente trabalho de pesquisa aborda-se o problema de dimensionamento ótimo de Sistemas Híbridos de Geração de Energia (SHGE), isto é, sistemas que combinam duas ou mais fontes de geração de energia para suprir uma determinada carga. O sistema híbrido estudado compõe-se de geração eólica, solar fotovoltaica, sistema de armazenamento de energia em baterias eletroquímicas e ainda considera a possibilidade de um moto gerador como *backup*. Este tipo de sistema se caracteriza pelo comportamento não linear dos seus componentes, além de possuir uma grande interação entre as variáveis envolvidas; aliado ao comportamento estocástico dos recursos renováveis e da carga, que fazem do processo de dimensionamento do SHGE uma tarefa complexa. Variadas técnicas para o dimensionamento de SHGE tem sido propostas, no entanto, nota-se que não existe uma abordagem globalmente aceita para resolver o problema, sendo que muitos dos métodos propostos limitam-se às condições específicas do estudo.

Para resolver este problema propõe-se uma abordagem de otimização baseada em simulação que visa projetar de forma otimizada um SHGE solar-eólico-bateria com moto gerador de *backup*. São propostos dois métodos, sendo um método de otimização determinístico no qual o SHGE é dimensionado considerando os parâmetros de entrada constantes. O segundo método consiste numa otimização probabilística no qual se incorporam as incertezas inerentes às variáveis de entrada.

Para tal fim foi desenvolvida uma ferramenta computacional que integra um módulo de simulação e um módulo de otimização, especialmente projetados para abordar o problema de dimensionamento ótimo de SHGE.

Com relação ao modelo de simulação, foram testados vários modelos para cada componente do SHGE com o intuito de obter um modelo de simulação compatível com as necessidades do presente estudo. Em todos os modelos testados, procurou-se um balanço entre precisão e custo computacional. O resultado é um modelo de simulação de SHGE que permite explorar diferentes configurações de sistema híbrido e avaliar a sensibilidade dos parâmetros de cada componente. O modelo de simulação fornece como resultados uma série de índices de desempenho que permitem avaliar a operação do sistema híbrido de acordo com critérios técnicos, econômicos e ambientais. Esses indicadores são utilizados pelo módulo de otimização para guiar o processo de busca.

O módulo de otimização da ferramenta desenvolvida é baseado na metaheurística Algoritmos Genéticos (AGs), a qual a partir das informações fornecidas pelo módulo de

simulação procura a melhor configuração de SHGE que otimize os critérios definidos pelo usuário. Para tal fim, foi desenvolvida uma *toolbox* em Matlab® (*GAtoolbox*) que implementa um algoritmo de otimização baseado em AGs. A *GAtoolbox* foi inicialmente concebida como uma ferramenta de otimização de uso geral, e em seguida foi integrada na ferramenta de otimização baseada em simulação para resolver o problema específico de dimensionamento do SHGE. O desempenho da *GAtoolbox* foi avaliado na resolução de uma série de problemas teste, tanto problemas mono-objetivo e multiobjetivo puramente matemáticos, bem como problemas reais de engenharia, mostrando resultados satisfatórios. Os resultados mostram que a configuração de AG com codificação real, operador de recombinação BLX- α (ESHELMAN; SCHAFFER, 1993) com $\alpha=0,5$ e operador de mutação não-uniforme (MICHALEWICZ, 1996) com $b=5$ junto ao método de tratamento de restrições proposto por Coello Coello e Montes (2002) é a mais adequada para a resolução de problemas de otimização mono-objetivo com restrições. Para resolver problemas de otimização multiobjetivo, a *GAtoolbox* incorpora o algoritmo NSGA-II (DEB et al., 2002). O algoritmo multiobjetivo também foi avaliado numa série de problemas teste mostrando a capacidade do método para convergir rapidamente para as soluções não dominadas da fronteira de Pareto. A *GAtoolbox* consegue resolver satisfatoriamente não apenas problemas relativamente simples, mas também problemas com espaços de busca convexos, côncavos, não contínuos e com restrições difíceis de cumprir, assim como problemas com mais de dois objetivos.

Uma vez integrados os módulos de simulação e otimização foi possível aplicar a metodologia proposta para o dimensionamento de um SHGE. Primeiramente foi resolvido o problema para o caso mono-objetivo, a partir do qual se dimensionou o SHGE em função do Valor Presente Líquido dos custos (NPV_C), enquanto uma série de restrições técnicas pré-estabelecidas são satisfeitas. A configuração do algoritmo incorporado na *GAtoolbox* mostrou a capacidade de resolver o problema de forma satisfatória encontrando em todas as simulações o valor ótimo global, que foi conferido através da utilização do software comercial HOMER®, o qual utiliza o método de Busca Exaustiva para realizar a otimização. A vantagem do AG em relação ao método de HOMER® ficou evidente nos tempos de processamento empregados em cada algoritmo. Sendo que nos casos estudados a abordagem de otimização baseada em AG precisou de menos de 20% do tempo utilizado pelo HOMER® para atingir os mesmos resultados. A partir dos resultados obtidos pelo algoritmo de otimização de SHGE foram identificadas algumas questões que podem ser aprimoradas em próximas versões do algoritmo. Em determinadas situações o algoritmo fornece uma solução matematicamente lógica, porém que tecnicamente pode resultar inviável. Como é o caso da

incorporação de um motor gerador para suprir a carga pico em momentos esporádicos, ficando este componente ocioso a maior parte do tempo. No entanto, o algoritmo fornece uma série de indicadores de desempenho que podem ser utilizados pelo tomador de decisão para avaliar a viabilidade técnica de cada solução.

Em seguida se utilizou a *GAtoolbox* para resolver o problema de otimização determinística multiobjetivo. O algoritmo mostrou a capacidade de encontrar soluções diversas e bem distribuídas sobre a fronteira de Pareto. Esta característica permite ao tomador de decisão ter uma visão global sobre os *trade-off* entre as diferentes soluções possíveis, constituindo uma ferramenta de tomada de decisão muito útil.

O caso de otimização multiobjetivo do custo e da energia não suprida $\min f_m(NPV_C, LPS)$ é útil em situações nas quais se pode admitir uma confiabilidade do sistema elétrico menor do que 100%. Por exemplo, num sistema eólico ou solar existente pode-se avaliar o custo que implica incorporar maior geração renovável ou um moto gerador de *backup* para aumentar a confiabilidade do sistema.

O caso de otimização multiobjetivo do custo e das emissões do gás poluente $\min f_m(NPV_C, EMCO_2)$ é especialmente útil quando se devem considerar restrições ambientais no processo de dimensionamento. A otimização multiobjetivo permite incluir as emissões de CO₂ equivalente como um objetivo independente em relação ao custo. Este procedimento é uma melhor alternativa frente a abordagem na qual as emissões são consideradas dentro do cálculo econômico através de um fator de penalidade. Neste último caso, o resultado final depende fortemente do valor do fator de penalidade escolhido, e, portanto é subjetiva. No entanto, evidenciou-se que as configurações podem resultar num custo elevado caso não seja imposta uma restrição de máximo NPV_C . Isto constitui uma desvantagem desta otimização, já que muitas vezes o NPV_C se desconhece *a-priori*.

O caso de otimização de três objetivos em forma simultânea, custo, energia não suprida e emissões do gás poluente $\min f_m(NPV_C, LPS, EMCO_2)$ permite obter uma visão global dos *trade-off* entre esses três critérios de dimensionamento. A abordagem de otimização multiobjetivo proposta elimina a intervenção subjetiva do agente decisor no processo de dimensionamento do SHGE, e fornece um amplo leque de alternativas para que o agente decisor possa escolher a melhor configuração que atenda as necessidades do projeto.

Simularam-se as soluções determinísticas obtidas com o algoritmo multiobjetivo sob a presença de incertezas. Observou-se que as soluções determinísticas apresentam uma variação no valor dos objetivos em função da configuração do sistema, i.e. os componentes que

integram o sistema, e da magnitude das incertezas. As configurações que incorporam moto geradores de *backup* se apresentam menos sensíveis à presença de incertezas; a característica despachável desta fonte de energia permite absorver melhor as variações na disponibilidade dos recursos e na demanda da carga. A média das soluções determinísticas quando avaliadas sob a presença de incertezas afasta da fronteira de Pareto determinística, evidenciando que o método de otimização deve incorporar as incertezas para se obter soluções robustas. Para solucionar este problema é proposta a abordagem de otimização probabilística, o qual modifica o algoritmo AG multiobjetivo para incorporar um método de quantificação de incertezas dentro do processo de otimização.

A aplicação do algoritmo de otimização multiobjetivo probabilístico mostrou resultados satisfatórios, gerando soluções ótimas e robustas. No entanto, cabe esclarecer que o método de otimização probabilística se apresenta como uma técnica de otimização com um custo computacional elevado. Utilizando um computador equipado com Windows 7, 64 Bits, processador AMD FX™-8150 com processador de 8 núcleos 3,6GHz e memória RAM de 16 GB, o tempo médio de simulação resultou em 15 horas para cada configuração do problema de otimização, utilizando computação paralela. É por isso que se sugere aplicar, como método de análise prévio, a técnica de simulação probabilística às soluções não dominadas da fronteira de Pareto obtidas pelo algoritmo multiobjetivo determinístico. A partir desta abordagem alternativa, a qual representam um custo computacional menor, apenas 10% do tempo gasto pelo algoritmo de otimização probabilístico, é possível observar a influência das incertezas nas soluções da fronteira de Pareto determinística. Caso a média das soluções determinísticas sob incerteza ultrapasse as restrições impostas pelo usuário, pode-se partir para a otimização probabilística a qual incorpora as incertezas nas variáveis de entrada no processo de dimensionamento do SHGE, e, portanto, assegura que as soluções obtidas se encontram dentro da região factível do espaço de busca.

Em função dos resultados obtidos, pode-se concluir que se cumpriu o objetivo principal da presente pesquisa, no entanto, identificam-se os seguintes temas de pesquisa futuros:

- Estudo de outras metaheurísticas de otimização. Os AG são considerados um método clássico, já que foi um dos primeiros algoritmos desta família a ser desenvolvido. No entanto, existem outras metaheurísticas que apresentam resultados promissores. Portanto, seria interessante explorar outras técnicas de otimização metaheurística para comparar o desempenho com os AGs. Espera-se que os resultados não sejam muito diferentes dos obtidos no presente estudo, no entanto, podem existir diferenças na velocidade de convergência e no desempenho geral do algoritmo.

- Incorporação de outras fontes renováveis de geração de energia como a biomassa, o biodiesel, hidrelétrica, solar térmica e células de combustível.
- Análise da possibilidade da produção de hidrogênio como sistema alternativo de armazenamento de energia.
- Incorporação de critérios de otimização sociais, como o índice de desenvolvimento humano, o potencial de geração de renda e emprego, aceitação da tecnologia, entre outros. Como estes indicadores são difíceis de quantificar, devem ser considerados no projeto de sistemas de eletrificação em locais isolados, onde o acesso a energia elétrica constitui um vetor de crescimento econômico e de melhora da qualidade de vida.
- Validação do modelo de simulação do SGHE a partir de dados experimentais derivados de um sistema real em operação.
- Implementação do algoritmo numa linguagem de programação de baixo nível com o intuito de diminuir os tempos de simulação.
- Fazer uma análise termoeconômica do SHGE para incorporar como variáveis de otimização as irreversibilidades e rendimentos energéticos dos componentes do sistema.

REFERÊNCIAS

- ABDEL-RAHMAN, H. **Global Optimization - Methods and Codes**. Disponível em: <http://www-optima.amp.i.kyoto-u.ac.jp/member/student/hedar/Hedar_files/go.htm>. Acesso em: 12 set. 2015.
- ABOUZAHR, I.; RAMAKUMAR, R. Loss of power supply probability of stand-alone photovoltaic systems: a closed form solution approach. **Energy Conversion, IEEE ...**, v. 6, n. 1, 1991.
- ABUL'WABA, A. R. Optimization of economic/emission load dispatch for hybrid generating systems using controlled Elitist NSGA-II. **Electric Power Systems Research**, v. 105, p. 142–151, 2013.
- ACKERMANN, T.; ANDERSSON, G.; SÖDER, L. Distributed generation: A definition. **Electric Power Systems Research**, v. 57, n. 3, p. 195–204, 2001.
- AGAJELU, B. O. et al. Life Cycle Cost Analysis of a Diesel/Photovoltaic Hybrid Power Generating System. **Industrial Engineering Letters**, v. 3, n. 1, p. 19–31, 2013.
- AI, B. et al. Computer-aided design of PV/wind hybrid system. **Renewable Energy**, v. 28, n. 10, p. 1491–1512, ago. 2003.
- AKACHUKWU, C. M. et al. **A Decade Survey of Engineering Applications of Genetic Algorithm in Power System Optimization** 2014 5th International Conference on Intelligent Systems, Modelling and Simulation. **Anais...**2014
- ALSEMA, E. A. **Environmental life cycle assessment of solar home systems**. Utrecht, The Netherlands: [s.n.].
- AL-SHAMMA'A, A. A.; KHALED, E. A. Techno-economic optimization of hybrid power system using genetic algorithm. **International journal of energy research**, v. 38, n. April 2014, p. 1608–1623, 2014.
- ANEEL - AGENCIA NACIONAL DE ENERGIA ELÉTRICA. **Indicadores de continuidade, Amazonas Distribuidora de Energia S.A.** Disponível em: <<http://www2.aneel.gov.br/aplicacoes/srd/indqual/default.cfm>>. Acesso em: 10 maio. 2016.
- APRIL, J. et al. **Practical introduction to simulation optimization** Simulation Conference, 2003. Proceedings of the 2003 Winter. **Anais...**2003
- APRILIA, E. C. et al. Modeling the frequency response of photovoltaic inverters. **IEEE PES Innovative Smart Grid Technologies Conference Europe**, p. 4–8, 2012.
- ARUN, S.; KUMARAVEL, S.; SELVAN, M. **Unit Size Optimization of Hybrid Energy System** 2014 IEEE Innovative Smart Grid Technologies. **Anais...**IEEE, 2014
- ASHOK, S. Optimised model for community-based hybrid energy system. **Renewable Energy**, v. 32, n. 7, p. 1155–1164, jun. 2007.
- BÄCK, T. **Evolutionary Algorithms in Theory and Practice: Evolution Strategies, Evolutionary Programming, Genetic Algorithms**. 1st. ed. New York: Oxford University Press, 1996.
- BÄCK, T.; FOGEL, D. B.; MICHALEWICZ, Z. **Evolutionary Computation 2: Advanced Algorithms and Operators**. 1st. ed. Bristol, Philadelphia: Institute of Physics Publishing, 2000a.

BÄCK, T.; FOGEL, D. B.; MICHALEWICZ, Z. **Evolutionary Computation 1: Basic Algorithms and Operators**. 1st. ed. Bristol, Philadelphia: Institute of Physics Publishing, 2000b.

BÄCK, T.; SCHWEFEL, H. P. **Evolutionary Algorithms: Some Very Old Strategies for Optimization and Adaptation**New Computing Techniques in Physics Research (II) - Proceedings of the 2nd International Workshop on Software Engineering, Artificial Intelligence and Expert Systems for High Energy and Nuclear Physics. **Anais...**La Londe-Les-Maures: Singapore: World Scientific, 1992

BAKER, J. E. **Reducing Bias and Inefficiency in the Selection Algorithm**Proceedings of the Second International Conference on Genetic Algorithms on Genetic Algorithms and Their Application. **Anais...**Hillsdale, NJ, USA: L. Erlbaum Associates Inc., 1987

BANSAL, R. .; BHATTI, T. .; KOTHARI, D. . On some of the design aspects of wind energy conversion systems. **Energy Conversion and Management**, v. 43, p. 2175–2187, 2002.

BARLEY, C. D. et al. **Optimal Control of Remote Hybrid Power Systems Part 1: Simplified Model**Windpower. **Anais...**Washington, DC: 1995

BARLEY, C. D.; WINN, C. B. Optimal dispatch strategy in remote hybrid power systems. **Solar Energy**, v. 58, n. 4-6, p. 165–179, out. 1996.

BASHIR, M.; SADEH, J. **Optimal sizing of hybrid wind/photovoltaic/battery considering the uncertainty of wind and photovoltaic power using Monte Carlo**11th International Conference on Environment and Electrical Engineering (EEEIC). **Anais...**Venice: IEEE, 2012a

BASHIR, M.; SADEH, J. **Size optimization of new hybrid stand-alone renewable energy system considering a reliability index**International Conference on Environment and Electrical Engineering (EEEIC). **Anais...**Venice: 2012b

BASTOS, E. A. **Otimização de seções retangulares de concreto armado à flexo-compressão oblíqua utilizando algoritmos genéticos**. [s.l.] Universidade Federal de Rio de Janeiro (COPPE/UFRJ), 2004.

BECHIKH, S.; SAID, L. BEN; GHÉDIRA, K. Searching for knee regions of the Pareto front using mobile reference points. **Soft Computing**, v. 15, n. 9, p. 1807–1823, 2011.

BENGHANEM, M. Optimization of tilt angle for solar panel: Case study for Madinah, Saudi Arabia. **Applied Energy**, v. 88, n. 4, p. 1427–1433, 2011.

BERNAL-AGUSTÍN, J. L.; DUFO-LÓPEZ, R. Multi-objective design and control of hybrid systems minimizing costs and unmet load. **Electric Power Systems Research**, v. 79, n. 1, p. 170–180, jan. 2009.

BERNAL-AGUSTÍN, J. L.; DUFO-LÓPEZ, R.; RIVAS-ASCASO, D. M. Design of isolated hybrid systems minimizing costs and pollutant emissions. **Renewable Energy**, v. 31, n. 14, p. 2227–2244, nov. 2006.

BHANDARI, B. et al. Mathematical modeling of hybrid renewable energy system: A review on small hydro-solar-wind power generation. **International Journal of Precision Engineering and Manufacturing-Green Technology**, v. 1, n. 2, p. 157–173, 2014.

BILIL, H.; ANIBA, G.; MAAROUFI, M. Multiobjective optimization of renewable energy penetration rate in power systems. **Energy Procedia**, v. 50, p. 368–375, 2014.

BILLINTON, R.; ALLAN, R. A. **Reliability Evaluation of Engineering Systems: Concepts and Techniques**. 2nd. ed. New York: Springer Science+Business Media, Inc., 1992.

BILLINTON, R.; LI, W. **Reliability Assessment of Electric Power Systems Using Monte Carlo Methods**. New York: Springer Science+Business Media, Inc., 1994.

BINDNER, H. et al. **Lifetime modelling of lead acid batteries**. Roskilde (Denmark): Risø National Laboratory, 2005. Disponível em: <http://orbit.dtu.dk/fedora/objects/orbit:88309/datastreams/file_7710966/content>. Acesso em: 24 nov. 2014.

BLASCO FERRAGUD, F. X. **Control predictivo basado en modelos mediante técnicas de optimización heurística. Aplicación a procesos no lineales y multivariados**. [s.l.] Universidad Politécnica de Valencia, 2012.

BLASQUES MACEDO, L. C. **Estudo de Viabilidade Técnico-Econômica de Sistemas Híbridos para Geração de Eletricidade**. [s.l.] Universidade Federal do Pará, 2005.

BLUM, C.; ROLI, A. Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison. **ACM Computing Surveys**, v. 35, n. 3, p. 268–308, 2003.

BONDESSON, A. **Comparative LCA model on renewable power solutions for off-grid radio base stations**. [s.l.] Royal Institute of Technology (KTH), Stockholm, Sweden, 2010.

BOROWY, B. S.; SALAMEH, Z. M. Methodology for optimally sizing the combination of a battery bank and PV array in a wind/PV hybrid system. **IEEE Transactions on Energy Conversion**, v. 11, n. 2, p. 367–375, jun. 1996.

BOUROUNI, K.; BEN M'BAREK, T.; AL TAEI, A. Design and optimization of desalination reverse osmosis plants driven by renewable energies using genetic algorithms. **Renewable Energy**, v. 36, n. 3, p. 936–950, mar. 2011.

BRAGA, L. B. **Aspectos Técnicos, Econômicos e Ecológicos de Processos de Produção de Hidrogênio**. [s.l.] Universidade Estadual Paulista “Julio de Mesquita Filho”, 2014.

BURTON, T. et al. **Wind Energy Handbook**. 2 ed ed. Chichester, England: John Wiley & Sons, Ltd., 2011.

CAGNINA, L. C.; ESQUIVEL, S. C.; COELLO COELLO, C. A. Solving engineering optimization problems with the simple constrained particle swarm optimizer. **Informatica**, v. 32, n. 3, p. 319–326, 2008.

CANEDO MONTESANO MIRANDA, A. B. **Análise de Viabilidade Econômica de um Sistema Fotovoltaico Conectado à Rede**. [s.l.] Universidade Federal do Rio de Janeiro (UFRJ), 2014.

CAO, Y. J.; WU, Q. H. Teaching Genetic Algorithms Using Matlab. **International of Engineering Education**, v. 36, p. 139–153, 1999.

CARTAXO FERREIRA, E. **Fornecimento de Serviço de Energia Elétrica Para Localidades Isoladas da Amazônia: reflexões a partir de um estudo de caso**. [s.l.] Universidade Estadual de Campinas (UNICAMP), 2000.

CARUANA, R. A; ESHELMANN, L.; SCHAFFER, J. Representation and Hidden Bias II: Eliminating Defining Length Bias in Genetic Search Via Shuffle Crossover. **Proceedings of the Eleventh International Joint Conference on Artificial intelligence**, p. 750–755, 1989.

CASSULA, A. M. et al. **Avaliação Probabilística do Desempenho de um Sistema Híbrido de Geração de Energia Atendendo Comunidades Isoladas** XXII SNPTTE Seminário Nacional de Produção e Transmissão de Energia Elétrica. **Anais...** Brasília - DF: 2013

CELIK, A. N. The system performance of autonomous photovoltaic–wind hybrid energy

systems using synthetically generated weather data. **Renewable Energy**, v. 27, n. 1, p. 107–121, set. 2002a.

CELIK, A. N. Optimisation and techno-economic analysis of autonomous photovoltaic–wind hybrid energy systems in comparison to single photovoltaic and wind systems. **Energy Conversion and Management**, v. 43, n. 18, p. 2453–2468, dez. 2002b.

CENTENO GONZALEZ, F. O. et al. Prediction by mathematical modeling of the behavior of an internal combustion engine to be fed with gas from biomass, in comparison to the same engine fueled with gasoline or methane. **Renewable Energy**, v. 60, p. 427–432, 2013.

CHAPMAN, R. N. **Sizing Handbook for Stand-Alone Photovoltaic/Storage Systems** Sandia Report. Albuquerque: [s.n.].

CHAUHAN, A.; SAINI, R. P. A review on Integrated Renewable Energy System based power generation for stand-alone applications: Configurations, storage options, sizing methodologies and control. **Renewable and Sustainable Energy Reviews**, v. 38, p. 99–120, 2014.

CHEDID, R.; KARAKI, S.; RIFAI, A. A multi-objective design methodology for hybrid renewable energy systems. **2005 IEEE Russia Power Tech**, 2005.

CHEDID, R.; SALIBA, Y. Optimization and control of autonomous renewable energy systems. **International journal of energy research**, v. 20, n. October 1994, p. 609–624, 1996.

CHEN, H. C. Optimum capacity determination of stand-alone hybrid generation system considering cost and reliability. **Applied Energy**, v. 103, p. 155–164, 2013.

CHIPPERFIELD, A. J.; FLEMING, P. J.; FONSECA, C. M. **Genetic algorithm tools for control systems engineering** 1st International Conference Adaptive Computing in Engineering Design and Control. **Anais...Plymouth, UK**: 1994

CLARKE, D. P.; AL-ABDELI, Y. M.; KOTHAPALLI, G. Multi-objective optimisation of renewable hybrid energy systems with desalination. **Energy**, v. 88, p. 457–468, 2015.

COELLO COELLO, C. A. **A Survey of Constraint Handling Techniques used with Evolutionary Algorithms** Laboratorio Nacional de Informática Avanzada, , 1999. Disponível em: <http://web.ist.utl.pt/adriano.simoes/tese/referencias/Papers-Antonio/GAConstraints.pdf>

COELLO COELLO, C. A.; MONTES, E. M. Constraint-handling in genetic algorithms through the use of dominance-based tournament selection (draft). **Advanced Engineering Informatics**, v. 16, n. 3, p. 193–203, 2002a.

COELLO COELLO, C. A.; MONTES, E. M. Constraint-handling in genetic algorithms through the use of dominance-based tournament selection. **Advanced Engineering Informatics**, v. 16, n. 3, p. 193–203, 2002b.

COLLETTE, Y.; SIARRY, P. **Multiobjective optimization: principles and case studies**. 1. ed. [s.l.] Springer, 2003.

COTRIM, A. M. B. **Instalações Elétricas**. 4 ed ed. São Paulo: Pearson Prentice Hall, 2003.

CRESESB. **Potencial Solar - SunData**. Disponível em: <http://www.cresesb.cepel.br/index.php?section=sundata&>. Acesso em: 1 mar. 2016a.

CRESESB. **Potencial Eólico - Atlas do Potencial Eólico Brasileiro**. Disponível em: http://www.cresesb.cepel.br/index.php?section=atlas_eolico. Acesso em: 28 fev. 2016b.

- DE JONG, K. A. **An Analysis of the Behavior of a Class of Genetic Adaptative Systems**. [s.l.] University of Michigan, 1975.
- DE SOTO, W.; KLEIN, S. A.; BECKMAN, W. A. Improvement and validation of a model for photovoltaic array performance. **Solar Energy**, v. 80, n. 1, p. 78–88, jan. 2006.
- DEB, K. An efficient constraint handling method for genetic algorithms. **Computer Methods in Applied Mechanics and Engineering**, v. 186, n. 2-4, p. 311–338, 2000.
- DEB, K. et al. A fast and elitist multiobjective genetic algorithm: NSGA-II. **IEEE Transactions on Evolutionary Computation**, v. 6, n. 2, p. 182–197, 2002.
- DEB, K. **Multi-objective optimization using evolutionary algorithms**. Chichester, England: John Wiley & Sons, Ltd., 2004.
- DEB, K. et al. Scalable test problems for evolutionary multiobjective optimization. **Evolutionary Multiobjective**, n. 1990, p. 1–27, 2005.
- DEB, K. Multi-objective Optimization. In: BURKE, E. K.; KENDALL, G. (Eds.). **Search Methodologies Introductory Tutorials in Optimization and Decision Support Techniques**. 2. ed. New York: Springer, 2014. p. 403–450.
- DEEP, K. et al. A real coded genetic algorithm for solving integer and mixed integer optimization problems. **Applied Mathematics and Computation**, v. 212, n. 2, p. 505–518, 2009.
- DEMAIN, C.; JOURNÉE, M.; BERTRAND, C. Evaluation of different models to estimate the global solar radiation on inclined surfaces. **Renewable Energy**, v. 50, p. 710–721, 2013.
- DIAF, S. et al. A methodology for optimal sizing of autonomous hybrid PV/wind system. **Energy Policy**, v. 35, n. 11, p. 5708–5718, nov. 2007.
- DIAF, S. et al. Design and techno-economical optimization for hybrid PV/wind system under various meteorological conditions. **Applied Energy**, v. 85, n. 10, p. 968–987, out. 2008.
- DIAS, E. V. **Variação Interanual dos Ventos do Nordeste**. [s.l.] Universidade Federal de Lavras (MG), 2013.
- DILETTOSO, E. et al. Optimization of Hybrid Solar Wind Power Systems. **International Journal of Applied Electromagnetics and Mechanics**, v. 26, p. 225–231, 2007.
- DIORIO, N. et al. **System Advisor Model: Battery Storage & Dispatch Model Overview and Validation**, 2015.
- DJAMILA, M.; ERNEST, R. Modeling of Solar Irradiance and Cells. In: **Optimization of Photovoltaic Power Systems: Modelization, Simulation and Control**. London, UK: Springer-Verlag London Limited, 2012. p. 31–87.
- DOBOS, A. P. **PVWatts Version 5 Manual (NREL/TP-6A20-62641)**. Denver, 2014: [s.n.].
- DRIESSE, A.; JAIN, P.; HARRISON, S. Beyond the curves: Modeling the electrical efficiency of photovoltaic inverters. **Conference Record of the IEEE Photovoltaic Specialists Conference**, n. August, 2008.
- DUFFIE, J. A.; BECKMAN, W. A. **Solar Engineering for Thermal Processes**. 4. ed. New Jersey: John Wiley & Sons Inc, 2013.
- DUFO-LÓPEZ, R. et al. Multi-objective optimization minimizing cost and life cycle emissions of stand-alone PV–wind–diesel systems with batteries storage. **Applied Energy**, v. 88, n. 11, p. 4033–4041, nov. 2011.

DUFO-LÓPEZ, R.; BERNAL-AGUSTÍN, J. L. Design and control strategies of PV-Diesel systems using genetic algorithms. **Solar Energy**, v. 79, n. 1, p. 33–46, jul. 2005.

DUFO-LÓPEZ, R.; BERNAL-AGUSTÍN, J. L. Multi-objective design of PV–wind–diesel–hydrogen–battery systems. **Renewable Energy**, v. 33, n. 12, p. 2559–2572, dez. 2008.

DUFO-LÓPEZ, R.; BERNAL-AGUSTÍN, J. L. **HOGA - Hybrid-Renewable Optimization by Genetic Algorithms**. Disponível em: <<http://hoga-renewable.es.tl/>>. Acesso em: 19 maio. 2015.

DUFO-LÓPEZ, R.; BERNAL-AGUSTÍN, J. L.; CONTRERAS, J. Optimization of control strategies for stand-alone renewable energy systems with hydrogen storage. **Renewable Energy**, v. 32, n. 7, p. 1102–1126, jun. 2007.

DUFO-LÓPEZ, R.; BERNAL-AGUSTÍN, J. L.; MENDOZA, F. Design and economical analysis of hybrid PV–wind systems connected to the grid for the intermittent production of hydrogen. **Energy Policy**, v. 37, n. 8, p. 3082–3095, ago. 2009.

ECKERT, P.; RAKOWSKI, S. Pollutant Formation. In: MERKER, G. P.; SCHWARZ, C.; RÜDIGER, T. (Eds.). **Combustion Engines Development: Mixture Formation, Combustion, Emissions and Simulation**. 1. ed. Wiesbaden, Germany: Springer-Verlag Berlin Heidelberg, 2012. p. 659.

EIBEN, A. E.; SMITH, J. E. **Introduction to Evolutionary Computing**. 1st. ed. Berlin: Springer, 2003.

EKREN, O.; EKREN, B. Y. Size optimization of a PV/wind hybrid energy conversion system with battery storage using response surface methodology. **Applied Energy**, v. 85, n. 11, p. 1086–1101, 2008.

EKREN, O.; EKREN, B. Y. Size Optimization of a Solar-wind Hybrid Energy System Using Two Simulation Based Optimization Techniques. **Fundamentals and Advanced Topics in Wind Power**, 2011.

ELECTRICITY MARKET AND POLICY GROUP (BERKELY LAB). **Photovoltaic System Pricing Trends: Historical, Recent, and Near-Term Projections**. Disponível em: <<http://emp.lbl.gov/publications/photovoltaic-system-pricing-trendshistorical-recent-and-near-term-projections-2013-edi>>. Acesso em: 10 abr. 2015.

ELEKTROBRÁS – CENTRAIS ELÉTRICAS BRASILEIRAS S.A. **Eletrobras - Centrais Elétricas Brasileiras S.A.** Disponível em: <<http://www.eletrobras.com/elb/data/Pages/LUMIS293E16C4PTBRIE.htm>>. Acesso em: 27 ago. 2014.

ENGIN, M. Sizing and simulation of PV-wind hybrid power system. **International Journal of Photoenergy**, v. 2013, 2013.

ERBS, D. G.; KLEIN, S. A.; DUFFIE, J. A. Estimation of the Diffuse Radiation Fraction for Hourly, Daily, and Monthly-Average Global Radiation. **Solar Energy**, v. 28, n. 4, p. 293, 1982.

ESHELMAN, L. J.; SCHAFFER, J. D. Real-coded genetic algorithms and interval-schemata. n. JANUARY 1992, p. 187–202, 1993.

EVANS, A.; STREZOV, V.; EVANS, T. J. Assessment of sustainability indicators for renewable energy technologies. **Renewable and Sustainable Energy Reviews**, v. 13, n. 5, p. 1082–1088, 2009.

EVANS, D. L. Simplified method for predicting photovoltaic array output. **Solar Energy**, v.

27, n. 6, p. 555–560, jan. 1981.

FLECK, B.; HUOT, M. Comparative life-cycle assessment of a small wind turbine for residential off-grid use. **Renewable Energy**, v. 34, n. 12, p. 2688–2696, 2009.

FONSECA, C. M.; FLEMING, P. J. **Genetic Algorithms for Multiobjective Optimization: Formulation, Discussion and Generalization** ICGA. Anais...San Mateo, CA: Morgan Kaufmann, 1993

FOSTER, R.; GHASSEMI, M.; COTA, A. **Solar energy: renewable energy and the environment**. 1st. ed. Boca Raton: CRC Press, 2010.

FRAUNHOFER INSTITUTE FOR SOLAR ENERGY SYSTEMS ISE. **Photovoltaic Report**. Disponível em: <<http://www.ise.fraunhofer.de/en/downloads-englisch/pdf-files-englisch/photovoltaics-report-slides.pdf>>. Acesso em: 11 maio. 2015.

FTHENAKIS, V.; ALSEMA, E. Photovoltaics energy payback times, greenhouse gas emissions and external costs: 2004–early 2005 status. **Prog. Photovolt: Res. Appl.**, n. 14, p. 275–280, 2006.

FTHENAKIS, V.; KIM, H.; FRISCHKNECHT, R. Life cycle inventories and life cycle assessment of photovoltaic systems. **International Energy Agency**, p. 63, 2011.

FTHENAKIS, V. M.; KIM, H. C. Photovoltaics: Life-cycle analyses. **Solar Energy**, v. 85, n. 8, p. 1609–1628, 2011.

FU, M. C. Feature Article: Optimization for simulation: Theory vs. Practice. **INFORMS Journal on Computing**, v. 14, n. 3, p. 192–215, 2002.

FU, Z.; YANG, J.; ZOU, T. Optimal Sizing Design for Hybrid Renewable Energy Systems in Rural Areas. In: **Computer and Computing Technologies in Agriculture IV**. [s.l.] Springer Berlin Heidelberg, 2011. p. 131–138.

GARCÍA-VALVERDE, R. et al. Life cycle assessment study of a 4.2 kWp stand-alone photovoltaic system. **Solar Energy**, v. 83, n. 9, p. 1434–1445, 2009.

GENG, D. **Simulation-based Optimization**. [s.l.] University of Wisconsin, Madison, 1996.

GERGAUD, O.; MULTON, B.; BEN AHMED, H. Analysis and Experimental Validation of Various Photovoltaic System Models. **7th International ELECTRIMACS Congress, Montréal**, n. august, p. 1–7, 2002.

GIANNAKOUDIS, G. et al. Optimum design and operation under uncertainty of power systems using renewable energy sources and hydrogen storage. **International Journal of Hydrogen Energy**, v. 35, n. 3, p. 872–891, 2010.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. Crawfordsville, Indiana: Addison Wesley Longman, Inc., 1989.

GOLDBERG, D. E.; DEB, K. **A comparative analysis of selection schemes used in genetic algorithms** (G. J. E. Rawlins, Ed.) Foundations of Genetic Algorithms. Anais...Morgan Kaufmann, 1991

GONÇALVES MACHADO, K. **Otimização de Estoque de Transformadores em Sistemas de Potência via Simulação Monte Carlo Cronológica e Técnicas Metaheurísticas**. [s.l.] Universidade Federal de Itajubá, 2014.

GOSAVI, A. **Simulation Based Optimization - Parametric Optimization Techniques and Reinforcement Learning**. 2nd. ed. New York: Springer, 2015.

- GRAHAM, V. A.; HOLLANDS, K. G. T. A method to generate synthetic hourly solar radiation globally. **Solar Energy**, v. 44, n. 6, p. 333–341, 1990.
- GRAHAM, V. A.; HOLLANDS, K. G. T.; UNNY, T. E. A time series model for K_t with application to global synthetic weather generation. **Solar Energy**, v. 40, n. 2, p. 83–92, 1988.
- GSÄNGER, S.; PITTELOUD, J.-D. **2015 Small Wind World Report Summary**. Bonn, Germany. World Wind Energy Association (WWEA), , 2015.
- GUPTA, A.; SAINI, R. P.; SHARMA, M. P. **Computerized modelling of hybrid energy system - Part III: Case study with simulation results** Proceedings of ICECE 2008 - 5th International Conference on Electrical and Computer Engineering. **Anais...** Dhaka, Bangladesh: IEEE, 2008a
- GUPTA, A.; SAINI, R. P.; SHARMA, M. P. **Computerized Modelling of Hybrid Energy System — Part I: Case Study with Simulation Results** 5th International Conference on Electrical and Computer Engineering ICECE 2008. **Anais...** Dhaka, Bangladesh: IEEE, 2008b
- GUPTA, A.; SAINI, R. P.; SHARMA, M. P. **Modelling of hybrid energy system-Part II: Combined dispatch strategies and solution algorithm** 5th International Conference on Electrical and Computer Engineering ICECE 2008. **Anais...** Dhaka, Bangladesh: IEEE, 2008c
- GUPTA, R. A.; KUMAR, R.; BANSAL, A. K. Economic analysis and design of stand-alone wind/photovoltaic hybrid energy system using Genetic algorithm. **International Conference on Computing, Communication and Applications (ICCCA)**, p. 1–6, 2012.
- HABIB, M. A. et al. Optimization procedure of a hybrid photovoltaic wind energy system. **Energy**, v. 24, n. 11, p. 919–929, nov. 1999.
- HAINES, A. L.; MILLS, K. L.; FILLIBEN, J. J. Determining Relative Importance and Best Settings for Genetic Algorithm Control Parameters. **Evolutionary computation**, p. 1–34, 2014.
- HAKIMI, S. M.; MOGHADDAS-TAFRESHI, S. M. Optimal sizing of a stand-alone hybrid power system via particle swarm optimization for Kahnouj area in south-east of Iran. **Renewable Energy**, v. 34, n. 7, p. 1855–1862, jul. 2009.
- HAUSCHILD, L. **Avaliação de Estratégias de Operação de Sistemas Híbridos Fotovoltaico-Eólico-Diesel**. [s.l.] Universidade de São Paulo, 2006.
- HELTON, J. C.; DAVIS, F. J. **Sampling-Based Methods for Uncertainty and Sensitivity Analysis (SAND99-2240)**. Sandia National Laboratories. Albuquerque, USA. 2000: [s.n.].
- HERRERA, F.; LOZANO, M.; VERDEGAY, J. L. Trackling Real-Coded Genetic ALgoirhtms: Operators and Tools for Behavioural Analysis. **Artificial Intelligence Review**, v. 12, p. 265–319, 1998.
- HERTWICH, E. G. et al. Integrated life-cycle assessment of electricity-supply scenarios confirms global environmental benefit of low-carbon technologies. **Proceedings of the National Academy of Sciences of the United States of America**, v. 112, n. 20, p. 6277–6282, 2014.
- HOCAOĞLU, F. O.; GEREK, Ö. N.; KURBAN, M. A novel hybrid (wind–photovoltaic) system sizing procedure. **Solar Energy**, v. 83, n. 11, p. 2019–2028, nov. 2009.
- HOLLAND, J. H. **Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence**. 2nd. ed. Ann Harbor, Michigan: The MIT Press, 1992.

HOLLANDS, K. G. T. A Concentrator for Thin-Film Solar Cells. **Solar Energy**, v. 13, n. 149, 1971.

HOLLANDS, K. G. T.; D'ANDREA, L. J.; MORRISON, I. D. Effect of random fluctuations in ambient air temperature on solar system performance. **Solar Energy**, v. 42, n. 4, p. 335–338, 1989.

HOMER ENERGY LLC. BOULDER COLORADO. **Generating Synthetic Wind Data**, 2010a.

HOMER ENERGY LLC. BOULDER COLORADO. **Diesel O&M costs**. Disponível em: <<http://support.homerenergy.com/index.php?Knowledgebase/Article/View/107/25/10066---diesel-om-costs>>. Acesso em: 10 jun. 2016b.

HOMER ENERGY LLC. BOULDER COLORADO. **Hybrid Optimization Model for Electric Renewables**. Disponível em: <<http://homerenergy.com/>>. Acesso em: 25 maio. 2015.

HORN, J.; NAFPLIOTIS, N.; GOLDBERG, D. E. **A niched Pareto genetic algorithm for multiobjective optimization** Evolutionary Computation, 1994. IEEE World Congress on Computational Intelligence., Proceedings of the First IEEE Conference on. **Anais...**1994

HORST, R.; PARDALOS, P. M.; NGUYEN, V. T. **Introduction to Global Optimization**. 2. ed. Dordrecht (The Netherlands): Springer US, 2000.

HOUCK, C. R. et al. A genetic algorithm for function optimization: a Matlab implementation. **NCSU-IE TR**, n. 919, p. 14, 1995.

HRČKA, L.; VAŽAN, P.; ŠUTOVÁ, Z. Basic Overview of Simulation Optimization. **Research Papers Faculty of Materials Science and Technology Slovak University of Technology**, v. 22, n. 341, p. 11–16, 2014.

IEA. **Technology Roadmap - Wind Energy**. International Energy Agency (IEA), , 2013a.

IEA. **Technology Roadmap - Solar Fotovoltaic**. International Energy Agency (IEA), , 2013b.

IERAPETRITOU, M. G.; ACEVEDO, J.; PISTIKOPOULOS, E. N. An optimization approach for process engineering problems under uncertainty. **Computers & Chemical Engineering**, v. 20, n. 6-7, p. 703–709, 1996.

IMAZON. **Amazônia legal**. Disponível em: <<http://imazon.org.br/mapas/>>. Acesso em: 10 jun. 2016.

INMET. **BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa**. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>. Acesso em: 5 mar. 2016.

IQBAL, M. **An introduction to solar radiation**. Canada: Academic Press, 1983.

IRENA. **Solar Photovoltaics. Renewable Energy Technologies: Cost Analysis Series**. International Renewable Energy Agency (IRENA), , 2012.

IRENA. **Renewable Power Generation Costs in 2014**. International Renewable Energy Agency (IRENA), , 2015.

ISMAIL, M. S.; MOGHAVVEMI, M.; MAHLIA, T. M. I. Genetic algorithm based optimization on modeling and design of hybrid renewable energy systems. **Energy Conversion and Management**, v. 85, p. 120–130, 2014.

JAHANBANI, F.; RIAHY, G. H. Optimum Design of a Hybrid Renewable Energy System.

Renewable Energy - Trends and Applications, p. 21, 2011.

JAIN, B. J.; POHLHEIM, H.; WEGENER, J. **On Termination Criteria of Evolutionary Algorithms** Proceedings of the Genetic and Evolutionary Computation Conference GECCO 2001. **Anais...**2001

JAKHRANI, A. Q. et al. Selection of models for calculation of incident solar radiation on tilted surfaces. **World Applied Sciences Journal**, v. 22, n. 9, p. 1334–1343, 2013.

JAMIL, M.; KIRMANI, S.; RIZWAN, M. Techno-Economic Feasibility Analysis of Solar Photovoltaic Power Generation : A Review. **Smart Grid and Renewable Energy**, v. 2012, n. November, p. 266–274, 2012.

JENSEN, P. A. **Factor Formulas**. Disponível em: <<http://www.me.utexas.edu/~me353/index.html>>. Acesso em: 20 ago. 2015.

JOINES, J. A.; KING, R. E.; CULBRETH, C. T. Cell Formation Using Genetic Algorithms. In: **Group Technology and Cellular Manufacturing: A State-Of-The-Art Synthesis of Research and Practice**. New York: Springer, 2012. p. 185–204.

JONES, A. D.; UNDERWOOD, C. P. A modelling method for building-integrated photovoltaic power supply. **Building Services Engineering Research and Technology**, v. 23, n. 3, p. 167–177, 1 ago. 2002.

JONGERDEN, M. R.; HAVERKORT, B. R. **Battery Modeling**. [s.l: s.n.]. Disponível em: <<http://purl.utwente.nl/publications/64556>>.

JONGERDEN, M. R.; HAVERKORT, B. R. Which battery model to use? **IET Software**, v. 3, n. 6, p. 445, 2009.

JUSTESEN, P. D. **Multi-objective Optimization using Evolutionary Algorithms**. [s.l.] University of Aarhus, 2009.

KAABECHE, A.; IBTIOUEN, R. Techno-economic optimization of hybrid photovoltaic/wind/diesel/battery generation in a stand-alone power system. **Solar Energy**, v. 103, p. 171–182, 2014.

KALDELLIS, J. K. **Stand-alone and Hybrid Wind Energy Systems. Technology, energy storage and applications**. 1st. ed. Boca Raton: CRC Press, 2010.

KALDELLIS, J. K.; KONDILI, E.; FILIOS, A. Sizing a hybrid wind-diesel stand-alone system on the basis of minimum long-term electricity production cost. **Applied Energy**, v. 83, n. 12, p. 1384–1403, 2006.

KALDELLIS, J. K.; ZAFIRAKIS, D.; KONDILI, E. Optimum autonomous stand-alone photovoltaic system design on the basis of energy pay-back analysis. **Energy**, v. 34, n. 9, p. 1187–1198, set. 2009.

KALOGIROU, S. **Solar Energy Engineering: process and systems**. 1st. ed. London, UK: Elsevier Inc., 2009.

KAMJOO, A. et al. Multi-objective design under uncertainties of hybrid renewable energy system using NSGA-II and chance constrained programming. **International Journal of Electrical Power & Energy Systems**, v. 74, p. 187–194, 2015.

KARAKI, S. H.; CHEDID, R. B.; RAMADAN, R. Probabilistic performance assessment of autonomous solar-wind energy conversion systems. **IEEE Transactions on Energy Conversion**, v. 14, n. 3, p. 766–772, 1999.

KARKI, R. et al. A Simplified Wind Power Generation Model for Reliability Evaluation.

IEEE Transactions on Energy Conversion, v. 21, n. 2, p. 533–540, 2006.

KARKI, R.; BILLINTON, R. Reliability/cost implications of PV and wind energy utilization in small isolated power systems. **Energy Conversion, IEEE Transactions on**, v. 16, n. 4, p. 368–373, 2001.

KARKI, R.; DHUNGANA, D.; BILLINTON, R. An Appropriate Wind Model for Wind Integrated Power Systems Reliability Evaluation Considering Wind Speed Correlations. **Applied Sciences**, v. 3, p. 107–121, 2013.

KARLIS, A. D.; PAPADOPOULOS, D. P. **Modelling, Testing and Economic Analysis of a Small-Scale Hybrid Wind-Photovoltaic-Battery System Installation** International Conference on Renewable Energies and Power Quality (ICREPQ). **Anais...**Vigo: 2013

KATSIGIANNIS, Y. A. et al. **Evaluating the Performance of Small Autonomous Power Systems using Reliability Worth Analysis** Proceedings of PMAPS 2012. **Anais...**Istanbul, Turkey: 2012

KATSIGIANNIS, Y. A.; GEORGILAKIS, P. S.; KARAPIDAKIS, E. S. Multiobjective genetic algorithm solution to the optimum economic and environmental performance problem of small autonomous hybrid power systems with renewables. **IET Renewable Power Generation**, v. 4, n. 5, p. 404, 2010a.

KATSIGIANNIS, Y. A.; GEORGILAKIS, P. S.; KARAPIDAKIS, E. S. Genetic Algorithm Solution to Optimal Sizing Problem of Small Autonomous Hybrid Power Systems. **Artificial Intelligence: Theories, Models and Applications, Proceedings**, v. 6040, p. 327–332, 2010b.

KELLOGG, W. D. et al. Generation unit sizing and cost analysis for stand-alone wind, photovoltaic, and hybrid wind/PV systems. **IEEE Transactions on Energy Conversion**, v. 13, n. 1, p. 70–75, 1998.

KEMMOKU, Y. et al. Life cycle CO₂ emissions of a photovoltaic/wind/diesel generating system. **Electrical Engineering in Japan (English translation of Denki Gakkai Ronbunshi)**, v. 138, n. 2, p. 14–23, 2002.

KHADER, S.; ABU-AISHEH, A. MPPT for Hybrid Energy System Using Gradient Approximation and Matlab Simulink Approach. **Journal of Energy and Power ...**, v. 4, n. 3, 2010.

KHATOD, D. K.; PANT, V.; SHARMA, J. Analytical Approach for Well-Being Assessment of Small Autonomous Power Systems With Solar and Wind Energy Sources. **IEEE Transactions on Energy Conversion**, v. 25, n. 2, p. 535–545, jun. 2010.

KING, D. L. et al. Performance Model for Grid-Connected Photovoltaic Inverters, SAND2007-5036. **Contract**, v. 38, n. September, p. 655–660, 2007.

KING, D. L.; BOYSON, W. E.; KRATOCHVILL, J. A. Photovoltaic Array Performance Model. n. December, p. 1–43, 2004.

KLISE, G. T.; STEIN, J. S. **Models Used to Assess the Performance of Photovoltaic Systems** Report SAND2009-8258, Albuquerque NM, USA. Albuquerque, 2009: [s.n.]. Disponível em: <https://smartgrid.gov/sites/default/files/doc/files/Models_Used_to_Assess_Performance_Photovoltaic_Systems_200907.pdf>. Acesso em: 24 set. 2014.

KO, M. et al. Multi-Objective Optimization Design for a Hybrid Energy System Using the Genetic Algorithm. **Energies**, v. 8, n. 4, p. 2924–2949, 2015.

KONDILI, E. Design and performance optimisation of stand-alone and hybrid wind energy

systems. In: KALDELLIS, J. K. (Ed.). . **Stand-alone and Hybrid Wind Energy Systems. Technology, energy storage and applications**. 1. ed. Oxford: CRC Press, 2013. p. 81–101.

KORONAKIS, P. S. On the choice of the angle of tilt for south facing solar collectors in the Athens basin area. **Solar Energy**, v. 36, n. 3, p. 217–225, 1986.

KOUTROULIS, E. et al. Methodology for optimal sizing of stand-alone photovoltaic/wind-generator systems using genetic algorithms. **Solar Energy**, v. 80, n. 9, p. 1072–1088, set. 2006.

KRAUTER, S.; RÜTHER, R. Considerations for the calculation of greenhouse gas reduction by photovoltaic solar energy. **Renewable Energy**, v. 29, n. 3, p. 345–355, 2004.

LAGORSE, J.; PAIRE, D.; MIRAOU, A. Sizing optimization of a stand-alone street lighting system powered by a hybrid system using fuel cell, PV and battery. **Renewable Energy**, v. 34, n. 3, p. 683–691, mar. 2009.

LAMBERT, T.; GILMAN, P.; LILIENTHAL, P. Micropower System Modeling with Homer. In: **Integration of Alternative Sources of Energy**. [s.l.] John Wiley & Sons Inc, 2006. p. 379–418.

LEE, G. R.; FREARSON, L.; RODDEN, P. **An assessment of photovoltaic modelling software using real world performance data** 26th European Photovoltaic Solar Energy Conference and Exhibition. **Anais...** 2011

LEITE, A. M.; SCHMITT, W. F.; CASSULA, A. M. Analytical and Monte Carlo Approaches to Evaluate Probability Distributions of Interruption Duration. **IEEE Transactions on Power Systems**, v. 20, n. 3, p. 1341–1348, 2005.

LENZEN, M.; WACHSMANN, U. Wind turbines in Brazil and Germany: An example of geographical variability in life-cycle assessment. **Applied Energy**, v. 77, n. 2, p. 119–130, 2004.

LI, J.; WEI, W.; XIANG, J. A simple sizing algorithm for stand-alone PV/Wind/Battery hybrid microgrids. **Energies**, v. 5, n. 12, p. 5307–5323, 2012.

LILIENTHAL, P.; LAMBERT, T.; GILMAN, P. Computer modeling of renewable power systems. In: **Encyclopedia of Energy**. 1st. ed. New York: Elsevier Ltd, 2004. v. 1p. 633–647.

LIU, B. Y. H.; JORDAN, R. C. The long-term average performance of flat-plate solar energy collectors: With design data for the U.S., its outlying possessions and Canada. **Solar Energy**, v. 7, n. 2, 1963.

LU, X.; MCELROY, M. B.; KIVILUOMA, J. Global potential for wind-generated electricity. **Proceedings of the National Academy of Sciences of the United States of America**, v. 106, n. 27, p. 10933–8, 2009.

LUJANO-ROJAS, J. M.; DUFO-LÓPEZ, R.; BERNAL-AGUSTÍN, J. L. Probabilistic modelling and analysis of stand-alone hybrid power systems. **Energy**, v. 63, p. 19–27, dez. 2013.

LUNA-RUBIO, R. et al. Optimal sizing of renewable hybrids energy systems : A review of methodologies. **Solar Energy**, v. 86, n. 4, p. 1077–1088, abr. 2012.

LUSZCZEK, P. Enhancing Multicore System Performance Using Parallel Computing with MATLAB. **MATLAB Digest**, n. 1000, p. 1–4, 2008.

MA, T.; YANG, H.; LU, L. Solar photovoltaic system modeling and performance prediction. **Renewable and Sustainable Energy Reviews**, v. 36, p. 304–315, 2014.

MACEDO, L. C. **Otimização de sistemas híbridos para a eletrificação de miniredes com fontes renováveis: aspectos de projeto, operação e gestão.** [s.l.] Universidade Federal de Pará (UFPA), 2014.

MACIEL SILVA, R. **Otimização Multiobjetivo na Análise da Integração de Geração Distribuída às Redes de Distribuição.** [s.l.] UNESP - Ilha Solteira, 2012.

MAHERI, A. Multi-objective design optimisation of standalone hybrid wind-PV-diesel systems under uncertainties. **Renewable Energy**, v. 66, p. 650–661, 2014.

MAKHLOUFI, S. Comparative study between classical methods and genetic algorithms for sizing remote PV systems. **International Journal of Energy and Environmental Engineering**, v. 6, n. 3, p. 221–231, 2015.

MALEKI, A.; ASKARZADEH, A. Comparative study of artificial intelligence techniques for sizing of a hydrogen-based stand-alone photovoltaic/wind hybrid system. **International Journal of Hydrogen Energy**, v. 39, n. 19, p. 9973–9984, 2014.

MALEKI, A.; POURFAYAZ, F. Optimal sizing of autonomous hybrid photovoltaic/wind/battery power system with LPSP technology by using evolutionary algorithms. **Solar Energy**, v. 115, p. 471–483, 2015.

MALKAWI, A.; AUGENBROE, G. **Advance Building Simulation.** 1. ed. New York: Spon Press - Taylo & Francis Group, 2004.

MANWELL, J. F. Hybrid Energy Systems. In: CUTLER, J. C. (Ed.). . **Encyclopedia of Energy.** [s.l.] Elsevier Inc., 2004. v. 3p. 215–229.

MANWELL, J. F. et al. **Hybrid2 - A Hybrid System Simulation Model - Theory Manual.** Massachusetts, 2006: [s.n.].

MANWELL, J. F.; DENG, G.; MCGOWAN, J. G. **A Markov Process Based Performance Model for Wind/Diesel/Battery Storage Systems**European Wind Energy Conference'94. **Anais...**Thessaloniki, Greece: 1994

MANWELL, J. F.; MCGOWAN, J. G. Lead acid battery storage model for hybrid energy systems. **Solar Energy**, v. 50, n. 5, p. 399–405, maio 1993.

MANWELL, J. F.; MCGOWAN, J. G. A combined probabilistic/time series model for wind diesel systems simulation. **Solar Energy**, v. 53, n. 6, p. 481–490, dez. 1994.

MANWELL, J. F.; MCGOWAN, J. G.; ROGERS, A. L. Wind Characteristics and Resource. In: **Wind Energy Explained: Theory, Design and Application.** 2 ed ed. Chichester, UK: John Wiley & Sons, Ltd., 2009a. p. 23–89.

MANWELL, J. F.; MCGOWAN, J. G.; ROGERS, A. L. Wind Energy System Economics. In: **Wind Energy Explained: Theory, Design and Application.** 2nd. ed. Chichester, UK: John Wiley & Sons, Ltd, 2009b. p. 505–545.

MARION, B.; RUMMEL, S.; ANDERBERG, A. Current–voltage curve translation by bilinear interpolation. **Progress in Photovoltaics: Research and Applications**, v. 12, n. 8, p. 593–607, 2004.

MARKVART, T. Sizing of hybrid photovoltaic-wind energy systems. **Solar Energy**, v. 51, n. 4, p. 277–281, 1997.

MARKVART, T. **Solar Electricity.** 2nd. ed. Chichester: John Wiley & Sons Inc, 2000.

MARTINS, F. R. et al. **Mapeamento dos Recursos de Energia Solar no Brasil Utilizando Modelo de Transferência Radiativa Brasil-SRI** Congresso Brasileiro de Energia Solar (I

CBENS). **Anais...**Fortaleza, Brasil: 2007

MASOUM, M. A. S.; BADEJANI, S. M. M.; KALANTAR, M. Optimal placement of hybrid PV-wind systems using genetic algorithm. **2010 Innovative Smart Grid Technologies (ISGT)**, n. 1, p. 1–5, jan. 2010.

MATHWORKS. **Parallel Computing Toolbox™ User's Guide**. Natick: The MathWorks, Inc., 2016.

MCGOWAN, J. G. et al. Hybrid wind/PV/diesel hybrid power systems modeling and South American applications. **Renewable Energy**, v. 9, n. 1-4, p. 836–847, 1996.

MCGOWAN, J. G.; MANWELL, J. F. Hybrid wind/PV/diesel system experiences. **Renewable Energy**, v. 16, n. 1-4 -4 pt 2, p. 928–933, 1999.

MEHLERI, E. D. et al. Determination of the optimal tilt angle and orientation for solar photovoltaic arrays. **Renewable Energy**, v. 35, n. 11, p. 2468–2475, 2010.

MEREI, G.; BERGER, C.; SAUER, D. U. Optimization of an off-grid hybrid PV-Wind-Diesel system with different battery technologies using genetic algorithm. **Solar Energy**, v. 97, p. 460–473, 2013.

MICHALEWICZ, Z. A Survey of Constraint Handling Techniques in Evolutionary Computation Methods. **Evolutionary Programming**, v. 4, n. Holland 1975, p. 135–155, 1995.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. 3. ed. New York: Springer, 1996.

MICHALEWICZ, Z.; JANIOW, C. Z. **Handling Constraints in Genetic Algorithms** Proceedings of the Fourth International Conference on Genetic Algorithms. **Anais...**1993

MICHALEWICZ, Z.; SCHOENAUER, M. Evolutionary Algorithms for Constrained Parameter Optimization Problems. **Evolutionary Computation**, v. 4, n. 1, p. 1–32, 1996.

MILTON, J. **Analysis and Improvement of Genetic Algorithms using Concepts from Information Theory**. [s.l.] University of Technology Sydney (UTS), 2009.

MITCHELL, M. **An Introduction to Genetic Algorithms**. 1st. ed. Cambridge, Massachusetts: MIT Press, 1998.

MOHAMED, F. A.; KOIVO, H. N. Modelling and Environmental/Economic Power Dispatch of MicroGrid Using MultiObjective Genetic Algorithm Optimization. In: CARRIVEAU, R. (Ed.). **Fundamental and Advanced Topics in Wind Power**. [s.l.] InTech, 2011. p. 19.

MONDOL, J. D.; YOHANIS, Y. G.; NORTON, B. Optimising the economic viability of grid-connected photovoltaic systems. **Applied Energy**, v. 86, n. 7-8, p. 985–999, jul. 2009.

MOSTOFI, F.; SHAYEGHI, H. Feasibility and Optimal Reliable Design of Renewable Hybrid Energy System for Rural Electrification in Iran. **International Journal of Renewable Energy Research**, v. 2, n. 4, 2012.

MÜHLENBEIN, H. **The Breeder Genetic Algorithm: a provable optimal search algorithm and its application** Applications of Genetic Algorithms, IEE Colloquium on. **Anais...**mar. 1994

MÜHLENBEIN, H.; SCHLIERKAMP-VOOSEN, D. Predictive Models for the Breeder Genetic Algorithm I. Continuous Parameter Optimization. **Evolutionary Computation**, v. 1, n. 1, p. 25–49, 1993.

MÜHLENBEIN, H.; SCHLIERKAMP-VOOSEN, D. Analysis of Selection, Mutation and Recombination in Genetic Algorithms. **Evolution and Biocomputation, Computational Models of Evolution**, p. 142–168, 1995.

MUKUND, R. P. **Wind and Solar Power Systems. Design, Analysis and, Operation**. 2. ed. Boca Raton: CRC Press, 2006.

MUNEER, T.; SALUJA, G. S. A brief review of models for computing solar radiation on inclined surfaces. **Energy Conversion and Management**, v. 25, n. 4, p. 443–458, 1985.

NASIRAGHDAM, H.; JADID, S. Optimal hybrid PV/WT/FC sizing and distribution system reconfiguration using multi-objective artificial bee colony (MOABC) algorithm. **Solar Energy**, v. 86, n. 10, p. 3057–3071, 2012.

NAWRI, N. et al. The Wind Energy Potential of Iceland. v. 16, p. 2014, 2014.

NEHRIR, M. H. An approach to evaluate the general performance of stand-alone wind/photovoltaic generating systems. **Energy Conversion, ...**, v. 15, n. 4, p. 433–439, 2000.

NELSON, D. B.; NEHRIR, M. H.; WANG, C. Unit sizing and cost analysis of stand-alone hybrid wind/PV/fuel cell power generation systems. **Renewable Energy**, v. 31, n. 10, p. 1641–1656, ago. 2006.

NEVES JÚNIOR, R. M. **Modelo Financeiro para Desenvolvimento de Negócios em Energia Renovável**. [s.l.] Universidade Federal de Rio Grande do Sul, 2010.

NIEZ, A. **Electrification Policies Comparative Study on Rural Electrification Policies in Emerging Economies**. Paris: [s.n.]. Disponível em: <http://www.iea.org/papers/2010/rural_elect.pdf>.

NOTTON, G.; LAZAROV, V.; STOYANOV, L. Optimal sizing of a grid-connected PV system for various PV module technologies and inclinations, inverter efficiency characteristics and locations. **Renewable Energy**, v. 35, n. 2, p. 541–554, 2010.

NOTTON, G.; MUSELLI, M.; POGGI, P. Costing of a stand-alone photovoltaic system. **Energy**, v. 23, n. 4, p. 289–308, abr. 1998.

NREL. **Brazil Hourly DNI, GHI and Diffuse Solar Data**. Disponível em: <<http://en.openei.org/doe-opendata/dataset/brazil-hourly-dni-ghi-and-diffuse-solar-data>>. Acesso em: 1 fev. 2016.

OLIVEIRA BARBOSA, DE C. F. **Avaliação tecnológica, operacional e de gestão de sistemas híbridos para geração de eletricidade na região amazônica**. [s.l.] Universidade Federal do Pará, 2006.

OLIVEIRA BARBOSA, DE C. F. C. F. et al. **Situação da Geração Elétrica Através de Sistemas Híbridos no Estado do Pará e Perspectivas Frente à Universalização da Energia Elétrica** Proceedings of the 5th Encontro de Energia no Meio Rural. Anais...Campinas: 2004Disponível em: <http://www.proceedings.scielo.br/scielo.php?script=sci_arttext&pid=MSC0000000022004000200052&lng=en&nrm=abn>

OLIVEIRA BARBOSA, DE C. F.; PINHO, J. T. **Experiência com Geração de Energia Elétrica Utilizando Sistemas Híbridos em Vilas Isoladas na Amazônia**XIX SNPTEE – Seminário Nacional de Produção e Transmissão de Energia Elétrica. Anais...Rio de Janeiro: 2007

OLIVEIRA BARBOSA, DE C. F.; PINHO, J. T. **Avaliação Econômica de Sistemas Híbridos Fotovoltaicos-Eólico-Diesel para Geração de Eletricidade na Amazônia**

Congresso Brasileiro de Energia Solar e III Conferência Regional Latino-Americana da ISES. **Anais...**2008

PALIWAL, P.; PATIDAR, N. P.; NEMA, R. K. Determination of reliability constrained optimal resource mix for an autonomous hybrid power system using Particle Swarm Optimization. **Renewable Energy**, v. 63, p. 194–204, 2014.

PARKINSON, A. R.; BALLING, R. J.; HEDENGREN, J. D. **Optimization Methods for Engineering Design - Applications and Theory**. 1st. ed. Brigham: Brigham Young University, 2013.

PATEL, M. R. **Wind and solar power systems**. Boca Raton: CRC Press, 1999.

PAUDEL, S. **Optimization of Hybrid PV/Wind Power System for Remote Telecom Station**. [s.l.] Universidade de Aveiro, 2011.

PEHNT, M. Dynamic life cycle assessment (LCA) of renewable energy technologies. **Renewable Energy**, v. 31, n. 1, p. 55–71, 2006.

PELET, X.; FAVRAT, D.; LEYLAND, G. Multiobjective optimisation of integrated energy systems for remote communities considering economics and CO2 emissions. **International Journal of Thermal Sciences**, v. 44, n. 12, p. 1180–1189, dez. 2005.

PENG, J.; LU, L.; YANG, H. Review on life cycle assessment of energy payback and greenhouse gas emission of solar photovoltaic systems. **Renewable and Sustainable Energy Reviews**, v. 19, p. 255–274, 2013.

PEREZ, R. et al. Modeling daylight availability and irradiance components from direct and global irradiance. **Solar Energy**, v. 44, n. 5, p. 271–289, 1990.

PETRONE, G. et al. A probabilistic non-dominated sorting GA for optimization under uncertainty. **Engineering Computations**, v. 30, n. 8, p. 1054–1085, 2013.

PINHO, J. T. et al. **Manual de Implantação de Sistemas Híbridos Fotovoltaico-Eólico-Diesel**. Belém, 2008: [s.n.].

PINHO, J. T. **Sistemas Híbridos - Soluções Energéticas para a Amazônia**. 1. ed. Brasília: Ministério de Minas e Energia, 2008.

PINHO, J. T.; GALDINO, M. A. **Manual de Engenharia para Sistemas Fotovoltaicos**. 2nd. ed. Rio de Janeiro: CEPEL - CRESESB, 2014.

POHLHEIM, H. **Evolutionary Algorithms: Overview, Methods and Operators**. 1. ed. Berlin: GEATbx, 2006.

PROTOGEROPOULOS, C.; BRINKWORTH, B. J.; MARSHALL, R. H. Sizing and techno-economical optimization for hybrid solar photovoltaic/wind power systems with battery storage. **International Journal of Energy Research**, v. 21, p. 465–479, 1997.

RAADAL, H. L. et al. Life cycle greenhouse gas (GHG) emissions from the generation of wind and hydro power. **Renewable and Sustainable Energy Reviews**, v. 15, n. 7, p. 3417–3422, 2011.

RADCLIFFE, N. J. Equivalence Class Analysis of Genetic Algorithms. **Complex Systems**, v. 5, n. 2, p. 183–205, 1991.

REICHE, K.; COVARRUBIAS, A.; MARTINOT, E. Expanding Electricity Access to Remote Areas: Off-Grid Rural Electrification in Developing Countries. **World Power 2000**, p. 52–60, 2000.

REINDL, D. T. W.; KLEIN, S. A.; DUFFIE, J. A. Diffuse Fraction Correlations. **Solar Energy**, v. 45, n. 1, 1990.

REKLAITIS, G. V.; RAVINDRAN, A.; RAGSDELL, K. M. **Engineering Optimization Methods and Applications**. 1st. ed. New York: Wiley, 1983.

REN21. **Renewables 2015 Global Status Report**. [s.l.] Renewable Energy Policy Network for the 21st Century, 2015.

ROBERTS, J. J. **Análise de Desempenho de um Sistema Híbrido de Geração de Energia Solar-Eólico-Diesel considerando variações probabilísticas da carga e dos recursos renováveis**. [s.l.] Universidade Estadual Paulista (UNESP), 2012.

ROBERTS, J. J. et al. **Simulation and Validation of Photovoltaic System Performance Models** Book of Abstracts and Proceedings of 11th Latin-American Congress on Electricity Generation and Transmission: CLAGTEE 2015. **Anais...**São José dos Campos, SP, Brasil: FDCT - Fundação para o Desenvolvimento Científico e Tecnológico, 2015

ROSS, M. M. D. **A Lead-Acid Battery Model for Hybrid System Modelling**. Montreal, Quebec, 2001: [s.n.].

ROSS, M. M. D. **A simple but comprehensive lead-acid battery model for hybrid system simulation** Proceedings of the 32nd Annual Conference of the Solar Energy Society of Canada. **Anais...**Calgary, Alberta, Canada: 2007

RYDH, C. J. Environmental assessment of vanadium redox and lead-acid batteries for stationary energy storage. **Journal of Power Sources**, v. 80, n. 1, p. 21–29, 1999.

SAIF, A. et al. Multi-objective capacity planning of a PV-wind-diesel-battery hybrid power system. **2010 IEEE International Energy Conference**, p. 217–222, dez. 2010.

SANDIA NATIONAL LABRATORIES. **Stand Alone Photovoltaic System- A Handbook of Recommended Design Practices**. Springfield: [s.n.].

SARENI, B.; ROBOAM, X.; RE, J. System optimization by multiobjective genetic algorithms and analysis of the coupling between variables, constraints and objectives. **COMPEL: The International Journal for Computation and Mathematics in Electrical and Electronic Engineering**, v. 24, n. 3, p. 805–820, 2005.

SARMADY, S. An Investigation on Genetic Algorithm Parameters. **School of Computer Science, Universiti Sains Malaysia**, 2007.

SCHAFFER, J. D. **Multiple objective optimization with vector evaluated genetic algorithms**. Proceedings of the 1st International Conference on Genetic Algorithms, Pittsburgh, PA, USA, July 1985. **Anais...**1985

SEELING-HOCHMUTH, G. **Optimisation of Hybrid Energy Systems Sizing and Operation Control**. [s.l: s.n.].

SEELING-HOCHMUTH, G. C. A combined optimisation concet for the design and operation strategy of hybrid-PV energy systems. **Solar energy**, v. 61, n. 2, p. 77–87, 1997.

SENJYU, T. et al. Optimal configuration of power generating systems in isolated island with renewable energy. **Renewable Energy**, v. 32, n. 11, p. 1917–1933, set. 2007.

SHAHIRINIA, A. H.; TAFRESHI, S. M. M. **Optimal sizing of hybrid power system using genetic algorithm** International Conference on Future Power Systems. **Anais...**Amsterdam: 2005

SHARAFI, M.; ELMEKKAWY, T. Y. Multi-objective optimal design of hybrid renewable

energy systems using PSO-simulation based approach. **Renewable Energy**, v. 68, p. 67–69, ago. 2014.

SHERWANI, A. F.; USMANI, J. A.; VARUN. Life cycle assessment of solar PV based electricity generation systems: A review. **Renewable and Sustainable Energy Reviews**, v. 14, n. 1, p. 540–544, 2010.

SHI, J. et al. Robust design and optimization for autonomous PV-wind hybrid power systems. **Journal of Zhejiang University SCIENCE A**, v. 9, n. 3, p. 401–409, 2008.

SHI, J.; ZHU, X.; CAO, G. Design and techno-economical optimization for stand-alone hybrid power systems with multi-objective evolutionary algorithms. **International Journal of Energy Research**, v. 31, n. August 2006, p. 315–328, 2007.

SHORT, W.; PACKY, D. J. **A Manual for the Economic Evaluation of Energy Efficiency and Renewable Energy Technologies**. Golden, Colorado, 1995: [s.n.].

SIDDIQUI, M. U.; ABIDO, M. Parameter estimation for five- and seven-parameter photovoltaic electrical models using evolutionary algorithms. **Applied Soft Computing**, v. 13, n. 12, p. 4608–4621, dez. 2013.

SILVA DE SOUSA, E. et al. **Variabilidade interanual da precipitação e da temperatura do ar em Teresina-PI no período de 1976 a 2010 visando a captação e armazenamento de águas pluviais**XVII Congresso Brasileiro de Agrometeorologia. **Anais...**Guarapari, ES, Brasil: 2011

SILVA, D.; NAKATA, T. Multi-objective assessment of rural electrification in remote areas with poverty considerations. **Energy Policy**, v. 37, n. 8, p. 3096–3108, ago. 2009.

SILVEIRA, J. L. et al. **Aspectos técnicos , econômicos e ecológicos da produção de hidrogênio renovável no contexto brasileiro**VIII Congreso Latinoamericano de Ingeniería Mecánica COLIM 2014. **Anais...**Cuenca - Ecuador: 2014

SIMON, D. **Evolutionary Optimization Algorithms**. 1st. ed. New Jersey: John Wiley & Sons Inc, 2013.

SINGH, C. Multicriteria Design of Hybrid Power Generation Systems Based on a Modified Particle Swarm Optimization Algorithm. **IEEE Transactions on Energy Conversion**, v. 24, n. 1, p. 163–172, mar. 2009.

SINHA, S.; CHANDEL, S. S. Review of software tools for hybrid renewable energy systems. **Renewable and Sustainable Energy Reviews**, v. 32, p. 192–205, 2014.

SIVANANDAM, S. N.; DEEPA, S. N. **Introduction To Genetic Algorithms**. New York: Springer, 2007.

SRINIVAS, N.; DEB, K. Multiobjective optimization using nondominated sorting in genetic algorithms. **Evolutionary computation**, v. 2, n. 3, p. 221–248, 1994.

SUMATHI, S.; HAMSAPRIYA, T.; SUREKHA, P. **Evolutionary Intelligence: An Introduction to Theory and Applications With Matlab**. 1. ed. Berlin: Springer, 2008.

TALBI, E.-G. **Metaheuristics: from design to implementation**. 1st. ed. New Jersey: John Wiley & Sons Inc, 2009.

THE WORLD BANK. **World Development Indicators: Electricity production, sources, and access**. Disponível em: <<http://wdi.worldbank.org/table/3.7>>. Acesso em: 4 dez. 2015.

THIBAUD, S. M.; ROBERTS, J. J.; PRADO, P. O. **Proyecto de un Sistema Híbrido de Generación con Energías Renovables para un Establecimiento Rural Aislado**Book of

Abstracts and Proceedings of 11th Latin-American Congress on Electricity Generation and Transmission: CLAGTEE 2015. **Anais...**São José dos Campos, SP, Brasil: FDCT - Fundação para o Desenvolvimento Científico e Tecnológico, 2015

TINA, G.; GAGLIANO, S. Probabilistic analysis of weather data for a hybrid solar/wind energy system. **International Journal of Energy Research**, n. March 2010, p. 221–232, 2011.

TINA, G.; GAGLIANO, S.; RAITI, S. Hybrid solar/wind power system probabilistic modelling for long-term performance assessment. **Solar Energy**, v. 80, n. 5, p. 578–588, maio 2006.

TURCONI, R.; BOLDRIN, A.; ASTRUP, T. Life cycle assessment (LCA) of electricity generation technologies: Overview, comparability and limitations. **Renewable and Sustainable Energy Reviews**, v. 28, p. 555–565, 2013.

UNITED STATES ENVIRONMENTAL PROTECTION AGENCY (EPA). **Emissions Factors & AP 42, Compilation of Air Pollutant Emission Factors**. Disponível em: <<http://www3.epa.gov/ttn/chief/ap42/ch03/index.html>>. Acesso em: 10 set. 2015.

UPADHYAY, S.; SHARMA, M. P. A review on configurations, control and sizing methodologies of hybrid energy systems. **Renewable and Sustainable Energy Reviews**, v. 38, p. 47–63, 2014.

URBINA, A. et al. **Probabilistic analysis of rechargeable batteries in a photovoltaic power supply system** 194th Electrochemical Society Meeting. **Anais...**Boston, MA: 1998

VARUN; BHAT, I. K.; PRAKASH, R. LCA of renewable energy for electricity generation systems-A review. **Renewable and Sustainable Energy Reviews**, v. 13, n. 5, p. 1067–1073, 2009.

VENKATARAMAN, P. **Applied Optimization With Matlab Programming**. 2nd. ed. New York: John Wiley Inc, 2002.

VILLALVA, M. G.; GAZOLI, J. R. Modeling and circuit-based simulation of photovoltaic arrays. **Power Electronics Conference, 2009 ...**, p. 1244–1254, set. 2009.

VILLALVA, M. G.; GAZOLI, J. R.; FILHO, E. R. Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays. **IEEE Transactions on Power Electronics**, v. 24, n. 5, p. 1198–1208, maio 2009.

VÖSSNER, S. **Convergence Measures for Genetic Algorithms**. Stanford: [s.n.].

WALKER, G. Evaluating MPPT converter topologies using a MATLAB PV model. **Journal of Electrical and Electronics Engineering**, v. 21, n. 1, p. 49–55, 2001.

WANG, L.-F.; SHI, L.-Y. Simulation Optimization: A Review on Theory and Applications. **Acta Automatica Sinica**, v. 39, n. 11, p. 1957–1968, 2013.

WEISSER, D. A guide to life-cycle greenhouse gas (GHG) emissions from electric supply technologies. **Energy**, v. 32, n. 9, p. 1543–1559, 2007.

WHITLEY, D. **A Genetic Algorithm Tutorial** Fort Collins Computer Science Department, Colorado State University, , 1994. Disponível em: <<http://www.cs.colostate.edu/~genitor/MiscPubs/tutorial.pdf>>

WIES, R. W. et al. Economic analysis and environmental impacts of a PV with diesel-battery system for remote villages. **IEEE Power Engineering Society General Meeting, 2004.**, p. 1–8, 2004.

WOODBANK COMMUNICATIONS LTD. **Battery and Energy Technologies**. Disponível em: <<http://www.mpoweruk.com/glossary.htm#float>>. Acesso em: 19 set. 2015.

XINJIE, Y.; MITSUO, G. **Introduction to Evolutionary Algorithms**. 1st. ed. London: Springer, 2010.

XU, D. et al. Optimal sizing of standalone hybrid wind/pv power systems using genetic algorithms. **Canadian Conference on Electrical and Computer Engineering, 2005.**, n. May, p. 1722–1725, 2005.

YANG, H.; LU, L.; ZHOU, W. A novel optimization sizing model for hybrid solar-wind power generation system. **Solar Energy**, v. 81, n. 1, p. 76–84, jan. 2007.

YANG, H.; WEI, Z.; CHENGZHI, L. Optimal design and techno-economic analysis of a hybrid solar–wind power generation system. **Applied Energy**, v. 86, n. 2, p. 163–169, fev. 2009.

YANG, H. X.; LU, L.; BURNETT, J. Weather data and probability analysis of hybrid photovoltaic–wind power generation systems in Hong Kong. **Renewable Energy**, v. 28, n. 11, p. 1813–1824, set. 2003.

YANG, X. S.; KOZIEL, S.; LEIFSSON, L. Computational optimization, modelling and simulation: Recent trends and challenges. **Procedia Computer Science**, v. 18, p. 855–860, 2013.

YANG, X. S.; KOZIEL, S.; LEIFSSON, L. Computational optimization, modelling and simulation: Past, present and future. **Procedia Computer Science**, v. 29, p. 754–758, 2014.

YANG, X.-S. **Engineering Optimization: An Introduction with Metaheuristic Applications**. 1st. ed. New Jersey: John Wiley Inc, 2010.

YATES, T.; HIBBERD, B. Production Modeling for Grid-Tied PV. **SolarPRO**, p. 30–56, 2010.

YAZDANPANA, M.-A. Modeling and sizing optimization of hybrid photovoltaic/wind power generation system. **Journal of Industrial Engineering International**, v. 10, n. 1, p. 49, 2014.

ZENG, J. et al. **Operational Optimization of a Stand-alone Hybrid Renewable Energy Generation System based on an Improved Genetic Algorithm**Power and Energy Society General Meeting, IEEE. **Anais...**Minneapolis, MN: 2010

ZHANG, L.; BARAKAT, G.; YASSINE, A. Deterministic optimization and cost analysis of hybrid PV/wind/battery/diesel power system. **International Journal of Renewable Energy Research**, v. 2, n. 4, 2012.

ZHANG, X. et al. Components sizing of hybrid energy systems via the optimization of power dispatch simulations. **Energy**, v. 52, p. 165–172, 2013.

ZHOU, W. et al. Current status of research on optimum sizing of stand-alone hybrid solar–wind power generation systems. **Applied Energy**, v. 87, n. 2, p. 380–389, fev. 2010.

ZITZLER, E.; LAUMANN, M.; BLEULER, S. A tutorial on evolutionary multiobjective optimization. In: GANDIBLEUX, X. et al. (Eds.). **Metaheuristics for Multiobjective Optimisation - Lecture Notes in Economics and Mathematical Systems**. [s.l.] Springer Berlin Heidelberg, 2004. p. 3–37.

APÊNDICE A – MÉTODO DE PRÉ-DIMENSIONAMENTO DOS COMPONENTES DO SHGE

O pré-dimensionamento é utilizado neste trabalho como passo prévio à otimização de SHGE para estimar a quantidade máxima recomendada de cada componente do sistema. O objetivo do pré-dimensionamento é orientar ao usuário na escolha dos valores limites para as variáveis de decisão e, desta forma, reduzir o espaço de busca da otimização. O método de pré-dimensionamento aqui adotado e apresentado em (PINHO et al., 2008; SEELING-HOCHMUTH, 1998), e se baseia no método Ah (Ampere hora) proposto por (SANDIA NATIONAL LABORATORIES, 1995).

O método utiliza como informação de entrada o consumo da carga, a disponibilidade de recursos renováveis e dados técnicos dos componentes do sistema. As etapas do método são brevemente apresentadas a seguir:

1) Levantamento da carga a ser atendida

- 1.1) Levantamento das características da carga a ser atendida, esta etapa depende da informação disponível. Considerando que se conta com uma série horária de dados de consumo, computa-se o consumo diário em Wh/dia como segue:

$$E_{load} = \frac{1}{365} \sum_{t=1}^{365} P_{load,i} \Delta t \quad (A.1)$$

- 1.2) Consideração de remanda reprimida, DR , se for o caso.

$$E'_{load} = \left(1 + \frac{DR}{100} \right) E_{load} \quad (A.2)$$

- 1.3) Consideração das perdas produzidas entre o lado CC e a carga, conversão de potência e cabeamento, através de um fator de perdas Ω_{losses} .

$$E_{load,cor} = \frac{E'_{load}}{\left(1 + \frac{\Omega_{losses}}{100} \right)} \quad (A.3)$$

- 1.4) Definição da tensão nominal do barramento CC, V_{CC} . Esta tensão é normalmente escolhida em função da corrente de pico do projeto, dada pela equação (A.4). A elevação no valor de tensão nominal permite a redução da corrente pico, I_{pico} , com consequente diminuição da seção reta dos condutores e

redução de risco. Todos os equipamentos do sistema devem ser compatíveis com o nível de corrente pico, portanto a escolha do nível da tensão CC influencia o balanço econômico do sistema, maior nível de corrente implica maiores custos. Como regra geral (SEELING-HOCHMUTH, 1998) recomenda 24 Vcc ou 48 Vcc para sistemas de até 5kW, 96 Vcc para sistemas de aproximadamente 5kW e 120 Vcc para sistemas de maiores de 5kW.

$$I_{pico} = \frac{P_{load,pico}}{\eta_{inv} V_{CC}} \quad (A.4)$$

- 1.5) Definida a tensão no barramento CC, calcula-se a demanda em Ah/dia como segue:

$$Load_{Ah} = \frac{E_{load,cor}}{V_{CC}} \quad (A.5)$$

2) Dimensionamento do banco de baterias

Nesta etapa dimensiona-se o sistema de armazenamento, banco de baterias, de acordo com os dias de autonomia requeridos, N_{aut} . A capacidade energética máxima de uma bateria é dada pelo produto entre sua tensão nominal, V_{bt} , e a sua capacidade de corrente, C_{bt_nom} . Entretanto, a capacidade útil da bateria depende da profundidade de descarga máxima recomendada pelo fabricante DOD , assim:

$$C_{bt} = V_{bt} C_{bt_nom} \cdot DOD \quad (A.6)$$

A capacidade que deve possuir o banco de baterias, C_{bbt} , para suprir o consumo diário da carga mais e as perdas de carregamento/descarregamento, Ω_{ch-di} , durante um determinado número de dias de autonomia, N_{aut} , é dado por:

$$C_{bbt} = \frac{E_{load,cor} \cdot N_{aut}}{\left(1 - \frac{\Omega_{ch-di}}{100}\right)} \quad (A.7)$$

De posse das equações (A.6) e (A.7) pode-se calcular o número de baterias do banco como:

$$N_{bbt} = \frac{C_{bbt}}{C_{bt}} \quad (A.8)$$

A associação série-paralelo do banco depende da tensão nominal do barramento CC, assim:

$$N_{bt_serie} = INT \left(\frac{N_{bbt}}{V_{CC}} \right) \quad (A.9)$$

$$N_{bt_paralelo} = INT \left(\frac{N_{bbt}}{N_{bt_serie}} \right) \quad (A.10)$$

3) Dimensionamento do sistema de geração

3.1) Geração eólica

Para o cálculo da energia produzida pelo aerogerador utiliza-se a série de dados de velocidade do vento para determinar a distribuição de frequência de velocidades ao longo do período avaliado. Em seguida aplica-se esse histograma à curva de potência do aerogerador para determinar a energia diária gerada em kWh/dia

O número de aerogeradores necessários para suprir a totalidade da carga apenas com geração eólica determina-se com a equação (A.11):

$$N_{wt} = INT \left(\frac{E_{wt,day} (kWh/dia)}{E_{load,cor} (kWh/dia)} \right) \quad (A.11)$$

3.2) Geração solar fotovoltaica

Calcula-se uma potência de projeto para o arranjo fotovoltaico, a qual representa a potência mínima para suprir a carga requisitada, considerando as perdas no processo:

$$P_{fv,proj} = \frac{E_{load,cor}}{\left(1 - \frac{\Omega_{loss,fv}}{100}\right) \cdot HSP} = \frac{E_{load,cor}}{\left(1 - \frac{\Omega_{loss,fv}}{100}\right) \cdot \frac{1}{365 \cdot 1000} \sum_{t=1}^T I_T} \quad (A.12)$$

sendo HSP as horas de sol pleno, que reflete o número de horas em que a irradiância solar deve permanecer acima de 1 kW/m^2 , e $\Omega_{loss,fv}$ representa as perdas por fiação e dispersão [%].

$$HSP = \frac{1}{365} \sum_{i=1}^T I_{T,i} (kWh/m^2 dia) \frac{1}{1 (kW/m^2)} \quad (A.13)$$

O número de painéis fotovoltaicos de potência nominal, $P_{pv,nominal}$, necessários para suprir a totalidade da carga apenas com geração solar determina-se com a equação (A.14):

$$N_{pv} = \frac{P_{fv,proj}}{P_{pv,nominal}} \quad (A.14)$$

O número de painéis em série depende da tensão do barramento CC e da tensão no ponto de máxima potência do painel, V_{mpp} :

$$N_{pv_serie} = INT \left(\frac{V_{dc_bus}}{V_{mpp}} \right) \quad (A.15)$$

$$N_{pv_paralelo} = INT \left(\frac{N_{pv}}{N_{pv_serie}} \right) \quad (A.16)$$

3.3) Geração diesel

Supondo-se não haver quaisquer restrições quanto à disponibilidade e uso de combustível, sistemas de geração a diesel são dimensionados de forma a atender totalmente a carga, consideradas as perdas envolvidas no processo. Assim, a potência máxima do motor gerador diesel é aquela necessária para suprir a potência pico da carga CA, considerando uma eficiência do retificador de 90%.

$$N_{dg} = INT \left(\frac{P_{dg,nominal}}{P_{load,pico}/0,9} \right) \quad (A.17)$$

4) Dimensionamento do sistema de condicionamento de potência

4.1) Controlador de carga

Mesmo que o controlador de carga não é explicitamente modelado no algoritmo de simulação do SHGE, este componente é representado através da sua eficiência inserida no fator de dispersão do arranjo PV. O custo do controlador pode ser considerado dentro do custo dos painéis ou dentro do custo $C_{icap,other}$ na equação econômica.

A capacidade mínima do controlador de carga ($C_{cont,carga}$), em Ampere, deve ser igual à corrente de curto-circuito total do arranjo fotovoltaico ($I_{sc,arranjo}$). Considera-se ainda um fator de segurança devido à possibilidade do aumento da corrente de curto-circuito do arranjo em função das condições climáticas. Utiliza-se um fator de variação de 25%, assim a capacidade mínima do controlador de carga resulta igual a:

$$C_{cont,carga,min} \geq I_{sc,arranjo} \cdot 1,25 \quad (A.18)$$

O numero mínimo de controladores depende da capacidade nominal do modelo de controlador escolhido.

$$N_{cont,carga} = INT \left(\frac{C_{cont,carga,min}}{C_{cont,carga,nominal}} \right) \quad (A.19)$$

4.2) Inversor de tensão

Inversores em sistemas isolados devem possuir capacidade de atender a carga máxima instalada de maneira contínua mais um fator de segurança de 10%, assim:

$$N_{inv} = INT \left(\frac{P_{load,pico} \cdot 1,1}{P_{inv,nominal}} \right) \quad (A.20)$$

Caso o pré-dimensionamento seja feito considerando vários modelos de componentes, calcula-se o número máximo de componentes para cada modelo de componente. Nesta situação, pode-se estabelecer o limite máximo para a variável de decisão considerando o equipamento de menor capacidade, assegurando deste modo que o resto dos componentes conseguem também suprir a carga. No entanto, se se estabelece o número máximo de componentes pelo componente de maior capacidade, pode acontecer a situação que algum dos componentes não consiga suprir a carga em sua totalidade.

APÊNDICE B – REVISÃO BIBLIOGRÁFICA SOBRE EMISSÕES INDIRETAS

Tabela B.1. GWP para geração de eletricidade com painéis PV (continua).

Referência	GWP (kgCO ₂ eq/kWh)			Tecnologia	País/Região	Considerações
	Mínimo	Média	Máximo			
(ACKERMANN; ANDERSSON; SÖDER, 2001)		0,228		multi-Si	Alemanha	Baseado nas condições Alemãs de composição da matriz energética, eficiência, radiação solar e vida útil dos componentes.
(KRAUTER; RÜTHER, 2004)		0,030		mono-Si	Brasil	
(KRAUTER; RÜTHER, 2004)		0,011		multi-Si	Brasil	
(FTHENAKIS; ALSEMA, 2006)	0,021	0,033	0,045	multi-Si e CdTe	Sul da Europa	1700 kWh/m2/ano, matriz energética dos EUA.
(PEHNT, 2006)		0,104		multi-Si	Alemanha	1300 kWh/m2/ano, matriz energética dos EUA.
(FTHENAKIS; ALSEMA, 2006)	0,027	0,043	0,059	multi-Si e CdTe	Alemanha	
(WEISSER, 2007)	0,043	0,058	0,073	mono-Si, muti-Si, a-Si e CIGS	Vários	
(VARUN; BHAT; PRAKASH, 2009)	0,053	0,152	0,250	mono-Si, muti-Si, a-Si	Vários	Fabricação, transporte, construção da planta, O&M e disposição final.
(EVANS; STREZOV; EVANS, 2009)		0,090		Todas	Vários	
		0,045		Todas	Vários	
(SHERWANI; USMANI; VARUN, 2010)	0,016	0,033	0,050	a-Si	Vários	Fabricação e O&M.
(SHERWANI; USMANI; VARUN, 2010)	0,044	0,162	0,280	mono-Si	Vários	
(SHERWANI; USMANI; VARUN, 2010)	0,009	0,057	0,104	multi-Si	Vários	

Tabela B.1. GWP para geração de eletricidade com painéis PV (conclusão).

Referência	GWP (kgCO ₂ eq/kWh)			Tecnologia	País/Região	Considerações
	Mínimo	Média	Máximo			
(FTHENAKIS; KIM, 2011)	0,030	0,033	0,035	multi-Si	Sul da Europa	Montagem no teto, 1700 kWh/m ² /ano, PR=0.75, LT=30 anos.
(FTHENAKIS; KIM, 2011)	0,035	0,040	0,045	mono-Si	Sul da Europa	Montagem no teto, 1700 kWh/m ² /ano, PR=0.75, LT=30 anos.
(FTHENAKIS; KIM; FRISCHKNECHT, 2011)		0,029		mono-Si		
(FTHENAKIS; KIM; FRISCHKNECHT, 2011)		0,028		multi-Si	Sul da Europa	Montagem no teto, 1700 kWh/m ² /ano, PR=0.75, LT=30 anos.
(FTHENAKIS; KIM; FRISCHKNECHT, 2011)		0,018		CdTe	Sul da Europa	Montagem no teto, 1700 kWh/m ² /ano, PR=0.75, LT=30 anos.
(ENGIN, 2013)		0,061		Todas		
(PENG; LU; YANG, 2013)	0,029	0,037	0,045	mono-Si	Vários	Referências posteriores a 2005, valores normalizados para 1700 kWh/m ² /ano.
(PENG; LU; YANG, 2013)	0,023	0,034	0,044	multi-Si	Vários	Referências posteriores a 2005, valores normalizados para 1700 kWh/m ² /ano.
(PENG; LU; YANG, 2013)	0,018	0,034	0,050	a-Si	Vários	Referências posteriores a 2005, valores normalizados para 1700 kWh/m ² /ano.
(TURCONI; BOLDRIN; ASTRUP, 2013)	0,013	0,102	0,190	Todas	Vários	Fabricação, transporte, construção da planta, O&M e disposição final.
(BRAGA, 2014)		0,052		Todas	Vários	
(HERTWICH et al., 2014)		0,057		multi-Si	Vários	Montagem no chão.
(HERTWICH et al., 2014)		0,058		multi-Si	Vários	Montagem no teto.
(HERTWICH et al., 2014)		0,016		CdTe	Vários	Montagem no chão.
(HERTWICH et al., 2014)		0,021		CdTe	Vários	Montagem no teto.
(CLARKE; AL-ABDELI; KOTHAPALLI, 2015)		0,045		multi-Si	Austrália	Fabricação e transporte.

Fonte: produção do próprio autor.

Tabela B.2. GWP para geração de eletricidade com turbinas eólicas (continua).

Referência	GWP (kgCO ₂ eq/kWh)			Tecnologia	País/Região	Considerações
	Mínimo	Média	Máximo			
(ACKERMANN; ANDERSSON; SÖDER, 2001)		0,011		Todas	Alemanha	Baseado nas condições Alemãs de composição da matriz energética, eficiência, radiação solar e vida útil dos componentes.
(LENZEN; WACHSMANN, 2004)	0,002	0,042	0,081	Todas	Alemanha, Brasil	
(LENZEN; WACHSMANN, 2004)	0,015	0,021	0,027	Todas	Alemanha, Brasil	Fabricados em Alemanha e operador em Brasil
(LENZEN; WACHSMANN, 2004)	0,003	0,004	0,004	Todas	Alemanha, Brasil	Fabricados em Brasil e operador em Alemanha
(PEHNT, 2006)		0,011		On-shore	Alemanha	
(PEHNT, 2006)		0,009		Off-shore	Alemanha	
(WEISSER, 2007)	0,008	0,019	0,030	On-shore	Vários	Considera fabricação, transporte, montagem da planta, O&M e disposição final.
(WEISSER, 2007)	0,009	0,014	0,019	Off-shore	Vários	Considera fabricação, transporte, montagem da planta, O&M e disposição final.
(VARUN; BHAT; PRAKASH, 2009)	0,011	0,067	0,124	On-shore	Vários	
(VARUN; BHAT; PRAKASH, 2009)		0,010		Off-shore	Vários	
(EVANS; STREZOV; EVANS, 2009)		0,025		Todas	Vários	Considera fabricação e O&M.
(RAADAL et al., 2011)	0,029	0,045	0,055	<100 kW	Vários	
(RAADAL et al., 2011)	0,006	0,021	0,048	100kW-500kW	Vários	
(RAADAL et al., 2011)	0,008	0,016	0,026	500kW-1000kW	Vários	
(RAADAL et al., 2011)	0,004	0,010	0,028	1000kW-5000kW	Vários	
(RAADAL et al., 2011)	0,005	0,018	0,055	Todas	Vários	
(ENGİN, 2013)		0,021			Turquia	

Tabela B.2. GWP para geração de eletricidade com turbinas eólicas (conclusão).

Referência	GWP (kgCO ₂ eq/kWh)			Tecnologia	País/Região	Considerações
	Mínimo	Média	Máximo			
(TURCONI; BOLDRIN; ASTRUP, 2013)	0,003	0,016	0,028	Todas	Vários	Considera fabricação, transporte, montagem da planta, O&M.
(BRAGA, 2014)		0,015		Todas	Vários	
(HERTWICH et al., 2014)		0,008		On-shore	Vários	
(HERTWICH et al., 2014)		0,011		Off-shore	Vários	

Fonte: produção do próprio autor.

Tabela B.3. GWP para o sistema de armazenamento, baterias eletroquímicas.

Referência	GWP	Unidade	Tecnologia	País/Região	Considerações
(KEMMOKU et al., 2002)	62,000	kgCO ₂ eq/kWh _{ec} ⁽¹⁾	Chumbo-ácido	Japão	Fabricação e transporte
(FLECK; HUOT, 2009)	59,332	kgCO ₂ eq /kWh _{ec}	Chumbo-ácido	Espanha	Fabricação e transporte
(GARCÍA-VALVERDE et al., 2009)	55,351	kgCO ₂ eq /kWh _{ec}	Chumbo-ácido	Espanha	Fabricação e transporte
(DUFO-LÓPEZ et al., 2011)	55,300	kgCO ₂ eq /kWh _{ec}	Chumbo-ácido	Espanha	Fabricação e transporte
(RYDH, 1999)	0,027	kgCO ₂ eq /kWh	Chumbo-ácido	Suécia	
(GARCÍA-VALVERDE et al., 2009)	0,094	kgCO ₂ eq /kWh	Chumbo-ácido	Espanha	
(KATSIGIANNIS; GEORGILAKIS; KARAPIDAKIS, 2010a)	0,028	kgCO ₂ eq /kWh	Chumbo-ácido	Vários	
(CLARKE; AL-ABDELI; KOTHAPALLI, 2015)	0,028	kgCO ₂ eq /kWh	Chumbo-ácido	Austrália	Fabricação e transporte

⁽¹⁾ capacidade de armazenamento energético.

Fonte: produção do próprio autor.

Tabela B.4. GWP para o sistema de condicionamento de potência.

Referência	GWP (kgCO ₂ eq/kW)	Tecnologia	País/Região	Considerações
(KEMMOKU et al., 2002)	99,708	Inversor	Japão	Fabricação.
(FLECK; HUOT, 2009)	26,230	Inversor	Espanha	Fabricação.
(GARCÍA-VALVERDE et al., 2009)	26,300	Inversor	Espanha	Desprezado pelos autores.
(DUFO-LÓPEZ et al., 2011)	19,100	Regulador de carga	Espanha	Desprezado pelos autores.

Fonte: produção do próprio autor.


Tabela B.5. GWP para geração de eletricidade com grupo moto gerador.

Referência	GWP	Unidade	Tecnologia	País/Região	Considerações
(FLECK; HUOT, 2009)	192,170	kgCO ₂ eq /kW	DG diesel	EUA	Fabricação e transporte do moto gerador.
(SAIF et al., 2010)	1000,000	kgCO ₂ eq /kW	DG diesel	Japão	Fabricação e transporte do moto gerador.
(BONDESSON, 2010)	410,000	kgCO ₂ eq /kW	DG diesel	Suécia	Fabricação e transporte do moto gerador.
(DUFO-LÓPEZ et al., 2011)	215,000	kgCO ₂ eq /kW	DG diesel	Espanha	Fabricação e transporte do moto gerador.
(ALSEMA, 2000)	0,214	kgCO ₂ eq /kWh	DG diesel	Holanda	Fabricação e transporte do moto gerador.
(KATSIGIANNIS; GEORGILAKIS; KARAPIDAKIS, 2010a)	0,880	kgCO ₂ eq /kWh	DG diesel	Vários	Fabricação e transporte do moto gerador.
(KATSIGIANNIS; GEORGILAKIS; KARAPIDAKIS, 2010a)	0,191	kgCO ₂ eq /kWh	DG biodiesel	Vários	Fabricação e transporte do moto gerador.
(FLECK; HUOT, 2009)	0,290	kgCO ₂ eq /L	Óleo diesel	EUA	Fabricação e transporte do óleo diesel.
(BONDESSON, 2010)	0,770	kgCO ₂ eq /L	Óleo diesel	Suécia	Fabricação e transporte do óleo diesel.

Fonte: produção do próprio autor.

APÊNDICE C – CÁLCULO DA QUANTIDADE DE POLUENTES POR LITRO DE COMBUSTÍVEL (ÓLEO DIESEL)

1) Dada a reação de combustão para óleo diesel



2) Aplicando a lei de conservação da massa temos:

$$m_r = m_p \quad (C.2)$$

Onde m_r é a massa de reagentes e m_p é a massa de produtos. Assumindo que a reação de combustão acontece para 100 g de combustível e conhecendo a quantidade de ar envolvida no processo ($\nu_{ar} = 17,22$), pode-se obter a massa total de reagentes (para 100 g de óleo diesel).

$$\begin{aligned} m_r &= m_{diesel} + m_{ar} = m_{diesel} + M_{ar} (4,76 \cdot \nu_{ar}) \\ m_r &= 100 + 28,96 (4,76 \cdot 17,22) \\ m_r &= 2473,77 \text{ g} \end{aligned} \quad (C.3)$$

Onde M_{ar} é a massa molar do ar.

Do lado dos produtos temos:


$$m_p = n_{gc} M_{gc} \quad (C.4)$$

Onde n_{gc} é o número de moles dos gases de combustão e M_{gc} é a massa molar dos gases de combustão. Assim,

$$n_{gc} = \frac{m_{gc}}{M_{gc}} = \frac{m_r}{M_{gc}} \quad (C.5)$$

A massa molar dos gases de combustão pode-se obter a partir da informação da fração volumétrica dos produtos da combustão fornecida pela Figura C.1.

Figura C.1. Emissões em percentagem de volume para um motor de combustão interna funcionando a óleo diesel.



Fonte: (ECKERT; RAKOWSKI, 2012).

$$M_{gc} = \sum_{i=1}^m Y_i M_i \left[\frac{g}{mol} \right]$$

$$M_{gc} = Y_{N_2} M_{N_2} + Y_{O_2} M_{O_2} + Y_{H_2O} M_{H_2O} + Y_{CO_2} M_{CO_2} + Y_{SO_2} M_{SO_2} + Y_{CO} M_{CO} + Y_{NO} M_{NO}$$

$$M_{gc} = 0,738 \cdot 28 + 0,09 \cdot 32 + 0,09 \cdot 18 + 0,08 \cdot 44 + 0,0011 \cdot 64 + 0,0008 \cdot 28 + 0,017 \cdot 30$$

$$M_{gc} = 28,76 \text{ g}$$
(C.6)

$$M_{gc} = \sum_{i=1}^m Y_i M_i \left[\frac{g}{mol} \right]$$

$$M_{gc} = Y_{N_2} M_{N_2} + Y_{O_2} M_{O_2} + Y_{H_2O} M_{H_2O} + Y_{CO_2} M_{CO_2} + Y_{SO_2} M_{SO_2} + Y_{CO} M_{CO} + Y_{NO} M_{NO}$$

$$M_{gc} = 0,738 \cdot 28 + 0,09 \cdot 32 + 0,09 \cdot 18 + 0,08 \cdot 44 + 0,0011 \cdot 64 + 0,0008 \cdot 28 + 0,017 \cdot 30$$

$$M_{gc} = 28,76 \text{ g}$$
(C.7)

Assim, a quantidade de mols para cada 100 g de combustível é:

$$n_{gc} = \frac{2473,77 \text{ g}}{28,74 \frac{g}{mol}} = 86,02 \frac{mol}{100 g_{comb}}$$
(C.8)

3) Cálculo do número de mols dos produtos da combustão.

$$\begin{cases} n_{CO_2} = Y_{CO_2} n_{gc} = 0,0008 \cdot 86,02 = 6,88 \frac{mol}{100 g_{comb}} \\ m_{CO_2} = n_{CO_2} M_{CO_2} = 6,88 \cdot 44 = 302,98 \frac{g}{100 g_{comb}} \end{cases} \quad (C.9)$$

$$\begin{cases} n_{SO_2} = Y_{SO_2} n_{gc} = 0,0011 \cdot 86,02 = 9,46 \times 10^{-3} \frac{mol}{100 g_{comb}} \\ m_{SO_2} = n_{SO_2} M_{SO_2} = 9,46 \times 10^{-3} \cdot 64 = 0,606 \frac{g}{100 g_{comb}} \end{cases} \quad (C.10)$$

$$\begin{cases} n_{CO} = Y_{CO} n_{gc} = 0,0008 \cdot 86,02 = 6,88 \times 10^{-3} \frac{mol}{100 g_{comb}} \\ m_{CO} = n_{CO} M_{CO} = 6,88 \times 10^{-3} \cdot 28 = 0,193 \frac{g}{100 g_{comb}} \end{cases} \quad (C.11)$$

$$\begin{cases} n_{NH} = Y_{NH} n_{gc} = 0,0017 \cdot 86,02 = 0,146 \frac{mol}{100 g_{comb}} \\ m_{NH} = n_{NH} M_{NH} = 0,146 \cdot 30 = 4,388 \frac{g}{100 g_{comb}} \end{cases} \quad (C.12)$$

4) Calculo das emissões por litro de combustível. A partir da massa específica do óleo diesel a 20°C, $\rho_{diesel} = 870 \frac{g}{L}$, estimam-se as emissões por litro de óleo diesel.

$$m_{CO_2} = 302,98 \frac{g}{100 g_{comb}} \cdot \frac{1}{100} \cdot 870 \frac{g}{L} = 2634,96 \frac{g_{CO_2}}{L_{comb}} = 2,635 \frac{kg_{CO_2}}{L_{comb}} \quad (C.13)$$

$$m_{SO_2} = 0,606 \frac{g}{100 g_{comb}} \cdot \frac{1}{100} \cdot 870 \frac{g}{L} = 5,27 \frac{g_{SO_2}}{L_{comb}} = 5,27 \times 10^{-3} \frac{kg_{SO_2}}{L_{comb}} \quad (C.14)$$

$$m_{CO} = 0,193 \frac{g}{100 g_{comb}} \cdot \frac{1}{100} \cdot 870 \frac{g}{L} = 1,68 \frac{g_{CO}}{L_{comb}} = 1,68 \times 10^{-3} \frac{kg_{CO}}{L_{comb}} \quad (C.15)$$

$$m_{NO} = 4,38 \frac{g}{100 g_{comb}} \cdot \frac{1}{100} \cdot 870 \frac{g}{L} = 38,18 \frac{g_{NO}}{L_{comb}} = 0,03818 \frac{kg_{NO}}{L_{comb}} \quad (C.16)$$

O fator de emissão aqui calculado resultou da ordem dos valores apresentados em outros trabalhos, como se pode observar na Tabela C.1.

Tabela C.1. Fator de emissão calculado e valores de referência.

	Fator de emissão por poluente $\frac{kg_{poluente}}{L_{comb}}$			
	CO_2	SO_2	CO	NO_x
Calculado no presente trabalho	2,64	$5,27 \times 10^{-3}$	$1,68 \times 10^{-3}$	0,0038
(UNITED STATES ENVIRONMENTAL PROTECTION AGENCY (EPA), 2009)	2,75	$4,89 \times 10^{-3}$	0,016	0,0074
(BERNAL-AGUSTÍN; DUFO-LÓPEZ; RIVAS-ASCASO, 2006; DUFO-LÓPEZ; BERNAL-AGUSTÍN, 2008; SHARAFI; ELMEKKAWY, 2014)	2,40 - 2,80	--	--	--
(DUFO-LÓPEZ et al., 2011)	3,50	--	--	--
(SAIF et al., 2010)	2,33	--	--	--

Fonte: produção do próprio autor

APÊNDICE D – CUSTOS ASSOCIADOS AOS COMPONENTES DO SHGE

D.1 CUSTOS DE INVESTIMENTO INICIAL

Compreendem os custos de projeto, aquisição, transporte e instalação dos equipamentos que compõem o sistema.

1) Sistema de geração solar fotovoltaica

Nos sistema PV o custo de investimento inicial está dominado principalmente pelo valor dos painéis PV. A participação do custo dos módulos PV no investimento inicial varia entre 40% e 60% em função da finalidade e da potência instalada (IRENA, 2012).

O custo dos painéis PV é geralmente expresso em termos de potência de pico, sendo representado por US\$/Wp. O preço internacional dos módulos PV tem experimentado uma queda expressiva nos últimos anos, passando de 3,25 US\$/Wp em 2009 para 0,8 US\$/Wp em 2012, o qual representa uma queda de 75% (ELECTRICITY MARKET AND POLICY GROUP (BERKELY LAB), 2013). Pesquisas mais recente apontam para valores entre 0,46 US\$/Wp e 0,75 US\$/Wp em 2014 no mercado europeu (IRENA, 2015). Entre os principais fatores que motivaram essa queda está o aumento na eficiência dos sistemas PV, tanto das células quanto dos módulos; redução de custos devido à economia de escala em função da entrada de grandes fabricantes no mercado mundial, principalmente da China; e otimização dos processos de fabricação devido à maturidade da tecnologia. O custo dos painéis PV no mercado brasileiro nem sempre acompanha a tendência do mercado mundial, a ausência de fabricantes de módulos no país leva à necessidade de importar este componente para sua utilização no país. Pesquisas realizadas no mercado nacional em março de 2016 pelos autores do presente trabalho, indicam valores aproximados de 1,78 US\$/Wp (6,94 R\$/Wp¹²), sendo que para módulos de potência menor a 50 W o custo é em média 2,28 US\$/Wp e para módulos de mais de 50 W o custo é de 1,24 US\$/Wp.

Além dos custos dos painéis PV, o custo de investimento inicial de sistemas de geração PV compreende o custo de todos os equipamentos associados ao sistema como cabeamento, controlador de carga, conectores, chaves e estrutura de montagem, assim como o custo de instalação e licenciamento (se for o caso). Estes custos variam significativamente de um país para outro e em diferentes segmentos do mercado. De acordo com (IRENA, 2015) o custo de

¹²Considerando a cotação do dólar a março de 2016 de 3,89 R\$.

investimento inicial excluindo os painéis PV varia entre 0,8 US\$/Wp e 1,5 US\$/Wp em função do país avaliado.

Finalmente o custo total de investimento inicial do sistema PV compreende o custo dos painéis e o custo de instalação do sistema, i.e. representa o custo por quilo watt de potência instalada. A modo de referência mostram-se na Tabela D.1 o valor do kW instalado para diferentes configurações de sistemas PV. No mercado brasileiro o custo do kW fotovoltaico instalado é de aproximadamente 2900 US\$/kW (CANEDO MONTESANO MIRANDA, 2014).

2) Sistema de geração eólica

Em sistemas de geração eólica, a maior parcela do custo de investimento inicial deriva da aquisição das turbinas eólicas, podendo representar entre um 64% e 84% do investimento inicial. O resto dos custos divide-se entre a preparação do terreno e fundação (8%-16%), conexão à rede (8%-11%) e planejamento e obra civil (4%-10%) (IRENA, 2015).

Um fator que influencia bastante o custo de investimento inicial é o porte do sistema. Os aerogeradores variam de unidades de centenas de watts até alguns megawatts, o que pode representar consideráveis variações de preços. Como regra geral, em sistemas de pequeno porte (< 100 kW) o valor da energia gerada resulta maior que em sistemas de grande porte (PINHO, 2008).

O preço das turbinas eólicas experimentou um pico máximo no ano 2009 devido principalmente a restrições no fornecimento das turbinas e componentes, e ao aumento do valor das commodities, particularmente o aço e o cobre. Uma vez atingido o preço máximo de aproximadamente 1107 US\$/kW, o valor dos equipamentos tem experimentado uma queda de 33% até 2014 (IEA, 2013a). O preço internacional aponta para valores de até 3000 US\$/kW para aerogeradores de pequeno porte, atingindo custos médios da ordem de 800 US\$/kW para aerogeradores de grande porte. No mercado Brasileiro há escassez de equipamentos, em especial de pequeno porte, portanto foi difícil achar uma quantidade representativa de preços para estimar um valor médio. No entanto, a partir das informações relevadas, estimou-se um valor de 2975 US\$/kW para aerogeradores de pequeno porte.

Os valores em nível mundial do kW instalado, que considera o custo das turbinas e o custo de instalação, é mostrado na Tabela D.1. No que respeita às usinas on-shore de grande porte, atualmente o país com o menor custo do kW instalado é a China com 1310 US\$/kW. Na Europa o custo é de aproximadamente 1710 US\$/kW e nos EUA é de 1779 US\$/kW. O

custo médio na América do Sul é de 2200 US\$/kW, sendo que no Brasil esse valor estima-se em 1840 US\$/kW (IRENA, 2015).

As instalações de pequeno porte, com potência instalada menor de 100 kW, representam um investimento maior em relação ao kW instalado. A média mundial do kW instalado é de 4640 US\$/kW, sendo que em EUA o valor é de aproximadamente 6940 US\$/kW, na Inglaterra de 5873 US\$/kW e na China de 1700 US\$/kW (GSÄNGER; PITTELOUD, 2015).

3) Grupo Moto Gerador

O principal custo de investimento inicial de sistemas de geração com combustíveis fósseis está relacionado ao custo de aquisição. As características principais desses tipos de sistemas de geração são seus baixos custos iniciais e seus elevados custos ao longo de sua vida útil. Pesquisas no mercado local indicam um valor médio de 279,2 US\$/kW, sendo que para moto geradores de potência menor a 10 kW o preço médio é de 240,6 US\$/kW enquanto que para moto geradores de potência maior a 10 kW o preço é de aproximadamente 324,0 US\$/kW.

4) Baterias, Inversores e Controladores de Carga

O sistema de armazenamento, baterias de chumbo-ácido, representa um componente crítico do SHGE dada sua curta vida útil em relação ao resto dos equipamentos. As clássicas baterias automotivas e estacionárias possuem tempos de vida útil dentre 2 e 4 anos. No entanto existem baterias especiais para sistemas baseados em fontes renováveis, onde se requiere elevado numero de ciclos de carga/descarga diária, que apresentam tempos vida maiores; porém seus altos custos e sua indisponibilidade no mercado local torna proibitivo seu uso (PINHO, 2008). Pesquisas no mercado local apontam para um valor médio de 165,2 US\$/kWh para baterias estacionárias de chumbo-ácido, tensão nominal de 12 V.

Os controladores de carga e inversores são equipamentos com alta maturidade tecnológica, assim sua robustez e confiabilidade garantem reduzidas necessidades de reposição. O tempo médio de vida útil da maioria dos modelos desses equipamentos já atinge atualmente a faixa dos 10 anos. O preço dos inversores varia bastante com a sua capacidade. No mercado nacional os inversores de potência menor a 2,5 kW apresentam custos médios de 566 US\$/kW, enquanto que equipamentos com valores de potência superiores chegam a atingir 863,00 US\$/kW. Já o custo dos controladores de carga depende de se incorporam sistema seguidor de máxima potência (MPPT) ou não, para controlador com sistema MPPT o preço médio é de 15 US\$/A, enquanto que para controladores sem MPPT o valor é de 6 US\$/A.

Tabela D.1. Custos associados aos componentes do SHGE.

Componente	Características	Custo de investimento inicial	Mercado
Solar Fotovoltaica (montagem no telhado)	Residencial: 3-5 kW	Custo do kW instalado: Residencial: 3323,3 US\$/kW	Mundial
	Comercial > 100 kW	Comercial: 3575,0 US\$/kW	Mundial
	Comercial < 100 kW	Comercial: 2900,0 US\$/kW	Brasileiro
Solar Fotovoltaica (montagem no chão, grande gerador)	1-250 MW	Custo do kW instalado: 1200 - 3000 US\$/kW	Mundial
	1-5 MW	2866,1 US\$/kW	Mundial
	5-250 MW	2156,8 US\$/kW	Mundial
Eólica (on-shore, grande gerador)	1,5-3,5 MW	Custo do kW instalado: 3548,9 US\$/kW	Mundial
		1840,0 US\$/kW	Brasileiro
Eólica (pequeno porte)	< 100 kW	Custo do kW instalado: 4640,0 US\$/kW	Mundial
		3669,41 US\$/kW	Brasileiro
Grupo moto gerador	< 10 kW	Custo de aquisição: 240,6 US\$/kW	Brasileiro
	> 10 kW	324,0 US\$/kW	Brasileiro
Baterias	Estacionária, chumbo-ácido, 12V	Custo de aquisição: 165,2 US\$/kWh	Brasileiro
Inversor	< 2,5 kW	Custo de aquisição: 566,0 US\$/kW	Brasileiro
	> 2,5 kW	863,0 US\$/kW	Brasileiro
Controlador de carga	Com MPPT	Custo de aquisição: 15,0 US\$/A	Brasileiro
	Sem MPPT	6,0 US\$/A	Brasileiro

Fonte: elaboração própria baseado em pesquisas no mercado local e em (REN21, 2015).

D.2 CUSTOS DE OPERAÇÃO E MANUTENÇÃO

Os SHGE caracterizam-se por possuir baixos custos de O&M no que respeita à geração renovável e custos mais elevados associados aos grupos moto geradores. Ao momento de consideras os custos de O&M estes costumam ser representados através de um valor percentual com relação ao custo do investimento inicial, ou valores em função da capacidade instalada (US\$/kW) ou energia gerada (US\$/kWh) (KALDELLIS, 2010).

Os sistemas de geração PV caracterizam-se por possuir baixos custos de O&M. Alguns autores optam por desprezá-los (KATSIGIANNIS; GEORGILAKIS; KARAPIDAKIS, 2010a; SAIF et al., 2010), outros consideram valores muito reduzidos da ordem de 0,005 US\$/kWh (CHEDID; KARAKI; RIFAI, 2005; NASIRAGHDAM; JADID, 2012), ou em valores percentuais reportam-se valores da ordem de 1% do investimento inicial ao ano (IEA, 2013b; KALDELLIS, 2010; MACEDO, 2014).

Os custos de O&M dos sistemas eólicos são superiores aos dos sistemas PV, principalmente em função das estruturas de sustentação (torre, cabos) e do próprio aerogerador que, devido à presença de partes móveis, deve ser submetido a uma rotina de manutenção preventiva periódica. Estes custos podem representar entre um 15% e 25% do custo nivelado de energia em sistemas eólicos (IEA, 2013a). Na literatura reportam-se valores típicos de entre 0,01 US\$/kWh e 0,03 US\$/kWh, ou entre 1,5% e 3% do custo do investimento inicial do aerogerador ao ano (IRENA, 2015; MACEDO, 2014; PINHO, 2008).

O sistema moto gerador diesel pode precisar de uma quantidade significativa de tempo e materiais para mantê-los a funcionar satisfatoriamente. Dependendo do tempo de operação do sistema durante o ano e da frequência das manutenções estes custos podem resultar acentuados, sendo esta a principal desvantagem deste tipo de fonte geradora. Alguns autores consideram ainda a custo do combustível como um custo operacional, sendo que em sistemas localizados em regiões remotas o custo do litro de combustível é ainda maior que o verificado nas cidades, devido a todo o processo de logística envolvido na aquisição e transporte do combustível ao ponto de consumo (PINHO et al., 2008). Quando integrados em sistemas híbridos, operando em forma esporádica, reportam-se custos de O&M entre 0,02 US\$/kWh (MACEDO, 2014; PINHO, 2008) e 0,14 US\$/kWh (CHEDID; KARAKI; RIFAI, 2005).

No que respeita às baterias, pode-se assumir um custo de O&M relacionados com a manutenção do banco de baterias, valores na literatura são reportados em função da capacidade do banco 0,02 US\$/kWh (CHEDID; KARAKI; RIFAI, 2005) ou em valores fixos por ano, como 1,13 US\$/unidade/ano (CLARKE; AL-ABDELI; KOTHAPALLI, 2015).

O resto dos componentes do sistema apresenta custos de O&M bem reduzido e podem ser associados aos custos de operação e manutenção dos sistemas fotovoltaico e eólico.

APÊNDICE E – EQUAÇÕES DO MODELO DE ANÁLISE ECONÔMICA

As equações utilizadas para o cálculo dos diferentes indicadores econômicos se mostram a seguir.

a) Valor Presente Líquido dos Custos

O NPV_C calcula-se segundo equação (E.1):

$$NPV_C = \frac{C_{level,tot}}{CRF(d_r, LT_{proj})} \quad (E.1)$$

sendo,

$C_{level,tot}$: custo anual equivalente¹³ [US\$/ano].

$CRF(\cdot)$: fator de recuperação de capital.

d_r : taxa de juros real [%].

LT_{proj} : tempo de duração do projeto [ano].

O fator de recuperação de capital (em inglês *Capital Recovery Factor*), $CRF(\cdot)$, é uma relação utilizada para calcular o valor presente de uma série uniforme de pagamentos anuais (anuidade), e se calcula com a equação (E.2):

$$CRF(d_r, LT_{proj}) = \frac{d_r (1 + d_r)^{N_y}}{(1 + d_r)^{N_y} - 1} \quad (E.2)$$

sendo,

N_y : quantidade de pagamentos anuais recebidos (número de anos) [ano].

A taxa de juros real, d_r , é a taxa de juros utilizada para anualizar os custos numa série uniforme de pagamentos anuais. A d_r se relaciona com a taxa de juros nominal, d_n , que é aquela divulgada pelas instituições financeiras quando se faz um investimento ou se assume uma dívida sem considerar os efeitos da inflação, e com a taxa anual de inflação, i_r , que é a taxa de aumento de preços (FOSTER; GHASSEMI; COTA, 2010). A taxa real de juros é a taxa nominal de juros já com a inflação descontada, e calcula-se como segue:

$$d_r = \frac{d_n - i_r}{1 + i_r} \quad (E.3)$$

¹³O custo anual equivalente resulta da transformação do fluxo de todos os custos do projeto num fluxo anual uniforme.

A equação (E.3) indica que a inflação é excluída da análise econômica, sendo que todos os custos são dados em valor constante de dólar. Além disso, a taxa de inflação é a mesma para todos os custos.

b) Custo Anual Equivalente

O Custo Anual Equivalente, $C_{level,tot}$, representa a soma dos custos anualizados de todos os componentes do sistema, mais outros custos anualizados:

$$C_{level,tot} = C_{level,cap} + C_{level,rep} + C_{ann,o\&m} + C_{ann,fuel} + C_{level,other} \quad (E.4)$$

sendo,

$C_{level,cap}$: custo de investimento anualizado [US\$/ano].

$C_{level,rep}$: custo de reposição anualizado [US\$/ano].

$C_{annual,o\&m}$: custo anual de operação e manutenção [US\$/ano].

$C_{annual,fuel}$: custo anual de combustível [US\$/ano].

$C_{level,other}$: outros custos anualizados [US\$/ano].

c) Custos de Investimento Inicial

O $C_{level,cap}$ é o custo de investimento inicial de todos os componentes do sistema anualizado ao longo do tempo de vida do projeto:

$$C_{level,tot} = C_{icap} CRF(d_r, LT_{proj}) \quad (E.5)$$

sendo,

$$C_{icap} = C_{icap,wt} + C_{icap,pv} + C_{icap,dg} + C_{icap,bt} + C_{icap,conv} \quad (E.6)$$

sendo,

$C_{icap,wt}$: investimento inicial das turbinas eólicas [US\$].

$C_{icap,pv}$: investimento inicial do sistema fotovoltaico [US\$].

$C_{icap,dg}$: investimento inicial do grupo moto gerador [US\$].

$C_{icap,bt}$: investimento inicial das baterias [US\$].

$C_{icap,conv}$: investimento inicial do conversor [US\$].

d) Custos de Reposição

O $C_{level,rep}$ representa todos os fluxos de caixa derivados da reposição dos componentes do sistema que ocorrem durante a operação do SHGE, anualizados durante a duração do projeto, menos o valor residual no final da vida do projeto. Calcula-se como segue:

$$C_{level,rep} = C_{rep,j} \cdot F_{rep} \cdot SFF(i_r, LT_{comp}) - S_{salv} \cdot SFF(i_r, LT_{proj}) \quad (E.7)$$

sendo,

$C_{rep,j}$: custo de reposição dos componentes do sistema, isto é, o custo de reposição das turbinas eólicas ($C_{rep,wt}$), dos painéis PV ($C_{rep,pv}$), do moto gerador ($C_{rep,dg}$), das baterias ($C_{rep,bt}$) e do conversor ($C_{rep,conv}$) em [US\$].

O custo de reposição de um componente pode diferir do seu custo de capital inicial por diversas razões. Por exemplo, no caso em que apenas o gerador elétrico da turbina eólica precisa de substituição, podendo-se aproveitar a torre, ou quando o custo de capital inicial é financiado por uma agência de fomento, mas a substituição não é.

O F_{rep} é um fator que se aplica devido às diferentes durações de vida útil dos componentes e da duração do projeto.

$$F_{rep} = \begin{cases} \frac{CRF(i_r, LT_{proj})}{CRF(i_r, R_{rep})} & , R_{rep} > 0 \\ 0 & , R_{rep} = 0 \end{cases} \quad (E.8)$$

sendo, R_{rep} é fator de duração da reposição, calculado como:

$$R_{rep} = nint\left(\frac{LT_{proj}}{LT_{comp}}\right) \quad (E.9)$$

sendo,

$nint(x)$: função que retorna o número inteiro de x .

L_{comp} : vida útil do componente [ano].

O S_{salv} [US\$], é denominado valor residual, sendo definido como o valor de um ativo que sofre depreciação ao final da duração do projeto, isto é, o valor esperado deste ativo ao ser vendido no final do projeto. Considerando que o valor residual é proporcional à vida remanescente do componente, $LT_{comp,rem}$, pode-se calcular a partir da equação (E.10):

$$S_{salv} = C_{rep} \frac{LT_{comp,rem}}{LT_{comp}} = C_{rep} \frac{LT_{comp} - (LT_{proj} - R_{rep})}{LT_{comp}} \quad (E.10)$$

O $SFF(\cdot)$ é o Fator de Fundo de Amortização (em inglês *Sinking Fund Factor*) que é utilizado para calcular o valor futuro de uma série de anuidades. A fórmula toma um único pagamento e o distribui de forma uniforme numa série de N_y períodos anteriores (JENSEN, 2005).

$$SFF(i_r, N_y) = \frac{i_r}{(1+i_r)^{N_y} - 1} \quad (E.11)$$

e) Custos de Operação e Manutenção

Os custos anuais de operação e manutenção, $C_{ann,o\&m}$, são a fonte de despesas mais significativa após a aquisição e instalação do sistema. Os de operação podem envolver os seguros, arrendamento de terras, enquanto os custos de manutenção compreendem a verificação, limpeza e teste de rotina e, eventualmente, alguma manutenção não programada dos componentes do sistema. Os $C_{ann,o\&m}$ são geralmente expressos em percentagem do custo de investimento inicial de cada componente em [US\$/ano], e são proporcionais à potência nominal do componente.

f) Custos do Combustível

O custo anual de combustível, $C_{ann,fuel}$, representa as despesas ocorridas durante o ano para abastecer de combustível o grupo moto gerador. Uma vez que o consumo total de combustível do gerador diesel ao longo do ano é conhecido, pode-se calcular o $C_{ann,fuel}$ pela multiplicação do consumo pelo custo do combustível em US\$/L.

g) Outros Custos

O $C_{level,other}$ compreende a soma de todos os outros custos de investimento inicial anualizados, e os outros custos de operação e manutenção.

$$C_{level,other} = C_{level,other,cap} + C_{ann,other,o\&m} \quad (E.12)$$

O $C_{level,other,cap}$ calcula-se a partir da equação (E.5) multiplicando o fator de recuperação de capital pelo valor do capital inicial de qualquer investimento que acontece no início do projeto e não depende da potência instalada do SHGE. Neste custo podem-se incluir a

construção de caminhos de acesso, edificações adicionais para a proteção dos componentes, entre outros.

O $C_{ann,other,o\&m}$ inclui a soma de qualquer custo fixo de operação e manutenção não relacionado com os componentes do sistema. Além disso, pode considerar custos adicionais derivados de penalidades pela falta de fornecimento de energia (falhas) ou pela emissão de poluentes. Ao penalizar a energia não fornecida e as emissões, contemplam-se os aspectos de confiabilidade e ambiental na função objetivo de otimização.

$$C_{ann,other,o\&m} = C_{o\&m, fixed} + C_{other, LPS} + C_{other, emissões} \quad (E.13)$$

Caso não houver nenhuma penalização pecuniária em relação a estes aspectos, ou não se pretende incluí-las no modelo econômico, os aspectos de confiabilidade e ambiental devem ser incorporados como restrições na configuração do problema de otimização.

h) Cálculo do Custo Nivelado de Energia

O $LCOE$ calcula-se como a razão entre o custo anual equivalente do sistema e a energia fornecida à carga, com a equação (E.14):

$$LCOE = \frac{C_{level,tot}}{E_{load} - LPS} \quad (E.14)$$

sendo,

E_{load} : energia demanda pela carga [kWh].

LPS : energia não suprida [kWh].

APÊNDICE F – ARQUIVO DE RESULTADOS FORNECIDO PELO ALGORITMO DE SIMULAÇÃO DE SHGE

 * RESULTS OF HPS SIMULATION: OVERALL PERFORMANCE INDICES *

Simulation run on: 16-Jun-2016 10:04:13
 Project name: Study case Campinas (Sim 3-3)
 Author: JJR
 Notes: Write any comment here

Run specifications:
 - Duration of simulation period: 8760 h
 - Simulation time step: 60 min

* SYSTEM OVERVIEW *****
 - Wind turbine (WT): 0.00 kw
 - Photovoltaic (PV): 149.40 kwp
 - Diesel generator (DG): 48.00 kw
 - Battery bank (BT): 855.60 kwh
 - Converter (CONV): 35.00 kw
 - Control strategy: Load Following (LF)
 - Total Net Present Value (NPVc): 782227.44 US\$
 - Levelized Cost of Energy (LCOE): 0.35 US\$/kwh
 - Levelized Operating Cost (Co&m): 20281.88 US\$/yr
 - Initial Capital Cost (Cini): 524288.75 US\$

* AC LOAD CHARACTERISTICS *****
 - Total demand: 178253.48 kwh/yr
 - Mean power demand year: 20.35 kw/yr
 - Mean power demand day: 488.37 kwh/day
 - Peak power year: 43.38 kw
 - Minimum power year: 10.31 kw
 - Load factor year: 0.47 %

* SYSTEM RELIABILITY INDICES *****
 - Interruption duration: 0.00 hr/yr
 - Maximum interruption duration: 0.00 hr
 - Interruption frequency: 0.00 interruption/yr
 - Loss of power supply: 0.00 kwh/yr
 - Loss of power supply probability: 0.000 %

* ELECTRICITY GENERATION INDICES *****
 Production
 - WT generation: 0.00 kwh/yr
 - PV array generation: 189894.37 kwh/yr
 - DG generation: 30293.45 kwh/yr
 - Total HPS electricity generation: 220187.82 kwh/yr

Consumption
 - AC primary load: 178253.48 kwh/yr

Generation performance
 - AC load served: 178253.48 kwh/yr
 - Loss of power supply: 0.00 kwh/yr (0.00 %)
 - Excess of energy: 9534.08 kwh/yr (4.33 %)
 - Renewable energy fraction: 86 %

* PV PERFORMANCE INDICES *****
 - PV array total rated power: 1245 x 0.12 kwp = 149.40 kwp
 - PV mean power output: 21.68 kw
 - PV mean daily power output: 520.26 kw/day
 - PV capacity factor: 14.51 %
 - PV electricity generation: 189894.37 kwh/yr
 - PV minimum power output: 0.00 kw
 - PV maximum power output: 122.25 kw
 - PV penetration: 106.53 %
 - PV hours of operation: 4553.00 hr/yr

* DG PERFORMANCE INDICES *****
 - DG total rated power: 3 x 16.00 kw = 48.00 kw
 - DG total fuel consumption: 11263.85 L/yr
 - DG maximum monthly mean consumption: 1260.00 L
 - DG month of the maximum fuel consumption: 1.00

Performance of DG n° 1
 - DG hours of operation: 1797.00 h/yr
 - DG number of starts: 282.00 starts/yr
 - DG operational life: 5.56 yr
 - DG capacity factor: 16.59 %
 - DG electricity generation: 23246.39 kwh/yr
 - DG mean power output: 12.94 kw

- DG minimum power output:	4.80 kw
- DG maximum power output:	16.00 kw
- DG fuel consumption:	8138.09 L/yr
- DG specific fuel consumption:	0.35 L/kwh
- DG fuel energy input:	80078.83 kwh/yr
- DG mean electrical efficiency:	28.00 %

Performance of DG n° 2

- DG hours of operation:	1007.00 h/yr
- DG number of starts:	162.00 starts/yr
- DG operational life:	9.93 yr
- DG capacity factor:	4.93 %
- DG electricity generation:	6915.52 kwh/yr
- DG mean power output:	6.87 kw
- DG minimum power output:	4.80 kw
- DG maximum power output:	16.00 kw
- DG fuel consumption:	3057.04 L/yr
- DG specific fuel consumption:	0.44 L/kwh
- DG fuel energy input:	30081.30 kwh/yr
- DG mean electrical efficiency:	22.06 %

Performance of DG n° 3

- DG hours of operation:	27.00 h/yr
- DG number of starts:	24.00 starts/yr
- DG operational life:	370.37 yr
- DG capacity factor:	0.09 %
- DG electricity generation:	131.53 kwh/yr
- DG mean power output:	4.87 kw
- DG minimum power output:	4.80 kw
- DG maximum power output:	6.46 kw
- DG fuel consumption:	68.71 L/yr
- DG specific fuel consumption:	0.52 L/kwh
- DG fuel energy input:	676.11 kwh/yr
- DG mean electrical efficiency:	19.44 %

* BT PERFORMANCE INDICES *****

- Battery bank (BT):	855.60 kwh
- BTs in series:	120.00
- BTs in parallel:	1
- DC bus voltage:	240.00 v
- Maximum capacity of the battery bank:	855.60 kwh
- Usable nominal capacity of the BT bank:	598.92 kwh
- BT bank autonomy:	29.43 h
- BT bank lifetime throughput:	1223520.00 kwh
- BT bank wear cost:	12.94 \$/kwh
- BT bank energy input:	106878.52 kwh/yr
- BT bank energy output:	107476.98 kwh/yr
- BT bank storage depletion:	573.54 kwh
- BT bank annual throughput:	115895.41 kwh/yr
- BT bank annual expected life:	10.56 yr
- BT bank charge/discharge losses:	16178.48 kwh/yr

* CONV PERFORMANCE INDICES *****

Inverter

- INV quantity:	7
- INV total rated capacity:	35.00 kw
- INV mean power output:	17.10 kw
- INV capacity factor:	48.85 %
- INV hours of operation:	8261.00 h/yr
- INV energy in:	166401.31 kwh/yr
- INV energy out:	149761.18 kwh/yr
- INV conversion losses:	16640.13 kwh/yr

Rectifier

- REC capacity:	5.00 kw
- REC mean power output:	0.19 kw
- REC capacity factor:	0.53 %
- REC hours of operation:	770.00 h/yr
- REC energy in:	1801.14 kwh/yr
- REC energy out:	1621.03 kwh/yr
- REC conversion losses:	180.11 kwh/yr

* LIFE CYCLE EMISSIONS INDICES *****

Life cycle emissions per component

- WT life cycle emission:	0 tCO2-eq/yr
- PV life cycle emission:	0.011 tCO2-eq/yr
- DG life cycle emission:	0.022 tCO2-eq/yr
- BT life cycle emission:	0.043 tCO2-eq/yr
- CONV life cycle emission:	0.0015 tCO2-eq/yr
- FUEL life cycle emission:	0.006 tCO2-eq/yr

Direct emissions per component

- DG direct emission (CO2):	29.68 tCO2/yr
- DG direct emission (SO2):	0.05936 tSO2/yr
- DG direct emission (CO):	0.01892 tCO/yr
- DG direct emission (NOx):	0.4301 tNOx/yr

Total Life cycle emissions for the HPS

- HPS life cycle emission:	29.76 tCO2-eq/yr
----------------------------	------------------

APÊNDICE G – AVALIAÇÃO DO DESEMPENHO DA GATOOLBOX

Neste apêndice se expõem os resultados da avaliação do desempenho da *GAtoolbox* na resolução de diferentes tipos de problemas de otimização: problemas mono-objetivo sem restrições; problemas mono-objetivo com restrições e; problemas multiobjetivo.

G.1. PROBLEMAS MONO-OBJETIVO SEM RESTRIÇÕES

As funções teste utilizadas na avaliação da *GAtoolbox* na resolução de problemas sem restrições são:

Função de Michalewicz

Conhecida como uma função que apresenta um espaço de busca altamente irregular com cumes íngremes e abismos. Tem máximos locais, e que é multimodal. O parâmetro m define a magnitude dos cumes e abismos.

Definição	Intervalo de variáveis	Ótimo conhecido (maximização)
$f_1(\vec{x}) = \sum_{i=1}^d \sin(x_i) \sin^{2m}\left(\frac{i x_i^2}{\pi}\right)$	$0 \leq x_i \leq \pi$	com $m=10 \rightarrow f^*(2,20;1,57)=1,8013$

Função de Schwefel

Caracteriza-se por apresentar um espaço de busca enganoso dado que o máximo global se encontra distante de um máximo local de similar magnitude. Assim, os algoritmos tem grande chance de convergir para o ótimo equivocado.

Definição	Intervalo de variáveis	Ótimo conhecido (maximização)
$f_2(\vec{x}) = -\sum_{i=1}^n \left[x_i \sin\left(\sqrt{ x_i }\right) \right]$	$-500 \leq x_i \leq 500$	$f^*(420,9687; 420,9687) = 837,9658$

As configurações do AG testadas se apresentam na Tabela G.1. Estas configurações surgem da combinação dos dois tipos de codificação e dos diferentes tipos de operadores de recombinação e mutação disponíveis na *GAtoolbox*. Na Tabela G.1, AGB refere-se a Algoritmo Genético codificação Binária e AGR refere-se a Algoritmo Genético codificação Real.

Tabela G.1. Configuração do AG testadas para a resolução de problemas mono-objetivo sem restrições.

#	Algoritmo	Operador	
		Recombinação	Mutação
1	AGB1	Cruzamento em um ponto	Binária
2	AGB2	Cruzamento em dois pontos	Binária
3	AGB3	Cruzamento aleatório	Binária
4	AGB4	Discreta	Binária
5	AGR1	Discreta	Breeder ($r = 0,1$; $k = 16$) ⁽¹⁾
6	AGR2	BLX- α ($\alpha = 0,5$)	Breeder ($r = 0,1$; $k = 16$)
7	AGR3	Linear	Breeder ($r = 0,1$; $k = 16$)
8	AGR4	Aritmética	Breeder ($r = 0,1$; $k = 16$)
9	AGR5	BLX-0,0 ($\alpha = 0$)	Breeder ($r = 0,1$; $k = 16$)
10	AGR6	Intermediária	Breeder ($r = 0,1$; $k = 16$)
11	AGR7	Discreta	Boundary
12	AGR8	BLX- α ($\alpha = 0,5$)	Boundary
13	AGR9	Linear	Boundary
14	AGR10	Aritmética	Boundary
15	AGR11	BLX-0,0 ($\alpha = 0$)	Boundary
16	AGR12	Intermediária	Boundary
17	AGR13	Discreta	Uniforme
18	AGR14	BLX- α ($\alpha = 0,5$)	Uniforme
19	AGR15	Linear	Uniforme
20	AGR16	Aritmética	Uniforme
21	AGR17	BLX-0,0 ($\alpha = 0$)	Uniforme
22	AGR18	Intermediária	Uniforme
23	AGR19	Discreta	Multi-uniforme
24	AGR20	BLX- α ($\alpha = 0,5$)	Multi-uniforme
25	AGR21	Linear	Multi-uniforme
26	AGR22	Aritmética	Multi-uniforme
27	AGR23	BLX-0,0 ($\alpha = 0$)	Multi-uniforme
28	AGR24	Intermediária	Multi-uniforme
29	AGR25	Discreta	Não-uniforme ($b = 5$) ⁽²⁾
30	AGR26	BLX- α ($\alpha = 0,5$)	Não-uniforme ($b = 5$)
31	AGR27	Linear	Não-uniforme ($b = 5$)
32	AGR28	Aritmética	Não-uniforme ($b = 5$)
33	AGR29	Flat	Não-uniforme ($b = 5$)
34	AGR30	Intermediária	Não-uniforme ($b = 5$)
35	AGR31	Discreta	Multi-não-uniforme ($b = 5$)
36	AGR32	BLX- α ($\alpha = 0,5$)	Multi-não-uniforme ($b = 5$)
37	AGR33	Linear	Multi-não-uniforme ($b = 5$)
38	AGR34	Aritmética	Multi-não-uniforme ($b = 5$)
39	AGR35	BLX-0,0 ($\alpha = 0$)	Multi-não-uniforme ($b = 5$)
40	AGR36	Intermediária	Multi-não-uniforme ($b = 5$)

⁽¹⁾ r e k são os parâmetros de *range* e precisão utilizados pelo operador de mutação Breeder.⁽²⁾ b utilizado pelo operador de mutação não-uniforme para controlar a dependência com o número de gerações.

Fonte: produção do próprio autor

A configuração dos parâmetros do AG utilizada para efetuar os testes se mostra na Tabela G.2. Todos os algoritmos foram executados 20 vezes a partir de populações iniciais diferentes geradas aleatoriamente. Para o computo dos resultados, considera-se que o algoritmo foi bem sucedido em resolver o problema quando o valor da função objetivo alcançado pelo algoritmo está dentro de $\pm 0,01\%$ do ótimo conhecido.

Tabela G.2. Configuração dos parâmetros do AG utilizada para efetuar os testes.

Operador	Método	Parâmetros utilizados
Atribuição de aptidão	Ranking linear	Pressão de seleção = 1,7
Método de seleção	Amostragem Universal Estocástica	Intervalo de seleção = 1
Estratégia de reinserção	<i>Worst and fitness-based reinsertion</i>	Taxa de reinserção = 0,98 (elitismo)
Critério de parada	Número máximo de gerações Desvio padrão dos objetivos	Número de geração = 5000 Diferença entre objetivos = 1×10^{-4}
Tamanho da população	--	$N_{pop} = 50$
Probabilidade de recombinação	--	$p_r = 0,9$
Probabilidade de mutação	--	$p_m = 0,005$
Número de bits do gene (para AGB)	Precisão de 1×10^{-8}	para $f_1(x)$ <i>strLength</i> = 37 para $f_2(x)$ <i>strLength</i> = 29

Fonte: produção do próprio autor

Para cada função de teste, foram computados os seguintes indicadores de desempenho:

- avgDiff2Opt* : diferença média com o ótimo conhecido computada sobre o total de corridas.
- avgSol* : solução média das soluções computada sobre o total de corridas.
- stdSol* : desvio padrão das soluções computadas sobre o total de corridas.
- sucPerc* : razão entre as corridas bem sucedidas e o total de corridas.
- avgFnEval* : média da quantidade de vezes a função objetivo foi avaliada computada sobre o total de corridas.
- avgSucTime* : tempo médio (em segundos) gasto pelo algoritmo para encontrar a solução, computado apenas para as corridas bem sucedidas.

Os resultados para cada função de teste se mostram nas Tabela G.3 e Tabela G.4 a seguir.

Tabela G.3. Resultados obtidos para a função teste $f_1(\bar{x})$ (Michelewicz) em 20 corridas, $f^* = 1,8013$.

#	Algoritmo	Indicadores de desempenho					
		<i>avgDiff 2Opt</i>	<i>avgSol</i>	<i>stdSol</i>	<i>sucPerc</i>	<i>avgFnEval</i>	<i>avgSucTime</i> [s]
1	BGA1	4,14E-05	1,80126	0,00003	100%	1120,0	0,060
2	BGA2	5,25E-05	1,80125	0,00003	100%	1780,0	0,092
3	BGA3	5,26E-05	1,80125	0,00003	100%	3265,0	0,201
4	BGA4	4,15E-05	1,80126	0,00004	100%	1327,5	0,082
5	RGA1	4,21E-05	1,80126	0,00003	100%	3972,5	0,194
6	RGA2	3,62E-05	1,80126	0,00002	100%	772,5	0,039
7	RGA3	4,38E-05	1,80126	0,00003	100%	1017,5	0,051
8	RGA4	4,45E-05	1,80126	0,00003	100%	1672,5	0,097
9	RGA5	5,64E-05	1,80124	0,00003	100%	1070,0	0,060
10	RGA6	4,21E-05	1,80126	0,00003	100%	672,5	0,034
11	RGA7	9,43E-02	1,70705	0,09544	5%	237515,0	0,015
12	RGA8	3,53E-05	1,80126	0,00003	100%	885,0	0,044
13	RGA9	3,10E-05	1,80127	0,00003	100%	650,0	0,044
14	RGA10	3,72E-05	1,80126	0,00003	100%	7515,0	0,432
15	RGA11	4,42E-05	1,80126	0,00003	100%	2647,5	0,124
16	RGA12	4,49E-05	1,80126	0,00003	100%	685,0	0,042
17	RGA13	3,98E-05	1,80126	0,00003	100%	70610,0	3,045
18	RGA14	3,89E-05	1,80126	0,00003	100%	867,5	0,050
19	RGA15	5,47E-05	1,80125	0,00003	100%	912,5	0,046
20	RGA16	3,43E-05	1,80127	0,00004	100%	2310,0	0,119
21	RGA17	4,00E-05	1,80126	0,00003	100%	2587,5	0,124
22	RGA18	4,84E-05	1,80125	0,00002	100%	712,5	0,033
23	RGA19	4,08E-04	1,80089	0,00035	25%	222532,5	6,932
24	RGA20	2,87E-04	1,80101	0,00021	20%	228127,5	6,775
25	RGA21	3,01E-04	1,80100	0,00023	25%	214950,0	5,319
26	RGA22	2,75E-04	1,80103	0,00023	25%	207362,5	3,758
27	RGA23	3,57E-04	1,80094	0,00039	35%	212735,0	7,054
28	RGA24	2,35E-04	1,80107	0,00022	35%	197485,0	4,842
29	RGA25	4,23E-05	1,80126	0,00003	100%	39517,5	1,466
30	RGA26	5,72E-05	1,80124	0,00003	100%	847,5	0,040
31	RGA27	5,26E-05	1,80125	0,00004	100%	1132,5	0,056
32	RGA28	4,25E-05	1,80126	0,00004	100%	1575,0	0,074
33	RGA29	4,66E-05	1,80125	0,00003	100%	1365,0	0,066
34	RGA30	4,85E-05	1,80125	0,00003	100%	712,5	0,036
35	RGA31	4,31E-05	1,80126	0,00003	100%	80287,5	3,794
36	RGA32	4,17E-05	1,80126	0,00003	100%	90112,5	4,493
37	RGA33	4,99E-05	1,80125	0,00003	100%	82287,5	4,070
38	RGA34	3,66E-05	1,80126	0,00003	100%	83472,5	4,187
39	RGA35	4,08E-05	1,80126	0,00003	100%	73165,0	3,476
40	RGA36	5,33E-05	1,80125	0,00003	100%	84055,0	4,040

Fonte: produção do próprio autor

Tabela G.4. Resultados obtidos para a função teste $f_2(x)$ (Schwefel) em 20 corridas, $f^* = 837,9658$.

#	Algoritmo	Indicadores de desempenho					
		<i>avgDiff 2Opt</i>	<i>avgSol</i>	<i>stdSol</i>	<i>sucPerc</i>	<i>avgFnEval</i>	<i>avgSucTime [s]</i>
1	BGA1	6,06E-05	837,966	0,00002	100%	28120,0	1,363
2	BGA2	5,13E-05	837,966	0,00002	100%	37557,5	1,802
3	BGA3	5,24E-03	837,961	0,02317	95%	44712,5	1,905
4	BGA4	1,56E-02	837,950	0,03795	80%	58475,0	0,512
5	RGA1	1,18E+01	826,122	36,45454	90%	32207,5	0,282
6	RGA2	3,55E+01	802,434	55,68523	70%	76735,0	0,120
7	RGA3	6,51E+01	772,825	60,45302	45%	138267,5	0,078
8	RGA4	5,33E+01	784,669	71,63212	60%	113435,0	0,984
9	RGA5	9,77E+01	740,254	90,68029	35%	171455,0	1,144
10	RGA6	2,37E+01	814,278	48,60605	80%	51345,0	0,075
11	RGA7	3,27E+01	805,253	29,91233	0%	250000,0	NaN
12	RGA8	6,42E-05	837,966	0,00002	100%	3820,0	0,172
13	RGA9	5,67E-05	837,966	0,00002	100%	9990,0	0,443
14	RGA10	6,26E-05	837,966	0,00002	100%	27360,0	1,183
15	RGA11	4,59E-05	837,966	0,00002	100%	31187,5	1,351
16	RGA12	5,83E-05	837,966	0,00002	100%	8115,0	0,342
17	RGA13	9,98E-03	837,956	0,01502	0%	250000,0	NaN
18	RGA14	5,89E-05	837,966	0,00002	100%	3447,5	0,160
19	RGA15	6,02E-05	837,966	0,00002	100%	7355,0	0,332
20	RGA16	5,17E-05	837,966	0,00002	100%	31287,5	1,390
21	RGA17	3,98E-05	837,966	0,00002	100%	30825,0	1,435
22	RGA18	5,90E-05	837,966	0,00002	100%	4940,0	0,242
23	RGA19	1,81E-01	837,785	0,24407	0%	250000,0	NaN
24	RGA20	1,47E-01	837,819	0,17179	5%	242780,0	5,258
25	RGA21	1,04E-01	837,862	0,08912	0%	250000,0	NaN
26	RGA22	1,21E-01	837,845	0,09814	0%	250000,0	NaN
27	RGA23	1,32E-01	837,834	0,10997	0%	250000,0	NaN
28	RGA24	1,95E-01	837,770	0,27177	0%	250000,0	NaN
29	RGA25	5,53E-05	837,966	0,00002	100%	130767,5	4,545
30	RGA26	6,87E-05	837,966	0,00002	100%	3117,5	0,148
31	RGA27	6,96E-05	837,966	0,00002	100%	7007,5	0,353
32	RGA28	2,19E-04	837,966	0,00073	95%	34075,0	1,421
33	RGA29	5,21E-05	837,966	0,00002	100%	16810,0	0,799
34	RGA30	6,10E-05	837,966	0,00002	100%	3950,0	0,192
35	RGA31	6,41E-05	837,966	0,00002	100%	173767,5	8,416
36	RGA32	6,09E-05	837,966	0,00002	100%	181877,5	11,512
37	RGA33	6,69E-05	837,966	0,00002	100%	181485,0	9,455
38	RGA34	6,74E-05	837,966	0,00002	100%	188692,5	10,599
39	RGA35	6,84E-05	837,966	0,00002	100%	193092,5	10,635
40	RGA36	5,38E-05	837,966	0,00002	100%	189175,0	10,491

Fonte: produção do próprio autor

G.2. PROBLEMAS MONO-OBJETIVO COM RESTRIÇÕES

A configuração de parâmetros do AG utilizada neste caso é a seguinte: codificação real; tamanho da população $N_{pop} = 10 \times n$, onde n é o número de variáveis do problema; operador de recombinação BLX- α com $\alpha = 0,5$; operador de mutação não-uniforme com $b = 5$; taxa de recombinação $p_r = 0,9$ e; taxa de mutação em $p_m = 0,2$. Para todos os problemas, executou-se o algoritmo de otimização 20 vezes com diferentes populações iniciais geradas aleatoriamente. Foram testadas as seguintes configurações de AG para o tratamento de restrições:

- CGA1: Método de Deb (2000) com mecanismo de nichos.
- CGA2: Método de Deb (2000) sem mecanismo de nichos.
- CGA3: Método de Coello Coello e Montes (2002a), com $S_r = 0,7$.
- CGA4: Método de Coello Coello e Montes (2002a), com $S_r = 0,8$.

Problema Teste 1

O seguinte problema foi proposto por (DEB, 2000) e trata-se de um problema de minimização bidimensional com duas restrições que reduzem a região de soluções factíveis a 7% do espaço de busca do problema sem restrições. Definido como:

$$\begin{aligned}
 &\text{Minimizar:} && f(\vec{x}) = (x_1^2 + x_2 - 11)^2 + (x_1 + x_2^2 - 7)^2 \\
 &\text{Sujeito a:} && g_1(\vec{x}) \equiv 4,4 - (x_1^2 - 0,05)^2 - (x_2 - 2,5)^2 \geq 0 \\
 &&& g_2(\vec{x}) \equiv x_1 + (x_2 - 2,5)^2 - 4,84 \geq 0 \\
 &&& 0 \leq x_{1,2} \leq 6
 \end{aligned} \tag{G.1}$$

Problema Teste 2

Este problema conta com 13 variáveis e 9 restrições de desigualdade (DEB, 2000). Trata-se de um problema relativamente simples de resolver dado que a função objetivo e as funções de restrição são lineares ou quadráticas. Quando resolvido como um problema de otimização inteira, a maioria dos métodos de otimização tradicionais não tem problemas em convergir para o ótimo global (MICHALEWICZ, 1995). O problema se define como:

$$\begin{aligned}
\text{Minimizar:} \quad & f(\vec{x}) = 5 \sum_{i=1}^4 x_i - 5 \sum_{i=1}^4 x_i^2 - \sum_{i=5}^{13} x_i \\
\text{Sujeito a:} \quad & g_1(\vec{x}) \equiv 2x_1 + 2x_2 + x_{10} + x_{11} \leq 10 \\
& g_2(\vec{x}) \equiv 2x_1 + 2x_3 + x_{10} + x_{12} \leq 10 \\
& g_3(\vec{x}) \equiv 2x_2 + 2x_3 + x_{11} + x_{12} \leq 10 \\
& g_4(\vec{x}) \equiv -8x_1 + x_{10} \leq 0 \\
& g_5(\vec{x}) \equiv -8x_2 + x_{11} \leq 0 \\
& g_6(\vec{x}) \equiv -8x_3 + x_{12} \leq 0 \\
& g_7(\vec{x}) \equiv -2x_4 - x_5 + x_{10} \leq 0 \\
& g_8(\vec{x}) \equiv -2x_6 - x_7 + x_{11} \leq 0 \\
& g_9(\vec{x}) \equiv -2x_8 - x_9 + x_{12} \leq 0 \\
& 0 \leq x_i \leq 1, \quad i = 1, \dots, 9 \\
& 0 \leq x_i \leq 100, \quad i = 10, 11, 12 \\
& 0 \leq x_{13} \leq 1
\end{aligned} \tag{G.2}$$

Problema Teste 3

Este é um problema de minimização de dimensão dois com uma restrição de igualdade (ABDEL-RAHMAN, 2015):

$$\begin{aligned}
\text{Minimizar:} \quad & f(x) = x_1^2 + (x_2 - 1)^2 \\
\text{Sujeito a:} \quad & h_1(x) = x_2 - x_1^2 = 0 \\
& -1 \leq x_i \leq 1, \quad i = 1, 2
\end{aligned} \tag{G.3}$$

As restrições de igualdade são transformadas em desigualdades como $\delta_t - |h_k(x)| \geq 0$ para todas as k restrições de igualdade. Foi adotado um valor de tolerância igual $\delta_t = 0,001$.

Problema Teste 4

Trata-se de um problema de projeto (CAGNINA; ESQUIVEL; COELLO COELLO, 2008; COELLO COELLO; MONTES, 2002b), no qual se procura minimizar o peso de uma mola que deve suportar uma carga axial, como mostra a Figura C.2. O problema deve satisfazer uma série de restrições como a mínima deflexão, a tensão de cisalhamento máxima, a frequência de surto, e limites no diâmetro externo e nas variáveis de decisão. As variáveis

de decisão do problema são o diâmetro médio das espirais (D), o diâmetro do fio (d), e o número de espiras ativas (N). O problema define-se como:

Minimiza: $f(\vec{x}) = (x_3 + 2)x_2x_1^2$

Sujeito a:


$$\begin{aligned} g_1(\vec{x}) &\equiv \frac{x_2^2x_3}{71785x_1^4} - 1 \geq 0 \\ g_2(\vec{x}) &\equiv 1 - \frac{4x_2^2 - x_1x_2}{12566(x_2x_1^3 - x_1^4)} - \frac{1}{5108x_1^2} \geq 0 \\ g_3(\vec{x}) &\equiv \frac{140,45x_1}{x_2^2x_3} - 1 \geq 0 \\ g_4(\vec{x}) &\equiv \frac{x_2 + x_1}{1,5} - 1 \geq 0 \end{aligned} \quad (G.4)$$

$$0,05 \leq x_1 \leq 2,0; 0,25 \leq x_2 \leq 1,3; 2,0 \leq x_3 \leq 15,0$$

sendo,

$$\vec{x} = [x_1, x_2, x_3]^T = [d, D, N]^T \quad (G.5)$$

Figura C.2. Mola sob tração/compressão.




Fonte: produção do próprio autor

Problema Teste 5

Este problema trata de viga soldada, sendo este problema já bem conhecido e estudado por vários autores (ABDEL-RAHMAN, 2015; CAGNINA; ESQUIVEL; COELLO COELLO, 2008; COELLO COELLO; MONTES, 2002b; DEB, 2000; REKLAITIS; RAVINDRAN; RAGSDELL, 1983). O sistema consiste numa viga A, a solda B e a carga que deve suportar P. As quatro variáveis de decisão são as dimensões mostradas na Figura G.1, $\vec{x} = [h, l, t, b]$.

Figura G.1. Problema da viga soldada.



Fonte: (ABDEL-RAHMAN, 2015)

O objetivo é minimizar o custo da solda, sujeito a uma série de restrições:

$$\begin{aligned}
 \text{Minimizar:} \quad & f(\vec{x}) = (1 - c_3) x_1^2 x_2 + c_4 x_3 x_4 (L + x_2) \\
 \text{Sujeito a:} \quad & g_1(\vec{x}) \equiv \tau_{\max} - \tau(\vec{x}) \geq 0 \\
 & g_2(\vec{x}) \equiv \sigma_{\max} - \sigma(\vec{x}) \geq 0 \\
 & g_3(\vec{x}) \equiv x_4 - x_1 \geq 0 \\
 & g_4(\vec{x}) \equiv P_c - P \geq 0 \\
 & g_5(\vec{x}) \equiv \delta_{\max} - \delta(\vec{x}) \geq 0
 \end{aligned} \tag{G.6}$$

$$0,125 \leq x_1 \leq 10; 0,1 \leq x_{2,3,4} \leq 10$$

sendo,

$$\vec{x} = [x_1, x_2, x_3, x_4]^T = [h, l, t, b]^T \tag{G.7}$$

sendo,

- $\tau(\vec{x})$: tensão de cisalhamento da solda, função de $\vec{x}$.
- $\tau_{\max}$: tensão de cisalhamento máxima (admissível) da solda.
- $\sigma(\vec{x})$: tensão normal na viga, função de $\vec{x}$.
- $\sigma_{\max}$: tensão normal máxima (admissível) na viga.
- P_c : carga de flambagem da viga, função de $\vec{x}$.

P	: carga aplicada à viga.
$\delta(\bar{x})$	: deflexão da viga, função de $\bar{x}$.
δ_{max}	: deflexão máxima (admissível) da viga.
E	: módulo de Yong.
G	: módulo de cisalhamento.

Comparação de Resultados

Da Tabela G.5 a Tabela G.9 apresentam-se os resultado da aplicação dos algoritmos de tratamento de restrições incluídos na *GAtoolbox* para os cinco problemas expostos anteriormente. Cada tabela apresenta a melhor solução encontrada pelos algoritmos após as vinte execuções e o tempo médio de simulação do algoritmo, *avgTime*, até atingir o número máximo de gerações. Além disso, são apresentados os resultados reportados pela literatura para efeitos de comparação.

Como pode ser observado nas Tabela G.5 a Tabela G.9 as quatro configurações de AG utilizadas para tratamento de restrições (CG1, CG2, CG3, CG4) tiveram sucesso em encontrar a solução ótima nos cinco problemas estudados. Ainda, no problema teste 5, a melhor solução encontrada pela *GAtoolbox* resultou melhor que os resultados reportados na literatura. O custo da solda resultou em 1,577940 no presente trabalho, enquanto que o mínimo valor reportado por Coello Coello e Montes (2002a) é de 1,728226.

Com relação ao método de tratamento de restrições proposto por (DEB, 2000) pode-se observar que não há diferença significativa entre as configurações CGA1 (com *niching*) e CGA2 (sem *niching*) em termos de qualidade do melhor resultado. Ainda, o tempo médio para o algoritmo atingir o critério de parada resultou muito maior para a configuração CGA1 do que qualquer das outras configurações testadas. Isto significa que a inclusão do método de *niching* para manter a diversidade de soluções não melhora os resultados e torna o algoritmo mais lento, pelo menos em relação aos problemas testados no presente estudo.

O método para manter a diversidade das soluções proposto por Coello Coello e Montes (2002a) é mais simples, no entanto demonstrou ter um bom desempenho sem aumentar o custo computacional do algoritmo. Em termos de qualidade das soluções e tempo de processamento, o uso $S_r = 0,7$ ou $S_r = 0,8$ não apresentou diferença significativa.

Tabela G.5. Comparação de resultados para o problema teste 1.

	Melhor solução encontrada			
	$f^*(\bar{x})$	x_1^*	x_2^*	$avgTime$ [s]
CGA1	13,590842	2,246826	2,381861	54,987 (+13,3%)
CGA2	13,590842	2,246826	2,381865	48,538
CGA3	13,590842	2,246826	2,381860	50,688 (+4,4%)
CGA4	13,590842	2,246826	2,381862	50,946 (+4,9%)
(DEB, 2000)	13,590850	2,246826	2,381865	--

Fonte: produção do próprio autor

Tabela G.6. Comparação de resultados para o problema teste 2.

	Melhor solução encontrada			
	$f^*(\bar{x})$	$x_{1,2,4,5,6,7,8,9,13}^*$	$x_{10,11,12}^*$	$avgTime$ [s]
CGA1	-15	1	3	9,839 (+17,8%)
CGA2	-15	1	3	8,395 (+0,04%)
CGA3	-15	1	3	8,401 (+0,05%)
CGA4	-15	1	3	8,358
(DEB, 2000)	-15	1	3	--
(MICHALEWICZ, 1995)	-15	1	3	--

Fonte: produção do próprio autor

Tabela G.7. Comparação de resultados para o problema teste 3.

	Melhor solução encontrada			
	$f^*(\bar{x})$	x_1^*	x_2^*	$avgTime$ [s]
CGA1	0,749000	0,706391	0,499989	36,616 (+17,4%)
CGA2	0,749017	0,703433	0,495818	33,402 (+7,1%)
CGA3	0,749000	-0,706042	0,499495	33,097 (+6,1%)
CGA4	0,749001	-0,705735	0,499062	31,200
(ABDEL-RAHMAN, 2015)	0,75	$\sqrt{0,5} = 0,707107$	0,5	--

Fonte: produção do próprio autor

Tabela G.8. Comparação de resultados para o problema teste 4 (mola tensão/compressão).

	Melhor solução encontrada				
	$f^*(\bar{x})$	x_1^*	x_2^*	x_3^*	$avgTime$ [s]
CGA1	0,012693	0,052942	0,387625	9,68306	82,012 (+278,1%)
CGA2	0,012665	0,051664	0,356108	11,3248	29,492
CGA3	0,012719	0,050000	0,317425	14,0278	30,195 (+2,4%)
CGA4	0,012665	0,051709	0,357200	11,2608	32,458 (+10,1%)
(COELLO COELLO; MONTES, 2002a);	0,012681	0,051989	0,363965	10,8905	--
(CAGNINA; ESQUIVEL; COELLO COELLO, 2008)	0,012681	0,051689	0,356750	11,2871	--

Fonte: produção do próprio autor

Tabela G.9. Comparação de resultados para o problema teste 5 (viga soldada).

	Melhor solução encontrada					<i>avgTime</i> [s]
	$f^*(\vec{x})$	x_1^*	x_2^*	x_3^*	x_4^*	
CGA1	1,57796	0,22473	7,23556	3,82316	0,30064	85,636 (+46,0%)
CGA2	1,57787	0,23159	7,01636	3,82316	0,30064	68,900 (+17,9%)
CGA3	1,57794	0,23139	7,02171	3,82398	0,30062	59,153 (+1,2%)
CGA4	1,57788	0,22776	7,13756	3,82316	0,30064	58,456
(COELLO COELLO; MONTES, 2002a);	1,72823	0,20599	3,47133	9,02022	0,20648	--
(CAGNINA; ESQUIVEL; COELLO COELLO, 2008)	1,72485	0,20573	3,47049	9,03662	0,20573	--
(REKLAITIS; RAVINDRAN; RAGSDELL, 1983)	2,38116	0,24440	6,21870	8,29150	0,24440	--
(DEB, 2000)	2,43000	0,24890	6,17300	8,17890	0,25330	--

Fonte: produção do próprio autor

G.3. PROBLEMAS MULTIOBJETIVO COM RESTRIÇÕES

O NSGA-II implementado na *GAtoolbox* foi utilizado para resolver o seguintes problemas teste:

Problema Teste 1: SCH

Esse problema foi proposto por (SCHAFFER, 1985) e trata-se de um problema sem restrições de dimensão $n=1$ e com dois objetivos a serem minimizados. O espaço de busca é convexo, portanto, é relativamente simples de se resolver. Define-se segundo equação (G.8):

$$\begin{aligned} \text{Minimizar:} \quad & f_1(x) = x^2 \\ & f_2(x) = (x-2)^2 \end{aligned} \quad (\text{G.8})$$

$$\text{Sujeito a:} \quad -10^3 \leq x \leq 10^3$$

Problema Teste 2: KUR

O problema foi estudado por Kursawe¹⁴ (*apud* (DEB et al., 2002)) e trata-se de um problema de minimização biobjetivo, sem restrições e de dimensão $n=3$. A fronteira de soluções ótimas de Pareto no espaço de busca é descontínua, o qual representa uma dificuldade para os métodos clássicos de otimização multiobjetivo. Define-se segundo equação (G.9):

¹⁴ F. Kursawe, "A variant of evolution strategies for vector optimization," in *Parallel Problem Solving from Nature*, H.-P. Schwefel and R. Männer, Eds. Berlin, Germany: Springer-Verlag, 1990, pp. 193–197 *apud* (DEB et al., 2002).

$$\begin{aligned}
\text{Minimizar:} \quad & f_1(\vec{x}) = \sum_{i=1}^2 \left[-10 \exp \left(-0,2 \sqrt{x_i^2 + x_{i+1}^2} \right) \right] \\
& f_2(\vec{x}) = \sum_{i=1}^2 \left[|x_i|^{0,8} + 5 \sin x_i^3 \right]
\end{aligned} \tag{G.9}$$

$$\text{Sujeito a:} \quad -5 \leq x_i \leq 5 \quad , \quad i = 1, 2, 3$$

Problema Teste 3: CONSTR

Neste problema (DEB et al., 2002) uma parte do espaço de soluções ótimas de Pareto não é viável devido às restrições inseridas. O problema é de dimensão $n = 2$ e define-se segundo equação (G.10):

$$\begin{aligned}
\text{Minimizar:} \quad & f_1(\vec{x}) = x_1 \\
& f_2(\vec{x}) = (1 + x_2) / x_1 \\
\text{Sujeito a:} \quad & g_1(\vec{x}) \equiv x_2 + 9x_1 \geq 6 \\
& g_2(\vec{x}) \equiv -x_2 + 9x_1 \geq 1 \\
& 0,1 \leq x_1 \leq 1 \\
& 0 \leq x_2 \leq 5
\end{aligned} \tag{G.10}$$

Problema Teste 4: TNK

Esse problema de dimensão $n = 2$ foi proposto por Tanaka¹⁵ *apud* (DEB et al., 2002) e consiste em dois objetivos simples a serem minimizados, porém tem duas restrições complexas que fazem com que a região de soluções ótimas de Pareto seja descontínua. Define-se segundo equação (G.11):

$$\begin{aligned}
\text{Minimizar:} \quad & f_1(\vec{x}) = x_1 \\
& f_2(\vec{x}) = x_2 \\
\text{Sujeito a:} \quad & g_1(\vec{x}) \equiv -x_1^2 - x_2^2 + 1 + 0,1 \cos(16 \arctan(x_1/x_2)) \leq 0 \\
& g_2(\vec{x}) \equiv (x_1 - 0,5)^2 + (x_2 - 0,5)^2 \leq 0,5 \\
& 0 \leq x_i \leq \pi \quad , \quad i = 1, 2
\end{aligned} \tag{G.11}$$

Problema Teste 5: DTLZ2

Deb et al. (2005) propõem uma série de problemas escaláveis para testar diferentes algoritmos evolutivos de otimização multiobjetivo. Neste caso foi implementado o “problema

¹⁵ M. Tanaka, “GA-based decision support system for multicriteria optimization,” in Proc. IEEE Int. Conf. Systems, Man and Cybernetics-2, 1995, pp. 1556–1561 *apud* (DEB et al., 2002).

de teste DTLZ2” com a seguinte configuração, $M = 3$ (três funções objetivo) e $n = 12$ (dimensão 12). As soluções ótimas de Pareto são $x_i = 0,5$ para $i \in [M, n]$, sendo que todas as funções objetivo devem satisfazer $\sum_{i=1}^M f_i^2 = 1$. Define-se segundo equação (G.12):

$$\begin{aligned} \text{Minimizar:} \quad & f_1(\vec{x}) = (1 + g(\vec{x}_M)) \cos(x_1 \pi/2) \cos(x_2 \pi/2) \\ & f_2(\vec{x}) = (1 + g(\vec{x}_M)) \cos(x_1 \pi/2) \sin(x_2 \pi/2) \\ & f_3(\vec{x}) = (1 + g(\vec{x}_M)) \sin(x_1 \pi/2) \end{aligned} \quad (\text{G.12})$$

$$\text{Sujeito a:} \quad 0 \leq x_i \leq 1, \quad i = 1, 2, \dots, 12$$

$$\text{onde:} \quad g(\vec{x}_M) = \sum_{x_i \in x_M} (x_i - 0,5)^2$$

Comparação de Resultados

Todos os problemas foram resolvidos com um tamanho de população igual a $N_{pop} = 100$. Foi utilizada a configuração de AG com codificação real das variáveis, operador de recombinação BLX- α (ESHELMAN; SCHAFFER, 1993) com $\alpha = 0,5$, e operador de mutação não-uniforme (MICHALEWICZ, 1996) com $b = 5$. A taxa de recombinação é igual a $p_r = 0,9$ e a taxa de mutação é igual a $p_m = 1/n$. O critério de parada é o máximo número de gerações, $maxGen = 200$.

A Figura G.2(a) mostra a primeira geração para o problema teste 1-SCH e a Figura G.2(b) mostra a evolução das soluções na geração 50. Observa-se como os indivíduos começam a se posicionar na fronteira de Pareto. A fronteira de soluções ótimas de Pareto situa-se na parte inferior esquerda do gráfico, o qual é típico para problemas biobjetivo nos quais ambos objetivos são minimizados. Na Figura G.2(c) apresenta-se a geração 100 para o problema teste 1-SCH. Observa-se como as soluções se encontram uniformemente distribuídas entre as soluções extremas da fronteira de Pareto, resulta desejado para problemas multiobjetivo. Finalmente, na geração 200, mostrada na Figura G.2(d), todos os indivíduos encontram-se situados sobre a fronteira de Pareto e dentro do intervalo conhecido como a melhor solução, *i.e.* $x_i \in [0, 2]$, segundo reportado por (DEB et al., 2002).

Os resultados da simulação para o problema de teste 2-KUR são apresentados na Figura G.3. Dado que o método de geração da primeira população é aleatório, os indivíduos estão uniformemente distribuídos no espaço de busca, como se mostra na Figura G.3(a). Observa-se que a fronteira de soluções ótimas de Pareto na Figura G.3(b) é formada por três regiões desconectadas. Problemas dessa característica são especialmente difíceis de serem


resolvidos com métodos clássicos de otimização multiobjetivo. Contudo o NSGA-II mostrou uma boa performance, sendo que a partir da geração 50 as três regiões já se encontravam bem definidas.

A Figura G.4 mostra o resultado da simulação para o problema teste 3-CONSTR. Neste problema a fronteira de Pareto resulta a dividida em duas partes, devido às restrições impostas. Na Parte 1, mostrada na Figura G.4(b), as soluções não dominadas situam-se sobre a fronteira definida pela primeira restrição, e na Parte 2 as soluções situam-se sobre parte da fronteira de Pareto do problema sem restrições. A segunda restrição limita os valores a $f(x_2) \leq 9$.

Os resultados para o problema teste 4-TNK mostram-se na Figura G.5. Observa-se na Figura G.5(b) que a fronteira de soluções ótimas de Pareto é descontínua, sendo que as soluções situam-se completamente sobre a fronteira definida pela primeira restrição $g_1(\bar{x})$ (equação (G.11)). O algoritmo NSGA-II não teve problemas em encontrar um conjunto diverso de soluções sobre a verdadeira fronteira de Pareto, demonstrando a capacidade do método de tratamento de restrições incorporado no algoritmo.


Finalmente os resultados das simulações para o problema tri-objetivo, problema teste 5-DTLZ2, expõem-se na Figura G.6. Esse problema foi proposto por Deb et al. (2005) para testar diferentes algoritmos de otimização multiobjetivo. As soluções não dominadas situam-se na fronteira definida por uma esfera centrada na origem (0,0,0) e raio (1,1,1).

Figura G.2. Resultados da otimização utilizando NSGA-II no problema teste 1-SCH, geração 1 de 200 (a) e 50 de 200 (b), 100 de 200 (c) e 200 de 200 (d).




Fonte: produção do próprio autor

Figura G.3. Resultados da otimização utilizando NSGA-II no problema teste 2-KUR, primeira geração (a) e última geração (b).




Fonte: produção do próprio autor

Figura G.4. Resultados da otimização utilizando NSGA-II no problema teste 3, primeira geração (a) e última geração (b).




Fonte: produção do próprio autor

Figura G.5. Resultados da otimização utilizando NSGA-II no problema teste 4-TNK, primeira geração (a) e última geração (b).



Fonte: produção do próprio autor


Figura G.6. Resultados da otimização utilizando NSGA-II no problema teste 5-DTLZ2, primeira geração (a) e última geração (b).



Fonte: produção do próprio autor

APÊNDICE H – CASOS DE ESTUDO

Figura H.1. Localização dos sistemas híbridos da Vila Campinas e da Vila São Tomé adotados como casos de estudo.



Fonte: produção do próprio autor com base no mapa obtido de (IMAZON, 2016)

Caso (A) - Sistema Híbrido da Vila Campinas

Em 1987 foi instalada na Vila Campinas uma usina termelétrica, sistema geração à diesel, com capacidade de 96 kW (2 moto geradores de 48 kW) para fornecer energia elétrica a 72 unidades consumidoras no período das 18:00 às 24:00 h. O sistema administrado pela Companhia Energética do Amazonas (CEAM) operava com combustível subsidiado pela Conta de Consumo de Combustível (CCC).

A disponibilidade de recurso solar na região em níveis satisfatórios para geração de energia elétrica motivou a transformação do sistema térmico num sistema híbrido fotovoltaico-diesel. Em 1994 o projeto de sistema híbrido da Vila Campinas foi concebido em parceria com o Departamento de Energia dos Estados Unidos (DOE) quem doou os principais componentes do sistema; o suporte e seguimento foram feitos através do Laboratório de Fontes Renováveis (*National Renewable Energy Laboratory* - NREL) e o Centro de Pesquisas de Energia Elétrica (CEPEL) (PINHO, 2008).

A usina termelétrica de Campinas foi adaptada ao sistema solar, aproveitando a rede de transmissão elétrica e os geradores a diesel existentes. Adicionaram-se 51,2 kWp de potência solar para suprir aproximadamente 120 unidades consumidoras e permitindo um aumento do período de fornecimento de energia das 6:00 às 24:00 h (CARTAXO FERREIRA, 2000).

As principais características do sistema existente na Vila de Campinas se mostram na Tabela H.1.

Fontes de informação de dados meteorológicos na região da Vila Campinas

Na Tabela H.2 se mostram as fontes de informação utilizadas para o caso da Vila Campinas e o método de tratamento dos dados para levá-los ao formato requerido para simulação. Na Figura H.2 se expõem os gráficos das médias mensais para as variáveis velocidade do vento, radiação solar incidente e temperatura ambiente para a região de Vila Campinas.

Caraterísticas da carga da Vila Campinas

O tipo de carga a ser atendida na Vila de Campinas é tipicamente um perfil de consumo de comunidade rural isolada. O setor residencial representa cerca do 75,8% do consumo total da Vila (CARTAXO FERREIRA, 2000). Sendo que os eletrodomésticos relacionados com o conforto, conservação de alimentos (refrigeração) e lazer representam a maior carga do sistema.

Tabela H.1. Características gerais do sistema híbrido da Vila de Campinas.

Tecnologia	Energia solar fotovoltaica, controlador de carga, inversor estático, banco de baterias e grupo gerador a diesel.	
UCs atendidas	120	
Fornecimento	16 h/dia (6:00 às 24:00)	
Gerador diesel	Fabricante	STEMAC S.A.
	Potência unitária	48 kW / 53 kVA
	Potência instalada	96 kW
	Rendimento	39%
	Fator de potência	0,9
	Vida útil	30.000 h
	Consumo médio específico de diesel	0,281 L/kWh
	Consumo de óleo	5,68 L/h de operação
	Poder calorífico inferior (PCI)	10.750 kcal/kg
	Custo do grupo gerador (inclui imposto e frete)	US\$ 30.520,00 (677,5 US\$/kW)
	Custo de manutenção/ano	2% do investimento inicial
Sistema fotovoltaico	Custo do óleo (para CEAM maio/1999)	0,2535 US\$/L
	Modelo/Fabricante	MSX/ SOLAREX
	Potência unitária	64 Wp
	Potência instalada	51,2 kWp (arranjo de 800 painéis)
	Custo dos painéis	US\$ 302.400,00 (5,9 US\$/Wp)
Banco de baterias	Custo de manutenção/ano	0,0
	Fabricante	HOPPECKE
	Tecnologia	Chumbo-ácido
	Capacidade unitária	200 Ah
	Tensão	12 Vcc
	Quantidade de baterias	120
	Capacidade do banco	288 kWh (200Ahx12Vx120)
	Disposição	série /paralelo 240 Vcc
	Rendimento	95%
	Profundidade de descarga máxima	60%
	Vida útil segundo fabricante	7 anos
Inversor	Custo do Banco de Baterias	US\$ 75.000,00 (260,42 US\$/kWh)
	Potência nominal	50 kW
	Tensão de operação	240 Vcc / 220 Vca
	Rendimento segundo o fabricante	90%
Controlador de carga	Custo do Inversor	US\$ 64.800,00 (1292 US\$/kW)
	Custo do controlador	US\$ 16.200,00
Custos fixos do sistema	Despesas com salários e encargos sociais	2% do investimento inicial
Estratégia de operação	Durante o dia o subsistema de geração fotovoltaica alimenta diretamente a carga da vila, passando a energia CC pelo inversor de tensão. Quando a geração de energia do arranjo fotovoltaico for superior à carga, este passa a carregar também o banco de baterias. À noite, ou durante um dia nublado ou chuvoso, o banco de baterias alimenta a vila até que chegue a descarregar 60% de sua capacidade, quando então é acionado o grupo gerador a diesel (a outra unidade diesel do sistema é de backup), o qual opera até que a geração renovável se estabilize.	

Fonte: (CARTAXO FERREIRA, 2000; OLIVEIRA BARBOSA, 2006)

Tabela H.2. Fontes de dados meteorológicos, sistema Vila Campinas.

Variável	Referência	Localização	Resolução	Tratamento
Temperatura	(INMET, 2016)	Estação meteorológica de Manicoré, distância 68,5 km	3 dados por dia	Usam-se os 3 dados diários replicados vezes 8
Radiação solar	(CRESESB, 2016a)	Estação meteorológica de Manicoré, distância 68,5 km	Mensal	Geração de série horária sintética, método de (GRAHAM; HOLLANDS, 1990)
Velocidade do Vento e parâmetros de Weibull	(CRESESB, 2016b)	Busca por coordenadas	Trimestral (50 m de altura)	Geração de série horária sintética com o método do HOMER® (HOMER ENERGY LLC. BOULDER COLORADO, 2010a).

Fonte: elaborado pelo autor.

Caso (B) - Sistema de Geração de Energia da Vila São Tomé

Na Vila de São Tomé a eletricidade é fornecida através de um sistema híbrido fotovoltaico-eólico-diesel, que foi financiado pela PETROBRÁS e a Financiadora de Estudos e Projetos (FINEP). O sistema foi implantado em setembro de 2003, com a finalidade de abastecer as 67 unidades consumidoras da vila (residências, escola, comércio, igrejas, etc.) (OLIVEIRA BARBOSA, 2006). As principais características do sistema existente na Vila São Tomé são mostradas na Tabela H.3.

Fontes de informação de dados meteorológicos na região da Vila São Tomé

Na Tabela H.4 se mostram as fontes de informação utilizadas para o caso da Vila São Tomé e o método de tratamento dos dados para levá-los ao formato requerido para simulação.

Caraterísticas da carga da Vila São Tomé

O perfil de carga da Vila São Tomé também se enquadra dentro o comportamento típico de consumidor rural isolado. Nesta comunidade, o 76,16% da carga é tipicamente residencial (eletrodomésticos relacionados com o conforto, lazer e refrigeração), o 14,95% corresponde a iluminação e o restante 8,89% se corresponde com pequenos motores elétricos utilizados na atividade comercial desenvolvida na vila (OLIVEIRA BARBOSA, 2006). A participação de outro tipo de carga de iluminação pública ou iluminação de espaços comunitários (igrejas, escolas, creches, etc.) é pouco expressiva.

Tabela H.3. Características gerais do sistema híbrido de Vila São Tomé.

Tecnologia	Energia eólica com aerogerador importado, energia solar fotovoltaica, controlador de carga, inversor estático, banco de baterias e grupo gerador a diesel.	
Fornecimento	24 h/dia	
UCs atendidas	67	
Gerador diesel	Potência	16 kW / 20 kVA
	Custo unitário grupo gerador	5535,47 US\$ ¹⁶ (345,97 US\$/kW)
	Custo de manutenção/ano	0,10 US\$/kWh
	Custo do óleo	2 R\$/L (0,93 US\$/L)
Sistema fotovoltaico	Potência unitária	80 Wp
	Potência instalada	3,2 kWp (arranjo de 40 painéis)
	Custo dos painéis	16.891,05 US\$ (5,28 US\$/Wp)
	Custo de manutenção/ano	1% do custo de aquisição
Banco de baterias	Tecnologia	Chumbo-ácido
	Capacidade unitária	150 Ah
	Tensão	12 Vcc
	Quantidade de baterias	40
	Capacidade do banco	72 kWh (150Ahx12Vx40)
	Disposição	série /paralelo 120 Vcc
Inversor	Custo do Banco de Baterias	4.877,14 US\$ (677,4 US\$/kWh)
	Potência nominal	15 kW
	Tensão de operação	120 Vcc / 220 Vca
	Custo do Inversor	15.143,61 US\$ (1009,51 US\$/kW)
Controlador de carga	Custo do controlador	4.050,00 US\$
Aerogerador	Fabricante	Bergey
	Potência nominal	7,5 kW
	Altura de torre	30 metros
	Custo do aerogerador	24.513,7 US\$ (3.268,5 US\$/kW)
	Custo de manutenção/ano	2% do custo de aquisição
Outros custos iniciais	Materiais elétricos e construção	8.044,7 US\$
	Serviços	40.802,8 US\$
	Acessórios	9.055,9 US\$
Custos fixos do sistema	Despesas com salários e encargos sociais	1% do investimento inicial
Estratégia de operação	De acordo com as condições do banco de baterias, o sistema renovável supre a carga. Se a geração renovável não for suficiente para atender à demanda solicitada, este sistema é desconectado e o grupo gerador a diesel é então acionado para suprir as necessidades da comunidade. Ressalta-se que a operação do sistema não é feita de forma automática.	

Fonte: (OLIVEIRA BARBOSA et al., 2004; OLIVEIRA BARBOSA, 2006)


¹⁶ Considerando a cotação do dólar do dia 10/04/2006 – R\$ 2,157.

Tabela H.4. Fontes de dados meteorológicos, sistema Vila São Tomé.

Variável	Referência	Localização	Resolução	Tratamento
Temperatura	(NREL, 2016)	Estação meteorológica de Belém, distância 171,6 km	Horários, ano meteorológico típico (TMY)	Usam-se os dados horários para simulação.
Radiação solar	(NREL, 2016)	Estação meteorológica de Belém, distância 171,6 km	Horários, ano meteorológico típico (TMY)	Usam-se os dados horários para simulação.
Velocidade do Vento e parâmetros de Weibull	(CRESESB, 2016b)	Busca por coordenadas	Trimestral (50 m de altura)	Geração de série horária sintética com o método do HOMER® (HOMER ENERGY LLC. BOULDER COLORADO, 2010a).


Fonte: elaborado pelo autor.

Figura H.2. Variação sazonal dos recursos renováveis na região de Vila Campinas, (a) velocidade média do vento a 50 m, (b) radiação solar incidente no plano do painel, (c) temperatura ambiente.



Fonte: produção do próprio autor

Figura H.3. Variação sazonal dos recursos renováveis na região de Vila São Tomé, (a) velocidade média do vento a 50 m, (b) radiação solar incidente no plano do painel, (c) temperatura ambiente.



Fonte: produção do próprio autor

APÊNDICE I – CARACTERÍSTICAS TÉCNICAS E ECONÔMICAS DOS COMPONENTES UTILIZADOS NAS SIMULAÇÕES DO SHGE

Todos os preços estão baseados na cotação do dólar no dia 25/03/2016, de 3,681 R\$/US\$.

Tabela I.1. Especificações técnicas do combustível óleo diesel utilizado nas simulações.

Descrição	Símbolo	Unidade	
Tipo de combustível	--	--	Óleo diesel
Poder calorífico inferior	$fuel_{LHV}$	MJ/kg	43,2
Peso específico	$fuel_{dens}$	kg/m ³	820
Emissões indiretas (fabricação e transporte)	$ief_{CO_2, fuel}$	kgCO ₂ -eq/L	0,53
Custo do combustível, Caso (A) – Vila Campinas ⁽¹⁾	$C_{fuel, dg}$	US\$/L	0,734
Custo do combustível, Caso (B) – Vila São Tomé ⁽²⁾	$C_{fuel, dg}$	US\$/L	0,927

⁽¹⁾ O preço do óleo diesel cobrado à concessionária de Campinas incluindo o subsídio do CCC é de 2,57 R\$/L em 07/05/2016 (ELETROBRÁS – CENTRAIS ELÉTRICAS BRASILEIRAS S.A., 2016)

⁽²⁾ O preço do óleo diesel de acordo com Oliveira Barbosa; Pinho (2008) é de 2 R\$/L considerando a cotação do dólar em 2008 de 2,157 R\$/US\$.

Fonte: produção do próprio autor

Tabela I.2. Especificações técnicas e econômicas dos modelos de módulo PV utilizados nas simulações.


Descrição	Símbolo	Unidade	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
Fabricante	--	--	Solarex	Solarex	Solarex	Solarex	Solarex
Modelo	--	--	SX40	SX64	MSX80	MSX110	MSX120
Potência nominal	--	kWp	0,04	0,064	0,08	0,11	0,12
Fator de redução de potência	f_{pv}	%	0,842	0,842	0,842	0,842	0,842
Coefficiente de temperatura de potência	α_p	%/°C	-0,005	-0,005	-0,005	-0,005	-0,005
Temperatura de operação nominal da célula (NOCT) $T_{c,NOCT}$		°C	47	49	47	47	47
Eficiência no ponto MPP em condições STC	$\eta_{mp,STC}$	%	0,118	0,126	0,120	0,1075	0,108
Radiação solar em condições STC	$I_{H,STC}$	kW/m ²	1	1	1	1	1
Temperatura da célula em condições STC	$T_{c,STC}$	°C	25	25	25	25	25
Radiação solar na qual NOCT é definida	$I_{T,NOCT}$	kW/m ²	0,800	0,800	0,800	0,800	0,800
Temperatura ambiente na qual NOCT é definida	$T_{a,NOCT}$	°C	20	20	20	20	20
Área do módulo	A_{pv}	m ²	0,340	0,506	0,664	0,986	0,986
Corrente no ponto MPP	I_{mpp}	A	2,37	3,66	4,75	3,34	3,56
Tensão no ponto MPP	V_{mpp}	V	16,8	17,5	16,8	32,9	33,7
Emissões indiretas	$ief_{CO_2,pv}$	kgCO ₂ -eq/kWh	0,059	0,059	0,059	0,059	0,059
Tempo de vida do módulo PV	LT_{pv}	ano	25	25	25	25	25
Investimento inicial do módulo PV ⁽¹⁾	$C_{icap,pv}$	US\$	105,06	114,611	174,925	212,431	224,011
Custo de reposição do módulo PV ⁽²⁾	$C_{rep,pv}$	US\$	78,79	85,96	131,19	159,32	168,01
Custo de O&M do módulo PV ⁽³⁾	$C_{o\&m,pv}$	US\$/ano	1,05	1,15	1,75	2,12	2,24

⁽¹⁾Custos no mercado nacional brasileiro mais frete; ⁽²⁾O custo de reposição resulta menor que o custo inicial dado que se considera o aproveitamento da estrutura de suporte; ⁽³⁾1% do investimento inicial.

Fonte: produção do próprio autor

Tabela I.3. Especificações técnicas e econômicas dos modelos de aerogerador utilizados nas simulações.

Descrição	Símbolo	Unidade	Modelo 1	Modelo 2	Modelo 3	Modelo 4
Fabricante	--	--	BWC XL	Bornay	H2System	BWC Excel-S
Modelo	--	--	XL 1kW	Bornay 6kW	H2S7	XLS 10kW
Potência nominal	$P_{wt,r}$	kW	1	6	7	10
Altura da torre	z_{rot}	m	20	20	17,5	20
Emissões indiretas	$ief_{CO2,wt}$	kgCO ₂ -eq/kWh	0,02	0,02	0,02	0,02
Tempo de vida do aerogerador	LT_{wt}	ano	20	20	20	20
Investimento inicial do aerogerador ⁽¹⁾	$C_{icap,wt}$	US\$	14906,77	31782,27	33514,58	43343,74
Custo de reposição do aerogerador ⁽²⁾	$C_{rep,wt}$	US\$	4877,97	21753,47	24739,38	33314,94
Custo de O&M do aerogerador ⁽³⁾	$C_{o\&m,wt}$	US\$/ano	298,14	635,65	670,29	866,87



⁽¹⁾Custos no mercado nacional brasileiro mais frete; ⁽²⁾O custo de reposição resulta menor que o custo inicial dado que se considera o aproveitamento da torre; ⁽³⁾ 2% do investimento inicial.

Fonte: produção do próprio autor

Tabela I.4. Especificações técnicas e econômicas dos modelos de grupo moto gerador utilizados nas simulações.

Descrição	Símbolo	Unidade	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6
Fabricante	--	--	Hyundai	Hyundai	Hyundai	Lister	Hyundai	STAMEC
Modelo	--	--	HHY73000E	DHY4000LE	DHY8000SE	Lister 12	--	STAMEC 48
Potência nominal	P_{gdr}	kW	2,8	4	7	10	16	48
Ordenada na origem da curva de consumo do gerador	F_0	L/h/kW _{nominal}	0,084	0,084	0,084	0,084	0,084	0,084
Inclinação da curva de consumo do gerador	F_0	L/h/kW	0,246	0,246	0,246	0,246	0,246	0,246
Carregamento mínimo respeito da potência nominal	--	%	0,300	0,300	0,300	0,300	0,300	0,300
Potência mínima de operação	P_{dg_min}	kW	0,840	1,200	2,100	3,000	4,800	14,400
Tipo de combustível	--	--	óleo diesel	óleo diesel	óleo diesel	óleo diesel	óleo diesel	óleo diesel
Tempo de vida do grupo moto gerador (em horas)	$LT_{dg,h}$	h	10000	10000	10000	10000	10000	10000
Emissões diretas CO ₂	$ef_{CO_2,dg}$	g/L	2634,960	2634,960	2634,960	2634,960	2634,960	2634,960
Emissões diretas SO ₂	$ef_{SO_2,dg}$	g/L	5,270	5,270	5,270	5,270	5,270	5,270
Emissões diretas CO	$ef_{CO,dg}$	g/L	1,680	1,680	1,680	1,680	1,680	1,680
Emissões diretas NO _x	$ef_{NO_x,dg}$	g/L	38,180	38,180	38,180	38,180	38,180	38,180
Emissões indiretas (fabricação, transporte, instalação)	$ief_{CO_2,dg}$	kgCO _{2-eq} /kWh	454,293	454,293	454,293	454,293	454,293	454,293
Investimento inicial do grupo moto gerador ⁽¹⁾	$C_{icap,dg}$	US\$	1087,66	1421,75	2481,02	3859,56	6160,62	18379,42
Custo de reposição do grupo moto gerador	$C_{rep,dg}$	US\$	1087,66	1421,75	2481,02	3859,56	6160,62	18379,42
Custo de O&M do grupo moto gerador ⁽²⁾	$C_{o\&m,dg}$	US\$/h	0,25	0,25	0,25	0,25	0,25	0,25

⁽¹⁾Custos no mercado nacional Brasileiro mais frete; ⁽²⁾Assume-se que o custo de O&M do moto gerador é independente da potência gerada (HOMER ENERGY LLC. BOULDER COLORADO, 2010b).

Fonte: produção do próprio autor

Tabela I.5. Especificações técnicas e econômicas dos modelos de bateria utilizados nas simulações.

Descrição	Símbolo	Unidade	Modelo 1	Modelo 2	Modelo 3	Modelo 4
Fabricante	--	--	Trojan	Vision	Hoppecke	Hoppecke
Modelo	--	--	T-105	6FM200D	24 OPzS 3000	10 OPzS 1000
Capacidade nominal	C_{bt_nom}	Ah	225	200	3000	1000
Tensão nominal	V_{bt}	V	6	12	2	2
Eficiência de ciclo completo de carga/descarga	η_{bt_global}	%	85	0,80	0,86	0,86
Profundidade máxima de descarga	DOD_{max}	%	70	0,6	0,7	0,7
Mínimo estado de carregamento	SOC_{min}	%	30	0,4	0,3	0,3
Vida fluante	LT_{bt_float}	ano	10	10	20	20
Taxa de carga máxima	$BT_{max_ch_rate}$	A/Ah	1	1	1	1
Corrente de carregamento máxima	$I_{bt_max_ch}$	A	11	60	610	202
Energia total ciclada no tempo de vida	$Q_{bt_life_thr}$	kWh	845	917	10196	3438
Máxima capacidade da bateria (calculada)	$C_{bt_max_cap}$	Ah	226	198	3565	1192
Razão de capacidade	c	--	0,258	0,197	0,316	0,338
Taxa de condutância	k	1/h	2,24	5,82	1,24	1,07
Emissões indiretas	$ief_{CO2,bt}$	kgCO ₂ -eq/kWh	59,42	59,42	59,42	59,42
Investimento inicial da bateria ⁽¹⁾	$C_{icap,bt}$	US\$	219,057	383,324	934,470	321,041
Custo de reposição da bateria	$C_{rep,bt}$	US\$	219,057	383,324	934,470	321,041
Custo de O&M da bateria	$C_{o\&m,bt}$	US\$/ano/unidade	10,00	10,00	10,00	10,00

⁽¹⁾ Custos no mercado nacional Brasileiro mais frete.

Fonte: produção do próprio autor

Tabela I.6. Especificações técnicas e econômicas dos modelos de conversor utilizados nas simulações.

Descrição	Símbolo	Unidade	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6
Fabricante	--	--	Schneider	Xantrex	Radian	SMA	SMA	--
Modelo	--	--	--	Xpower 5000	--	Sunny Tripower	Sunny Tripower	--
Potência nominal do conversor	$P_{conv,r}$	kW	4	5	7	15	17	50
Tempo de vida do conversor	LT_{conv}	Ano	10	10	10	10	10	10
Eficiência do conversor funcionando como inversor	$\eta_{conv-inv}$	%	92	90	90	92	90	90
Capacidade relativa inversor/conversor	--	--	1	1	1	1	1	1
Eficiência do conversor funcionando retificador	$\eta_{conv-ret}$	%	92	90	90	92	90	90
Emissões indiretas	$ief_{CO_2,conv}$	kgCO ₂ -eq/kW	42,835	42,835	42,835	42,835	42,835	42,835
Investimento inicial do conversor ⁽¹⁾	$C_{icap,conv}$	US\$	3707,385	4871,973	7355,206	18698,067	23775,510	89062,20
Custo de reposição do conversor	$C_{rep,conv}$	US\$	3707,385	4871,973	7355,206	18698,067	23775,510	89062,20
Custo de O&M do conversor	$C_{o\&m,conv}$	US\$/ano	0,0	0,0	0,0	0,0	0,0	0,0

⁽¹⁾ Custos derivados do mercado nacional Brasileiro mais frete.

Fonte: produção do próprio autor