



**UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

MARCUS VINÍCIUS SILVEIRA MACÊDO

**APLICAÇÃO DE ALGORITMOS DE OTIMIZAÇÃO HEURÍSTICA À
ENERGIA EÓLICA: DETERMINAÇÃO DOS PARÂMETROS DA CURVA
DE WEIBULL PARA DUAS REGIÕES BRASILEIRAS**

FORTALEZA

2018

MARCUS VINÍCIUS SILVEIRA MACÊDO

APLICAÇÃO DE ALGORITMOS DE OTIMIZAÇÃO HEURÍSTICA À ENERGIA
EÓLICA: DETERMINAÇÃO DOS PARÂMETROS DA CURVA DE WEIBULL PARA
DUAS REGIÕES BRASILEIRAS

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Engenharia Mecânica da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Mecânica. Área de Concentração: Processos, Equipamentos e Sistemas para Energias Renováveis.

Orientador(a): Prof^a. Dr^a. Carla Freitas de Andrade (Orientadora)

Coorientador(a): Prof. Dr. Paulo Alexandre Costa Rocha

FORTALEZA

2018

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

M122a Macêdo, Marcus Vinícius Silveira.

Aplicação de algoritmos de otimização heurística à energia eólica: determinação dos parâmetros da curva de Weibull para duas regiões brasileiras / Marcus Vinícius Silveira Macêdo. – 2018.

86 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Mecânica, Fortaleza, 2018.

Orientação: Profa. Dra. Carla Freitas de Andrade.

Coorientação: Prof. Dr. Paulo Alexandre Costa Rocha.

1. Distribuição de Weibull . 2. Métodos heurísticos. 3. Energia eólica. I. Título.

CDD 620.1

MARCUS VINÍCIUS SILVEIRA MACÊDO

APLICAÇÃO DE ALGORITMOS DE OTIMIZAÇÃO HEURÍSTICA À ENERGIA
EÓLICA: DETERMINAÇÃO DOS PARÂMETROS DA CURVA DE WEIBULL PARA
DUAS REGIÕES BRASILEIRAS

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Engenharia Mecânica da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Mecânica. Área de Concentração: Processos, Equipamentos e Sistemas para Energias Renováveis.

Aprovada em: 09/10/2018

BANCA EXAMINADORA

Prof^a. Dr^a. Carla Freitas de Andrade (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Paulo Alexandre Costa Rocha
Universidade Federal do Ceará (UFC)

Prof. Dr. Antonio Clecio Fontelles Thomaz
Universidade Estadual do Ceará (UECE)

À minha família.

AGRADECIMENTOS

Agradeço aos professores Dr^a. Carla Freitas de Andrade e Dr. Paulo Alexandre Costa Rocha, pela excelente orientação.

Ao Valdi, secretário do Programa de Pós-Graduação em Engenharia Mecânica pela atenção e pelos avisos.

Aos colegas de turma pela atenção e que sempre me mantiveram atualizados sobre os assuntos das disciplinas.

Aos colegas Felipe Ferreira Gomes e Kevin Santos Guedes pelo auxílio e o desenvolvimento dos códigos computacionais essenciais para a finalização do estudo.

Ao amigo e colega de trabalho Lindenberg Ferreira do Santos pela paciência, ajuda e discussões que enriqueceram a minha dissertação.

E, sobretudo, agradeço à minha esposa pela compreensão nas noites que passava escrevendo a dissertação e lhe dava pouca atenção.

*"Grandes obras não são feitas com força, mas sim com a perseverança."
(Samuel Johnson)*

RESUMO

A energia eólica é considerada uma das mais promissoras fontes naturais do mundo. A escolha do local de construção de um empreendimento eólico requer o estudo minucioso do local, o qual engloba, como um dos parâmetros de decisão, a qualidade do regime de ventos na região. O estudo do regime dos ventos no local reduz o risco de se construir parques eólicos em locais com baixa eficiência energética. A aplicação de métodos heurísticos em otimização para ajuste de curvas de Weibull, para a caracterização do regime de ventos, tem-se mostrado bastante eficaz. Neste trabalho, buscou-se avaliar o desempenho de três Funções Objetivo diferentes, a minimização da soma de erro ao quadrado das frequências de ocorrência (E.Q), a minimização de erro aplicada aos valores do desvio de produção (E.W) e a soma das duas funções (E.Q.W), selecionar os parâmetros para cada método e comparar, entre si, os métodos: Enxame de Partículas (PSO), Busca Harmônica (HS), Busca do Cuco (CSO), Algoritmo de Competição Imperialista (ICA), Pássaros Migratórios (MBO) e Colônia de Formigas (ACO) com a finalidade de encontrar os parâmetros do fator de forma k e de escala c da distribuição de Weibull que melhor caracterizem o regime de ventos e a produção energética para dois conjuntos de dados provenientes do Sistema de Organização de Dados Ambientais (SONDA) das cidades de Triunfo-PE e São João do Cariri-PB. O desempenho do ajuste foi avaliado pelos testes da Raiz do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (MAE), Coeficiente de determinação (R^2) e pelo Desvio da Produção Eólica (WPD). A função Objetivo (E.Q.W) foi selecionada para os métodos heurísticos nas duas regiões com exceção do método HS para a região do Pernambuco cuja função escolhida foi (E.Q). Os seis métodos foram comparados entre si para as regiões do Pernambuco e da Paraíba. Percebeu-se que o Algoritmo de Competição Imperialista, utilizando a Função Objetivo (E.Q.W), foi o método mais eficiente para determinar os parâmetros de distribuição de Weibull para a cidade de Triunfo-PE por ter apresentado o valor do teste WPD de 0,007% e que o método ACO foi o menos eficaz para ajustar as curvas de distribuição de Weibull para os dados de velocidade do vento da região da Paraíba, utilizando os dados analisados para a cidade de São João do Cariri, devido a discrepância dos resultados dos demais e da aparência da curva de distribuição em relação ao histograma da região.

Palavras-chave: Distribuição de Weibull, Métodos heurísticos, Energia eólica.

ABSTRACT

Wind power is considered one of the most promising natural sources in the world. The wind farm site construction choice requires a careful study of the site, which includes, as one of the decision parameters, the quality of the wind regime in the region. The wind regime local study reduces wind farms building risk in places with low energy efficiency. The heuristic methods application in optimization for adjustment of Weibull curves, for the characterization of the wind regime, has been shown to be quite effective. In this study, it was tried to evaluate three different Objective Functions, the minimization of the square error sum (E.Q), the error minimization applied to the values of the deviation of production (E.W) and the sum of the them (E.Q.W), select the parameters for each method and compare them with each other, the methods are Particle Swarm (PSO), Harmonic Search (HS), Cuckoo Search Optimization (CSO), Imperialist Competitive Algorithm (ICA), Migrating Birds Optimization (MBO) and Ant Colony Optimization (ACO) with the purpose of finding the shape k and scale c factor parameters factor Weibull distribution that best characterize the regime of winds and the energy production for two data sets from the System of Environmental Data Organization (SONDA) of the cities of Triunfo-PE and São João do Cariri-PB. The performance of the adjustment was evaluated by the Root Mean Square Error (RMSE), Main Absolute Error (MAE), Coefficient of determination (R^2) tests and by the Wind Production Deviation (WPD). The objective function (E.Q.W) was selected for the two regions with the exception of the HS method for Pernambuco region whose chosen function was (E.Q). The six methods were compared to each other for the regions of Pernambuco and Paraíba. It was concluded that the Imperialist Competition Algorithm, using the Objective Function (E.Q.W), was the most efficient method to determine the Weibull distribution parameters for the city of Triunfo-PE for presenting the WPD test value of 0.007% and that the ACO method was the least effective for adjusting the Weibull distribution curve for the wind speed data from the Paraíba region using the data analyzed for the city of São João do Cariri, due to the discrepancy of the results in relation to the others and the appearance of the distribution curve in relation to the histogram of the region.

Keywords: Weibull distribution, Heuristic methods, Wind energy.

LISTA DE FIGURAS

Figura 1 – Distribuição de Weibull com $k = 3,0$ (constante)	23
Figura 2 – Distribuição de Weibull com $c = 4$ m/s (constante)	24
Figura 3 – Representação gráfica de pontos ótimos em A e C, onde visualmente pode-se entender o ponto C como ótimo global no domínio admissível	26
Figura 4 – Fluxograma do algoritmo do PSO	31
Figura 5 – Fluxograma do algoritmo HS	33
Figura 6 – Fluxograma do algoritmo CSO	38
Figura 7 – Esquema de migração dos pássaros	39
Figura 8 – Fluxograma do algoritmo MBO	40
Figura 9 – Fluxograma do algoritmo ICA	45
Figura 10 – Amostra do plano cartesiano discretizado	47
Figura 11 – Algoritmo para o procedimento ACO apresentado por Socha (2009)	49
Figura 12 – Localização das cidades de Triunfo - PE e São João do Cariri - PB	50
Figura 13 – Curva de Weibull (a) e curva de inversão logarítmica (b) do método HS, CSO, ICA, PSO, MBO e ACO para a estação SCR25	64
Figura 14 – Curva de Weibull (a) e curva de inversão logarítmica (b) do método HS, CSO, ICA, PSO, MBO e ACO para a estação TRI23	65

LISTA DE TABELAS

Tabela 1 – Velocidade média do vento (m/s) 50 metros acima do nível da superfície	20
Tabela 2 – Parâmetros aplicados aos métodos heurísticos	55
Tabela 3 – Análise estatística da Função Objetivo dos métodos heurísticos para a cidade de Triunfo - PE	57
Tabela 4 – Análise estatística da função objetivo dos métodos heurísticos para São João do Cariri	58
Tabela 5 – Parâmetros do método HS	59
Tabela 6 – Resultados da seleção dos parâmetros para o método HS	59
Tabela 7 – Parâmetros do método CSO	60
Tabela 8 – Resultados da seleção do parâmetros para o método CSO	60
Tabela 9 – Parâmetros do método ICA	60
Tabela 10 – Resultados da seleção do parâmetros para o método ICA	61
Tabela 11 – Parâmetros do método PSO	61
Tabela 12 – Resultados da seleção do parâmetros para o método PSO	62
Tabela 13 – Parâmetros do método MBO	62
Tabela 14 – Resultados da seleção do parâmetros para o método MBO	62
Tabela 15 – Parâmetros do método ACO	63
Tabela 16 – Resultados da seleção do parâmetros para o método ACO	63
Tabela 17 – Resultados dos métodos heurísticos para São João do Cariri	65
Tabela 18 – Resultados dos métodos heurísticos para Triunfo	66
Tabela 19 – Escolha do melhor valor de N_h para Triunfo	71
Tabela 20 – Escolha do melhor valor de N_h para São João do Cariri	71
Tabela 21 – Escolha do melhor valor de N_n para Triunfo	72
Tabela 22 – Escolha do melhor valor de P_a para Triunfo	72
Tabela 23 – Escolha do melhor valor de N_n para São João do Cariri	73
Tabela 24 – Escolha do melhor valor de P_a para São João do Cariri	73
Tabela 25 – Escolha do melhor valor de N_{pop} para Triunfo	74
Tabela 26 – Escolha do melhor valor de N_{imp} para Triunfo	74
Tabela 27 – Escolha do melhor valor de T_{rev} para Triunfo	75
Tabela 28 – Escolha do melhor valor de N_{pop} para São João do Cariri	75
Tabela 29 – Escolha do melhor valor de N_{imp} para São João do Cariri	76
Tabela 30 – Escolha do melhor valor de T_{rev} para São João do Cariri	76
Tabela 31 – Escolha do melhor valor de N_p para Triunfo	77
Tabela 32 – Escolha do melhor valor de w_i para Triunfo	77

Tabela 33 – Escolha do melhor valor de w_f para Triunfo	78
Tabela 34 – Escolha do melhor valor de c_1 para Triunfo	78
Tabela 35 – Escolha do melhor valor de c_2 para Triunfo	79
Tabela 36 – Escolha do melhor valor de N_p para São João do Cariri	79
Tabela 37 – Escolha do melhor valor de w_i para São João do Cariri	80
Tabela 38 – Escolha do melhor valor de w_f para São João do Cariri	80
Tabela 39 – Escolha do melhor valor de c_1 para São João do Cariri	81
Tabela 40 – Escolha do melhor valor de c_2 para São João do Cariri	81
Tabela 41 – Escolha do melhor valor de n para Triunfo	82
Tabela 42 – Escolha do melhor valor de m para Triunfo	82
Tabela 43 – Escolha do melhor valor de n para São João do Cariri	83
Tabela 44 – Escolha do melhor valor de m para São João do Cariri	83
Tabela 45 – Escolha do melhor valor de N_f para Triunfo	84
Tabela 46 – Escolha do melhor valor de μ para Triunfo	84
Tabela 47 – Escolha do melhor valor de ρ para Triunfo	85
Tabela 48 – Escolha do melhor valor de N_f para São João do Cariri	85
Tabela 49 – Escolha do melhor valor de μ para São João do Cariri	86
Tabela 50 – Escolha do melhor valor de ρ para São João do Cariri	86

LISTA DE ABREVIATURAS E SIGLAS

GWEC	Global Wind Energy Council (Conselho Global de Energia Eólica)
ANEEL	Agência Nacional de Energia Elétrica
WWEA	World Wind Energy Association (Associação Mundial de Energia Eólica)
ABEEólica	Associação Brasileira de Energia Eólica
MMQ	Método dos Mínimos Quadrados
MM	Método do Momento
MMV	Método da Máxima Verossimilhança
PSO	Particle Swarm Optimization (Otimização do Enxame de Partículas)
HS	Harmony Search (Busca Harmônica)
HM	Harmony Memory (Memória Harmônica)
HCMR	Harmony Memory Considering Rate (Taxa de Consideração da Memória Harmônica)
PAR	Pitching Adjust Rate (Taxa de Consideração de Som)
CSO	Cuckoo Search Optimization (Otimização da Busca do Cuco)
MBO	Migrating Birds Optimization (Otimização por Pássaros Migratórios)
WTS	Wing-Tip Spacing (Espaçamento entre a ponta da asa de uma ave e a ponta da asa da ave subsequente)
ICA	Imperialist Competitive Algorithm (Algoritmo Competitivo Imperialista)
ACO	Ant Colony Optimization (Otimização por Colônia de Formigas)
SONDA	Sistema de Organização de Dados Ambientais
RMSE	Raiz Quadrada Média do Erro
MAE	Erro Absoluto Médio

LISTA DE SÍMBOLOS

P	Potência
ρ	Massa específica
V	Velocidade cúbica
\bar{V}	Velocidade média
A	Área
n	Número de amostras
f	Frequência de ocorrência
$F(V)$	Probabilidade de ocorrência
k	Fator de Forma
c	Fator de Escala
t	Tempo
w_i	Inércia da Partícula inicial
w_f	Inércia da Partícula final
m	Número máximo de iterações
c_1	Coefficiente de individualidade
c_2	Coefficiente de coletividade
gn	Geração Atual
NI	Número de gerações
bw	Largura de Avanço
i	Número de iterações
β	Fator de escala
Γ	Função gama

σ	Desvio Padrão
P_a	Probabilidade de detecção
C_n	Custo normalizado
c_n	Custo do n-ésimo imperialista
p_n	Poder normalizado
$T \cdot C_n$	Custo Total do império
$N \cdot T \cdot C_n$	Custo normalizado do n-ésimo império
P_{pn}	Probabilidade de posse
P_r	Probabilidade de ocorrência de cada retículo
τ	Intensidade de feromônio
R^2	Coefficiente de determinação

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Objetivos	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Potencial eólico no mundo	19
2.2	Potencial eólico no Brasil	19
2.3	Recurso eólico	20
2.4	Distribuição de Weibull	21
2.5	A distribuição de Weibull na energia eólica	22
2.5.1	<i>Modelagem Matemática da Distribuição de Weibull</i>	22
2.6	Métodos determinísticos <i>versus</i> métodos probabilísticos	24
2.7	Métodos Heurísticos e Meta-Heurísticos	25
2.8	Metodologia de otimização heurística	25
2.8.1	<i>Ótimos locais versus ótimos globais</i>	26
2.8.2	<i>Otimização combinatória</i>	26
2.9	Inteligência artificial	27
2.9.1	<i>Inteligência de enxame</i>	27
2.9.1.1	<i>Enxame de partículas</i>	27
2.9.1.1.1	Modelagem matemática	28
2.9.1.1.2	Algoritmo	30
2.9.1.2	<i>Busca Harmônica</i>	31
2.9.1.3	<i>Busca do Cuco</i>	34
2.9.1.3.1	Comportamento de criação do cuco	34
2.9.1.3.2	Voos Lévy	35
2.9.1.3.3	Algoritmo da busca do cuco (CSO)	35
2.9.1.4	<i>Pássaros Migratórios</i>	38
2.9.1.4.1	Comportamento das aves migratórias	38
2.9.1.4.2	Algoritmo da otimização dos pássaros migratórios (MBO)	39
2.9.1.5	<i>Algoritmo de Competição Imperialista</i>	42
2.9.1.5.1	Comportamento da Competição Imperialista	42
2.9.1.5.2	Algoritmo de Competição Imperialista (ICA)	42
2.9.1.6	<i>Otimização por Colônia de Formigas</i>	45
2.9.1.6.1	Comportamento da Colônia de formigas	45

2.9.1.6.2	Abordagens da Otimização da Colônia de formigas	46
2.9.1.6.3	Abordagem segundo Socha (2009)	46
3	METODOLOGIA	50
3.1	Dados de vento	50
<i>3.1.1</i>	<i>Tratamento de dados</i>	<i>51</i>
3.2	Linguagem R	51
3.3	Função Objetivo	51
3.4	Cálculo dos testes estatísticos	52
3.5	Geração dos gráficos	54
<i>3.5.1</i>	<i>Curva de densidade</i>	<i>54</i>
<i>3.5.2</i>	<i>Curva de inversão logarítmica</i>	<i>54</i>
3.6	Parâmetros aplicados aos métodos heurísticos	54
3.7	Seleção dos parâmetros dos métodos heurísticos	55
3.8	Teste de desempenho dos métodos heurísticos	56
4	RESULTADOS E DISCUSSÕES	57
<i>4.0.1</i>	<i>Seleção da Função Objetivo</i>	<i>57</i>
<i>4.0.2</i>	<i>Seleção dos parâmetros para os métodos</i>	<i>59</i>
4.1	Testes com os métodos heurísticos	64
5	CONCLUSÃO	67
	REFERÊNCIAS	68
	APÊNDICE A – SELEÇÃO DOS PARÂMETROS PARA MÉ-	
	TODOS	71
A.1	Seleção do parâmetro para o método HS	71
A.2	Seleção dos parâmetros para o método CSO	72
A.3	Seleção dos parâmetros para o método ICA	74
A.4	Seleção dos parâmetros para o método PSO	77
A.5	Seleção dos parâmetros para o método MBO	82
A.6	Seleção dos parâmetros para o método ACO	84

1 INTRODUÇÃO

Desde de 1970, a utilização das energias alternativas vem sendo amplamente procurada. Isso ocorreu devido às crises do petróleo, que levaram diversos países a procurar outras possibilidades para a redução da dependência da importação de combustíveis e a consequente segurança do fornecimento de energia. Devido às preocupações ambientais, vem crescendo a busca de alternativas mais limpas de produção de energia. Dentre estas, destaca-se a eólica que despertou significativa atenção durante os últimos anos.

A análise dos recursos de vento é um passo chave no desenvolvimento de projetos de geração de energia. Uma das informações mais importantes na análise desses recursos eólicos é a caracterização do regime de vento de acordo com uma distribuição de probabilidade.

A caracterização do regime do vento é uma condição que propicia o estudo das aplicações de métodos heurísticos, neste caso, *Particle Swarm Optimization - PSO*, *Harmony Search - HS*, *Cuckoo Search Optimization - CSO*, *Imperialist Competitive Algorithm - ICA*, *Migrating Birds Optimization - MBO* e *Ant Colony Optimization - ACO*, com o intuito de minimizar os erros que impactam na previsão de produção podendo, nos piores cenários, provocar perdas financeiras ao investidor ou sobrecarga nas turbinas eólicas.

Os métodos PSO, HS, CSO, ICA, MBO e ACO são métodos computacionais que simulam o comportamento social de bandos, improvisação de harmonias musicais, estratégia de reprodução de aves cucos, competição imperialista entre países, comportamento de aves migratórias e comportamento social de formigas, respectivamente.

Este trabalho avaliou o desempenho de três Funções Objetivo diferentes, a minimização da soma de erro ao quadrado, a minimização de erro aplicada aos valores do desvio de produção e a soma dos mesmos, selecionou os parâmetros de cada método, validou e comparou seis métodos heurísticos para encontrar os parâmetros da distribuição de Weibull que melhor caracterizem o regime de ventos e a produção energética para duas cidades brasileiras.

Os testes com cada método heurístico, aplicando dados reais foram executados com dados públicos do projeto Sistema de Organização de Dados Ambientais (SONDA), do Governo Federal, referentes às estações TRI23, situada em Triunfo-PE e SCR25, em São João do Cariri-PB. Os testes escolhidos para avaliar o desempenho dos ajustes foram a Raiz do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (MAE) e o Coeficiente de determinação R^2 , a serem aplicados para avaliar os valores da curva e do histograma. Além destes, o valor percentual do Desvio da Produção Eólica (WPD) entre a curva e o histograma.

1.1 Objetivos

O objetivo deste trabalho foi avaliar a aplicação dos métodos heurísticos PSO, HS, CSO, ICA, MBO e ACO na otimização do ajuste da distribuição de probabilidades dos ventos. Especificamente, os objetivos foram:

- a) Implementar os métodos heurísticos Enxame de Partículas - PSO, Busca Harmônica - HS, Busca do Cuco - CSO, Algoritmo de Competição Imperialista - ICA, Pássaros Migratórios - MBO e da Colônia de Formigas - ACO para ajuste da curva de Weibull utilizando a linguagem R;
- b) Ajustar dois histogramas reais de vento, relativos à região Triunfo-PE e São João do Cariri-PB;
- c) Selecionar através de testes estatísticos e do teste de desvio de produção eólica qual das três funções objetivo estudadas deve ser aplicada em cada método heurístico;
- d) Selecionar os parâmetros de cada método através do valor da Função Objetivo e do número de iterações;
- e) Comparar os seis métodos entre si, utilizando os testes estatísticos RMSE, MAE, R^2 e o desvio WPD.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Potencial eólico no mundo

O Conselho Global de Energia Eólica (GWEC) divulgou em seu Relatório Global de Vento que mais de 52 GW de energia eólica limpa e livre de emissões foram adicionadas em 2017, elevando o total de instalações a 539 GW globalmente.

A Dinamarca obteve 44% de sua eletricidade a partir do vento em 2017, e o Uruguai, mais de 30%. No mesmo ano, a energia eólica forneceu 11,6% da energia da União Européia, liderada pela Dinamarca, Portugal e Irlanda, com 24%, e a Espanha e a Alemanha, com menos de 20%.

O relatório também prevê que o setor retornará a um crescimento elevado em 2019, ultrapassando o marco de 60 GW em 2020 e subirá até alcançar um total de 840 GW até 2022 (GWEC, 2018).

2.2 Potencial eólico no Brasil

O Brasil possui um dos melhores potenciais de recursos eólicos do mundo, excedendo, em até três vezes, as atuais necessidades de eletricidade do país. O ano de 2017 terminou com 12,77GW de potência eólica instalada, totalizando 508 usinas, o que representou um crescimento de 18,87% de potência em relação a dezembro de 2016 (ABEEÓLICA, 2018). No Nordeste, a energia eólica forneceu mais de 60% da demanda de eletricidade, superando todos os recordes de geração anteriores durante um período em que os reservatórios de energia hidrelétrica na região eram muito baixos (GWEC, 2018).

Um dos fatores que motivam a aplicação da energia eólica no Brasil é sua associação com a produção de energia hídrica, já que no período de estiagem são registradas as maiores médias de velocidade do vento e no período de chuva essas velocidades diminuem. Por esta razão, a energia eólica não só pode ser aplicada de forma a manter os níveis dos reservatórios no período de estiagem como ainda auxiliar a produção no período de chuvas (BARBOSA, 2015).

Feitosa et al. (2003) definiram quatro classes de energia eólica e cinco condições topográficas brasileiras distintas de acordo com a Tabela 1. A classe 1 representa regiões de baixo potencial eólico, de pouco ou nenhum interesse para o aproveitamento da energia eólica, as classes 2 e 3 podem ou não ser favoráveis, dependendo das condições topográficas e a classe 4 corresponde aos melhores locais para aproveitamento dos ventos no Brasil.

Em relação às condições topográficas, a zona costeira é representada por áreas de

praia, normalmente com larga faixa de areia, campo aberto por áreas planas de pastagens, plantações e/ou vegetação baixa sem muitas árvores altas, mata por áreas de vegetação nativa com arbustos e árvores altas, mas de baixa densidade, tipo de terreno que causa mais obstruções ao fluxo de vento, morro por áreas de relevo levemente ondulado, relativamente complexo, com pouca vegetação ou pasto e montanha por áreas de relevo complexo, com altas montanhas.

Tabela 1 – Velocidade média do vento (m/s) 50 metros acima do nível da superfície

Classes de energia	Condições Topográficas				
	Mata	Campo aberto	Zona costeira	Morro	Montanha
4	>6,0	>7,0	>8,0	>9,0	>11,0
3	4,5 - 6,0	6,0 - 7,0	6,0 - 7,0	7,5 - 9,0	8,5 - 11,0
2	3,0 - 4,5	4,5 - 6,0	4,5 - 6,0	6,0 - 7,5	7,0 - 8,5
1	<3,0	<4,5	<4,5	<6,0	<7,0

Fonte: Adaptado de Feitosa, E. A. N. et al. (2003).

2.3 Recurso eólico

A inclinação natural que a Terra possui em relação à direção de incidência da radiação solar e a mudança na distribuição de massas de água e de terra envolta do globo provocam diferenças de temperatura e de energia térmica acumulada nas diversas áreas do planeta. Esta ação causa diferenças de pressões nas massas atmosféricas e essas, por sua vez, causam o movimento das massas de ar por convecção das regiões de alta pressão para as de baixa pressão, fenômeno denominado vento. A energia cinética de translação é convertida em energia de rotação através de turbinas eólicas, denominadas aerogeradores, para a geração de eletricidade ou moinhos para trabalhos mecânicos como bombeamento d'água (ANEEL, 2008).

Assim como a energia hidráulica, a energia eólica é utilizada há muito tempo com os mesmos objetivos, tais como: moagem de grãos, bombeamento de água e outras aplicações que envolvem energia mecânica. Com o intuito de gerar eletricidade, as primeiras tentativas surgiram no final do século XIX, porém somente um século depois, com a crise internacional do petróleo em meados de 1970, é que houve interesse e investimentos suficientes para viabilizar o desenvolvimento e aplicação de equipamentos em escala comercial (ANEEL, 2008).

A velocidade do vento é a principal variável na estimativa do potencial de produção de energia eólica de uma dada região, pois a potência produzida é diretamente proporcional ao cubo da velocidade do vento de acordo com a relação fornecida na Equação 2.1.

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

O vento possui velocidade variável com o tempo, o que dificulta a previsão do potencial fornecido por uma dada região, pois a distribuição da velocidade do vento ao longo do tempo depende de diversos fatores como relevo, vegetação e temperatura. Dessa forma, a velocidade do vento é, portanto, uma variável aleatória contínua (BARBOSA, 2015).

Outro parâmetro importante é o cálculo da velocidade cúbica média que é utilizado para o cálculo de densidade de potência, sendo determinante no estudo do parque, segundo a equação 2.2.

$$\bar{V}^3 = \frac{1}{n} \cdot \sum_{i=1}^n V_i^3 \quad (2.2)$$

Uma correta estimativa do recurso eólico depende da utilização de métodos sistemáticos de medição e análise. A norma IEC 61400 PART 12-1 (2005b) define 1 (um) ano de dados integrados a cada 10 minutos, ou seja, um ciclo de estações, como o período mínimo para a caracterização dos ventos de uma região, totalizando 52.560 valores.

Um modelo de distribuição probabilística é uma forma de representar o regime de velocidade do vento de uma dada região de forma contínua, sendo que a aplicação destes modelos depende do tipo de regime de vento.

As formas de distribuições mais utilizadas na representação de regimes de vento, segundo Azevedo (2015) são:

- a) Distribuição normal ou distribuição Gaussiana;
- b) Distribuição normal bivariável;
- c) Distribuição exponencial;
- d) Distribuição de Rayleigh;
- e) Distribuição de Weibull.

2.4 Distribuição de Weibull

A distribuição de Weibull é uma distribuição de probabilidade contínua, podendo ser utilizada com dois ou três parâmetros, introduzida por Weibull (1939) em detalhes no qual propõe diversas aplicações em algumas áreas da ciência. Em geral, as aplicações dessa distribuição visam a determinação do tempo de vida médio e da taxa de falhas em função do tempo da população analisada.

Segundo Walpole (1999), a distribuição de Weibull, introduzida pelo físico sueco Waloddi Weibull em 1939, tem sido amplamente utilizada nos últimos anos para lidar com problemas de sistemas complicados cuja operação e segurança dependem da confiabilidade de vários componentes que compõem os sistemas. Por exemplo, um dispositivo sensível ao calor pode falhar, um fusível pode queimar, uma coluna de aço pode se torcer. O autor acredita que componentes idênticos submetidos a condições ambientais idênticas falharão em tempos diferentes e imprevisíveis.

2.5 A distribuição de Weibull na energia eólica

Várias funções de densidade de probabilidade representaram a distribuição da frequência da velocidade do vento. Porém, ultimamente, a distribuição de Weibull foi uma das distribuições mais utilizadas, recomendadas e aceitas para determinar o potencial de energia eólica, inclusive essa distribuição serve de referência para softwares comerciais de energia eólica, como *Wind Atlas Analysis e Application Program* (AKDAG; DINLER, 2009).

Akdag e Dinler (2009) destacaram que a distribuição de Weibull não é adequada para representar a distribuição do vento para toda a localização geográfica do mundo e recomenda que sejam utilizadas outras propostas para representar a distribuição de frequência de velocidade do vento desses locais.

Justus et al. (1978) apontaram que o modelo de Weibull é uma ferramenta muito útil para a análise de energia eólica e que dentre uma série de vantagens pode-se citar três como as mais representativas:

- a) Se uma distribuição de vento desejada está em uma altura diferente da medida pelo anemômetro, conhecendo os parâmetros k e c em relação à altura medida, pode-se extrapolar a distribuição para outras alturas desejadas;
- b) A distribuição de Weibull requer dois parâmetros definidores k e c , portanto, representando melhor a distribuição de vento do que a distribuição de Rayleigh que requer apenas um parâmetro e mais fácil de se determinar do que a distribuição bivariada que requer cinco parâmetros;
- c) Em um amplo número de casos, a distribuição de Weibull parece dar um ajuste razoável para observar as distribuições.

2.5.1 Modelagem Matemática da Distribuição de Weibull

A Equação 2.3 mostra a função de densidade de probabilidade, curva de frequência de velocidade do vento, que expressa a distribuição de Weibull para a velocidade x .

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

Onde c é o fator de escala (em m/s) e k é o fator de forma (adimensional).


A função de probabilidade acumulada, curva de duração da velocidade do vento, é expressa pela Equação 2.4. Note que $F(x)$ denota a probabilidade de existirem velocidades menores ou iguais a x .

$$F(x) = \int_0^x f(x)dx = 1 - e^{-\left(\frac{x}{c}\right)^k} \text{ com } x, k \text{ e } c > 0. \quad (2.4)$$

Analisando as equações acima, pode-se avaliar o impacto da variação dos parâmetros k e c , conforme as Figuras 1 e 2.

A Figura 1 apresenta cinco distribuições de Weibull com o mesmo valor de $k = 3$. O gráfico aponta que um aumento do valor do parâmetro c diminui a curtose seguindo para uma forma platicúrtica, caracterizando uma dispersão dos valores. Essa dispersão nos valores, no qual as velocidades dos ventos atingidas são maiores, porém ocorrem em menor frequência, caracterizando um regime de instabilidade do vento na região (AZEVEDO, 2015).

Figura 1 – Distribuição de Weibull com $k = 3,0$ (constante)




Fonte: Elaborado pelo autor.

A Figura 2 apresenta cinco distribuições de Weibull em que foi mantido constante o parâmetro $c = 4$ m/s. O gráfico exibe que para $k = 1$ a distribuição assume a forma de uma

exponencial; para $k = 2$, a forma da distribuição de Rayleigh, e, ao contrário da Figura 01, indica que um aumento do valor do parâmetro k , cresce também o valor da curtose, seguindo para uma forma leptocúrtica. Isto significa que quanto maior o valor do fator de forma, mais concentrada e simétrica é a distribuição, caracterizando um regime de vento constante (AZEVEDO, 2015).

Figura 2 – Distribuição de Weibull com $c = 4$ m/s (constante)



Fonte: Elaborado pelo autor.

Nota-se que um estudo do regime de ventos não pode ser realizado considerando apenas um dos parâmetros da curva, pois o fator de forma k e o fator de escala c apresentam uma dependência entre si, fazendo com que estes ajam de forma contrária sobre o comportamento da curva de distribuição.

2.6 Métodos determinísticos *versus* métodos probabilísticos

De acordo com Rodrigues (2005), os algoritmos utilizados para a solução de um problema de otimização podem ser, fundamentalmente, determinísticos ou probabilísticos. Os métodos de otimização determinísticos, nos quais estão incluídos os métodos de programação matemática tais como: Método dos Mínimos Quadrados (MMQ), Método do Momento (MM), Método da Máxima Verossimilhança (MMV), entre outros, em geral são baseados nos cálculos de derivadas de primeira ou segunda ordem ou de uma aproximação dessas derivadas. Ao mesmo tempo, os métodos baseados nos algoritmos probabilísticos inserem no processo de otimização dados e parâmetros estocásticos, ou seja, de origem aleatória, resolvendo o problema do ponto de vista probabilístico.

Albuquerque (2007) apontou que os métodos determinísticos apresentaram algumas limitações, tais como: a dificuldade em identificar soluções ótimas globais por serem fortemente dependentes do ponto de partida; dificuldade de trabalhar com variáveis discretas e dificuldade de operar com funções descontínuas e não diferenciáveis.

Os métodos probabilísticos não utilizam o cálculo de derivadas, atuando diretamente na busca das soluções no espaço viável. Porém exigem um grande número de avaliações do valor da função objetivo e das restrições, sendo considerados métodos computacionalmente caros (BASTOS, 2004).

2.7 Métodos Heurísticos e Meta-Heurísticos

Um algoritmo é considerado um método heurístico quando não há conhecimentos matemáticos completos sobre seu comportamento, ou seja, quando, sem oferecer garantias, o algoritmo objetiva resolver problemas complexos utilizando uma quantidade não muito grande de recursos, especialmente, no que diz respeito ao consumo de tempo para encontrar soluções de boa qualidade.

As pesquisas realizadas ao longo de décadas, sobre o desempenho de métodos heurísticos e, em particular, sobre as características que conduzem ao êxito de tais métodos, levaram à elaboração de estratégias genéricas, esqueletos de algoritmos, para a construção de heurísticas. Essas estratégias são chamadas meta-heurísticas (SUCUPIRA, 2004)

Embora a comunidade científica não entre em consenso sobre a definição de meta-heurística, Metaheuristics (2017) apresentou um conceito de meta-heurística:

Uma meta-heurística é um conjunto de conceitos que pode ser utilizado para definir métodos heurísticos aplicáveis a um extenso conjunto de diferentes problemas. Em outras palavras, uma meta-heurística pode ser vista como uma estrutura algorítmica geral que pode ser aplicada a diferentes problemas de otimização com relativamente poucas modificações que possam adaptá-la a um problema específico. Alguns exemplos de meta-heurísticas são: recozimento simulado, busca tabu, busca local iterada, algoritmos evolutivos e otimização por colônia de formigas (METAHEURISTICS, 2017).

Vale a pena ressaltar que os métodos aplicados nesse estudo são todos considerados Meta-Heurísticos.


2.8 Metodologia de otimização heurística

Dentre as duas principais aplicações da heurística em soluções matemáticas, a Otimização Global e a Otimização Combinatória são as mais importantes.

2.8.1 Ótimos locais versus ótimos globais

Uma vez definido o problema, com suas respectivas variáveis e restrições, na grande maioria dos problemas práticos é preciso lidar com a existência de mais de um ponto ótimo local da função objetivo, conforme ilustrado na Figura 3. Pode-se visualmente entender que a função possui dois mínimos locais A e C, neste caso é fácil afirmar que C é o ponto mínimo global.

Figura 3 – Representação gráfica de pontos ótimos em A e C, onde visualmente pode-se entender o ponto C como ótimo global no domínio admissível



Fonte: Barbaresco (2014).

Os métodos que utilizam derivadas são otimizadores locais por natureza o que pode levar a avaliações equivocadas dos mínimos e máximos de funções mais complexas (SECCHI; BISCAIA, 2012).

2.8.2 Otimização combinatória

Conforme Krasnogor (2002), informalmente, problemas de otimização combinatória são problemas para os quais o espaço de soluções possíveis (viáveis, candidatas ou factíveis) é finito, embora extremamente grande e discreto.

Este problema pode ser adaptado a uma grande variedade de problemas reais que surgem na indústria, economia, logística, dentre outros. O problema do Caixeiro Viajante, em que o vendedor deve passar por diversas cidades, visitando uma única vez cada uma delas, retornando à cidade de origem e para isso deve percorrer o menor caminho possível, é hoje utilizado para testar métodos de otimização combinatória.

Não existem algoritmos que apresentem uma solução ótima em um tempo viável para problemas de natureza complexa. A aplicação de métodos heurísticos possibilita alcançar um resultado prático, mesmo que não seja constatado como ótimo.

2.9 Inteligência artificial

O desenho de modelos algorítmicos para solucionar problemas cada vez mais complexos estão motivando o desenvolvimento algorítmico. A modelagem da inteligência biológica e natural ocasionaram grandes sucessos chamados "sistemas inteligentes". Redes neurais artificiais, computação evolutiva, inteligência de enxames, sistemas imunológicos artificiais e sistemas difusos estão inseridos nesses algoritmos inteligentes. Esses algoritmos inteligentes fazem parte do campo de Inteligência Artificial (ENGELBRECHT, 2007).

2.9.1 *Inteligência de enxame*

A inteligência de enxame teve sua origem no estudo de colônias, ou enxames de organismos sociais. Estudos sobre o comportamento social dos organismos nos enxames provocaram a elaboração de algoritmos de otimização e agrupamento muito eficientes. Por exemplo, estudos de simulação da elegante, mas imprevisível, coreografia de bandos de pássaros levaram ao projeto do algoritmo de otimização de enxame de partículas, e estudos do comportamento da busca por alimentação de formigas resultaram em algoritmos de otimização de colônias de formigas (ENGELBRECHT, 2007).

2.9.1.1 *Enxame de partículas*

A otimização por enxames de partículas (PSO), segundo Eberhart e Kennedy (1995), tem origem em duas metodologias de componentes principais. A primeira seria os laços com a vida artificial em geral, modelada no comportamento social de um bando de aves, no cardume de peixes e na teoria de enxames em particular. A segunda está relacionada à computação evolutiva, e tem vínculos com algoritmos genéticos e estratégias de evolução.

Engelbrecht (2007) relatou que cada partícula no enxame representa uma possível solução para o problema de otimização. Em um sistema PSO, cada partícula "voa" através do espaço de busca multidimensional, ajustando sua posição no espaço de acordo com sua própria experiência e a da partícula vizinha. Uma partícula faz uso da melhor posição encontrada por si mesma e a melhor posição de seus vizinhos para posicionar-se em direção a uma solução ideal. O efeito é que as partículas "voam" em direção a um ótimo global, enquanto ainda investiga uma área em torno da melhor solução atual. A "proximidade" de uma partícula ao mínimo global é medida de acordo com uma função objetivo predefinida que

está relacionada ao problema a ser resolvido. Com o objetivo de facilitar o entendimento do processo, Clerc (1999) fez uma analogia a uma caça ao tesouro, onde um time de busca, através de radiocomunicadores, transmite a posição e o sucesso nas buscas. Com base nesses dados de cada membro da equipe, além da sua própria experiência, cada indivíduo é capaz de restringir a sua área de busca, reduzindo o tempo de procura.

Eberhart e Shi (2001) acreditaram que uma das razões que faz com que o método da otimização de enxames de partículas seja atrativo é a pouca quantidade de parâmetros que necessitam ser ajustados.

2.9.1.1.1 Modelagem matemática

De acordo com Secchi e Biscaia (2012), o trabalho de Eberhart e Kennedy (1995) não apresentou a demonstração formal do algoritmo proposto pelos autores. O método proposto se apresenta na sua forma recursiva adequada para implementação computacional. Uma versão modificada do algoritmo originalmente proposto é apresentada abaixo:

Para cada partícula k posicionada em um plano bidimensional e para cada iteração i , são avaliadas as posições e registrados o melhor resultado individual $(x_k^{melhor}, y_k^{melhor})$ e, posteriormente, registrado o melhor resultado entre as k partículas $(x_{global}^{melhor}, y_{global}^{melhor})$.

O movimento de cada partícula será proporcional à distância entre a posição atual da partícula e o ponto resultante da média ponderada entre a melhor posição individual da partícula e a melhor posição do enxame, conforme a Equação 2.5:

$$X_i^k = \begin{pmatrix} X_i^k \\ Y_i^k \end{pmatrix} = \begin{pmatrix} \lambda x_k^{melhor} + (1 - \lambda) \cdot x_{global}^{melhor} \\ \mu y_k^{melhor} + (1 - \mu) \cdot y_{global}^{melhor} \end{pmatrix} \quad (2.5)$$

Onde λ e μ são números aleatórios pertencentes ao conjunto $[0,1]$. As partículas são modeladas como sistemas massa-mola-amortecedor, de acordo com as Equações 2.6 e 2.7:

$$\frac{d^2 x_k(t)}{d(t)^2} = -2 \cdot \varepsilon_k \cdot \frac{dx_k(t)}{d(t)} - [x_k^t - X_k^{(i)}] \quad (2.6)$$

$$\frac{d^2 y_k(t)}{d(t)^2} = -2 \cdot \zeta_k \cdot \frac{dy_k(t)}{d(t)} - [y_k^t - Y_k^{(i)}] \quad (2.7)$$

O tempo t , a que se referem as Equações 2.6 e 2.7, é adimensional e representa as iterações do processo onde $t_i = i \cdot \Delta t < t \leq (i + 1) \cdot \Delta t = t + 1$, obtendo-se as Equações 2.8 até 2.11:

$$x_k(t_i) = x_k^t \quad (2.8)$$

$$\left. \frac{dx_k(t)}{dt} \right|_{t_i} = v_k^{(i)} \quad (2.9)$$

$$y_k(t_i) = y_k^t \quad (2.10)$$

$$\left. \frac{dy_k(t)}{dt} \right|_{t_i} = \nu_k^{(i)} \quad (2.11)$$

A posição da partícula é trocada com a adição do vetor velocidade, o qual direciona o processo de otimização, e reflete a própria experiência da partícula e a informação trocada com as partículas vizinhas (ENGELBRECHT, 2007). Sendo v e ν componentes do vetor velocidade da partícula, resultante das equações diferenciais de primeira ordem, Equações 2.12 até 2.15:

$$\frac{dv_k(t)}{dt} = -2 \cdot \varepsilon_k \cdot v_k(t) - [x_k^t - X_k^{(i)}] \quad (2.12)$$

$$\frac{dx_k(t)}{d(t)} = v_k(t) \quad (2.13)$$

$$\frac{d\nu_k(t)}{dt} = -2 \cdot \zeta_k \cdot \nu_k(t) - [y_k^t - Y_k^{(i)}] \quad (2.14)$$

$$\frac{dy_k(t)}{d(t)} = \nu_k(t) \quad (2.15)$$

Aplicando o método de Euler explícito, as Equações 2.16 até 2.19 resultam das Equações 2.12 até 2.14 :

$$v_k^{(i+1)} = v_k^{(i)} - 2 \cdot \varepsilon_k \cdot \Delta t \cdot v_k^{(i)} - \Delta t \cdot [x_k^{(i)} - X_k^{(i)}] \quad (2.16)$$

$$x_k^{(i+1)} = x_k^{(i)} + \Delta t \cdot v_k^{(i)} \quad (2.17)$$

$$\nu_k^{(i+1)} = \nu_k^{(i)} - 2 \cdot \zeta_k \cdot \Delta t \cdot \nu_k^{(i)} - \Delta t \cdot [y_k^{(i)} - Y_k^{(i)}] \quad (2.18)$$

$$y_k^{(i+1)} = y_k^{(i)} + \Delta t \cdot \nu_k^{(i)} \quad (2.19)$$

Reduzindo $\Delta t \cdot v = V_x$ e $\Delta t \cdot \nu = V_y$, resultam as Equações 2.20 até 2.23:

$$V_{x,k}^{(i+1)} = V_{x,k}^{(i)} - 2 \cdot \varepsilon_k \cdot \Delta t \cdot V_{x,k}^{(i)} - \Delta t^2 \cdot [x_k^{(i)} - X_k^{(i)}] \quad (2.20)$$

$$x_k^{(i+1)} = x_k^{(i)} + V_{x,k}^{(i)} \quad (2.21)$$

$$V_{y,k}^{(i+1)} = V_{y,k}^{(i)} - 2 \cdot \zeta_k \cdot \Delta t \cdot V_{y,k}^{(i)} - \Delta t^2 \cdot [y_k^{(i)} - Y_k^{(i)}] \quad (2.22)$$

$$y_k^{(i+1)} = y_k^{(i)} + V_{y,k}^{(i)} \quad (2.23)$$

Reformulando os termos das Equações apresentadas, chega-se ao modelo sugerido por Eberhart e Kennedy (1995), como mostram as Equações 2.24 até 2.27:

$$V_{x,k}^{(i+1)} = \omega^{(i)} \cdot V_{x,k}^{(i)} + c_1 \cdot \lambda \cdot [x_k^{(melhor)} - x_k^{(i)}] + c_2 \cdot \mu \cdot [x_{(global)}^{(melhor)} - x_k^{(i)}] \quad (2.24)$$

$$x_k^{(i+1)} = x_k^{(i)} + V_{x,k}^{(i)} \quad (2.25)$$

$$V_{y,k}^{(i+1)} = \omega^{(i)} \cdot V_{y,k}^{(i)} + c_1 \cdot \eta \cdot [y_k^{(melhor)} - y_k^{(i)}] + c_2 \cdot \epsilon \cdot [x_{(global)}^{(melhor)} - y_k^{(i)}] \quad (2.26)$$

$$y_k^{(i+1)} = y_k^{(i)} + V_{y,k}^{(i)} \quad (2.27)$$

O termo ω aparece como o termo de inércia da partícula. Secchi e Biscaia (2012) sugeriram um valor linearmente decrescente, segundo a Equação 2.28.

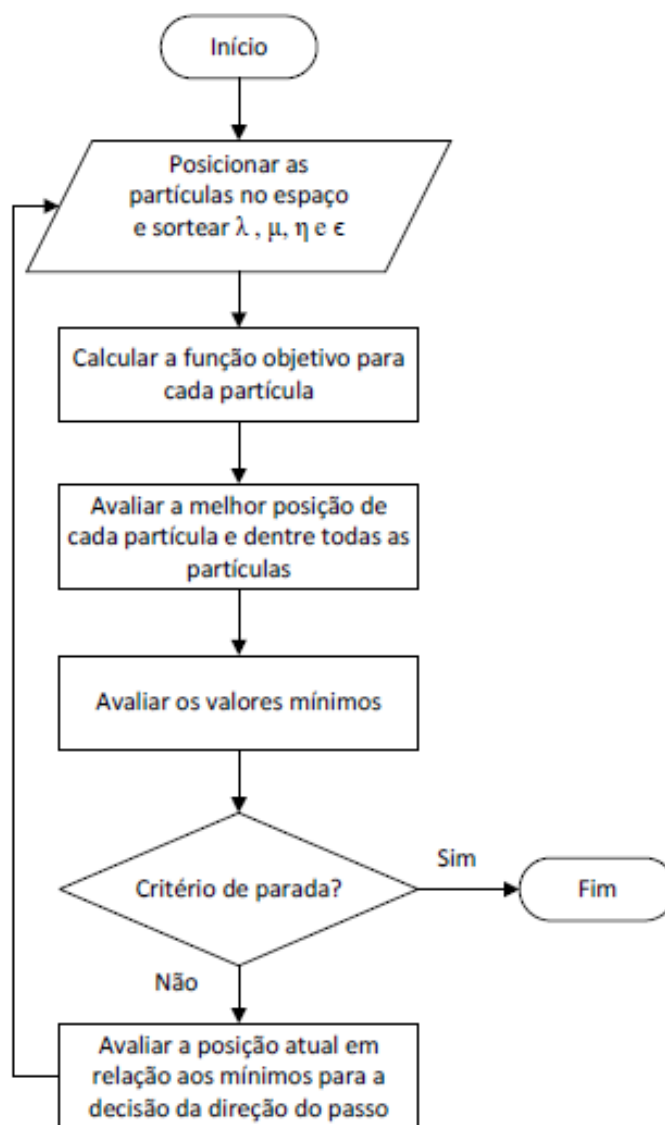
$$\omega^{(i)} = \omega_{inicial} + (\omega_{final} - \omega_{inicial}) \cdot \left(\frac{i}{m}\right) \quad (2.28)$$

Onde m é o número máximo de iterações. O termo de inércia age sobre o comportamento da partícula favorecendo a exploração global (altos valores de ω) ou favorecendo a exploração local (baixos valores de ω). Os termos λ , μ , η e ϵ são sorteados aleatoriamente entre 0 e 1, manipulando o "humor" da partícula.

2.9.1.1.2 Algoritmo

O decaimento de ω e a atribuição do valor zero às componentes da velocidade tem como intuito frear a partícula à medida em que esta se aproxima da melhor solução. O termo de inércia ω reduz-se em busca de melhorar a exploração local, supondo-se que com o passar das iterações, o problema esteja próximo da convergência (AZEVEDO, 2015). A Figura 4 apresenta o algoritmo do PSO em fluxograma.

Figura 4 – Fluxograma do algoritmo do PSO



Fonte: Elaborado pelo autor.

2.9.1.2 Busca Harmônica

Um fenômeno artificial denominado harmonia musical serviu de modelo para a criação de uma nova técnica meta-heurística. A música é um dos processos mais satisfatórios elaborados pelo ser humano. Um novo algoritmo foi derivado desse fenômeno artificial encontrado na performance musical, denominando o processo de busca pela melhor harmonia.

Define-se harmonia musical como a combinação de sons considerados prazerosos do ponto de vista do ser humano.

A performance musical busca o melhor estado, ou seja, a harmonia mais gloriosa,

determinado pela estimativa estética, assim como os algoritmos de otimização buscam o melhor estado, isto é, o ótimo global, determinado pela função objetivo.

A estimativa estética é determinada pelo conjunto de sons tocados por um conjunto de instrumentos, assim como a avaliação da função objetivo é determinada pelo conjunto de valores produzidos pelas variáveis de cada parâmetro do algoritmo; os sons para aperfeiçoar a estimativa estética podem ser melhorados com a prática dos instrumentistas, assim com os valores para uma melhor avaliação da função objetivo podem ser melhorados com a iteração do algoritmo (GEEM; KIM; LOGANATHAN, 2001).

Meziane e Zebarjadi (2014) fizeram uma analogia com a improvisação do Jazz com o objetivo de esclarecer o princípio da Memória Harmônica (HM), considerando um trio de Jazz composto por um guitarrista, um contrabaixista e um pianista. Cada músico no trio toca um conjunto de notas musicais criando uma harmonia primária composta por: guitarrista (Sol, Si, Re, Fa, Mi); contrabaixista (Fa, Mi, Re, La, Si); pianista (Si, Re, Mi, Do, La). O guitarrista toca aleatoriamente uma nota musical Sol fora de seu conjunto primário; o contrabaixista toca aleatoriamente uma nota musical Si fora de seu conjunto primário e o pianista toca aleatoriamente uma nota musical Re fora de seu conjunto primário. Portanto, a nova harmonia (Sol, Si, Re) composta pelo trio vai se tornar uma outra harmonia musicalmente satisfatória. Se a nova harmonia for melhor do que a pior harmonia existente no HM, a nova harmonia será incluída no HM e a pior será excluída do HM e o processo será repetido até que o conjunto das melhores harmonias seja obtido.

Parte-se do princípio que a melhor solução existe inicialmente na Memória Harmônica, porém, quando esse não é o caso, com o propósito de se encontrar o ótimo global, a Busca Harmônica inicia um parâmetro, a Taxa de Consideração da Memória Harmônica (HCMR), que é um número que varia entre 0 e 1.

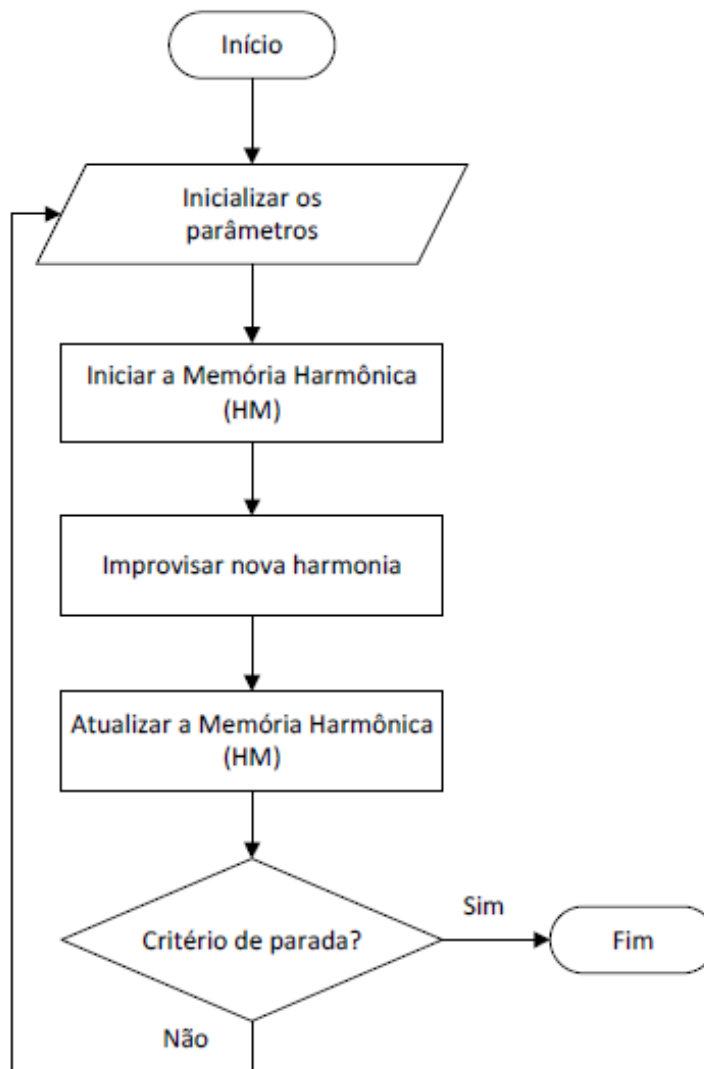
Com o intuito de melhorar as soluções e evitar que o método fique preso em mínimos locais, outro parâmetro é iniciado, denominado Taxa de Ajuste de Som (PAR), que também é um número que varia entre 0 e 1. Esse parâmetro imita o ajuste de afinação de cada instrumento para ajustar o conjunto (GEEM; KIM; LOGANATHAN, 2001).

O grau de similaridade é controlado por um parâmetro denominado largura de banda, bw (ASKARZADEH; ZEBARJADI, 2014).

Dessa maneira, se o valor de HCMR for alto, a busca global do método será prejudicada e a busca local será melhorada, pois esse valor representa uma maior probabilidade de que um elemento da HM seja selecionado, de modo igual, caso o valor do parâmetro PAR for alto, melhor será a busca local, pois o aumento do valor desse parâmetro aumenta a probabilidade da seleção de um elemento da vizinhança.

A Figura 5 apresenta o algoritmo da Busca Harmônica em fluxograma (GEEM; KIM; LOGANATHAN, 2001).

Figura 5 – Fluxograma do algoritmo HS



Fonte: Elaborado pelo autor

A formação do primeiro conjunto da memória inicial, pode se dar através do sorteio de valores aleatórios contemplados no intervalo de possíveis soluções ou através da seleção de valores que se supõe estar próximos da melhor solução (GEEM; KIM; LOGANATHAN, 2001).

O algoritmo proposto por Geem, Kim e Loganathan (2001) atribui valores constantes para os parâmetros HCMR, PAR e bw, porém, Mahdavi, Fesanghary e Damangir (2007) propuseram em seu trabalho a aplicação dos parâmetros PAR e bw, variando em relação ao número de gerações e sendo relacionados pelas Equações 2.29 e 2.30 :

$$PAR(gn) = PAR_{min} + \frac{(PAR_{max} - PAR_{min})}{NI} \cdot gn \quad (2.29)$$

Onde:

- a) $PAR(gn)$ é a taxa de ajuste do som para cada geração;
- b) PAR_{min} é a taxa mínima do ajuste do som;
- c) PAR_{max} é a taxa máxima de ajuste do som;
- d) NI é o número de gerações;
- e) gn é o número da geração.

$$bw(gn) = bw_{max} \cdot e^{\left(\frac{\ln\left(\frac{bw_{min}}{bw_{max}}\right)}{NI}\right) \cdot gn} \quad (2.30)$$

Onde:

- a) $bw(gn)$ é a largura de variação para cada geração;
- b) bw_{min} é a largura de variação mínima;
- c) bw_{max} é a largura de variação máxima.

Askarzadeh e Zebarjadi (2014) sugeriram um novo método de seleção dos parâmetros da busca harmônica (HS-NPSA), utilizando as Equações 2.31 a 2.33, com o objetivo de substituir o processo realizado manualmente para a seleção dos parâmetros apontados na metodologia adotada por Mahdavi, Fesanghary e Damangir (2007) e Geem, Kim e Loganathan (2001).

$$HCMR = 0,9 + 0,1 \cdot rand(0,1) \quad (2.31)$$

$$PAR = \frac{1 - rand(0,1)}{2} \quad (2.32)$$

$$bw = rand(0,1) \quad (2.33)$$

Onde:

- a) $rand(0,1)$ é o número aleatório no intervalo de zero a um.

2.9.1.3 Busca do Cuco

2.9.1.3.1 Comportamento de criação do cuco

Os pássaros cuco são espécies fascinantes pela sua agressiva estratégia de reprodução. Algumas espécies de cuco colocam seus ovos em ninhos comunais, embora possam remover

os outros ovos com o objetivo de aumentar as chances de incubação de seus próprios ovos. Muitas espécies utilizam o parasitismo de ninhada, depositando seus ovos em ninhos de espécies diferentes denominadas aves hospedeiras. É comum que algumas aves hospedeiras se envolvam em conflito direto com os pássaros cucos, pois se um pássaro hospedeiro descobrir que seu ninho foi invadido e os ovos depositados não são seus, essas aves podem jogar os ovos para fora do ninho ou simplesmente abandoná-lo e construí-lo em outra localidade. Algumas espécies de cuco evoluíram de tal forma que conseguem por ovos de cor e padrão similares aos dos pássaros hospedeiros, reduzindo a probabilidade dos ovos serem abandonados e aumentando as suas chances de sobrevivência. Os pássaros cuco, geralmente, escolhem um ninho onde a ave hospedeira já colocou seus próprios ovos. Em geral, os ovos de cuco eclodem um pouco mais rápido do que o do hospedeiro, e uma vez que o primeiro filhote eclode, a primeira ação instintiva é jogar os outros ovos para fora do ninho, aumentando a quantidade de alimento fornecida pela ave hospedeira (YANG; DEB, 2009).

2.9.1.3.2 Voos Lévy

Abarghooee et al. (2015) apontaram que os animais buscam alimentos, naturalmente, de forma acidental ou quase acidental. Uma vez que, o próximo passo do caminho é baseado na localização atual e na probabilidade de transição para o próximo local, o caminho de busca de um animal é efetivamente uma caminhada aleatória. A direção escolhida depende implicitamente de uma probabilidade que pode ser modelada matematicamente. De acordo com Yang e Deb (2009), vários estudos mostraram que o comportamento de voo de muitos animais e insetos frutíferos demonstrou as características típicas dos voos Lévy. Posteriormente, esse comportamento foi implementado para problemas de otimização, e os resultados preliminares mostraram sua capacidade promissora.

2.9.1.3.3 Algoritmo da busca do cuco (CSO)

Yang e Deb (2009) idealizaram as seguintes regras para o algoritmo:

- a) Cada pássaro cuco põe um ovo por vez e deposita o ovo em um ninho escolhido aleatoriamente;
- b) Os melhores ninhos com ovos de alta qualidade serão transferidos para as próximas gerações;
- c) O número de ninhos hospedeiros disponíveis é fixo, e o ovo colocado por uma ave cuco pode ser descoberto pelo pássaro hospedeiro através de uma probabilidade $P_a \in [0, 1]$.

A busca aleatória global é realizada usando voos Lévy, que é dado pelas equações 2.34, 2.35 e 2.36:

$$x_i^{t+1} = x_i^{(t)} + \alpha \oplus \text{Lévy}(\lambda) \quad (2.34)$$

$$\alpha = \alpha_0 \cdot (x_i^{(t)} - x_{melhor}^{(t)}) \quad (2.35)$$

$$\text{Lévy}(\lambda) \approx u = i^{-\lambda}, (1 < \lambda \leq 3) \quad (2.36)$$

Onde:

- a) x_i^{t+1} é a nova solução (ninho) gerada;
- b) $x_i^{(t)}$ é a solução anterior (ninho antigo);
- c) $\alpha > 0$ é o tamanho do passo que deve estar relacionado às escalas do problema de interesse;
- d) α_0 é uma constante, cujo valor, normalmente, atribuído é 0,01;
- e) $x_{melhor}^{(t)}$ representa a atual melhor solução;
- f) \oplus é um multiplicador de entrada;
- g) $\text{Lévy}(\lambda)$ é o comprimento do passo aleatório extraído da distribuição de Lévy;
- h) i é o número de iteração.

Segundo Jiang, Wang e Wang (2017), o primeiro passo é gerar novas soluções através de voos Lévy e armazenar as melhores soluções comparadas com as soluções atuais. Posteriormente, descarta-se um subconjunto das soluções de acordo com a probabilidade de detecção P_a , simplificando a última regra de (YANG; DEB, 2009). Por fim, obtêm-se novas soluções com o mesmo tamanho que as soluções abandonadas. O ciclo de iteração é fechado quando uma solução melhor foi armazenada. Existem várias maneiras de implementar a distribuição de Lévy, porém uma das maneiras mais simples, de acordo com Yang (2010), é o algoritmo Mantegna para uma distribuição simétrica de Lévy estável. O termo simétrica, citado anteriormente, significa que os passos podem assumir uma valor positivo ou negativo. No algoritmo de Mantegna, o comprimento do passo pode ser calculado através da Equação 2.37:

$$\text{Lévy}(\lambda) = \frac{u \cdot \sigma_u}{|v|^{\frac{1}{\beta}}} \quad (2.37)$$

Onde u e v são retirados de uma distribuição normal. Isso é:

$$u \sim N(0, \sigma_u^2) \quad (2.38)$$

$$v \sim N(0, \sigma_v^2) \quad (2.39)$$

Onde:

$$\sigma_u = \left\{ \frac{\Gamma(1 + \beta) \cdot \sin(\frac{\pi \cdot \beta}{2})}{\Gamma\left[\frac{(1+\beta)}{2}\right] \cdot \beta \cdot 2^{\frac{(\beta-1)}{2}}} \right\}^{\frac{1}{\beta}} \quad (2.40)$$

$$\sigma_v = 1 \quad (2.41)$$

β é o fator de escala e Γ é a função gama que equivale ao cálculo do fatorial de β .

Portanto, o algoritmo CSO assume a forma da 2.42 para gerar uma nova solução.

$$x_i^{t+1} = x_i^{(t)} + \alpha_0 \cdot \frac{u}{|v|^{\frac{1}{\beta}}} \cdot (x_i^{(t)} - x_{melhor}^{(t)}) \quad (2.42)$$

Segundo Jiang, Wang e Wang (2017), quando uma parte das soluções for descartada devido ao critério da probabilidade de detecção P_a , a Equação 2.43 irá gerar novas soluções com o mesmo tamanho que as soluções abandonadas.

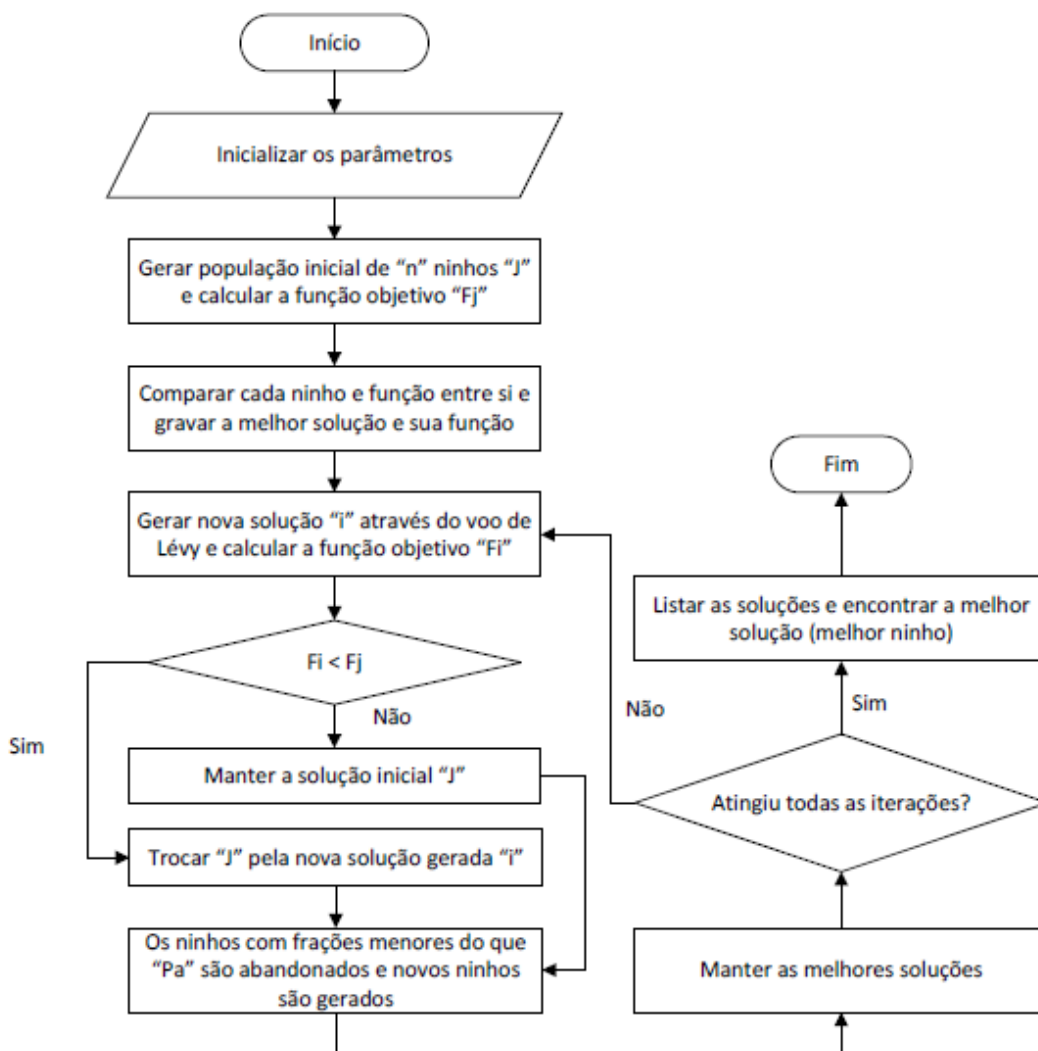
$$x_i^{t+1} = x_i^{(t)} + r \cdot (x_{k1}^{(t)} - x_{k2}^{(t)}) \quad (2.43)$$

Onde:

- a) r é o fator de escala, que é um número aleatório uniformemente distribuído entre 0 e 1;
- b) $x_k^{(t)}$ é selecionado aleatoriamente dentre as soluções existentes do passo anterior.

A Figura 6 apresenta o algoritmo CSO em fluxograma.

Figura 6 – Fluxograma do algoritmo CSO



Fonte: Elaborado pelo autor.

2.9.1.4 Pássaros Migratórios

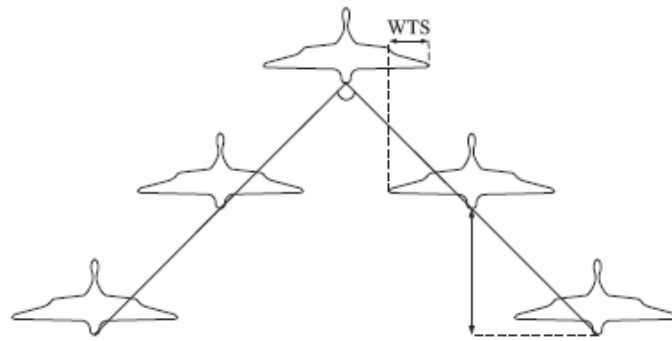
2.9.1.4.1 Comportamento das aves migratórias

A formação em “V” é a formação mais famosa que as aves migratórias usam para voar longas distâncias. O nome se dá devido à semelhança da forma que as aves fazem com a letra “V”, na qual há um líder que guia o bando e duas outras linhas de pássaros seguindo-o. Existem outras formações tais como em coluna, forma de arco e formação em “J”, entre outros. Acredita-se que essa formação seja muito eficiente para os pássaros migratórios.

Duas hipóteses foram propostas no intuito de explicar o uso dessa formação em “V” pelas aves. A primeira hipótese aponta que dessa forma é possível economizar energia durante o

voo, pois quando o pássaro líder se cansa, o seu lugar é ocupado por um dos pássaros que permanecem nas posições posteriores. A segunda hipótese é que a formação em “V” pode refletir um mecanismo pelo qual as aves evitam colisões entre si e permanecem em contato visual como mostra a Figura 7, apresentando o WTS, espaçamento entre a ponta da asa de uma ave e a ponta da asa da ave subsequente (DUMAN; UYSAL; ALKAYA, 2012).

Figura 7 – Esquema de migração dos pássaros



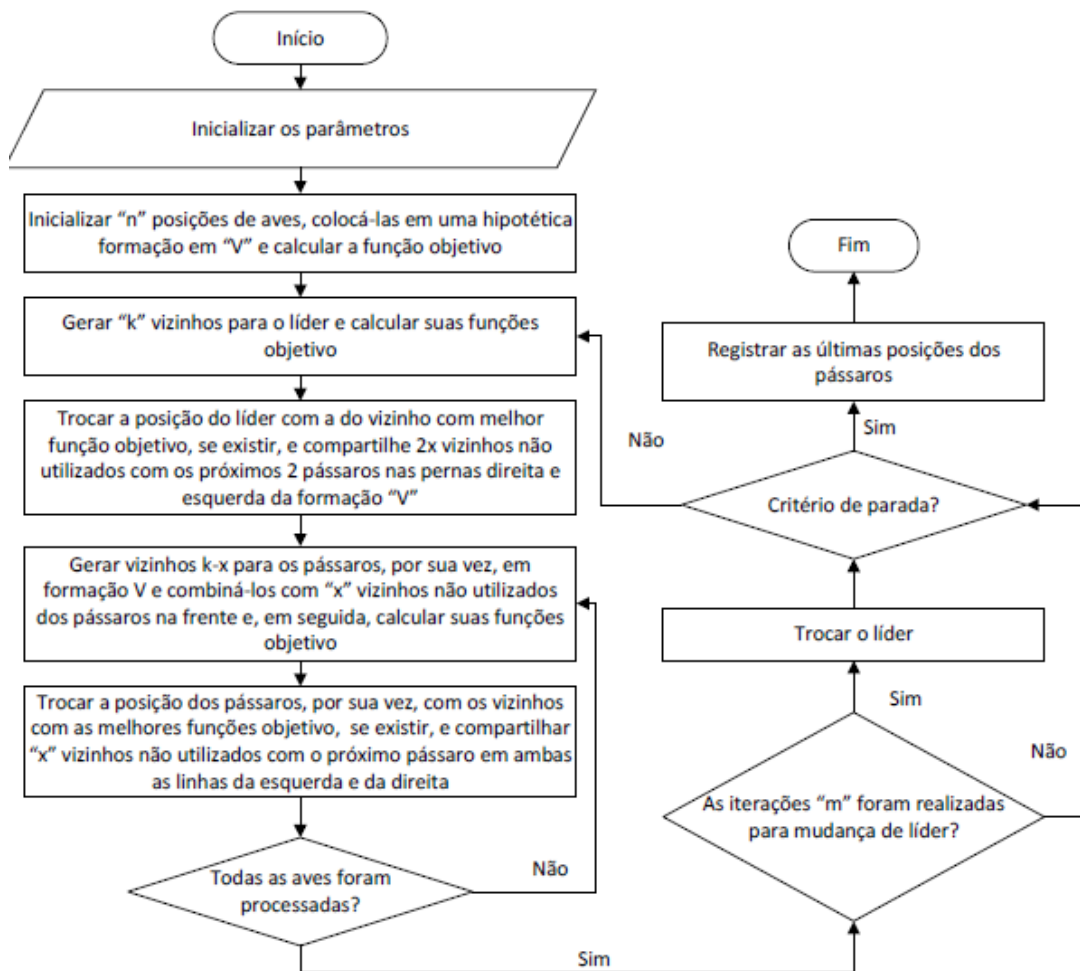
Fonte: Adaptado de Duman, Uysal e Alkaya (2012) pelo autor.

2.9.1.4.2 Algoritmo da otimização dos pássaros migratórios (MBO)

O algoritmo MBO é uma técnica de busca que leva em consideração a vizinhança. Cada ave da formação em “V” representa uma possível solução, inicia-se com a primeira solução, pássaro líder, prosseguindo por todos os outros indivíduos até chegar à última ave na ponta da formação. Cada solução deve ser desenvolvida através das soluções de seus vizinhos e se uma ave vizinha trazer uma solução melhor, ela é automaticamente trocada pela solução inicialmente registrada, a do pássaro líder, da formação. Há um outro mecanismo de eficiência no algoritmo. Este mecanismo transfere as melhores soluções vizinhas não utilizadas para a próxima solução. No algoritmo, esta situação é chamada de compartilhamento dos vizinhos. Desta forma, a solução existente se aprimora usando não só suas próprias soluções produzidas, mas também soluções vizinhas que vêm de outras soluções. Este compartilhamento de vizinhos é concluído com o compartilhamento da solução por todos os pássaros, exceto os dois últimos pássaros localizados nas duas linhas. Este processo continua até ser atingido o número total de iterações (DUMAN; UYSAL; ALKAYA, 2012).

O fluxograma do algoritmo MBO é dado na Figura 8. Os parâmetros do algoritmo MBO são o número de soluções que representam o tamanho do bando de pássaros (n), o número total de soluções vizinhas a serem consideradas (k), o número de soluções vizinhas a serem compartilhadas com a próxima solução (x), o número de turnos para mudar o líder (m) e o número máximo de iterações "K"(MAKAS; YUMUSAK, 2016).

Figura 8 – Fluxograma do algoritmo MBO



Fonte: Adaptado de Makas e Yumusak (2016) pelo autor.

Makas e Yumusak (2016) sugeriram que devido à diversidade da população inicial afetar diretamente o desempenho do algoritmo, a inicialização da posição das aves, que representam as possíveis soluções, é um ponto importante para melhorar a otimização. As posições iniciais são atribuídas através da Equação 2.44:

$$x_{ij} = x_j^{\min} + rand \cdot (x_j^{\max} - x_j^{\min}) \quad (2.44)$$

Onde:

- x_{ij} é a posição da i -ésima solução na dimensão j ;
- x_j^{\min} e x_j^{\max} são valores limite para a dimensão j ;
- $rand$ é um número aleatório que varia entre 0 e 1.

Após a inicialização, uma das soluções é escolhida como líder e todas as soluções geradas são colocadas arbitrariamente em uma hipotética formação em "V". Começando com a primeira solução, que corresponde ao pássaro líder, e progredindo ao longo das linhas para as caudas, o algoritmo MBO tem como objetivo melhorar cada solução usando suas soluções vizinhas.

Makas e Yumusak (2016) geraram os vizinhos "k" através da equação 2.45.

$$\hat{x}_{ij} = x_{ij} + \varphi \cdot (x_{ij} - x_{kj}) \quad (2.45)$$

Onde:

- a) \hat{x}_{ij} é a nova posição vizinha gerada na j-ésima dimensão para a i-ésima solução;
- b) x_{ij} é a posição da i-ésima solução na dimensão j;
- c) k é um valor de índice selecionado aleatoriamente, diferente de i;
- d) x_{kj} é a posição da k-ésima solução na dimensão j;
- e) φ é um número aleatório que varia de (-1, 1).

A Equação 2.45 calcula a criação da vizinhança ao mesmo tempo que realiza uma comparação entre duas posições de pássaros entre parênteses. Ou seja, quanto menor a diferença entre x_{ij} e x_{kj} , mais próximas são as soluções.

Depois da criação desses vizinhos, se a Função Objetivo da solução vizinha apresentar melhor resultado do que a do líder, a posição da solução vizinha é atribuída à solução líder e, em seguida, duas vezes o parâmetro x soluções inutilizadas não compartilhadas são partilhadas com os dois pássaros na segunda linha.

Uma iteração termina após implementar a melhoria para todas as aves. Em resumo, o pássaro líder gasta mais energia criando " k " vizinhos em iterações. No entanto, os pássaros em outras posições se beneficiam dos pássaros na frente e gastam menos energia criando vizinhos ($k-x$) em iterações.

O algoritmo simula o cansaço do pássaro líder depois de realizar um número de iterações (m) anterior. A solução líder é então deslocada para o fim de um lado na hipotética formação "V", e a segunda solução nesse lado é deslocada para a posição líder.

Os parâmetros k e x devem ser adequadamente escolhidos por afetarem diretamente o desempenho do algoritmo. O parâmetro k é inversamente proporcional à velocidade de voo das aves. Se pequenos valores forem escolhidos, assume-se que as aves voam em altas velocidades. Velocidades altas permitem que o algoritmo MBO reduza o tempo de execução total. No entanto, a profundidade de busca do algoritmo aumenta se o parâmetro k aumentar. O parâmetro x representa o benefício dos vórtices gerados através das pontas das asas das

aves após o líder (WTS). Uma vez que o compartilhamento dos vizinhos do algoritmo MBO é definido como o número de soluções de bons vizinhos obtidas a partir da solução predecessora, valores elevados de x fazem com que as soluções sejam semelhantes entre si. Assim, a convergência prematura pode acontecer (DUMAN; UYSAL; ALKAYA, 2012).

2.9.1.5 Algoritmo de Competição Imperialista

2.9.1.5.1 Comportamento da Competição Imperialista

O imperialismo é uma política de extensão do poder de um governo além dos limites de seu território. A expansão se dá através da conquista de outros territórios chamados de colônias. Quanto maior for o poder de um país imperialista, mais chance terá de adquirir mais colônias, enquanto que os países mais fracos terão mais chances de perder colônias ou até mesmo deixar de ser um país imperialista.

Um país imperialista juntamente com suas colônias forma um império, cujo o poder total é a soma do poder imperialista mais o poder de suas colônias. Dessa forma, os impérios com maior poder podem conquistar outros impérios com um poder menor, os quais serão extintos durante o processo. Se uma colônia adquirir um poder maior que de um país imperialista, a colônia tomará o lugar do país. O objetivo é que um conjunto de países convirjam para um único império onde, espera-se que esteja o ponto ótimo da função objetivo (ATASHPAZ-GARGARI; LUCAS, 2007).

2.9.1.5.2 Algoritmo de Competição Imperialista (ICA)

No Algoritmo de Competição Imperialista, os países são representados por um matriz de dimensão $1 \times N_{var}$, Equação 2.46:

$$países = (p_1, p_2, p_3, \dots, p_{N_{var}}) \quad (2.46)$$

Onde:

- a) N_{var} é o número de variáveis do problema.

O custo de um país, Equação 2.47, é dado pelo cálculo da função objetivo através de suas variáveis.

$$custo = f(países) = (p_1, p_2, p_3, \dots, p_{N_{var}}) \quad (2.47)$$

O algoritmo é iniciado quando o tamanho da população N_{pop} for gerada. N_{imp} representa os países mais poderosos que formarão um império. Os imperialistas serão os países com os menores custos, pois o algoritmo é de minimização. N_{col} representa a população de colônias que pertencerão a cada império. As colônias serão distribuídas entre os imperialistas de acordo com seus respectivos poderes. Para isso, é definido um custo normalizado de acordo com a Equação 2.48:

$$C_n = c_n - \max_i(c_i) \quad (2.48)$$

Onde c_n é o custo do n-ésimo imperialista e C_n é o custo normalizado. A partir do custo normalizado é definido o poder normalizado p_n de um imperialista através da Equação 2.49:

$$p_n = \frac{|C_n|}{|\sum_{i=1}^{N_{imp}} c_i|} \quad (2.49)$$

O poder normalizado de um imperialista representa a quantidade de colônias iniciais que serão atribuídas a ele, dado pela Equação 2.50:

$$N \cdot C_n = \text{round}(p_n \cdot N_{col}) \quad (2.50)$$

Onde $N \cdot C_n$ é o número inicial de colônias que o i-ésimo imperialista irá possuir e a operação *round* atribui um valor inteiro mais próximo. Os impérios são formados a partir de um imperialista com suas respectivas colônias. A operação principal do algoritmo de busca por novas soluções é a movimentação das colônias em relação aos imperialistas, pois a cada iteração todas as colônias se movimentam em direção aos seus respectivos imperialistas. Esse movimento é regido por dois parâmetros do algoritmo: o coeficiente de assimilação (γ) e o Coeficiente angular de Assimilação (δ). A Equação 2.51 descreve a movimentação.

$$pos_{i+1} = pos_i + \delta \cdot \gamma \cdot d \quad (2.51)$$

Onde:

- a) pos_i é o vetor de posicionamento das colônias;
- b) $\gamma > 1$;
- c) δ é um valor entre 0 e 1;
- d) d é a distância entre a colônia e o seu imperialista.

O custo total de um império é dado pelo custo do imperialista mais uma parte do custo total de suas colônias de acordo com a Equação 2.52.

$$T \cdot C_n = \text{Custo}(\text{imperialista}) + \varepsilon \cdot \text{média}\{\text{custo}(\text{colônias do imperialista})\} \quad (2.52)$$

Onde:

- a) $T \cdot C_n$ é o custo total do império;
- b) ε é um valor entre 0 e 1.

Através da revolução é ainda possível que uma colônia mude para uma nova posição que é gerada aleatoriamente. A probabilidade de isso acontecer se deve a um parâmetro ajustável denominado taxa de revolução, a qual indica que as características socio-políticas de um país mudam.

A competição imperialista acontece quando a colônia mais fraca do império considerado mais fraco pode ser conquistada por outro império com maior chance de adquiri-la. Nesse caso, é definido o custo normalizado dos impérios de acordo com a Equação 2.53.

$$N \cdot T \cdot C_n = T \cdot C_n - \max_i(T \cdot C_i) \quad (2.53)$$

Onde:

- a) $N \cdot T \cdot C_n$ é o custo normalizado do n-ésimo império cujo o valor deve maior que zero;
- b) $\max_i(T \cdot C_i)$ é o custo total do império com maior custo total de todos.

Com isto, a probabilidade de posse P_{pn} para cada império é dada pela Equação 2.54:

$$P_{pn} = \frac{|N \cdot T \cdot C_n|}{|\sum_{i=1}^{N_{imp}} N \cdot T \cdot C_i|} \quad (2.54)$$

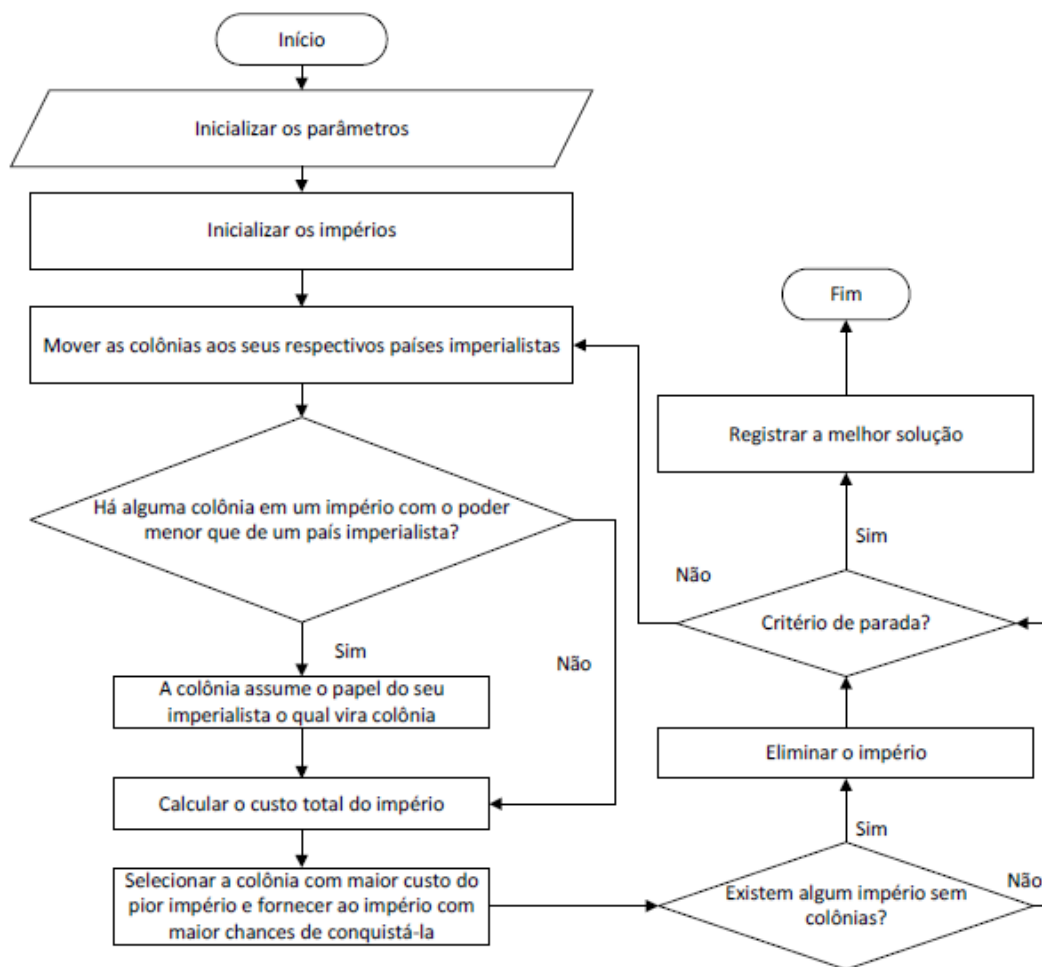
O vetor P , $(p_{p1}, p_{p2}, p_{p3}, \dots, p_{N_{imp}})$, é definido como as probabilidades de posse de cada império e o vetor R , $(r_1, r_2, r_3, \dots, r_n)$, do tamanho de P , com números aleatórios distribuídos uniformemente entre 0 e 1. O vetor D é definido pela subtração de P por R : $D=P-R=(D_1, D_2, D_3, \dots, D_{N_{imp}})$.

O império que tiver o índice do maior valor de D possuirá a colônia. Por conseguinte, o algoritmo analisará se há algum império sem colônias, se houver, o império será extinto. Depois de atingir um certo número de iterações, todos os impérios serão extintos, exceto o

mais poderoso, o qual possuirá todas as colônias sob seu domínio e todas as colônias estarão na mesma posição que a do imperialista, finalizando o algoritmo (ATASHPAZ-GARGARI; LUCAS, 2007).

A Figura 9 apresenta o fluxograma do Algoritmo de Competição Imperialista.

Figura 9 – Fluxograma do algoritmo ICA



Fonte: Elaborada pelo autor.

2.9.1.6 Otimização por Colônia de Formigas

2.9.1.6.1 Comportamento da Colônia de formigas

Algumas espécies de formigas são completamente cegas e outras possuem apenas uma visão desenvolvida rudimentarmente. De fato, a comunicação entre a maioria dos indivíduos, ou entre indivíduos e o meio ambiente, é baseada no uso de produtos químicos, chamado feromônio, produzidos pelas formigas.

O feromônio de trilha é um tipo específico de feromônio que algumas espécies de formigas usam para marcar caminhos no solo, por exemplo, o caminho entre a fonte de alimento e o ninho. Ao detectar trilhas de feromônio, as formigas forrageiras podem seguir o caminho trilhado por outras formigas até a fonte de alimento. Esse comportamento coletivo de trilha no qual uma formiga é influenciada por uma trilha química inspirou o método de otimização por colônias de formigas (DORIGO; STÜTZLE, 2004).

As primeiras formigas ao farejarem o feromônio tendem a escolher, probabilisticamente, as trilhas marcadas com fortes concentrações de feromônio. O segundo grupo de formigas perceberá mais intenso o caminho mais curto, devido ao menor tempo de evaporação. Com a continuação desse procedimento por todas as formigas, quantas vezes forem necessárias até que toda a comida seja levada ao formigueiro, ocorre a vaporização e o depósito de feromônio por onde as formigas transitarem. Em certo momento desse processo, um dos caminhos se destaca por ser o mais frequentado, sendo assinalado pela intensidade de feromônio e densidade de formigas superior aos demais. Neste ponto, define-se o melhor caminho encontrado pelas formigas (DORIGO; STÜTZLE, 2004).

2.9.1.6.2 Abordagens da Otimização da Colônia de formigas


Azevedo (2015) citou em seu trabalho duas abordagens de otimização por colônia de formigas, sendo uma apresentada por Toksari (2006) e a outra por Socha (2009). Nesse trabalho, a abordagem do método da colônia de formigas, utilizada por Toksari (2006), forneceu resultados diversos devido à variação dos seus parâmetros de calibração, enquanto que a abordagem utilizada por Socha (2009) não apersentou resultados alterados pela manipulação dos seus parâmetros. Azevedo (2015) considerou a aplicação desse último método mais segura e os ajustes mais consistentes.

2.9.1.6.3 Abordagem segundo Socha (2009)

O método ACO funciona através do qual cada formiga caminha entre os pontos do conjunto de entrada e deposita feromônio a cada aresta que liga esses pontos. A seleção do próximo ponto é realizada de forma probabilística, levando em consideração a quantidade de feromônio na aresta, juntamente com a informação heurística.

Segundo Azevedo (2015), para este método, os parâmetros k e c da curva de Weibull, alvo dessa otimização, devem formar um plano cartesiano que será dividido em N partes iguais. O ponto central de cada nova área será um par ordenado (k, c) em que se avaliará o ajuste da curva, conforme a Figura 10.

Figura 10 – Amostra do plano cartesiano discretizado



Fonte: Azevedo (2015)

A probabilidade de ocorrência de cada retículo é definida pela Equação 2.55:

$$P_r = \frac{\tau_r}{\sum_{r=1}^R \tau_r} \quad (2.55)$$

Onde τ_r é a intensidade de feromônio referente ao retículo r . Cada formiga é, então, posicionada aleatoriamente no plano através de sorteio por roleta, onde cada fatia da roleta representa um retículo e é definida pela probabilidade de ocorrência, até então igual para todas as fatias.

O sorteio por roleta tem o seguinte algoritmo:

- a) Atribui-se um número sequencial a cada retículo;
- b) Calcula-se a probabilidade de ocorrência de cada um dos retículos;
- c) Partindo do zero, somam-se as probabilidades de cada retículo ao seu antecessor até chegar ao valor 1; e
- d) Através de um gerador de valores aleatórios, sorteia-se um valor entre 0 e 1, e a fatia escolhida será aquela que contiver este valor.

Na inicialização do algoritmo, como não há formigas posicionadas nos retículos, a matriz com os valores de feromônio de cada retículo será definida atribuindo-se os valores iguais a 1.

Os quadrantes visitados são assinalados pelo depósito de feromônio, segundo a Equação 2.56. A cada iteração a quantidade do hormônio também é reduzida a uma taxa constante para simular a volatilidade do hormônio, conforme a Equação 2.57:

$$\tau_{i,r} = \tau_{i-1,r} + \left(\frac{\mu}{err_f} \right) \quad (2.56)$$

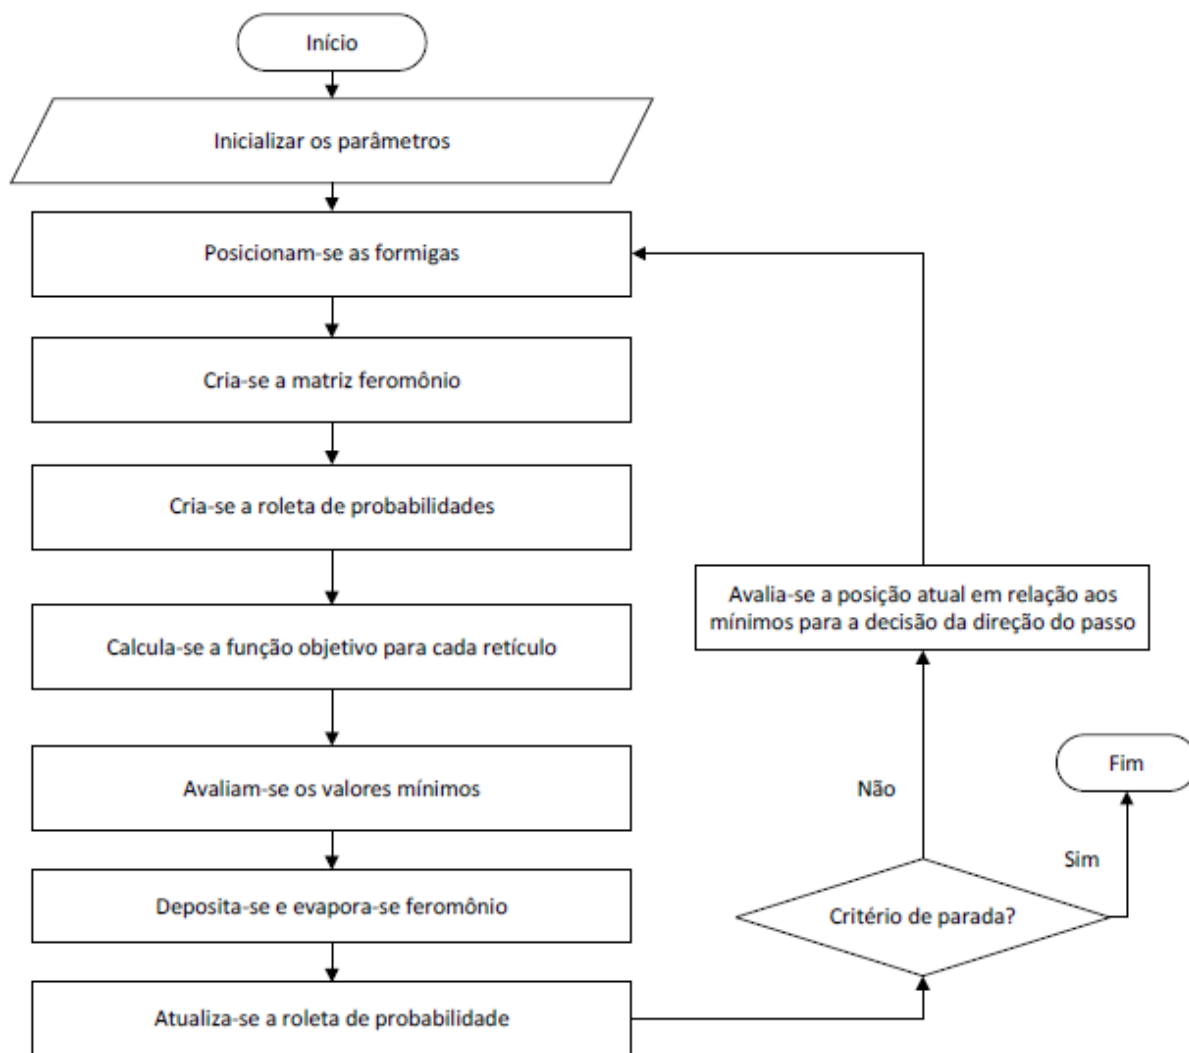
$$\tau_{i,r} = \rho \cdot \tau_{i,r} \quad (2.57)$$

Onde:

- a) $\tau_{i,r}$ é a intensidade de feromônio referente ao retículo r, na iteração i;
- b) err_f é o erro avaliado pela formiga f;
- c) μ é a constante de deposição; e,
- d) ρ é a constante de evaporação.

Neste ponto, atualizam-se as matrizes de feromônio, probabilidade, e repete-se o processo de escolha e avaliação de erro. Ao passo em que as iterações se sucedem, alguns retículos serão mais atraentes para as formigas por terem grande quantidade de feromônio, sendo esta atração simbolizada pelas maiores fatias da roleta, até que a maioria das formigas seguirá pelo mesmo caminho, caracterizando a convergência do método. A Figura 11 resume o procedimento ACO de forma geral.

Figura 11 – Algoritmo para o procedimento ACO apresentado por Socha (2009)




Fonte: Azevedo (2015).

3 METODOLOGIA

3.1 Dados de vento

Os testes com dados reais foram executados, utilizando 52.560 valores de velocidade. Essa quantidade de valores de velocidade está de acordo com a norma IEC 61400 PART 12-1 (2005a) que define 1 (um) ano de dados integrados com medições de velocidade médias ao longo de períodos de 10 minutos, como período mínimo para caracterização dos ventos de uma região. Os testes foram realizados com dados públicos do projeto Sistema de Organização de Dados Ambientais (SONDA), do Governo Federal, referentes às estações TRI23, situada em Triunfo com latitude de $07^{\circ} 49' 38''S$, longitude de $38^{\circ} 07' 20''O$, dados coletados em 2006, altitude de 1123 metros, cujo clima é o tropical de altitude que predomina nos planaltos e serras no sertão de Pernambuco e SCR25, em São João do Cariri com latitude $07^{\circ} 22' 54''S$ e Longitude $36^{\circ} 31' 38''O$, altitude de 718 metros, dados coletados no ano de 2008, cujo clima predominante é o semiárido, caracterizado pela baixa umidade e pouco volume pluviométrico no estado da Paraíba, ambas a 50 metros do nível do solo e com um ano completo de dados. A Figura 12 apresenta a localização das duas cidades estudadas.

Figura 12 – Localização das cidades de Triunfo - PE e São João do Cariri - PB



Fonte: Google maps, 2018.

3.1.1 Tratamento de dados

Os dados de cada local foram separados em intervalos com variação de 1 m/s, onde, para se encaixar no intervalo, a velocidade deve ser superior ao valor inferior do intervalo e menor ou igual ao valor superior, excetuando o primeiro intervalo onde: $0 \text{ m/s} \leq V \leq 1 \text{ m/s}$. Depois de separados, foi contada a quantidade total de dados dentro de cada intervalo, sendo que esta quantidade de cada intervalo foi dividida pelo número total de dados, gerando, assim, um valor de frequência relativa para cada intervalo. Os dados foram validados por uma metodologia do projeto SONDA, que não altera os bancos de dados, eliminando dados considerados inválidos pelo processo, apenas sinaliza os dados considerados como suspeitos para que o usuário decida a utilização ou não destes. Os dados coletados através do projeto SONDA para a cidade de Triunfo e São João do Cariri contabilizavam um total de 52.560 e 52.704, respectivamente, entretanto após o tratamento foi considerado um total de 52.560 e 52.662 dados, representando um aproveitamento de 100% e de 99,92%.

Vale ressaltar que foi utilizado um algoritmo, elaborado na linguagem R, para retirar dados não numéricos, como *NA (Not Available)* e *NAN (Not A Number)* e valores negativos, descartados para a elaboração do histograma.

3.2 Linguagem R

R é uma linguagem voltada para a manipulação de dados, cálculos e apresentação gráfica. Possui um ambiente de programação que se preocupa com a flexibilidade, com a capacidade de manipulação de dados e com a realização de análises.

O RStudio é uma interface de desenvolvimento integrado, de código livre, para utilização da linguagem R. Tem como principal função agilizar o uso da linguagem, disponibilizando bibliotecas e organizando o ambiente de trabalho de forma mais produtiva (RSTUDIO, 2015).

Todas as funções heurísticas foram elaboradas utilizando a linguagem R e o RStudio como interface.

3.3 Função Objetivo

É válido enfatizar que todo procedimento de otimização busca o melhor resultado de uma função para o cenário desejado e essa função recebe o nome de Função Objetivo. No caso dos métodos heurísticos que foram utilizados, foram avaliadas três Funções Objetivo diferentes. Os testes foram realizados nas duas regiões estudadas e o desempenho atestado através de testes estatísticos.

A Equação 3.1 apresenta a minimização da soma do erro quadrado aplicada aos valores de frequência de ocorrência (E.Q) encontrados pela curva ajustada pelo método e a frequência

de ocorrência observada no histograma dos dados testados.

$$\epsilon^2 = \sum_{i=1}^n (f_{ajuste} - f_{observado})^2 \quad (3.1)$$

Onde n é o número de intervalos de velocidade do histograma e f_{ajuste} e $f_{observado}$ são as frequências de ocorrência pela curva ajustada e observadas no histograma, respectivamente. Busca-se com a Equação 3.1 um algoritmo no qual os resultados deem ênfase na aproximação da curva de Weibull do histograma de dados.

A Equação 3.2 apresenta a minimização do erro quadrado aplicado aos valores de desvio de produção (E.W) entre a curva ajustada e o histograma dos dados.

$$\epsilon^2 = \left(\frac{WPD_{estimado} - WPD_{medido}}{WPD_{medido}} \right)^2 \quad (3.2)$$

Onde $WPD_{estimado}$ e WPD_{medido} são os desvios de produção pela curva ajustada e observada no histograma, respectivamente. Busca-se com a Equação 3.2 um algoritmo no qual os resultados deem ênfase na produção energética da região.

A Equação 3.3 apresenta a soma da minimização do erro quadrado aplicada aos valores de frequência de ocorrência com a minimização do erro quadrado aplicado aos valores de desvio de produção (E.Q.W).

$$\epsilon^2 = \sum_{i=1}^n (f_{ajuste} - f_{observado})^2 + \left(\frac{WPD_{estimado} - WPD_{medido}}{WPD_{medido}} \right)^2 \quad (3.3)$$

Busca-se com a equação 3.3 um algoritmo que gere resultados com valores intermediários entre a aproximação da curva de Weibull do histograma de dados e a produção energética da região.

Os resultados das funções heurísticas com a aplicação da Função Objetivo selecionada para cada método serão avaliados através de testes estatísticos e do valor percentual do desvio de produção.

3.4 Cálculo dos testes estatísticos

Os testes escolhidos para avaliar o desempenho dos ajustes foram a Raiz do Erro Quadrático Médio (RMSE) (Equação 3.4), o Erro Médio Absoluto (MAE) (Equação 3.5) e o Coeficiente de determinação R^2 (Equação 3.6), a serem aplicados para avaliar os valores da curva e do histograma. Além destes, o valor percentual do Desvio de Produção Eólica (WPD) entre a curva e o histograma também será avaliado (Equação 3.7).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i^{\text{calculado}} - y_i^{\text{medido}})^2}{n}} \quad (3.4)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i^{\text{calculado}} - y_i^{\text{medido}}| \quad (3.5)$$

$$R^2 = \frac{\sum_{i=1}^n (y_i^{\text{medido}} - \bar{y}^{\text{medido}})^2 - \sum_{i=1}^n (y_i^{\text{medido}} - y_i^{\text{calculado}})^2}{\sum_{i=1}^n (y_i^{\text{medido}} - \bar{y}^{\text{medido}})^2} \quad (3.6)$$

Onde n é o número de observações, $y_i^{\text{calculado}}$ é frequência de Weibull, \bar{y}^{medido} é a média da frequência das observações e y_i^{medido} é a frequência das observações.

$$WPD = \frac{WPD_{\text{estimado}} - WPD_{\text{medido}}}{WPD_{\text{medido}}} \cdot 100 \quad (3.7)$$

Onde, de acordo com Jamil, Parsa e Majidi (1995), WPD_{medido} and WPD_{estimado} são calculados pelas Equações 3.8 and 3.9

$$WPD_{\text{medido}} = \frac{1}{2} \cdot \rho \cdot c^3 \cdot \Gamma\left(1 + \frac{3}{k}\right) \quad (3.8)$$

$$WPD_{\text{estimado}} = \frac{1}{2} \cdot \rho \cdot v^3 \quad (3.9)$$

Onde ρ é a massa específica do ar, v é a velocidade do vento, Γ é a função gama, k é o fator de forma e c é o fator de escala.

3.5 Geração dos gráficos

3.5.1 *Curva de densidade*

As curvas de densidade de probabilidade foram sobrepostas ao histograma dos dados testados, de forma a verificar visualmente o desempenho do ajuste. É importante verificar que a proximidade da curva da distribuição de Weibull gerada através dos métodos heurísticos com os picos do histograma da velocidade do vento de cada região determina o desempenho do ajuste para os testes RMSE, MAE e R^2 , enquanto o teste do WPD investiga o valor da média da velocidade cúbica prevista pelo histograma, independente de onde está localizada a subestimativa ou sobreestimativa.

3.5.2 *Curva de inversão logarítmica*

A avaliação dos resultados foi feita com o auxílio das curvas de Weibull obtidas pelo ajuste, assim como pela abordagem da inversão logarítmica, que trata os dados de velocidade em forma de uma curva ascendente pela aplicação, por duas vezes, do logaritmo sobre função de densidade acumulada ($\text{Log}[-\text{Log}(F(v))]$). Esta forma de visualização facilita a análise do ajuste da curva sobre os pontos.

3.6 Parâmetros aplicados aos métodos heurísticos

Cada método heurístico depende de um certo número de parâmetros, sendo necessário o seu ajuste para reduzir a resposta de tempo computacional que leva à convergência para os valores ótimos. Vale a pena ressaltar que o ajuste desses parâmetros não tem efeito sobre o resultado final. Os parâmetros aqui aplicados, apresentados na Tabela 2, foram extraídos das obras cujos autores usaram os métodos propostos em diversas aplicações (BARBOSA, 2015), (WANG; WANG; WU, 2016), (RAHMANI et al., 2013), (ATASHPAZ-GARGARI; LUCAS, 2007), (BENHALA; BOUATTANE, 2014) e (TONGUR; ÜLKER, 2014).

Tabela 2 – Parâmetros aplicados aos métodos heurísticos

Autor	Método	Parâmetros	
Barbosa, 2015	HS	N_h	6,0
Wang; Wang; Wu, 2016	CSO	N_n	50
		P_a	0,25
Rahmani et al., 2013	PSO	N_p	30
		w_i	1,8
		w_f	0,2
		c_1	1,0
		c_2	1,0
Atashpaz-Gargari; Lucas, 2007	ICA	N_{pop}	20
		N_{imp}	3,0
		T_{rev}	0,3
Benhala; Bouattane, 2014	ACO	N_f	100
		μ	0,2
		ρ	0,1
Tongur; Ülker, 2014	MBO	n	51
		k	3,0
		x	1,0
		m	10

Fonte: Elaborado pelo Autor.

3.7 Seleção dos parâmetros dos métodos heurísticos

A seleção dos parâmetros dos métodos foram realizados com os dados reais, aplicando os parâmetros do item 3.7 e se deu através do seguinte procedimento:

- Utilizou-se os parâmetros extraídos de trabalhos citados na Tabela 2 como ponto de partida;
- Estabeleceu-se 50% do valor do parâmetro inicial como limite superior e inferior para a realização dos testes, pois foi necessário estabelecer um critério inicial que limitasse a infinidade de avaliações dos parâmetros;
- Variou-se 10% do valor do parâmetro inicial, arredondado para o maior valor inteiro, caso necessário, até o limite superior e inferior, devido à infinidade de números que poderiam ser testados;
- Selecionou-se os parâmetros que apresentaram o menor valor da Função Objetivo e do número de iterações, pois utilizou-se como critério a redução do tempo de processamento computacional do algoritmo.

3.8 Teste de desempenho dos métodos heurísticos

Os testes de desempenho dos métodos foram realizados com os dados reais após a seleção dos parâmetros de cada método e se deu através do seguinte procedimento:

- a) Utilizou-se os parâmetros selecionados de acordo com os critérios do item 3.8;
- b) Aplicou-se os testes de RMSE, MAE, R^2 para os parâmetros selecionados, para cada par (k, c) e calculou-se o WPD;
- c) Gerou-se uma tabela comparativa de k , c , RMSE, MAE, R^2 e WPD;
- d) Para cada método, criou-se a curva de Weibull e a curva de inversão logarítmica.

4 RESULTADOS E DISCUSSÕES

4.0.1 Seleção da Função Objetivo

As tabelas 3 e 4 apresentam os resultados, aplicados na cidade de Trinfo e São João do Cariri respectivamente, dos testes das três Funções objetivo utilizadas nos métodos heurísticos estudados.

Tabela 3 – Análise estatística da Função Objetivo dos métodos heurísticos para a cidade de Triunfo - PE

Método	Função Objetivo	RMSE	MAE	R ²	WPD[%]
PSO	E.Q	0,001034	0,004310	0,964724	10,875590
PSO	E.W	0,003003	0,012239	0,702464	-27,498352
PSO	E.Q.W	0,000766	0,002936	0,980623	0,557381
HS	E.Q	0,000695	0,002831	0,984060	-0,327501
HS	E.W	0,001930	0,006945	0,877154	0,042708
HS	E.Q.W	0,000785	0,002969	0,979635	0,702544
CSO	E.Q	0,000694	0,002822	0,984081	-0,325351
CSO	E.W	0,022164	0,055598	-15,200385	-2,04 · 10 ⁻¹⁰
CSO	E.Q.W	0,000695	0,002814	0,984069	-0,008930
ICA	E.Q	0,000694	0,002822	0,984081	-0,324294
ICA	E.W	0,012920	0,041805	-4,505384	-0,076617
ICA	E.Q.W	0,000695	0,002814	0,984066	0,024956
ACO	E.Q	0,000694	0,002821	0,984081	-0,322802
ACO	E.W	0,002380	0,008816	0,813085	0,000257
ACO	E.Q.W	0,000695	0,002805	0,984051	0,016961
MBO	E.Q	0,000695	0,002821	0,984081	-0,322802
MBO	E.W	0,000756	0,002923	0,981151	0,000000
MBO	E.Q.W	0,000695	0,002813	0,984069	-0,008967

De acordo com a Tabela 3 para a cidade de Triunfo, constatou-se que a Função Objetivo (E.Q.W) para o método PSO apresentou desempenho superior nos testes RMSE, MAE, R² e WPD em relação às Funções Objetivo (E.Q) e (E.W). Portanto, a função (E.Q.W) para o método PSO foi selecionada, destaque em negrito, por apresentar os menores valores

de RMSE, MAE e WPD, e o maior valor de R^2 . A função (E.Q) para o método HS foi selecionada, destaque em negrito, devido ao bom desempenho nos testes estatísticos e do WPD em comparação aos resultados das outras funções. A Função Objetivo (E.Q.W) para os métodos CSO, ICA, ACO e MBO, destacados em negrito, produziu valores com magnitudes similares nos testes estatísticos em relação a função (E.Q) e desempenho superior em relação a função (E.W). Em relação ao teste WPD, a função (E.Q.W) apresentou resultados similares ou melhores do que a função (E.W).

Tabela 4 – Análise estatística da função objetivo dos métodos heurísticos para São João do Cariri

Método	Função Objetivo	RMSE	MAE	R^2	WPD[%]
PSO	E.Q	0,001141	0,003439	0,993522	11,858317
PSO	E.W	0,019592	0,053740	-0,907461	$1,72 \cdot 10^{-9}$
PSO	E.Q.W	0,001829	0,005515	0,983362	0,059573
HS	E.Q	0,001145	0,003346	0,993480	2,132087
HS	E.W	0,041587	0,095123	-7,594243	-0,002714
HS	E.Q.W	0,002233	0,006437	0,975219	0,977815
CSO	E.Q	0,001141	0,003436	0,993522	11,879632
CSO	E.W	0,050139	10,575063	-11,492359	$-2,45 \cdot 10^{-9}$
CSO	E.Q.W	0,001734	0,543062	0,985096	0,312602
ICA	E.Q	0,001141	0,003440	0,993521	11,828390
ICA	E.W	0,009278	0,268761	0,572167	0,341304
ICA	E.Q.W	0,001731	0,005420	0,985096	0,336862
ACO	E.Q	0,001142	0,003431	0,993522	11,902135
ACO	E.W	0,030585	0,075310	-3,648393	-1,069204
ACO	E.Q.W	0,001726	0,005365	0,985180	0,397675
MBO	E.Q	0,001141	0,003436	0,993522	11,879632
MBO	E.W	0,011783	0,033758	0,310064	0,000000
MBO	E.Q.W	0,001734	0,005430	0,985058	0,3126025

Observou-se na Tabela 4 que a Função Objetivo, (E.Q.W), produziu valores com melhor desempenho nos testes estatísticos do que as funções (E.Q) e (E.W). No entanto, a função (E.Q) não teve um bom desempenho, uma vez que os valores de WPD obtidos foram cerca de 12% que, segundo Azevedo (2015), erros acima de 2% no teste do WPD pode restringir o uso dos métodos a avaliações preliminares para padrões de geração de energia. A Função Objetivo

(E.W) apresentou resultados opostos em relação a função (E.Q), devido ao desempenho baixo apresentado nos testes estatísticos e um bom desempenho no teste WPD. A Função Objetivo (E.Q.W), apresentou valores intermediários de RMSE, MAE, R^2 e WPD em comparação as outras funções.

Pode-se concluir que a Função Objetivo (E.Q.W) foi selecionada, destaque em negrito, para todos os métodos heurísticos, devido aos resultados da função (E.Q), mostrando um valor de WPD maior do que 2%, acima do limite aceitável para o desvio da produção de energia. Além disso, os resultados da função (E.W) não obtiveram bom desempenho nos testes estatísticos.

A importância da aplicação da Função Objetivo nos métodos heurísticos também foi confirmada, pois foi possível verificar que essa seleção pode ter impacto e tornar o método inviável para a avaliação da produção de energia eólica.

4.0.2 Seleção dos parâmetros para os métodos

O método HS foi inicialmente testado utilizando os parâmetros da Tabela 2 sugeridos por Barbosa (2015). Em seguida, a seleção dos parâmetros do método foi realizada por partes, variando um parâmetro por vez conforme a Tabela 5:

Tabela 5 – Parâmetros do método HS

Parâmetro	Valor Mínimo	Valor Máximo	Intervalo
N_h	3	9	1

A Tabela 6 apresenta os resultados da seleção dos parâmetros para o método de acordo com os critérios do item 3.9 para as cidades de Triunfo-PE e São João do Cariri-PB.

Tabela 6 – Resultados da seleção dos parâmetros para o método HS

Estação	N_h	k	c	Valor da Função Objetivo	Nº de Iterações
TRI23	3	3,1960	15,1302	0,000378	862
SCR25	5	2,3672	5,8766	0,000608	467

De acordo com os resultados da Tabela 19 e 20, referente a Triunfo e São João do Cariri, localizada no Apêndice A, observou-se que os valores da Função Objetivo e do número de iterações apresentaram uma sensibilidade alta em relação à variação do parâmetro, número de harmonias, isto é, a mudança no valor do parâmetro implicou em alterações significativas no tempo convergência.

O método CSO foi inicialmente testado utilizando os parâmetros da Tabela 2 sugeridos por Wang, Wang e Wu (2016). Em seguida, a seleção dos parâmetros do método foi realizada por partes, variando um parâmetro por vez, conforme a Tabela 7:

Tabela 7 – Parâmetros do método CSO

Parâmetro	Valor Mínimo	Valor Máximo	Intervalo
N_n	25	75	5
P_a	0,125	0,375	0,025

A Tabela 8 apresenta os resultados da seleção dos parâmetros para o método de acordo com os critérios do item 3.9 para as cidades de Triunfo-PE e São João do Cariri-PB.

Tabela 8 – Resultados da seleção do parâmetros para o método CSO

Estação	N_n	P_a	k	c	Valor da Função Objetivo	Nº de Iterações
TRI23	55	0,275	3,1911	15,1457	0,000379	90
SCR25	30	0,250	2,3896	5,8897	0,000599	43

Observou-se, a partir dos resultados das Tabelas 21 a 24 localizadas no Apêndice A, que os valores da Função Objetivo não apresentaram sensibilidade em relação à variação dos parâmetros, número de ninhos e probabilidade de detecção, ou seja, a mudança no valor desses parâmetros não implicou em alterações no tempo de convergência. Mas, para o número de iterações houve uma sensibilidade alta em relação à variação dos parâmetros.

Constatou-se que o método CSO mostrou-se ser um algoritmo robusto, pois durante os testes com a variação dos parâmetros, os valores de fator de escala, fator de forma e da Função Objetivo não apresentaram variação numérica.

O método ICA foi inicialmente testado utilizando os parâmetros da Tabela 2 sugeridos por Atashpaz-Gargari e Lucas (2007). Em seguida, a seleção dos parâmetros do método foi realizada por partes, variando um parâmetro por vez conforme a Tabela 9:

Tabela 9 – Parâmetros do método ICA

Parâmetro	Valor Mínimo	Valor Máximo	Intervalo
N_{pop}	10	30	2
N_{imp}	2	5	1
T_{rev}	0,15	0,45	0,03

A Tabela 10 apresenta os resultados da seleção do parâmetros para o método de acordo com os critérios do item 3.9 para as cidades de Triunfo-PE e São João do Cariri-PB.

Tabela 10 – Resultados da seleção do parâmetros para o método ICA

Estação	N_{pop}	N_{imp}	T_{rev}	k	c	Função Objetivo	Nº de Iterações
TRI23	30	3	0,42	3,1958	15,1492	0,000379	192
SCR25	26	3	0,30	2,3902	5,8905	0,000599	100

Consoante com os resultados das Tabelas 25 e 27 para Triunfo localizadas no Apêndice A, percebeu-se que os valores da Função Objetivo apresentaram sensibilidade baixa em relação à variação dos parâmetros, número de países e taxa de revolução. Contudo, de acordo com os resultados da Tabela 26, o valor da Função Objetivo não apresentou sensibilidade em relação à variação do parâmetro, número de imperialistas. Vale ressaltar que para o número de iterações houve uma sensibilidade alta em relação à variação dos três parâmetros.

Em relação aos resultados das Tabelas 28 a 30 para São João do Cariri, observou-se que os valores da Função Objetivo não apresentaram sensibilidade em relação à variação dos parâmetros, número de países, número de imperialistas e taxa de revolução. Mas, para o número de iterações houve uma sensibilidade alta em relação à variação dos parâmetros.

O método PSO foi inicialmente testado utilizando os parâmetros da Tabela 2 sugeridos por Rahmani et al. (2013). Em seguida, a seleção dos parâmetros do método foi realizada por partes, variando um parâmetro por vez conforme a Tabela 11:

Tabela 11 – Parâmetros do método PSO

Parâmetro	Valor Mínimo	Valor Máximo	Intervalo
N_p	15	45	3
w_i	0,9	2,7	0,18
w_f	0,1	0,3	0,2
c_1	0,5	1,5	0,1
c_2	0,5	1,5	0,1

A Tabela 12 apresenta os resultados da seleção do parâmetros para o método de acordo com os critérios do item 3.9 para as cidades de Triunfo-PE e São João do Cariri-PB.

Tabela 12 – Resultados da seleção do parâmetros para o método PSO

Estação	N_p	w_i	w_f	c_1	c_2	k	c	Função Objetivo	Nº de Iterações
TRI23	27	1,80	0,16	1,0	1,0	3,1439	15,1197	0,000379	870
SCR25	21	1,8	0,20	1,3	1,0	2,3863	5,8878	0,000599	9

Conforme os resultados das Tabelas 31 a 40, localizadas no Apêndice A, notou-se que os valores da Função Objetivo e do número de iterações apresentaram sensibilidade em relação à variação dos parâmetros, número de partículas, inércia da partícula inicial, final e dos coeficientes c_1 e c_2 , ou seja, a mudança no valor desses parâmetros implicou em alterações no tempo de convergência.

O método MBO foi inicialmente testado utilizando os parâmetros da Tabela 2 sugeridos por Tongur e Ülker (2014). Em seguida, a seleção dos parâmetros do método foi realizada por partes, variando um parâmetro por vez conforme a Tabela 13:

Tabela 13 – Parâmetros do método MBO

Parâmetro	Valor Mínimo	Valor Máximo	Intervalo
n	25	75	5
k	1,5	4,5	0,3
x	0,5	1,5	0,1
m	5	15	1

Durante os testes de seleção dos parâmetros, observou-se que o parâmetro, número de pássaros (n), não poderia ser um número par, logo foi necessário realizar os testes com o próximo número inteiro ímpar e os parâmetros (k) e (x) não poderia ser números fracionários, pois representam o número total de soluções e o número de soluções vizinhas a serem compartilhadas respectivamente. Portanto não foi possível parametrizá-las dentro dos critérios estabelecidos nesse estudo.

A Tabela 14 apresenta os resultados da seleção dos parâmetros para o método de acordo com os critérios do item 3.9 para as cidades de Triunfo-PE e São João do Cariri-PB.

Tabela 14 – Resultados da seleção do parâmetros para o método MBO

Estação	n	k	x	m	k	c	Função Objetivo	Nº de Iterações
TRI23	25	3,0	1,0	5,0	3,1929	15,1459	0,000381	5
SCR25	65	3,0	1,0	6,0	2,3887	5,8895	0,000599	17

Em conformidade com os resultados das Tabelas 41 e 43, localizada no Apêndice A, verificou-se que os valores da Função Objetivo não apresentaram sensibilidade em relação à variação do parâmetro do número de pássaros. Referente ao número de iterações, houve uma sensibilidade baixa em relação à variação do parâmetro. Para as Tabelas 42 e 44, percebeu-se que os valores da Função Objetivo não apresentaram sensibilidade em relação à variação dos parâmetro da troca do líder. Mas, para o número de iterações houve uma sensibilidade baixa para a estação de São João do Cariri e nenhuma para a estação de Triunfo em relação à variação do parâmetro.

O método ACO foi inicialmente testado utilizando os parâmetros da Tabela 2 sugeridos por Benhala e Bouattane (2014). Em seguida, a seleção dos parâmetros do método foi realizada por partes, variando um parâmetro por vez conforme a Tabela 15:

Tabela 15 – Parâmetros do método ACO

Parâmetro	Valor Mínimo	Valor Máximo	Intervalo
N_f	50	150	10
μ	0,1	0,3	0,02
ρ	0,05	0,15	0,01

A Tabela 16 apresenta os resultados da seleção do parâmetros para o método de acordo com os critérios do item 3.9 para as cidades de Triunfo-PE e São João do Cariri-PB.

Tabela 16 – Resultados da seleção do parâmetros para o método ACO

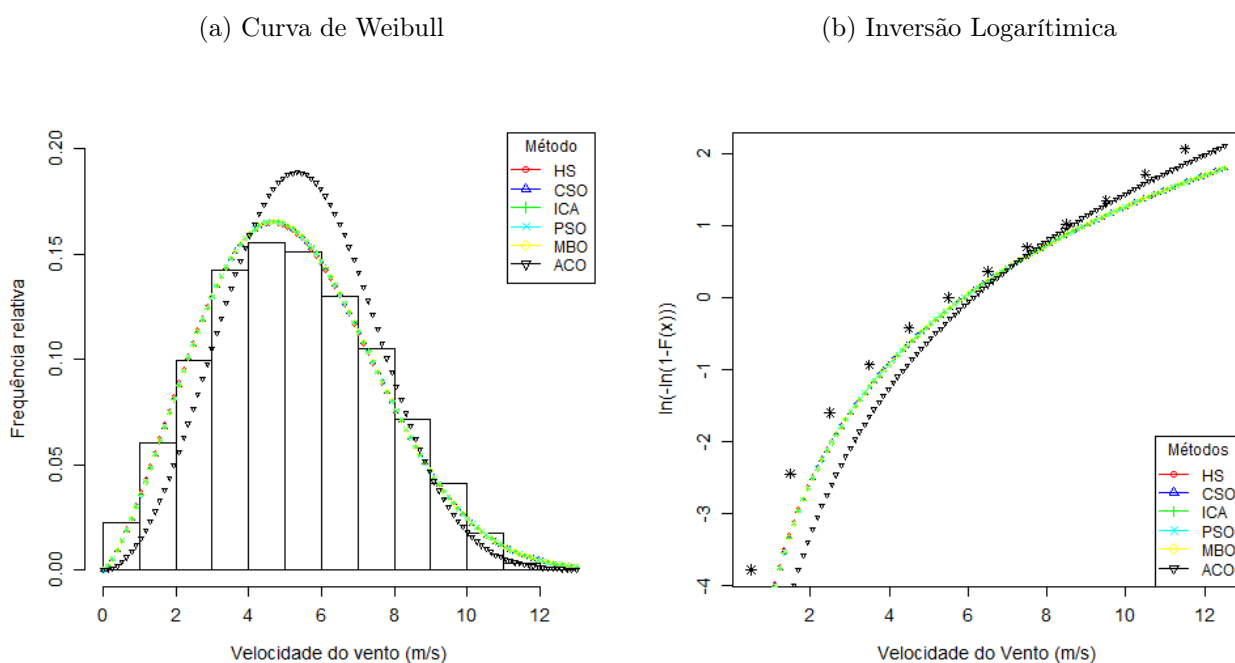
Estação	N_f	μ	ρ	k	c	Função Objetivo	Nº de Iterações
TRI23	120	0,2	0,1	3,2000	15,1520	0,000379	501
SCR25	100	0,2	0,1	2,9500	6,1300	0,005147	501

Em relação aos resultados das Tabelas 45 e 48, localizadas no Apêndice A, observou-se que os valores da Função Objetivo não apresentaram sensibilidade em relação à variação do parâmetro de número de formigas. Referente ao número de iterações, houve uma sensibilidade baixa em relação à variação do parâmetro. Para os resultados das Tabelas 46, 47, 49 e 50, observou-se que os valores da Função Objetivo e do número de iterações não apresentaram sensibilidade em relação à variação dos parâmetros da taxa de evaporação e depósito de feromônio.

4.1 Testes com os métodos heurísticos

Após as seleções da função objetivo e dos parâmetros para cada método em cada cidade, os testes preliminares foram realizados para a apreciação do comportamento dos métodos heurísticos. As Figuras 13 e 14 apresentam os gráficos das curvas de Weibull (a) e as curvas de inversão logarítmica (b) dos métodos heurísticos Busca Harmônica, Busca do Cuco, Algoritmo de Competição Imperialista, Enxame de Partículas, Pássaros Migratórios e Colônia de Formigas para as cidades de São João do Cariri-PB e Triunfo-PE e as Tabelas 15 e 16 mostram os resultados oriundos desses testes.

Figura 13 – Curva de Weibull (a) e curva de inversão logarítmica (b) do método HS, CSO, ICA, PSO, MBO e ACO para a estação SCR25

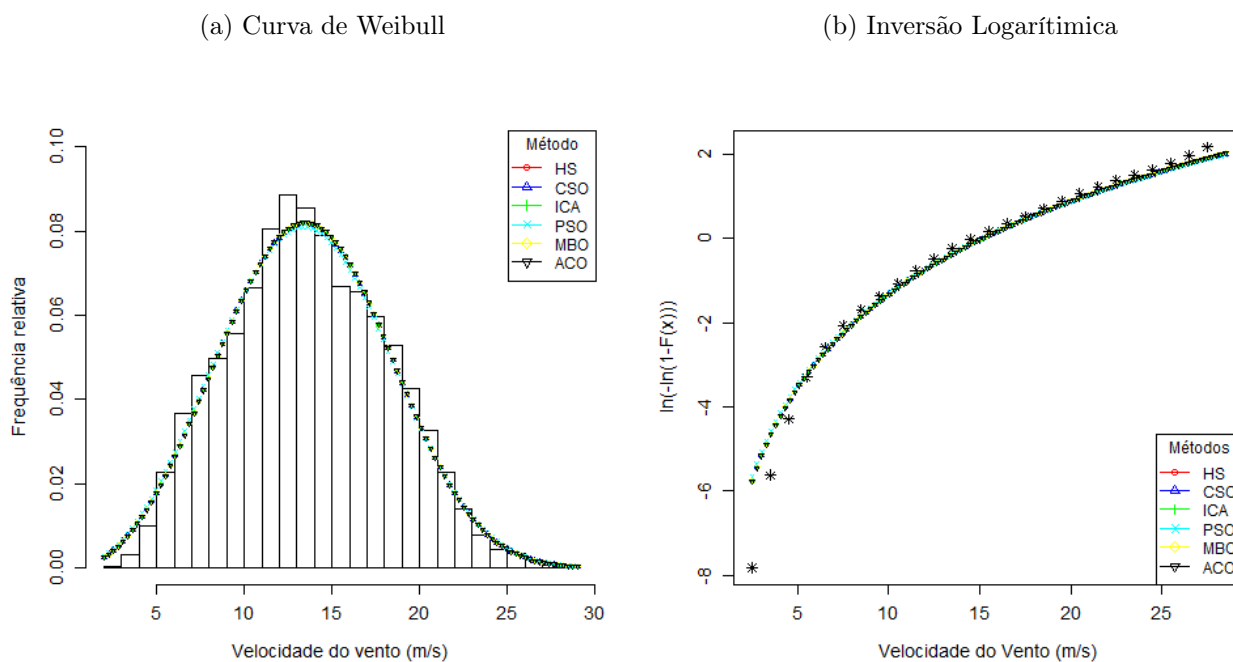


Fonte: Elaborada pelo Autor.

Tabela 17 – Resultados dos métodos heurísticos para São João do Cariri

Método	Função Obj.	k	c	RMSE	MAE	R2	WPD[%]
HS	E.Q.W	2,3672	5,8765	0,001745	0,005247	0,984859	0,331888
CSO	E.Q.W	2,3886	5,8887	0,001735	0,005426	0,985031	0,296402
ICA	E.Q.W	2,3918	5,8914	0,001732	0,005442	0,985088	0,333549
PSO	E.Q.W	2,3863	5,8876	0,001734	0,005405	0,985050	0,311042
MBO	E.Q.W	2,3886	5,8894	0,001732	0,005418	0,985086	0,330460
ACO	E.Q.W	2,9500	6,1300	0,005121	0,014828	0,869653	0,237038

Figura 14 – Curva de Weibull (a) e curva de inversão logarítmica (b) do método HS, CSO, ICA, PSO, MBO e ACO para a estação TRI23



Fonte: Elaborada pelo Autor.

Tabela 18 – Resultados dos métodos heurísticos para Triunfo

Método	Função Obj.	k	c	RMSE	MAE	R2	WPD[%]
HS	E.Q	3,1960	15,1302	0,000695	0,002822	0,984080	0,369604
CSO	E.Q.W	3,1855	15,1395	0,000695	0,002820	0,984066	0,066904
ICA	E.Q.W	3,1559	15,1492	0,000695	0,002809	0,984063	0,007679
PSO	E.Q.W	3,1439	15,1197	0,000705	0,002873	0,983629	0,023351
MBO	E.Q.W	3,1928	15,1458	0,000695	0,002812	0,984070	0,024833
ACO	E.Q.W	3,2000	15,1520	0,000695	0,002805	0,984051	0,016961

Graficamente, foi observado que os métodos heurísticos HS, CSO, ICA, PSO, MBO e ACO para determinar o parâmetro de forma k e o parâmetro de escala c da distribuição de Weibull representaram bem o formato do histograma de velocidade do vento para a cidade de Triunfo. O método ACO apresentou um resultado discrepante dos demais e da aparência do histograma, com um valor médio e uma dispersão maiores dos dados. Desse modo, pode-se concluir que o ACO, da forma como foi parametrizado, não representa satisfatoriamente o regime de ventos da cidade de São João do Cariri, sendo desaconselhado para uso nessa região. Já os demais métodos se mostraram adequados para a caracterização dos recursos eólicos.

As tabelas 17 e 18 mostram os resultados dos testes estatísticos e do teste WPD para os seis métodos heurísticos considerados no estudo. Percebeu-se, a partir da análise estatística e do Desvio da Produção Eólica, que os valores de RMSE, MAE, R^2 e WPD possuem magnitudes muito próximas, com exceção do método ACO para a cidade de São João do Cariri, entre si para os seis métodos heurísticos.

Pode-se concluir que, para a cidade de Triunfo, o método ICA obteve o melhor desempenho dentre os métodos testados, pois alcançou o menor resultado para o teste WPD com o valor de 0,007% e atingiu valores dos testes estatísticos com magnitudes similares aos dos outros métodos. Também pode-se aferir que, para a cidade de São João do Cariri, os métodos HS, CSO, ICA, PSO e MBO obtiveram resultados com valores cuja magnitude são similares em todos os testes com exceção do método ACO que obteve o pior desempenho em relação aos testes estatísticos, uma vez que obteve os maiores valores de RMSE, MAE e o menor valor de R^2 dentre os métodos heurísticos avaliados.

5 CONCLUSÃO

Os métodos heurísticos Enxame de Partículas, Busca Harmônica, Busca do Cuco, Algoritmo de Competição Imperialista, Pássaros Migratórios e Colônia de Formigas foram implementados nesse estudo, os histogramas reais de vento relativos à região Triunfo-PE e São João do Cariri-PB foram ajustados de acordo com os dados obtidos do Sistema de Organização de Dados Ambientais (SONDA) e as seguintes conclusões podem ser pontuadas:

Quanto à seleção da Função Objetivo, observou-se que a soma da minimização do erro quadrado aplicada aos valores de frequência de ocorrência com a minimização do erro quadrado aplicado aos valores de desvio de produção (E.Q.W) exibiu uma combinação dos ótimos resultados dos testes estatísticos referente a Função Objetivo (E.Q) com os excelentes resultados do teste WPD fornecidos pela Função Objetivo (E.W) para os métodos heurísticos nas duas cidades analisadas, com exceção do método HS cuja Função Objetivo selecionada foi a (E.Q) para a cidade de Triunfo. Esse fato contribuiu para mostrar a importância da escolha da Função Objetivo para os métodos heurísticos.

Os parâmetros para cada método foram selecionados através dos valores da Função Objetivo e do número de iterações e percebeu-se que a seleção paramétrica auxiliou na escolha daqueles parâmetros que implicaram significativamente na redução do tempo de convergência de cada algoritmo.

Quanto ao parâmetro k , observou-se que os valores variam de 2 a 3 para as cidades de Triunfo e São João do Cariri, mostrando menor constância da velocidade do vento para esses locais. Os valores de c , representando a velocidade média do vento para ambas as cidades, variam de 6 a 15.

Os seis métodos foram comparados entre si para as regiões do Pernambuco e da Paraíba. Notou-se que o Algoritmo de Competição Imperialista, utilizando a Função Objetivo (E.Q.W), foi o método mais eficiente para determinar os parâmetros de distribuição de Weibull, k e c , para a cidade de Triunfo-PE dentre os estudados por ter apresentado o valor do teste WPD de 0,007% e que o método ACO foi o menos eficaz para ajustar as curvas de distribuição de Weibull para os dados de velocidade do vento da região da Paraíba, utilizando os dados analisados para a cidade de São João do Cariri, devido a discrepância dos resultados em comparação aos demais e da aparência da curva de distribuição em relação ao histograma dos dados de vento da região.

Esse estudo pode contribuir para o desenvolvimento de softwares comerciais para a caracterização do regime de ventos de uma região.

REFERÊNCIAS

- ABARGHOOEE, R. A.; NIKNAM, T.; BINA, M. A.; ZARE, M. Coordination of combined heat and power-thermal-wind-photovoltaic units in economic load dispatch using chance constrained and jointly distributed random variables methods. *Energy*, v. 79, p. 50–67, 2015.
- ABEEÓLICA. *Boletim Anual de Geração Eólica*. 2018. Disponível em: <http://abeeolica.org.br/dados-abeeolica/Boletim_Anuar_de_Geracao_Eolica_2017.pdf>. Acesso em: 2 de julho de 2018.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. *Atlas da Energia Elétrica do Brasil*. 3. ed. Brasília, 2008.
- AKDAG, S. A.; DINLER, A. A new method to estimate weibull parameters for wind energy applications. *Energy Conversion and Management*, v. 50, n. 7, p. 1761–1766, 2009.
- ALBUQUERQUE, A. T. *Otimização de pavimentos de edifícios com estruturas de concreto pré- moldado utilizando algoritmos genéticos*. 241 f. Tese (Doutorado em Engenharia de Estruturas) — Escola de Engenharia de São Carlos, São Paulo, 2007.
- ASKARZADEH, A.; ZEBARJADI, M. Wind power modeling using harmony search with a novel parameter setting approach. *Journal Of Wind Engineering And Industrial Aerodynamics*, v. 135, p. 70–75, 2014.
- ATASHPAZ-GARGARI, E.; LUCAS, C. Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition. *Proceedings of IEEE Congress on Evolutionary Computation*, Singapore, p. 4661– 4667, 2007.
- AZEVEDO, D. C. R. *Métodos Heurísticos Aplicados no Ajuste de Curvas de Weibull em Energia Eólica*. 126 p. Dissertação (Mestrado em Engenharia Mecânica) — Universidade Federal do Ceará, Fortaleza, 2015.
- BARBARESCO, G. M. *Otimização de problemas de engenharia utilizando o algoritmo da competição imperialista (ICA)*. Monografia (Graduação em Engenharia Civil) — Universidade Federal de Santa Catarina, Santa Catarina, 2014.
- BARBOSA, H. de P. *Utilização da busca harmônica no ajuste da curva de weibull em energia eólica*. 66 p. Dissertação (Mestrado em Engenharia Mecânica) — Universidade Federal do Ceará, Fortaleza, 2015.
- BASTOS, E. A. *Otimização de seções retangulares de concreto armado submetidas à flexocompressão oblíqua utilizando algoritmos genéticos*. 151 p. Dissertação (Mestrado em Engenharia Civil) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2004.
- BENHALA, B.; BOUATTANE, O. Ga and aco techniques for the analog circuits design optimization. *Journal of Theoretical and Applied Information Technology*, v. 64, n. 2, p. 413–419, 2014.

- CLERC, M. The swarm and the queen. *IEEE*, v. 3, 1999.
- CONSELHO GLOBAL DE ENERGIA EÓLICA. *Global Wind Report*. Brasília, 2018. 72 p.
- DORIGO, M.; STÜTZLE, T. *Ant Colony Optimization*. Inglaterra: MIT Press, 2004. 301 p.
- DUMAN, E.; UYSAL, M.; ALKAYA, A. F. Migrating birds optimization: A new metaheuristic approach and its performance on quadratic assignment problem. *Information Sciences*, v. 217, p. 65–77, 2012.
- EBERHART, R. C.; KENNEDY, J. A new optimizer using particle swarm theory. v. 1, p. 39–43, 1995.
- EBERHART, R. C.; SHI, Y. Particle swarm optimization: Developments. *Applications and Resources*, v. 1, p. 81–86, 2001.
- ENGELBRECHT, A. P. *Computational intelligence: an introduction*. 2. ed. [S.l.]: John Wiley & Sons Ltd, 2007.
- FEITOSA, E.; PEREIRA, A. L.; SILVA, G. R.; VELEDA, D.; SILVA, C. C. *Panorama do Potencial Eólico no Brasil*. Brasília: Dupligráfica, 2003. 68 p.
- GEEM, Z. W.; KIM, J. H.; LOGANATHAN, G. A. New heuristic optimization algorithm: Harmony search. *Simulation*, v. 76, n. 2, p. 60–68, 2001.
- IEC 61400 PART 12-1. *Power performance measurement of electricity producing wind turbines*. 3. ed. Genebra, Suíça, 2005.
- INTERNATIONAL ELECTROTECHNICAL COMMISSION. *IEC 61400-1: Wind turbines - part 1: Design requirements*. 3. ed. [S.l.], 2005. 92 p.
- JAMIL, M.; PARSAN, S.; MAJIDI, M. Wind power statistics and an evaluation of wind energy density. *Renewable Energy*, v. 6, p. 623–628, 1995.
- JIANG, P.; WANG, Y.; WANG, J. Short-term wind speed forecasting using a hybrid model. *Energy, China*, v. 119, p. 561–577, 2017.
- JUSTUS, C. G.; HARGRAVES, W. R.; MIKHAIL, A.; GRABER, D. Methods for estimating wind speed frequency distributions. *Journal Of Applied Meteorology*, v. 17, n. 3, p. 350–353, 1978.
- KRASNOGOR, N. *Studies on the theory and design space of memetic algorithms*. Tese (PhD) — University of the West of England, UK, 2002.
- MAHDAVI, M.; FESANGHARY, M.; DAMANGIR, E. An improved harmony search algorithm for solving optimization problems. *Applied Mathematics And Computation*, v. 188, n. 2, p. 1567–1579, 2007.
- MAKAS, H.; YUMUSAK, N. System identification by using migrating birds optimization algorithm: a comparative performance analysis. *Information Sciences*, v. 24, p. 1879–1900, 2016.

METAHEURISTICS. *Project Summary*. 2017. Disponível em: <<http://www.metaheuristics.net>>. Acesso em: 21 de junho de 2017.

MEZIANE, R.; ZEBARJADI, M. Wind farm reliability optimization harmony search under performance and budget constraints. *Journal of Wind Engineering and Industrial Aerodynamics*, v. 135, p. 70–75, 2014.

RAHMANI, R.; YUSOF, R.; MAHMOUDIAN, M. S.; MEKHILEF, S. Hybrid technique of ant colony and particle swarm optimization for short term wind energy forecasting. *Journal of Wind Engineering and Industrial Aerodynamics*, v. 123, n. 0, p. 163–170, 2013.

RODRIGUES, S. J. *Otimização de pilares de edifícios altos de concreto armado*. 154 f. Tese (Doutorado em Engenharia Civil) — Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005.

RSTUDIO. 2015. Disponível em: <<http://cran.r-project.org/>>. Acesso em: 2 de setembro de 2017.

SECCHI, A. R.; BISCAIA, E. C. Otimização de processos.: Notas de aula. Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2012.

SOCHA, K. *Ant Colony Optimisation for Continuous and Mixed-variable Domains*. 177 f. Tese (Doutorado em Ciências Aplicadas) — Universidade Livre de Bruxelas, Bélgica, 2009.

SUCUPIRA, I. R. *Métodos heurísticos genéricos: metaheurísticas e hiper-heurísticas*. Monografia (Graduação em Ciência da Computação) — Universidade de São Paulo, São Paulo, 2004.

TOKSARI, M. D. Ant colony optimization for finding the global minimum. *Applied Mathematics and Computation*, Turquia, v. 176, p. 308 – 316, 2006.

TONGUR, V.; ÜLKER, E. Migrating birds optimization for flow shop sequencing problem. *Computer and Communications*, v. 2, p. 142–147, 2014.

WALPOLE, R. E. *Probabilidade y estadística para ingenieros*. 6. ed. México: Prentice-Hall Hispanoamericana, S.A, 1999. 752 p.

WANG, Z.; WANG, C.; WU, J. Wind energy potential assessment and forecasting research based on the data pre-processing technique and swarm intelligent optimization algorithms. *Sustainability*, v. 8, n. 11, p. 1191, 2016.

WEIBULL, E. W. A statistical distribution function of wide applicability. *Journal Of Applied Mechanics*, Estocolmo, v. 18, p. 293–297, 1939.

YANG, X. S. *Nature-inspired metaheuristic algorithms*. 2. ed. UK: Luniver Press, 2010. 115 p.

YANG, X.-S.; DEB, S. Cuckoo search via lévy flights. In: *Proceedings of World Congress on Nature Biologically Inspired Computing*, USA, p. 210–214, 2009.

APÊNDICE A – SELEÇÃO DOS PARÂMETROS PARA MÉTODOS

A.1 Seleção do parâmetro para o método HS

Tabela 19 – Escolha do melhor valor de N_h para Triunfo

N_h	Valor da Função Objetivo	Nº de Iterações de convergência
3	0,000378	862
4	0,000379	468
5	0,000380	467
6	0,000379	861
7	0,000379	978
8	0,000379	861
9	0,000379	574

Tabela 20 – Escolha do melhor valor de N_h para São João do Cariri

N_h	Valor da Função Objetivo	Nº de Iterações de convergência
3	0,001157	862
4	0,000839	468
5	0,000608	467
6	0,001073	978
7	0,000759	844
8	0,000620	861
9	0,000706	860

A.2 Seleção dos parâmetros para o método CSO

Tabela 21 – Escolha do melhor valor de N_n para Triunfo

N_n	Valor da Função Objetivo	Nº de Iterações de convergência
25	0,000379	180
30	0,000379	111
35	0,000379	134
40	0,000379	130
45	0,000379	210
50	0,000379	118
55	0,000379	98
60	0,000379	105
65	0,000379	161
70	0,000379	164
75	0,000379	107

Tabela 22 – Escolha do melhor valor de P_a para Triunfo

P_a	Valor da Função Objetivo	Nº de Iterações de convergência
0,125	0,000379	114
0,150	0,000379	164
0,175	0,000379	153
0,200	0,000379	111
0,225	0,000379	92
0,250	0,000379	98
0,275	0,000379	90
0,300	0,000379	148
0,325	0,000379	160
0,350	0,000379	156
0,375	0,000379	164

Tabela 23 – Escolha do melhor valor de N_n para São João do Cariri

N_n	Valor da Função Objetivo	Nº de Iterações de convergência
25	0,000599	132
30	0,000599	43
35	0,000599	149
40	0,000600	127
45	0,000600	119
50	0,000600	89
55	0,000600	108
60	0,000599	131
65	0,000600	79
70	0,000599	110
75	0,000599	49

Tabela 24 – Escolha do melhor valor de P_a para São João do Cariri

P_a	Valor da Função Objetivo	Nº de Iterações de convergência
0,125	0,000599	175
0,150	0,000600	109
0,175	0,000600	120
0,200	0,000599	122
0,225	0,000599	92
0,250	0,000599	43
0,275	0,000600	97
0,300	0,000599	108
0,325	0,000600	183
0,350	0,000599	168
0,375	0,000600	72

A.3 Seleção dos parâmetros para o método ICA

Tabela 25 – Escolha do melhor valor de N_{pop} para Triunfo

N_{pop}	Valor da Função Objetivo	Nº de Iterações de convergência
10	0,000384	244
12	0,000380	994
14	0,000389	977
16	0,000382	950
18	0,000380	776
20	0,000379	682
22	0,000379	886
24	0,000380	425
26	0,000380	285
28	0,000380	256
30	0,000379	357

Tabela 26 – Escolha do melhor valor de N_{imp} para Triunfo

N_{imp}	Valor da Função Objetivo	Nº de Iterações de convergência
2	0,000379	816
3	0,000379	357
4	0,000380	360
5	0,000379	458

Tabela 27 – Escolha do melhor valor de T_{rev} para Triunfo

T_{rev}	Valor da Função Objetivo	Nº de Iterações de convergência
0,15	0,000384	980
0,18	0,000379	654
0,21	0,000382	654
0,24	0,000379	815
0,27	0,000379	575
0,30	0,000379	357
0,33	0,000379	575
0,36	0,000379	505
0,39	0,000379	431
0,42	0,000379	192
0,45	0,000379	264

Tabela 28 – Escolha do melhor valor de N_{pop} para São João do Cariri

N_{pop}	Valor da Função Objetivo	Nº de Iterações de convergência
10	0,000607	746
12	0,000602	952
14	0,000602	919
16	0,000600	190
18	0,000601	899
20	0,000600	719
22	0,000602	316
24	0,000600	387
26	0,000599	100
28	0,000600	105
30	0,000600	441

Tabela 29 – Escolha do melhor valor de N_{imp} para São João do Cariri

N_{imp}	Valor da Função Objetivo	Nº de Iterações de convergência
2	0,000600	531
3	0,000599	100
4	0,000600	197
5	0,000600	336

Tabela 30 – Escolha do melhor valor de T_{rev} para São João do Cariri

T_{rev}	Valor da Função Objetivo	Nº de Iterações de convergência
0,15	0,000600	835
0,18	0,000599	280
0,21	0,000602	280
0,24	0,000600	832
0,27	0,000603	100
0,30	0,000599	100
0,33	0,000600	260
0,36	0,000600	343
0,39	0,000599	332
0,42	0,000600	151
0,45	0,000600	311

A.4 Seleção dos parâmetros para o método PSO

Tabela 31 – Escolha do melhor valor de N_p para Triunfo

N_p	Valor da Função Objetivo	Nº de Iterações de convergência
15	0,064303	22
18	0,007982	10
21	0,144983	17
24	0,000572	892
27	0,000379	990
30	0,000492	903
33	0,000385	904
36	0,006564	898
39	0,000406	900
42	0,004401	13
45	0,006460	892

Tabela 32 – Escolha do melhor valor de w_i para Triunfo

w_i	Valor da Função Objetivo	Nº de Iterações de convergência
0,9	0,012474	18
1,08	0,003721	18
1,26	0,000842	667
1,44	0,012006	670
1,62	0,001533	793
1,80	0,000379	990
1,98	0,000380	974
2,16	0,001453	18
2,34	0,001135	13
2,52	0,000516	15
2,70	0,000924	17

Tabela 33 – Escolha do melhor valor de w_f para Triunfo

w_f	Valor da Função Objetivo	Nº de Iterações de convergência
0,10	0,000380	849
0,12	0,000379	850
0,14	0,000381	865
0,16	0,000381	870
0,18	0,000384	892
0,20	0,000379	990
0,22	0,000437	906
0,24	0,000379	914
0,26	0,000418	929
0,28	0,000379	944
0,30	0,000382	971

Tabela 34 – Escolha do melhor valor de c_1 para Triunfo

c_1	Valor da Função Objetivo	Nº de Iterações de convergência
0,5	0,000452	870
0,6	0,000442	870
0,7	0,000389	871
0,8	0,002001	875
0,9	0,000386	870
1,0	0,000379	870
1,1	0,000801	871
1,2	0,000498	869
1,3	0,001041	871
1,4	0,001900	892
1,5	0,003615	888

Tabela 35 – Escolha do melhor valor de c_2 para Triunfo

c_2	Valor da Função Objetivo	Nº de Iterações de convergência
0,5	0,000948	32
0,6	0,002294	916
0,7	0,000435	870
0,8	0,000396	860
0,9	0,000498	871
1,0	0,000379	870
1,1	0,000383	887
1,2	0,000431	873
1,3	0,000446	887
1,4	0,003810	895
1,5	0,000955	895

Tabela 36 – Escolha do melhor valor de N_p para São João do Cariri

N_p	Valor da Função Objetivo	Nº de Iterações de convergência
15	0,001732	10
18	0,001859	33
21	0,000600	891
24	0,002473	895
27	0,000813	899
30	0,000657	889
33	0,000660	898
36	0,000607	910
39	0,000906	903
42	0,000606	886
45	0,001126	901

Tabela 37 – Escolha do melhor valor de w_i para São João do Cariri

w_i	Valor da Função Objetivo	Nº de Iterações de convergência
0,9	0,000722	10
1,08	0,000733	18
1,26	0,000653	475
1,44	0,000611	11
1,62	0,000601	808
1,80	0,000600	891
1,98	0,000605	974
2,16	0,000747	18
2,34	0,000748	22
2,52	0,000785	17
2,70	0,000742	36

Tabela 38 – Escolha do melhor valor de w_f para São João do Cariri

w_f	Valor da Função Objetivo	Nº de Iterações de convergência
0,10	0,000602	17
0,12	0,000602	17
0,14	0,000600	863
0,16	0,000602	17
0,18	0,000602	17
0,20	0,000600	891
0,22	0,000602	17
0,24	0,000602	17
0,26	0,000602	17
0,28	0,000600	941
0,30	0,000602	17

Tabela 39 – Escolha do melhor valor de c_1 para São João do Cariri

c_1	Valor da Função Objetivo	Nº de Iterações de convergência
0,5	0,000701	861
0,6	0,000686	861
0,7	0,000681	863
0,8	0,000610	872
0,9	0,000677	866
1,0	0,000600	863
1,1	0,000599	866
1,2	0,000599	11
1,3	0,000599	9
1,4	0,000600	866
1,5	0,000600	10

Tabela 40 – Escolha do melhor valor de c_2 para São João do Cariri

c_2	Valor da Função Objetivo	Nº de Iterações de convergência
0,5	0,000606	911
0,6	0,000600	14
0,7	0,000600	853
0,8	0,000600	878
0,9	0,000600	871
1,0	0,000599	9
1,1	0,000793	873
1,2	0,000627	876
1,3	0,000605	868
1,4	0,000643	867
1,5	0,000772	885

A.5 Seleção dos parâmetros para o método MBO

Tabela 41 – Escolha do melhor valor de n para Triunfo

n	Valor da Função Objetivo	Nº de Iterações de convergência
25	0,000381	5
31	0,000381	6
35	0,000381	8
41	0,000381	5
45	0,000381	9
51	0,000381	8
55	0,000381	8
61	0,000381	9
65	0,000381	7
71	0,000381	6
75	0,000381	7

Tabela 42 – Escolha do melhor valor de m para Triunfo

m	Valor da Função Objetivo	Nº de Iterações de convergência
5	0,000381	5
6	0,000381	5
7	0,000381	5
8	0,000381	5
9	0,000381	5
10	0,000381	5
11	0,000381	5
12	0,000381	5
13	0,000381	5
14	0,000381	5
15	0,000381	5

Tabela 43 – Escolha do melhor valor de n para São João do Cariri

n	Valor da Função Objetivo	Nº de Iterações de convergência
25	0,000599	26
31	0,077682	36
35	0,000599	45
41	0,000599	23
45	0,000599	19
51	0,000599	24
55	0,000599	31
61	0,000599	27
65	0,000599	17
71	0,000599	22
75	0,000599	19

Tabela 44 – Escolha do melhor valor de m para São João do Cariri

m	Valor da Função Objetivo	Nº de Iterações de convergência
5	0,000599	21
6	0,000599	17
7	0,000599	20
8	0,000599	18
9	0,000599	18
10	0,000599	17
11	0,000599	18
12	0,000599	18
13	0,000599	18
14	0,000599	17
15	0,000599	17

A.6 Seleção dos parâmetros para o método ACO

Tabela 45 – Escolha do melhor valor de N_f para Triunfo

N_f	Valor da Função Objetivo	Nº de Iterações de convergência
50	0,000379	502
60	0,000379	502
70	0,000379	503
80	0,000379	505
90	0,000379	503
100	0,000379	503
110	0,000379	505
120	0,000379	501
130	0,000379	504
140	0,000379	503
150	0,000379	502

Tabela 46 – Escolha do melhor valor de μ para Triunfo

μ	Valor da Função Objetivo	Nº de Iterações de convergência
0,10	0,000379	501
0,12	0,000379	501
0,14	0,000379	501
0,16	0,000379	501
0,18	0,000379	501
0,2	0,000379	501
0,22	0,000379	501
0,24	0,000379	501
0,26	0,000379	501
0,28	0,000379	501
0,30	0,000379	501

Tabela 47 – Escolha do melhor valor de ρ para Triunfo

ρ	Valor da Função Objetivo	Nº de Iterações de convergência
0,05	0,000379	501
0,06	0,000379	501
0,07	0,000379	501
0,08	0,000379	501
0,09	0,000379	501
0,1	0,000379	501
0,11	0,000379	501
0,12	0,000379	501
0,13	0,000379	501
0,14	0,000379	501
0,15	0,000379	501

Tabela 48 – Escolha do melhor valor de N_f para São João do Cariri

N_f	Valor da Função Objetivo	Nº de Iterações de convergência
50	0,005147	511
60	0,005147	503
70	0,005147	507
80	0,005147	508
90	0,005147	502
100	0,005147	501
110	0,005147	504
120	0,005147	502
140	0,005147	501
150	0,005147	508

Tabela 49 – Escolha do melhor valor de μ para São João do Cariri

μ	Valor da Função Objetivo	Nº de Iterações de convergência
0,10	0,005147	501
0,12	0,005147	501
0,14	0,005147	501
0,16	0,005147	501
0,18	0,005147	501
0,2	0,005147	501
0,22	0,005147	501
0,24	0,005147	501
0,26	0,005147	501
0,28	0,005147	501
0,30	0,005147	501

Tabela 50 – Escolha do melhor valor de ρ para São João do Cariri

ρ	Valor da Função Objetivo	Nº de Iterações de convergência
0,05	0,005147	501
0,06	0,005147	501
0,07	0,005147	501
0,08	0,005147	501
0,09	0,005147	501
0,1	0,005147	501
0,11	0,005147	501
0,12	0,005147	501
0,13	0,005147	501
0,14	0,005147	501
0,15	0,005147	501