



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

LINDEMBERG FERREIRA DOS SANTOS

**PARAMETRIZAÇÃO E APLICAÇÃO DE MÉTODOS HEURÍSTICOS NO
AJUSTE DA CURVA DE DISTRIBUIÇÃO DE WEIBULL EM ENERGIA
EÓLICA**

FORTALEZA

2018

LINDEMBERG FERREIRA DOS SANTOS

PARAMETRIZAÇÃO E APLICAÇÃO DE MÉTODOS HEURÍSTICOS NO AJUSTE DA
CURVA DE DISTRIBUIÇÃO DE WEIBULL EM ENERGIA EÓLICA

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Engenharia Mecânica da Universidade Federal do Ceará, como requisito parcial para obtenção do grau 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

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)

S236p Santos, Lindemberg Ferreira dos.
Parametrização e aplicação de métodos heurísticos no ajuste da curva de distribuição de Weibull em energia eólica / Lindemberg Ferreira dos Santos. – 2018.
68 f. : il.

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

CDD 620.1

LINDEMBERG FERREIRA DOS SANTOS

PARAMETRIZAÇÃO E APLICAÇÃO DE MÉTODOS HEURÍSTICOS NO AJUSTE DA
CURVA DE DISTRIBUIÇÃO DE WEIBULL EM ENERGIA EÓLICA

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

Aprovada em 18/09/2018.

BANCA EXAMINADORA

Prof.^a Dr.^a Carla Freitas de Andrade
Universidade Federal do Ceará

Prof. Dr. Paulo Alexandre Costa Rocha
Universidade Federal do Ceará

Prof. Dr. Antonio Clecio Fontelles Thomaz
Universidade Estadual do Ceará

A Deus e a minha família, em especial a Lindamar Ferreira, minha mãe.

AGRADECIMENTOS

A Deus, por sua graça sobre a minha vida, pela capacitação e por ter me direcionado por todos os passos nesta caminhada.

A Bárbara Camila, minha noiva, por todo o amor e carinho e pelo grande apoio, que foi de fundamental importância em minha vida acadêmica;

Aos professores Dra. Carla Freitas de Andrade e Dr. Paulo Alexandre Costa Rocha, pela indispensável contribuição com o trabalho pela orientação impecável.

Ao Valdi, secretário do Programa de Pós-Graduação em Engenharia Mecânica, por sua atenção e amizade.

Aos amigos Marcus Macedo, Felipe Gomes e Kevin Guedes, pela indispensável ajuda, sem a qual não seria possível a realização deste trabalho.

Aos professores do Programa de Pós-Graduação em Engenharia Mecânica, por todo o conhecimento adquirido e por contribuírem diretamente para a minha formação acadêmica.

E, sobretudo, agradeço a minha mãe, Lindamar Ferreira, que me apoia e que, com muita confiança, acredita em meus esforços, proporcionando-me as ferramentas necessárias para esta conquista.

"O temor do SENHOR é o princípio do conhecimento..."
(Provérbios 1: 7)

RESUMO

Há alguns anos a energia eólica destaca-se como uma das fontes de energias renováveis mais utilizadas no mundo. A caracterização do regime de ventos segundo uma distribuição de probabilidade é muito importante na análise do recurso eólico. Comumente a distribuição de Weibull de dois parâmetros é utilizada, contudo, um grande desafio na aplicação dessa distribuição é estimar os parâmetros k e c , de modo que um ajuste com erro desprezível seja obtido. Neste trabalho, buscou-se estimar esses parâmetros, para as regiões de Petrolina-PE e São Martinho da Serra-RS, através dos métodos de otimização heurística, Busca Harmônica, Busca Cuco, Pássaros Migratórios e Competição Imperialista e dos métodos determinísticos que são usualmente utilizados, Método dos Mínimos Quadrados, Método do Momento, Método Empírico, Método da Energia Padrão, Método da Máxima Verossimilhança, Método da Máxima Semelhança, Método da Energia Equivalente e Método do Qui-Quadrado. Os métodos foram implementados utilizando a linguagem R. Para cada método heurístico, foi determinada a função objetivo a ser utilizada e realizado o processo de parametrização, que definiu o valor ideal dos seus principais parâmetros. A qualidade do ajuste entre a curva gerada e o histograma de dados foi determinada pelos testes estatísticos RMSE, MAPE, R^2 e pelo desvio de produção - WPD. Os testes estatísticos mostraram que os quatro métodos propostos são eficazes e podem ser utilizados para estimar os parâmetros k e c nas duas regiões analisadas. Entre eles, destacou-se o método Busca Harmônica, que demandou o menor tempo para realizar a estimativa.

Palavras-chaves: Energia Eólica, Distribuição de Weibull, Métodos Heurísticos.

ABSTRACT

A few years ago, the wind energy stands out as one of the most widely used renewable energy sources in the world. The wind regime characterization according to a probability distribution is very important in the wind resource analysis. Commonly the two parameters' Weibull distribution is used, however, a major challenge in the application of this distribution is to estimate the parameters k and c , so that a negligible error setting is obtained. In this study, It was tried to estimate these parameters for Petrolina-PE and São Martinho da Serra-RS regions by the heuristic optimization methods Harmonic Search, Cuckoo Search, Migratory Birds and Imperialist Competition, and by the deterministic methods that are usually used Least Squares Method, Moment Method, Empirical Method, Energy Pattern Factor Method, Modified Maximum Likelihood Method, Maximum Likelihood Method, Equivalent Energy Method, and Chi-Squared Method. The methods were implemented using R language. The objective function was determined and the parameterization process was performed for each heuristic method applied, which defined the ideal value of the main parameters. The fit's quality between the generated curve and the data histogram was determined by the statistical tests RMSE (Root Mean Square Error), MAE (Mean Absolute Error), R^2 (Determination Coefficient) and by the WPD (Wind Production Deviation) test . The statistical tests showed that the proposed four heuristic methods are effective and can be used to estimate the parameters k and c at the two analyzed regions. Among them, it was highlighted the Harmonic Search method, which required the smallest time to perform the estimation.

Keywords: Wind Energy, Distribution of Weibull, Heuristic Methods.

LISTA DE FIGURAS

Figura 1 – Capacidade Instalada de Energia Eólica no Mundo (GW)	15
Figura 2 – Efeito da variação do parâmetro de forma k ($c=7$)	22
Figura 3 – Efeito da variação do parâmetro de escala c ($k = 2$)	23
Figura 4 – Esquema de migração das aves	33
Figura 5 – Sequência de etapas do algoritmo de tratamento dos dados	40
Figura 6 – Exemplo de histograma de dados de velocidade do vento	41
Figura 7 – Fluxograma do algoritmo HS	42
Figura 8 – Fluxograma do algoritmo CSO	43
Figura 9 – Fluxograma do algoritmo MBO	44
Figura 10 – Fluxograma do algoritmo ICA	45
Figura 11 – Regime de ventos característico aos parâmetros $k=2$ e $c=7$	49
Figura 12 – Regime de ventos característico aos parâmetros $k=4$ e $c=12$	50
Figura 13 – Comparação entre os métodos heurísticos e determinísticos - PTR11 . . .	59
Figura 14 – Comparação entre os métodos heurísticos e determinísticos - SMS08 . . .	61

LISTA DE TABELAS

Tabela 1 – Principais Estudos Realizados e Parâmetros Aplicados	38
Tabela 2 – Intervalo e passo de variação aplicados aos parâmetros	47
Tabela 3 – Testes Estatísticos para $k=2$, $c=7$	51
Tabela 4 – Testes Estatísticos para $k=4$, $c=12$	51
Tabela 5 – Determinação da Função Objetivo para a Busca Hamônica em PTR11 .	52
Tabela 6 – Determinação da Função Objetivo para a Busca Cuco em PTR11	52
Tabela 7 – Determinação da Função Objetivo para os Pássaros Migratórios em PTR11	52
Tabela 8 – Determinação da Função Objetivo para a Competição Imperialista em PTR11	53
Tabela 9 – Determinação da Função Objetivo para a Busca Hamônica em SMS08 .	53
Tabela 10 – Determinação da Função Objetivo para a Busca Cuco em SMS08	53
Tabela 11 – Determinação da Função Objetivo para os Pássaros Migratórios em SMS08	54
Tabela 12 – Determinação da Função Objetivo para a Competição Imperialista em SMS08	54
Tabela 13 – Parametrização do método Busca Harmônica - HS	55
Tabela 14 – Parametrização do método Busca Cuco - CSO	56
Tabela 15 – Parametrização do método Pássaros Migratórios - MBO	56
Tabela 16 – Parametrização do método Competição Imperialista - ICA	57
Tabela 17 – Comparação entre os métodos heurísticos e determinísticos - PTR11 . .	60
Tabela 18 – Comparação entre os métodos heurísticos e determinísticos - SMS08 . . .	62
Tabela 19 – Tempo de processamento dos métodos heurísticos	63

LISTA DE ABREVIATURAS E SIGLAS

PROINFA	Programa de incentivos às fontes alternativas de energia elétrica
MME	Ministério de Minas e Energia
MMQ	Método dos Mínimos Quadrados
MM	Método do Momento
MEP	Método da Energia Padrão
ME	Método Empírico
MMV	Método da Máxima Verossimilhança
MMS	Método da Máxima Semelhança
MQQ	Método do Qui Quadrado
MEE	Método da Energia Equivalente
HS	Harmony Search (Busca Harmônica)
CSO	Cuckoo Search Optimization (Otimização da Busca Cuco)
MBO	Migrating Birds Optimization (Otimização dos Pássaros Migratórios)
ICA	Imperialist Competitive Algorithm (Algoritmo da Competição Imperialista)
SONDA	Sistema de Organização de Dados Ambientais

LISTA DE SÍMBOLOS

P	Potência
ρ	Massa específica
v	Velocidade do vento
A	Área varrida pelas pás do rotor
n	Número de amostras
f	Frequência de ocorrência
k	Fator de Forma
c	Fator de Escala
ϵ	Erro
σ	Desvio Padrão
t	Tempo
i	Número de iterações
bw	Largura de variação
β	Fator de escala
Γ	Função gama
p_a	Probabilidade de detecção
C_n	Custo normalizado
c_n	Custo do n-ésimo imperialista
p_n	Poder do imperialista
P_{pn}	Probabilidade de posse

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivos	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Modelagem Numérica do Recurso Eólico	19
<i>2.1.1</i>	<i>Momentos amostrais de velocidade</i>	<i>20</i>
<i>2.1.2</i>	<i>Modelagem discreta e modelagem contínua</i>	<i>20</i>
2.2	Distribuição de Weibull em Estudos Eólicos	21
<i>2.2.1</i>	<i>Modelagem Matemática da Distribuição de Weibull</i>	<i>21</i>
<i>2.2.1.1</i>	<i>Impacto da variação dos parâmetros k e c</i>	<i>21</i>
<i>2.2.2</i>	<i>Ajustes da Curva da Weibull</i>	<i>23</i>
<i>2.2.2.1</i>	<i>Método dos Mínimos Quadrados (MMQ)</i>	<i>24</i>
<i>2.2.2.2</i>	<i>Método do Momento (MM)</i>	<i>25</i>
<i>2.2.2.3</i>	<i>Método Empírico (ME)</i>	<i>26</i>
<i>2.2.2.4</i>	<i>Método da Energia Padrão (MEP)</i>	<i>26</i>
<i>2.2.2.5</i>	<i>Método da Máxima Verossimilhança (MMV)</i>	<i>26</i>
<i>2.2.2.6</i>	<i>Método da Máxima Semelhança (MMS)</i>	<i>27</i>
<i>2.2.2.7</i>	<i>Método da Energia Equivalente (MEE)</i>	<i>27</i>
<i>2.2.2.8</i>	<i>Método do Qui-Quadrado (MQQ)</i>	<i>27</i>
<i>2.2.3</i>	<i>Métodos Heurísticos</i>	<i>28</i>
<i>2.2.3.1</i>	<i>Busca Harmônica (HS)</i>	<i>29</i>
<i>2.2.3.1.1</i>	<i>O algoritmo HS</i>	<i>29</i>
<i>2.2.3.2</i>	<i>Busca Cuco (CSO)</i>	<i>30</i>
<i>2.2.3.2.1</i>	<i>O Pássaro Cuco e sua Estratégia de Reprodução</i>	<i>30</i>
<i>2.2.3.2.2</i>	<i>Voos de L'evy</i>	<i>31</i>
<i>2.2.3.2.3</i>	<i>O algoritmo CSO</i>	<i>31</i>
<i>2.2.3.3</i>	<i>Pássaros Migratórios (MBO)</i>	<i>32</i>
<i>2.2.3.3.1</i>	<i>Migração de aves</i>	<i>32</i>
<i>2.2.3.3.2</i>	<i>O algoritmo MBO</i>	<i>34</i>
<i>2.2.3.4</i>	<i>Competição Imperialista (ICA)</i>	<i>35</i>
<i>2.2.3.4.1</i>	<i>O algoritmo ICA</i>	<i>36</i>
<i>2.2.3.5</i>	<i>Parâmetros</i>	<i>37</i>
3	METODOLOGIA	39

3.1	A linguagem R	39
3.2	Validação dos Métodos Heurísticos	39
3.3	Dados de velocidade do vento	39
3.4	Aplicação dos Métodos Determinísticos	41
3.5	Aplicação dos Métodos Heurísticos	42
3.6	Definição da Função Objetivo	45
3.7	Processo de Parametrização	46
3.8	Testes Estatísticos	47
3.8.1	<i>Raiz Quadrada do Erro Quadrado Médio</i>	47
3.8.2	<i>Erro Absoluto Médio</i>	48
3.8.3	<i>Coefficiente de Determinação</i>	48
4	RESULTADOS E DISCUSSÃO	49
4.1	Validação dos Métodos Heurísticos	49
4.2	Determinação da Função Objetivo	51
4.2.1	<i>Estação PTR11 em Petrolina</i>	52
4.2.2	<i>Estação SMS08 em São Martinho da Serra</i>	53
4.3	Processo de Parametrização	54
4.3.1	<i>Busca Harmônica - HS</i>	54
4.3.2	<i>Busca Cuco - CSO</i>	55
4.3.3	<i>Pássaros Migratórios - MBO</i>	56
4.3.4	<i>Competição Imperialista - ICA</i>	57
4.4	Comparação entre os métodos heurísticos e determinísticos	58
4.4.1	<i>Petrolina</i>	58
4.4.2	<i>São Martinho da Serra</i>	60
4.5	Análise do tempo de processamento	63
5	CONCLUSÃO	64
	REFERÊNCIAS	65


1 INTRODUÇÃO

A energia, cuja demanda cresce constantemente, é um recurso muito importante no desenvolvimento de qualquer nação. O fato da expansão da matriz energética ter fatores limitantes, aliado a constante busca por formas de energia que diminuam a emissão de gás carbônico para a atmosfera, faz com que se busquem métodos de produção que possuam um maior potencial de expansão e um menor grau de agressão ao meio ambiente. Neste contexto, a energia eólica se apresenta como um meio de geração de energia de eficiência já comprovada, com tecnologia consolidada e com um grande potencial a ser explorado.

O planeta tem um potencial de produção de energia eólica de cerca de 500 mil TWh/ano. Contudo, devido a questões técnicas e socioambientais, apenas 10% desse potencial poderia ser aproveitado (ANEEL, 2008).

De acordo com World Wind Energy Association (2017), a capacidade instalada de energia eólica no mundo, apresentada na Figura 1, atingiu 486 GW no final de 2016, 54 GW a mais que em 2015. Isso representa uma taxa de crescimento de 11,8%. Todas as turbinas eólicas instaladas no mundo até o final de 2016 geraram cerca de 5% da demanda mundial de eletricidade.

Figura 1 – Capacidade Instalada de Energia Eólica no Mundo (GW)



Fonte: WWEA (2017)

Quando se fala em recurso eólico, o Brasil é um país privilegiado. Segundo Barbosa (2015), os ventos brasileiros apresentam velocidade média duas vezes maior que a média mundial e sua oscilação é de, aproximadamente, 5%, fatos estes que os tornam previsíveis e com produção mais constante.

A energia eólica teve seu primeiro indício no Brasil em 1992 com o início da operação comercial do primeiro aerogerador instalado no país, resultado de uma parceria entre o Centro Brasileiro de Energia Eólica (CBEE) e a Companhia Energética de Pernambuco (CELPE). Essa turbina eólica, de 225 kW, localizada no arquipélago de Fernando de Noronha - PE foi a primeira a entrar em operação comercial na América do Sul. A Central Eólica de Taíba Localizada no Município de São Gonçalo do Amarante – CE foi a primeira a atuar como produtor independente no País. A central é composta por 10 turbinas de 500 kW, geradores assíncronos, rotores de 40 m de diâmetro e torre de 45 m de altura (ABEEÓLICA, 2017a).

Com o objetivo de possibilitar a expansão e a diversificação da matriz energética nacional, o governo estabeleceu algumas ações visando o desenvolvimento do setor, como a internalização da tecnologia e consolidação da indústria energética nacional; a participação da iniciativa privada; e o aprimoramento da legislação, do conhecimento da fonte primária e de sua interação energética como um parque gerador de base hidráulica (AZEVEDO, 2015).

O Programa de Incentivo às Fontes Alternativas de Energia (PROINFA), conforme descrito no Decreto nº 5.025, de 2004, foi instituído com o objetivo de aumentar a participação da energia elétrica produzida por empreendimentos concebidos com base em fontes eólica, biomassa e pequenas centrais hidrelétricas (PCH) no Sistema Elétrico Interligado Nacional (SIN). O intuito era promover a diversificação da Matriz Energética Brasileira, buscando alternativas para aumentar a segurança no abastecimento de energia elétrica, além de permitir a valorização das características e potencialidades regionais e locais. Coube ao Ministério de Minas e Energia (MME), definir as diretrizes, elaborar o planejamento do Programa e definir o valor econômico de cada fonte e a Eletrobrás, o papel de agente executora, com a celebração de contratos de compra e venda de energia (CCVE) (ANEEL, 2018).

Segundo ABEEÓLICA (2017a), o Brasil chega a setembro de 2017 com 12,19 GW de capacidade instalada de energia eólica, 7,9% da matriz energética do país, em 486 parques eólicos. Em construção e contratados, há 5,48 GW em outros 241 parques que estarão prontos até 2020. A produção de energia eólica em operação comercial no Sistema Interligado Nacional – SIN, entre janeiro e julho de 2017, foi 25,3% superior à geração no mesmo período do ano anterior. As usinas da fonte produziram um total de 3.794 MW médios frente aos 3.029 MW médios gerados no mesmo período de 2016.

O Rio Grande do Norte permanece como maior produtor de energia eólica do país com 1.227 MW médios em 2017, aumento de 25,6% em relação ao mesmo período do ano anterior. Em seguida, aparece a Bahia com 819 MW médios produzidos, aumento de 30% e o Rio

Grande do Sul, que alcançou 565,6 MW médios, aumento de 16,3%. O Ceará com 494 MW médios, aumento de 1,3% em relação ao mesmo período do ano anterior, ocupa a quarta posição do ranking dos estados que mais produzem energia eólica no Brasil (ABEEÓLICA, 2017b).

A análise do recurso eólico é uma etapa fundamental no desenvolvimento de projetos de geração de energia eólica. A minimização dos erros nesta etapa traz ganhos significativos de confiabilidade para o projeto. Uma das mais importantes etapas na análise do recurso eólico é a caracterização do regime de ventos segundo uma distribuição de probabilidade, com o objetivo de transformar os dados discretos coletados numa campanha de medição em dados contínuos. Neste procedimento, as velocidades são agrupadas em intervalos e uma função de distribuição de probabilidade é ajustada. Dependendo das condições de vento a curva a ser ajustada pode seguir a distribuição de Gauss, Rayleigh ou, mais comumente, de Weibull de dois parâmetros (WAIS, 2017).

A determinação destes parâmetros é feita por meio do ajuste de uma curva probabilística em um histograma de velocidades. Os métodos determinísticos são geralmente utilizados para isso. Neste contexto, Rocha et al. (2012) analisaram sete métodos numéricos determinísticos para a obtenção desses parâmetros para duas cidades do Ceará e Andrade et al. (2014) aplicaram seis métodos determinísticos para duas regiões do mesmo estado. No entanto, muitas vezes, estes métodos não conseguem representar de forma satisfatória o histograma. Essa é, portanto, uma condição propícia para o estudo das aplicações de métodos heurísticos. Neste trabalho, foram analisados os métodos Busca Harmônica, baseado na analogia do fenômeno artificial de um grupo musical em busca da melhor harmonia; Busca Cuco, fundamentado no comportamento de algumas espécies de Cucos, que apresentam uma agressiva estratégia de reprodução; Pássaros Migratórios, inspirado na formação de voo de aves migratórias e Competição Imperialista, baseado no imperialismo, política de um governo de estender seus limites territoriais através da conquista de outros territórios denominados colônias.

Os métodos foram implementados, através da linguagem R, e aplicados às regiões de Petrolina-PE e Sao Martinho da Serra- RS, com dados anemométricos referentes às estações PTR11 e SMS08, ambas a 50m ao nível do solo. A qualidade do ajuste foi avaliada pelos testes de RMSE, MAE, R^2 e pelo desvio na previsão de densidade de potência.

1.1 Objetivos

Este trabalho tem como objetivo aplicar e analisar os métodos heurísticos, sendo eles, Busca Harmônica, Busca Cuco, Pássaros Migratórios e Competição Imperialista, na otimização do ajuste da curva de distribuição de Weibull para as cidades de Petrolina - PE e São Martinho da Serra - RS. Especificamente, os objetivos são:

1. Ajustar dois histogramas reais de velocidade do vento, relativos às regiões de Petrolina - PE e São Martinho da Serra - RS;
2. Implementar os métodos para ajuste da curva de distribuição de Weibull utilizando a linguagem R;
3. Validar os métodos heurísticos propostos através da geração de duas séries de dados aleatórios a partir de valores conhecidos para os parâmetros da curva de distribuição de Weibull;
4. Determinar qual função objetivo, das três analisadas, deve ser aplicada a cada um dos métodos heurísticos para que os mesmos apresentem os resultados mais satisfatórios;
5. Determinar os parâmetros ideais para cada um dos métodos heurísticos, ou seja, aqueles que fazem com os métodos apresentem o resultado mais satisfatório com o menor esforço computacional;
6. Comparar, através de testes estatísticos, os métodos heurísticos com outros oito métodos clássicos de ajuste;
7. Avaliar os quatro métodos heurísticos propostos através do tempo de resposta computacional apresentado.

2 FUNDAMENTAÇÃO TEÓRICA

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

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

Onde P é a potência produzida (W), ρ é a massa específica do ar (kg/m^3), A é área varrida pelas pás do rotor (m^2) e v é a velocidade do vento (m/s).

Os ventos possuem velocidade variável, o que dificulta a previsão do potencial fornecido por uma dada região, além disso, 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.

2.1 Modelagem Numérica do Recurso Eólico

Uma correta estimativa do recurso eólico depende da utilização de métodos sistemáticos de medição e análise. A norma IEC 61400-1 (2005) estabelece que o intervalo de tempo mínimo de medição para uma adequada representação das características de vento de uma região tem de ser tal que abranja as variações das características de vento com todas as estações que possam corresponder ao período de um ano.

O esforço da campanha de medição deve culminar com a aplicação do recurso medido numa simulação computacional de um possível parque eólico instalado na área estudada. De acordo com NREL (1997), fatores complicadores afastam a simulação de uma situação real, portanto, deve-se buscar a mitigação desses efeitos com a seleção correta do modelo e sua devida parametrização. Alguns desses fatores são:

1. Existência de um ou até mesmo nenhum mastro local para investigar dados para diversas turbinas distribuídas ao longo do sítio;
2. Altura do rotor diferente da altura de medição;
3. Terreno complexo;
4. Rugosidade e obstáculos; e,
5. Interferência entre turbinas.

2.1.1 Momentos amostrais de velocidade

Segundo Silva (2003), os principais resultados estatísticos esperados na descrição do regime de ventos são os momentos amostrais. Estes momentos podem ser definidos como:

Primeiro momento - Média aritmética, apresentado na Equação 2.2

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

Segundo momento - Velocidade quadrática média. Este momento de velocidade, definido pela Equação 2.3, tem grande importância na análise de recurso eólico, uma vez que o mesmo é utilizado na determinação dos valores de empuxo e torque.

$$\bar{V}^2 = \frac{1}{n} \sum_{i=1}^n V_i^2 \quad (2.3)$$

Terceiro momento - Velocidade cúbica média. Este momento, definido pela Equação 2.4, é utilizado para o cálculo de densidade de potência, sendo determinante no estudo do sítio.

$$\bar{V}^3 = \frac{1}{n} \sum_{i=1}^n V_i^3 \quad (2.4)$$

Onde, para todas as equações, V_i é a velocidade (m/s) e n é o tamanho da amostra.

2.1.2 Modelagem discreta e modelagem contínua

A divisão dos registros de velocidade do vento em intervalos resulta em valores de frequências de ocorrência pontuais que representam a amostra de forma discreta, ou seja, com valores enumeráveis. Assim, o cálculo da energia produzida é determinado para os pontos selecionados que compõem o histograma, os intervalos, e quanto maior o número de intervalos, maior a proximidade com a realidade. Essa abordagem é chamada de modelagem contínua, se o tamanho do intervalo tender a zero, uma vez que uma representação contínua da distribuição de velocidade é obtida, possibilitando assim o cálculo de infinitos valores de produção. Isso pode ser realizado através do ajuste do histograma de frequências de ocorrências de velocidade por distribuições probabilísticas. O comportamento do padrão eólico de uma região pode ser melhor retratado por um modelo de distribuição probabilística, enquanto para outro local com diferente comportamento, uma segunda distribuição pode fornecer resultados melhores. A Distribuição normal ou distribuição Gaussiana; Distribuição normal bivariável; Distribuição exponencial; Distribuição de Rayleigh e a Distribuição de Weibull são as principais distribuições utilizadas pela engenharia eólica. (AZEVEDO, 2015).

2.2 Distribuição de Weibull em Estudos Eólicos

A distribuição de Weibull é uma função de distribuição de probabilidade contínua e unimodal, podendo ser utilizada com dois ou três parâmetros, sendo aplicada a diversas populações e fenômenos, como foi mostrado por Weibull (1951). A distribuição de Weibull de dois parâmetros pode ser utilizada na representação da distribuição da velocidade do vento de uma dada região para aplicações onshore, como foi mostrado por Hennessey Jr. (1977) e para aplicações offshore, como foi estudado por Shu, Li e Chan (2015).

As principais vantagens da distribuição de Weibull de dois parâmetros são: Possui dois parâmetros (k e c) adaptando-se melhor às distribuições de vento que a distribuição de Rayleigh (que tem apenas um parâmetro) e sendo mais simples de determinar que a distribuição bivariada (com cinco parâmetros); Ajusta-se bem a uma grande quantidade de condições de vento; e, conhecendo os parâmetros k e c em uma altura, pode-se extrapolar para diferentes níveis com um baixo nível de erro sem a necessidade de manipular os dados de vento (JUSTUS et al., 1978).

2.2.1 Modelagem Matemática da Distribuição de Weibull

Segundo Justus et al. (1978), a distribuição de Weibull para a velocidade v é expressa pela função de densidade de probabilidade (curva de frequência de velocidade do vento) mostrada na Equação 2.5.

$$f(v) = \left(\frac{k}{c}\right) \times \left(\frac{v}{c}\right)^{(k-1)} \times e^{-\left(\frac{v}{c}\right)^k} \quad (2.5)$$

Onde c é o fator de escala (unidade de velocidade) e k é o fator de forma (adimensional).


A função de probabilidade acumulada (curva de duração da velocidade do vento) é expressa pela Equação 2.6, com $v, k, c > 0$. Note que $F(v)$ denota a probabilidade de existirem velocidades menores ou iguais a v .

$$F(v) = \int_0^v f(v)dv = 1 - e^{-\left(\frac{v}{c}\right)^k} \quad (2.6)$$

2.2.1.1 Impacto da variação dos parâmetros k e c

O impacto da variação dos parâmetros k e c é apresentado nas Figuras 2 e 3. Na Figura 2, o parâmetro k foi variado de 1 a 5, enquanto o parâmetro c foi mantido constante, neste caso igual a 7.

Figura 2 – Efeito da variação do parâmetro de forma k ($c=7$)




Fonte: Elaborado pelo autor

Para $k = 1$, a distribuição assume a forma de uma exponencial e para $k = 2$, a forma da distribuição de Rayleigh. À medida que o parâmetro k aumenta, cresce também o valor da curtose, seguindo para uma forma leptocúrtica, ou seja, quanto maior o valor do fator de forma, mais concentrada e simétrica é a distribuição, são as caudas pesadas que indicam que os valores dificilmente se afastam da média, característica de um regime de vento constante (AZEVEDO, 2015).

Variando o valor de c e mantendo k constante (Figura 3), tem-se um efeito contrário. O aumento do valor do parâmetro c diminui a curtose seguindo para uma forma platicúrtica, caracterizando uma dispersão dos valores. Quanto maior a dispersão, maiores são os valores de velocidade atingidos, porém, com menor frequência de ocorrência. Essa característica está presente em lugares onde o vento é mais instável (AZEVEDO, 2015).

Uma vez que a interligação entre os parâmetros k e c faz com que estes ajam de forma contrária sobre o comportamento da curva, a análise de um regime de ventos não pode ser feita considerando apenas um dos parâmetros.

Figura 3 – Efeito da variação do parâmetro de escala c ($k = 2$)



Fonte: Elaborado pelo autor

2.2.2 Ajustes da Curva da Weibull

Um dos desafios na aplicação da distribuição de Weibull para representar o regime de ventos de uma região é a estimativa dos parâmetros k e c , de modo que se obtenha um ajuste com o menor erro possível. Para realizar essa estimativa muitos métodos numéricos vêm sendo empregados, tais como:

- Método dos Mínimos Quadrados;
- Método do Momento;
- Método Empírico;
- Método da Energia Padrão;
- Método da Máxima Verossimilhança;
- Método da Máxima Semelhança;
- Método da Energia Equivalente; e,

- Método do Qui-Quadrado;

Dorvlo (2002) utilizou o método do Chi-Quadrado para a determinação dos parâmetros de Weibull em quatro localidades de Oman, Arábia Saudita. Silva (2003) apresentou o Método da Energia Equivalente, onde os parâmetros são encontrados a partir da minimização do erro quadrado da potência. Akdag e Dinler (2009) propuseram o Método da Energia Padrão com o qual seria possível determinar os parâmetros k e c a partir da densidade de potência e velocidade média. Rocha et al. (2012) analisaram sete métodos numéricos para a obtenção dos parâmetros e compara-os através de análise de erro entre o histograma e a curva prevista dos dados de vento de Camocim e Paracuru, no Ceará, estado do Nordeste Brasileiro. Também na região Nordeste do Brasil, Andrade et al. (2014) compararam os métodos Gráfico, do Momento, da Energia Padrão, da Máxima Verossimilhança, da Máxima Semelhança, Empírico e da Energia Equivalente e avaliaram a eficiência através da potência disponível prevista e medida. Pishgar-Komleh, Keyhani e Sefeedpari (2015) apresentaram um estudo de caso do condado de Firouzkoh, Iran, onde são avaliadas a velocidade e a densidade de potência através do ajuste de curvas de Weibull e Rayleigh.

2.2.2.1 Método dos Mínimos Quadrados (MMQ)

As frequências de ocorrências da amostra de velocidade do vento podem ser obtidas classificando-se as velocidade em intervalos a partir de $0 - V_1, V_1 - V_2, \dots, V_{n-1} - V_n$. Assim, as frequências de ocorrências da amostra em cada intervalo são, f_1, f_2, f_{n-1}, f_n e as frequências acumuladas, $F_1=f_1, F_2=F_1+f_2, \dots, F_n=F_{n-1}+f_n$.

A distribuição acumulada, expressa na Equação 2.6, após a dupla aplicação de logaritmos naturais, assume o formato de função linear, $y = ax + b$, como mostra a Equação 2.7 .

$$\ln(-\ln(1 - F(v))) = k \ln(v) - k \ln(c) \quad (2.7)$$

Na Equação 2.7, y está representado pelo primeiro membro da equação e x por $\ln(v)$, sendo v a velocidade central do intervalo. Traçando-se um gráfico de y versus x é possível ajustar uma reta com coeficiente angular $a = k$, que intercepta o eixo y em $b = -k \ln(c)$ (JUSTUS et al., 1978).

O ajuste de curva é feito manualmente no método gráfico e através do método de Gauss no método dos mínimos quadrados. É importante lembrar que o primeiro e o último intervalos devem ser desprezados (AZEVEDO, 2015). A finalidade é definir uma reta onde os valores de uma amostra estejam contidos minimizando a raiz quadrada da discrepância entre o valor da amostra e o valor previsto pela reta, segundo a Equação 2.10.

$$y_i = ax_i + b \quad (2.8)$$

$$\epsilon_i = y_i - (ax_i + b) \quad (2.9)$$

$$\epsilon^2 = \sum_{i=1}^n y_i - (ax_i + b^2) \quad (2.10)$$

Portanto,

$$a = \frac{[\sum_{i=1}^n x_i(y_i - \bar{y})]}{[\sum_{i=1}^n x_i(x_i - \bar{x})]} \quad (2.11)$$

Conseqüentemente,

$$k = a \quad (2.12)$$

$$c = e^{-b/k} = e^{[\bar{x} - (\bar{y}/k)]} \quad (2.13)$$

2.2.2.2 Método do Momento (MM)

Hennessey Jr. (1977) sugeriu que o conhecimento do desvio padrão e da velocidade média, Equações 2.14 e 2.15, é suficiente para a caracterização do regime de ventos de uma região.

$$\sigma = c\sqrt{\Gamma(1 + \frac{2}{k}) - \Gamma^2(1 + \frac{2}{k})} \quad (2.14)$$

$$\bar{v} = c\Gamma(1 + \frac{1}{k}) \quad (2.15)$$

Sendo,

$$\bar{v} = \frac{1}{n} \sum_{i=1}^n v_i \quad (2.16)$$

$$\sigma = \sqrt{\left(\frac{1}{n-1}\right) \sum_{i=1}^n (v_i - \bar{v})^2} \quad (2.17)$$

$$\Gamma(x) = \int_0^{\infty} t^{(x-1)} e^{-t} dt \quad (2.18)$$

2.2.2.3 Método Empírico (ME)

O método empírico pode ser considerado uma forma simplificada do Método do Momento (CHANG, 2011). A determinação do parâmetro k segue a Equação 2.19 e o parâmetro c a Equação 2.15.

$$k = \left(\frac{\sigma}{v}\right)^{-1,086} \quad (2.19)$$

2.2.2.4 Método da Energia Padrão (MEP)

Baseia-se no fator de padrão energético E_{pf} , ou seja, a razão entre a velocidade cúbica média e o cubo da velocidade média, conforme a Equação 2.20.

$$E_{pf} = \frac{(\overline{v^3})}{(\bar{v})^3} \quad (2.20)$$

A definição do parâmetro de forma k segue a Equação 2.21, enquanto o parâmetro de escala c é obtido pela Equação 2.15.

$$k = 1 + \frac{3,69}{(E_{pf})^2} \quad (2.21)$$

Esse método tem como vantagens, de acordo com seu desenvolvedor, não requerer histogramas, solução de regressão linear ou métodos numéricos e, uma vez conhecidas a velocidade média e a densidade de potência, é relativamente simples determinar os parâmetros (AKDAG; DINLER, 2009).

2.2.2.5 Método da Máxima Verossimilhança (MMV)

Este método utiliza os dados da série de ventos, sem a necessidade de uma distribuição de frequência (histograma) prévia. Tem como vantagem o fato de todas as informações do período medido serem percebidas durante o cálculo dos parâmetros, aproximando bem o resultado da realidade. Os parâmetros de forma e escala são obtidos, respectivamente, segundo as Equações 2.22 e 2.23.

$$k = \left[\frac{\sum_{i=1}^n v_i^k \ln(v_i)}{\sum_{i=1}^n v_i^k} - \frac{\sum_{i=1}^n \ln(v_i)}{n} \right]^{-1} \quad (2.22)$$

$$c = \left(\frac{1}{n} \sum_{i=1}^n v_i^k \right)^{\frac{1}{k}} \quad (2.23)$$

2.2.2.6 Método da Máxima Semelhança (MMS)

É uma variação do método exposto anteriormente, sendo também chamado de Método da Máxima Verossimilhança Modificado (SILVA, 2003). Utiliza o histograma de velocidades para a obtenção dos parâmetros de ajuste da curva, segundo as Equações 2.23 e 2.24.

$$k = \left[\frac{\sum_{i=1}^n h_i v_i^k \ln(v_i)}{\sum_{i=1}^n h_i v_i^k} - \frac{\sum_{i=1}^n h_i \ln(v_i)}{\sum_{i=1}^n h_i} \right]^{-1} \quad (2.24)$$

$$c = \left[\frac{1}{\sum_{i=1}^n h_i} \sum_{i=1}^n (h_i v_i^k) \right]^{\frac{1}{k}} \quad (2.25)$$

2.2.2.7 Método da Energia Equivalente (MEE)

Em regiões onde a distribuição da velocidade do vento é muito concentrada em torno da média, o comportamento se afasta da distribuição de Weibull, ou seja, pode haver a convergência da solução iterativa para valores distantes da realidade. Modelar os parâmetros de Weibull com base na densidade de potência é uma forma de subsidiar o método iterativo para um ajuste mais próximo do real. Assim, busca-se a equivalência entre a densidade de energia das observações e da curva teórica. Para isso, o parâmetro k é estimado a partir do terceiro momento da velocidade, através da minimização do erro quadrado referente ao ajuste, representado pela Equação 2.26 (SILVA, 2003).

$$\epsilon^2 = \sum_{i=1}^n \left\{ W_i - e^{-\left[\frac{(v_i-1)(\Gamma(1+\frac{3}{k}))^{1/3}}{(v^3)^{1/3}} \right]^k} + e^{-\left[\frac{(v_i)(\Gamma(1+\frac{3}{k}))^{1/3}}{(v^3)^{1/3}} \right]^k} \right\}^2 \quad (2.26)$$

O parâmetro c é então estimado pela Equação 2.27.

$$c = \left[\frac{\bar{v}^3}{\Gamma(1 + \frac{3}{k})} \right]^{1/3} \quad (2.27)$$

2.2.2.8 Método do Qui-Quadrado (MQQ)

Assim como o ajuste pelo método da energia equivalente, o método do Chi-Quadrado busca minimizar o erro do teste de Qui-Quadrado entre dados medidos e os dados esperados, o parâmetro k pode ser estimado segundo a Equação 2.28 e o parâmetro de escala c pode ser obtido a partir da Equação 2.15 (DORVLO, 2002).

$$X^2 = \sum_{i=1}^n \left\{ \frac{\left[F(v_i) - (1 + e^{(\frac{v_i}{k})^k}) \right]^2}{(1 + e^{(\frac{v_i}{k})^k})} \right\} \quad (2.28)$$

Para todos os métodos que se utilizam de valores de distribuição de frequência de ocorrência (histograma), o valor v_i representa o valor central do intervalo de velocidade do vento.

2.2.3 *Métodos Heurísticos*

A Heurística engloba um conjunto de métodos, onde, para solucionar um problema as variáveis em questão utilizam a experiência adquirida ao longo das iterações. Os métodos heurísticos combinam diferentes conceitos inteligentemente para explorar o espaço de busca, de forma que estratégias de aprendizagem são usadas para estruturar informações e encontrar soluções eficientes e quase ótimas (OSMAN; LAPORTE, 1996). Muitas das abordagens heurísticas dependem de decisões probabilísticas tomadas durante a pesquisa, no entanto, a principal diferença da busca aleatória pura é que nos algoritmos heurísticos a aleatoriedade não é usada de forma cega, mas de forma inteligente e tendenciosa (STUTZLE, 1999).

Trabalhos recentes utilizaram a metodologia heurística em estudos de energia eólica. Salcedo-Sanz et al. (2018) trataram de um problema de seleção representativa de pontos de medição para análise de energia eólica a longo prazo, com o objetivo de selecionar o melhor conjunto de N pontos de medição, de tal forma que uma medida de reconstrução de erro de energia eólica fosse minimizada, considerando um campo de energia eólica média mensal. Para isso foi usado o algoritmo heurístico chamado de Otimização de Recifes de Coral com Camada de Substrato, que é um método do tipo evolutivo capaz de combinar diferentes procedimentos de busca dentro de uma única população. Hajibandeh et al. (2018) utilizaram o método heurístico multi-objetivo de tomada de decisões multicritério para propor um novo modelo para integração de energia eólica, otimizando as operações do lado da oferta e da demanda através de uma regra de preço. González et al. (2017) apresentaram uma nova abordagem para a otimização do layout de parques eólicos offshore comparando o comportamento de dois algoritmos de otimização heurística, o algoritmo genético e a otimização por enxame de partículas.

Diante da relação inconsistente entre a economia da China e a distribuição do potencial de energia eólica que causou dificuldades inevitáveis no transporte de energia eólica e até mesmo na integração da rede, Jiang et al. (2017) estudaram, através de métodos de otimização, entre eles o Busca Cuco e o Enxame de Partículas, o estabelecimento de um sistema de energia elétrica integrado com a energia eólica de baixa velocidade. Ghasemi et al. (2016) abordam o efeito das unidades de energia eólica no modelo clássico de Desarme Ambiental / Econômico (EED), denominado de problema Vento / Ambiente / Despacho Econômico (WEED). Para resolver o problema do WEED, os autores propõem um novo algoritmo de otimização heurística, *Honey Bee Mating Optimization* – HBMO.

2.2.3.1 Busca Harmônica (HS)

A Busca Harmônica, HS, do inglês *Harmony Search*, originalmente proposta por Geem, Kim e Loganathan (2001), é um algoritmo heurístico baseado na analogia do fenômeno artificial de um grupo musical em busca da melhor harmonia. Esta busca ocorre através da combinação dos elementos existentes e a geração de novos elementos que são combinados para formar possíveis soluções.

2.2.3.1.1 O algoritmo HS

O processo de busca é iniciado com a formação da Memória Harmônica (HM), através da memorização de uma série de possíveis soluções, chamadas de harmonias. A cada interação, uma nova harmonia é formada e comparada com as harmonias armazenadas na memória harmônica (ASKARZADEH; ZEBARJADI, 2014).

Como as novas harmonias são geradas a partir da HM, caso os elementos da solução ótima não estejam contidos na HM inicial, pelo processo de simples combinação, seria impossível para o método atingir essa solução. Para eliminar esse inconveniente, é aplicado um coeficiente denominado Taxa de Consideração da Memória Harmônica (HMCR), um número contido no intervalo de 0 a 1 para indicar se aquele elemento da harmonia será proveniente de algum elemento de mesma posição na memória harmônica ou se será selecionado a partir do conjunto total de elementos possíveis para aquela posição. Além disso, para evitar que o método fique preso em mínimos locais, outro parâmetro é adicionado, trata-se da Taxa de Ajuste do Som (PAR), que também varia de 0 a 1 e representa a probabilidade de substituição do elemento selecionado por um elemento da vizinhança dentro de um intervalo definido de Largura de Variação (bw) (BARBOSA, 2015).

O parâmetro HMCR é responsável por definir o nível de variabilidade de busca a nível global, enquanto o PAR é responsável pelo nível de busca local. Desta forma, quanto maior o valor de HMCR, pior será a busca global do método e melhor será busca dentro da HM. Enquanto que quanto maior o parâmetro PAR, melhor será a variabilidade na busca local, já que o aumento do valor deste parâmetro aumenta a probabilidade de selecionar um elemento da vizinhança do elemento selecionado.

Geem, Kim e Loganathan (2001) assumiram valores constantes para os parâmetros HMCR, PAR e bw. No entanto, Mahdavi, Fesanghary e Damangir (2007) propuseram a utilização dos parâmetros PAR e bw variando em relação ao número de iterações. Tais abordagens podem se tornar um processo demorado, uma vez que é necessário estimar e variar estes parâmetros manualmente e acompanhar o comportamento do método. Diante disso, Askarzadeh e Zebanjadi (2014) sugeriram um novo método de seleção dos parâmetros da busca harmônica (HS-NPSA) utilizando as seguintes relações:

$$HMCR = 0,9 + 0,1.rand(0,1) \quad (2.29)$$

$$PAR = \frac{1 - rand(0,1)}{2} \quad (2.30)$$

$$bw = rand(0,1) \quad (2.31)$$

Onde, $rand(0,1)$ é um número aleatório no intervalo de 0 a 1

A formação da memória harmônica inicial pode ocorrer através da seleção de valores que se supõem estar próximos da solução ótima ou, através de sorteio, de forma aleatória, dos valores dentro do intervalo de possíveis soluções. A geração de novas melodias ocorre através de duas etapas, a primeira é para selecionar se a nota da nova melodia será proveniente de algum dos elementos da memória harmônica ou se será sorteado aleatoriamente um elemento do conjunto total de soluções possíveis, esta seleção é controlada pelo HMCR. A segunda etapa é outro sorteio para adicionar ou subtrair um passo (bw) da nota selecionada na etapa anterior, esta probabilidade é fornecida pelo parâmetro PAR (BARBOSA, 2015).

2.2.3.2 Busca Cuco (CSO)

2.2.3.2.1 O Pássaro Cuco e sua Estratégia de Reprodução

De acordo com Payne, Sorenson e Klitz (2015), Cucos são pássaros que apresentam uma agressiva estratégia de reprodução. Algumas espécies como os cucos Ani e Guira colocam seus ovos em ninhos comunais, embora possam remover os ovos dos outros pássaros para aumentar a probabilidade e incubação dos seus. Outras espécies colocam seus ovos nos ninhos de aves hospedeiras (muitas vezes outras espécies), no entanto, se o pássaro hospedeiro descobrir que os ovos não são seus, ele joga o ovo do pássaro cuco fora ou simplesmente abandona o ninho e constroi um novo em outro lugar. Diante disso, espécies de cuco, como a Tapera de ninhada e Parasita do Novo Mundo, evoluíram de tal forma que os cucos parasitas femininos são muitas vezes especializados na mímica de cor e padrão dos ovos de algumas espécies hospedeiras. Isso reduz a probabilidade de seus ovos serem abandonados e, assim, aumenta sua reprodutividade. Além disso, os cucos parasitas geralmente escolhem um ninho onde o pássaro hospedeiro já colocou seus ovos, pois, em geral, os ovos do cuco chocam um pouco mais cedo do que os ovos do hospedeiro e, uma vez que o primeiro pinto cuco nasce, por instinto, a primeira ação é expulsar os ovos do hospedeiro. Estudos também mostram que um pintinho cuco pode imitar o chamado de filhotes do hospedeiro para obter acesso a mais oportunidades de alimentação.

2.2.3.2.2 Voos de L'evy

Estudos mostraram que o comportamento de voo de muitos animais e insetos demonstra as características típicas dos voos L'evy (BROWN L. S. LIEBOVITCH, 2007). Reynolds (2007) mostra que as moscas da fruta ou a *Drosophila melanogaster* exploram sua paisagem usando uma série de caminhos de voo diretos pontuados por uma súbita volta de 90 graus, levando a um padrão de busca de escala intermitente estilo L'evy-flight. Posteriormente, esse comportamento foi aplicado à otimização e busca ótima, e resultados preliminares mostram sua capacidade promissora.

2.2.3.2.3 O algoritmo CSO

O algoritmo Busca Cuco, CSO, do inglês *Cuckoo Search Optimization*, é derivado do comportamento do pássaro cuco no processo de busca de ninhos. Por simplificação, três hipóteses são idealizadas. A primeira é que um cuco põe apenas um ovo por vez, e que o ninho do passaro hospederio, onde o ovo é deixado, é escolhido aleatoriamente. A segunda é que, entre os ninhos parasitas selecionados aleatoriamente, o melhor ninho será reservado para a próxima geração. E por fim, o número de ninhos parasitas disponíveis é fixo, e a probabilidade do ovo do cuco ser encontrado pelo pássaro hospedeiro é p_a , valor entre 0 e 1. Uma vez que os ovos estrangeiros foram encontrados, os pássaros hospedeiros os lançarão fora ou abandonarão o ninho e construirão um novo em outro lugar (YANG; DEB, 2009).

De acordo com Jiang, Wang e Wang (2017), primeiramente são geradas aleatoriamente a população inicial de ninhos, N_n . Depois disso, as novas soluções são então geradas de acordo com a Equação 2.32, através do voo L'evy.

$$x_i^{t+1} = x_i^{(t)} + \alpha \oplus L'evy(\lambda) \quad (2.32)$$

Onde, para cada iteração t , $x_i^{(t)}$ é a solução anterior a partir da qual a nova solução $x_i^{(t+1)}$ foi gerada, \oplus é um multiplicador de entrada, α é o fator de ajuste do comprimento da etapa, que pode ser calculado pela Equação 2.33 e $L'evy(\lambda)$ obedece à distribuição de probabilidade de L'evy, Equação 2.34.

$$\alpha = \alpha_0 \cdot (x_i^{(t)} - x_{melhor}^{(t)}) \quad (2.33)$$

Onde α_0 é uma constante, normalmente 0,01 e $x_{melhor}^{(t)}$ representa a melhor solução atual.

$$L'evy(\lambda) \approx \frac{\phi \cdot u}{|v|^{1/\beta}} \quad (2.34)$$

Onde u e v obedecem à distribuição normal padrão, β é igual a 1,5 e ϕ é calculado de acordo com a Equação 2.35.

$$\phi = \left[\frac{\Gamma.(1 + \beta). \sin(\pi.\frac{\beta}{2})}{\Gamma.\frac{(1+\beta)}{2}.\beta.2^{\frac{(\beta-1)}{2}}} \right]^{\frac{1}{\beta}} \quad (2.35)$$

Em seguida, descarta-se o subconjunto das soluções de acordo com a probabilidade de detecção p_a . Quando isso acontece o algoritmo CSO leva uma caminhada aleatória tendenciosa para gerar novas soluções, através da Equação 2.36, com o mesmo tamanho que as soluções abandonadas.

$$x_i^{t+1} = x_i^{(t)} + r(x_{i,c} - x_{i,k}) \quad (2.36)$$

Onde r é um número aleatório uniformemente distribuído entre 0 e 1, e $x_{i,c}$ e $x_{i,k}$ denotam duas soluções aleatórias.

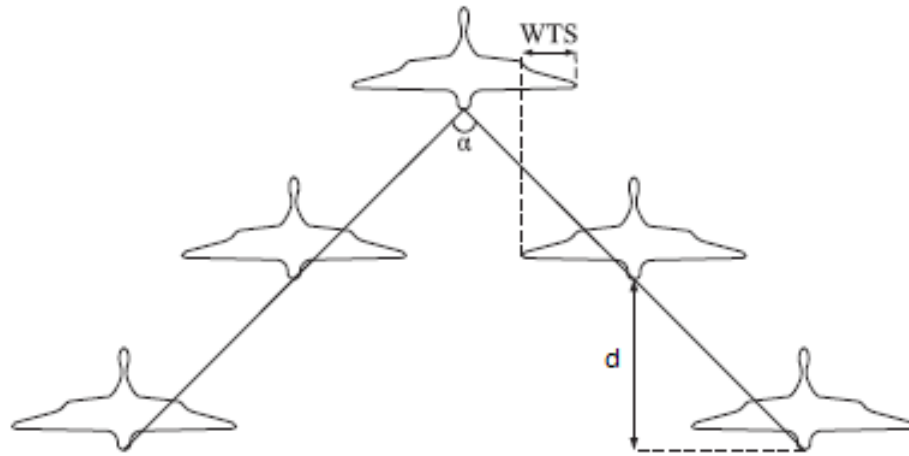
2.2.3.3 Pássaros Migratórios (MBO)

O algoritmo de otimização dos pássaros migratórios, MBO, do inglês *Migrating Birds Optimization*, é um método heurístico inspirado na formação de voo de aves migratórias

2.2.3.3.1 Migração de aves

A formação em V, representada na Figura 4, é a mais famosa formação usada pelas aves migratórias para voar longas distâncias. Obtém esse nome devido à semelhança da forma com a letra V, ou seja, há um pássaro que leva o bando e duas linhas de outros pássaros o seguindo.

Figura 4 – Esquema de migração das aves



Fonte: Duman, Uysal e Alkaya (2012)

Duas hipóteses alternativas foram propostas para explicar o uso da formação de V por aves. A primeira indica que com esta formação é possível economizar energia durante o voo (LISSAMAN; SHOLLENBERGER, 1970). No entanto, para Cutts (1994) a formação em V reflete um mecanismo pelo qual as aves evitam colisões entre si e permanecem em contato visual. Mesmo não rejeitando a segunda hipótese, o que também pode ser explicado pela correlação positiva do espaçamento entre asas (WTS) e a profundidade ou pelo ângulo constante do V, o impulso principal da formação provou ser a economia de energia (DUMAN; UYSAL; ALKAYA, 2012).

Lissaman e Shollenberger (1970) trouxeram uma explicação matemática para a economia de energia na formação de V. De acordo com o estudo, à medida que as aves se aproximam (WTS menor) e o número de aves aumenta, mais energia será salva. Assim, um grupo de 25 aves, por exemplo, teria aproximadamente 71% mais tempo de voo do que um único pássaro. O estudo citado foi seguido por alguns estudos experimentais. Badgerow e Hainsworth (1981) mostraram que para gansos canadenses com um intervalo de 1,5 m, a economia máxima é obtida quando há uma sobreposição de 16 cm. Mais tarde, Hummel e Beukenberg (1989) mostraram que o melhor WTS é:

$$WTS_{melhor} = -0,05b \quad (2.37)$$

Onde b é a extensão da asa.

Na formação V, o pássaro líder é aquele que gasta mais energia. Os pássaros nas outras posições se beneficiam dos pássaros na frente. Parece razoável que a poupança de energia seja maior à medida que voltamos na linha, mas não há estudo na literatura para apoiar

esta ideia. Andersson e Wallander (2004) afirmaram que a economia dos pássaros além do pássaro líder é a mesma, no entanto para Hainsworth (1987), a economia é um pouco mais para os pássaros na parte do meio.

Quando o pássaro líder se encontra exausto, depois de voar na frente por algum tempo, ele se desloca até o final da linha e um dos pássaros que o segue toma sua posição. Embora não seja fornecida evidência empírica, de acordo com o estudo de Andersson e Wallander (2004), os bandos de aves consistem em membros da mesma família, onde o pássaro mais forte assume a liderança ou uma combinação de várias famílias onde os membros mais fortes se revezam para liderar.

2.2.3.3.2 O algoritmo MBO

Para Makas e Yumusak (2016), a diversidade da população inicial n afeta diretamente o desempenho do algoritmo, portanto, a inicialização da posição das aves é um ponto importante na otimização. A posição inicial das aves é definida pela Equação 2.38.

$$x_{ij} = x_j^{min} + rand(x_j^{max} - x_j^{min}) \quad (2.38)$$

Onde x_{ij} é a posição da i -ésima solução na j -ésima dimensão, x_j^{max} e x_j^{min} são os valores limites para a j -ésima dimensão e $rand$ é um número aleatório entre 0 e 1.

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

O pássaro líder tenta ser melhorado no segundo passo mediante a geração de vizinhos k , que ocorre, de acordo com Makas e Yumusak (2016), através da Equação 2.39.

$$\hat{x}_{ij} = x_{ij} + \varphi \cdot (x_{ij} - x_{kj}) \quad (2.39)$$

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

Se a solução vizinha com a melhor aptidão for uma melhoria para o líder, a posição da solução vizinha é atribuída à solução líder e, em seguida, as soluções inutilizadas, $2x$, são compartilhadas com os dois pássaros na segunda linha, cada um recebendo, portanto, x vizinhos. Os outros pássaros tentam ser melhorados no terceiro passo, para isso, cada ave por sua vez, gera $(k - x)$ vizinhos. Estes são então combinados com os não utilizados que vieram dos pássaros da frente. Assim, o número total de soluções vizinhas a serem consideradas para cada pássaro é k , como na melhoria do pássaro líder. Se a solução da vizinhança com a melhor aptidão mostrar uma melhoria para o pássaro correspondente, a posição dessa solução é atribuída ao pássaro correspondente e, em seguida, as melhores soluções “ x ” não utilizadas são compartilhadas com o próximo pássaro. Uma iteração termina após completar ensaios de melhoria para todas as aves. Em suma, o pássaro líder gasta mais energia criando k vizinhos e, os pássaros em outras posições se beneficiam dos pássaros da frente e gastam menos energia criando $(k-x)$ vizinhos (SOTO et al., 2016).

No quarto passo, pensa-se que o pássaro líder está cansado depois de realizar um número predefinido de iterações m , a solução líder é então deslocada para o fim de um lado na formação V , e a segunda solução nesse lado é deslocada para a posição líder. Duman, Uysal e Alkaya (2012) recomendam $m = 10$. Os passos 2, 3 e 4 são executados até que os critérios de terminação predefinidos sejam satisfeitos pelas soluções geradas.

Os parâmetros k e x afetam diretamente o desempenho do algoritmo. O parâmetro k é inversamente proporcional à velocidade de vôo dos pássaros, se for escolhido um valor pequeno, assume-se que as aves voam a velocidades mais elevadas. Maiores velocidades permitem que o algoritmo MBO reduza o tempo de execução, esta é uma escolha vantajosa para problemas com um pequeno número de parâmetros. No entanto, a profundidade de busca do algoritmo aumenta se o parâmetro k aumentar (MAKAS; YUMUSAK, 2016).

O parâmetro x representa o benefício dos pássaros de trás devido aos pássaros da frente. Uma vez que o mecanismo de benefício do algoritmo MBO é definido como o número de soluções de “bom vizinho” obtidas a partir da solução predecessora, valores altos de x fazem com que as soluções sejam semelhantes entre si, assim, a convergência prematura pode acontecer (DUMAN; UYSAL; ALKAYA, 2012).

2.2.3.4 *Competição Imperialista (ICA)*

A Competição Imperialista, ICA, do inglês *Imperialist Competitive Algorithm*, proposto inicialmente por Atashpaz-Gargari e Lucas (2007), é baseado no imperialismo, política de um governo de estender seus limites territoriais através da conquista de outros territórios denominados colônias.

O país imperialista juntamente com suas colônias formam um império, cujo poder é a

soma do poder do país imperialista com uma fração do poder de suas colônias. Assim, os impérios com maior poder tendem a conquistar os impérios com menor poder, os quais são extintos durante o processo, fazendo com que o conjunto de países convirja para um único império.

2.2.3.4.1 O algoritmo ICA

De acordo com Moradi et al. (2014), primeiramente ocorre a geração aleatória da população inicial e a definição do número de países N_p e a quantidade de imperialistas N_{imp} . Em seguida, é encontrado o custo do país, que é dado pelo cálculo da Função Objetivo (Seção 3.6), de tal forma que os imperialistas serão os países com menores custos.

O passo seguinte é distribuir as colônias entre os imperialistas, esta distribuição ocorre de acordo com o poder de cada imperialista, expressado pela Equação 2.40.

$$p_n = \frac{|C_n|}{|\sum_{i=1}^{N_{imp}} c_i|} \quad (2.40)$$

Sendo,

$$C_n = c_n - \max_i(c_i) \quad (2.41)$$

Onde, C_n é o custo normalizado e c_n é o custo do n-ésimo imperialista.

A quantidade de colônias que o imperialista irá possuir inicialmente é determinada pela Equação 2.42.

$$N \cdot C_n = \text{arredondamento}(p_n \cdot N_{col}) \quad (2.42)$$

Onde $N \cdot C_n$ é o número de colônias iniciais que o i-ésimo imperialista irá possuir e N_{col} é quantidade total de colônias. A operação “arredondamento” atribui o valor inteiro mais próximo.

Seguindo o fluxo do algoritmo, o próximo passo é movimentar as colônias em direção aos seus respectivos imperialistas, sendo esta movimentação descrita pela Equação 2.43.

$$pos_{i+1} = pos_i + \gamma \cdot \delta \cdot d \quad (2.43)$$

Onde, Pos_i é o vetor de posições das colônias na iteração i, γ é uma constante com valor maior que 1, δ é um número aleatório entre 0 e 1 e d é o vetor distância (entre as colônias e seus imperialistas).

É ainda possível que uma colônia mude para uma posição aleatória. A probabilidade disso ocorrer se deve a um parâmetro ajustável denominado Taxa de Revolução T_{rev} . No final das movimentações, caso uma colônia se torne mais poderosa que seu imperialista (menor valor

para a Função Objetivo) ela se torna o novo Imperialista do Império. Após as movimentações, é calculado o custo total do império, através da Equação 2.44, ou seja, a soma entre o custo do Imperialista mais uma porcentagem do custo de suas colônias.

$$T \cdot C_n = \text{Custo}(\text{imperialista}) + \varepsilon \cdot \text{média}\{\text{custo}(\text{colônias do imperialista})\} \quad (2.44)$$

Onde, $T \cdot C_n$ é o custo total do império e ε é uma constante entre 0 e 1.

O custo normalizado dos impérios é definido pela Equação 2.45.

$$N \cdot T \cdot C_n = T \cdot C_n - \max_i(T \cdot C_i) \quad (2.45)$$

Onde, $N \cdot T \cdot C_n$ é o custo normalizado do n-ésimo império e $\max_i(T \cdot C_i)$ é o custo total do império com o maior custo total de todos.

O passo seguinte é promover a competição imperialista, neste caso, a colônia com o pior desempenho do império mais fraco é selecionada para ser adquirida pelo império com maiores chances de adquiri-lá. O império escolhido a possuir a colônia será aquele com o índice D de maior valor, definido pela Equação 2.46 (MORADI et al., 2014).

$$D = P - R \quad (2.46)$$

Onde P é um vetor com as probabilidades de posse de cada império e R é um vetor, do mesmo tamanho de P , de números aleatórios distribuídos uniformemente. O vetor de probabilidade de posse P é definido por:

$$P_{pn} = \frac{|N \cdot T \cdot C_n|}{|\sum_{i=1}^{N_{imp}} N \cdot T \cdot C_i|} \quad (2.47)$$

Em seguida, o algoritmo elimina, caso haja, os impérios sem colônias. Portanto, a partir de um número de iterações, todos os impérios serão eliminados, com exceção do mais forte, o qual terá todas as colônias sob seu domínio e todas as colônias estarão na mesma posição que a do imperialista. Nesta situação, não há diferenças entre imperialistas e colônias, o que leva ao fim a competição imperialista (ATASHPAZ-GARGARI; LUCAS, 2007).

2.2.3.5 Parâmetros

A Tabela 1 apresenta os principais estudos realizados com os métodos de otimização heurística, Busca Harmônica, Busca Cuco, Pássaros Migratórios e Competição Imperialista, bem como os valores dos parâmetros aplicados na implementação de cada um deles.

Tabela 1 – Principais Estudos Realizados e Parâmetros Aplicados

Método	Autor(es)	Estudo	Parâmetro
HS	Barbosa (2015)	Estimou os parâmetros k e c para duas regiões do Brasil	$N_h=6$
CSO	Wang, Wang e Wu (2016)	Estimou os parâmetros k e c para quatro regiões da China	$N_n = 50$ $P_a = 0,25$
MBO	Tongur (2014)	Utilizou o método para solucionar problemas de programação flow shop	$N_{pa} = 51$ $k = 3$ $x = 1$
ICA	Atashpaz-Gargari e Lucas (2007)	Propôs o método ICA e o aplicou a diversos problemas de otimização	$N_p=20$ $N_{imp} = 3$ $T_{rev} = 0,3$

Fonte: Elaborado pelo autor

Sendo, N_h o número de harmonias, N_n o número de ninhos, P_a a probabilidade detecção, N_{pa} o número de pássaros, k o numero de vizinhos criados, x a quantidade de vizinhos provenientes do pássaro da frente, N_p o número de países, N_{imp} o número de imperialistas e T_{rev} a taxa de revolução.

3 METODOLOGIA

3.1 A linguagem R

A linguagem R é hoje largamente utilizada entre estatísticos como ferramenta de desenvolvimento de softwares e rotinas de análises de dados. O nome "R" provém do nome de seus fundadores Ross Ihaka e Robert Gentleman, do departamento de Estatística da Universidade de Auckland, Nova Zelândia (R-PROJECT, 2017).

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 produtiva (RSTUDIO., 2017).

3.2 Validação dos Métodos Heurísticos

Para tornar os métodos Busca Harmônica, Busca Cuco, Pássaros Migratórios e Competição Imperialista válidos, e assim, aplicá-los aos dados reais, foi necessário que os mesmos passassem por um processo de validação.

Com o intuito de validar os quatro métodos, foi utilizada a função *rweibull* juntamente com a ferramenta *set.seed(1)*, usada como semente para os processos randômicos internos de cada método, para gerar duas séries de dados aleatórios a partir de valores conhecidos de k e c , a primeira com fator de forma $k=2$ e fator de escala $c=7$ e a segunda com $k=4$ e $c=12$, representando condições de vento frequentes no Brasil, sendo a primeira típica de regiões serranas e a segunda, da costa do nordeste. A quantidade de dados gerados considerou o valor equivalente ao período mínimo de um ano de acordo com a norma (IEC, 2005).

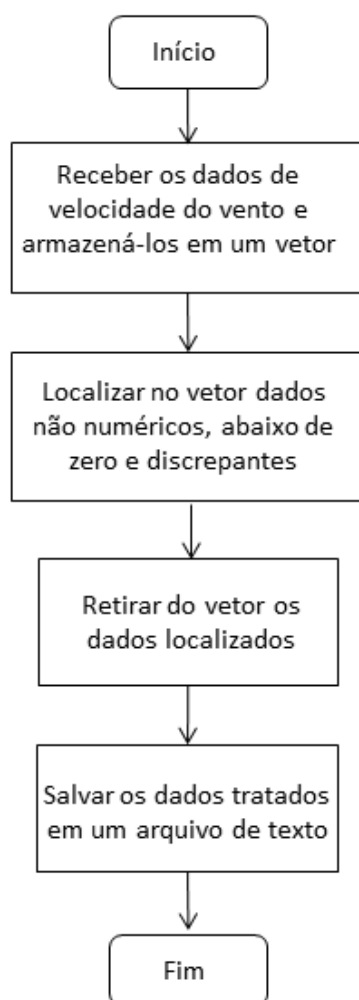
3.3 Dados de velocidade do vento

Os dados anemométricos são disponibilizados pelo Instituto Nacional de Pesquisas Espaciais (2017) em livre acesso através do Sistema Nacional de Organização de Dados Ambientais (SONDA). Os métodos foram executados com dados referentes às estações PTR11 (Latitude $09^{\circ} 04' 08''\text{S}$ e Longitude $40^{\circ} 19' 11''\text{O}$), em Petrolina, cidade localizada no estado de Pernambuco, a 376 metros acima do nível do mar, onde o relevo é marcado por uma superfície predominantemente suave-ondulado e; SMS08 (Latitude $29^{\circ} 26' 34''\text{S}$ e Longitude $53^{\circ} 49' 23''\text{O}$), em São Martinho da Serra, cidade localizada no Rio Grande do Sul, a uma altitude média de 453 m e caracterizada pelo clima frio da região sul do Brasil, todas a 50m ao nível do solo.

Os dados, medidos a cada minuto, cujas médias são registrados a cada 10 minutos, portanto, um total de 52.560 valores de velocidade, são referentes ao ano de 2010, pois este é o ano mais recente que possui dados de velocidade de vento para todos os doze meses do ano.

Para a retirada de valores incoerentes, resultados de falhas de medição, foram filtrados valores de velocidade excessivos e negativos, além de registros não numéricos NA (*Not Available*) e NAN (*Not A Number*), ao final da validação, obteve-se uma disponibilidade acima de 99% para ambas as estações. A Figura 5 apresenta a sequência de etapas do algoritmo de tratamento de dados.


Figura 5 – Sequência de etapas do algoritmo de tratamento dos dados



Fonte: Elaborado pelo autor

Os dados de velocidade do vento, já tratados, foram divididos em intervalos de 1m/s , sendo cada elemento maior que o valor inferior do intervalo e menor ou igual ao valor superior, com exceção do primeiro intervalo, cujos elementos devem ser maiores ou iguais ao valor inferior e menores ou iguais ao valor superior. Assim, um histograma similar ao apresentando na Figura 6 foi gerado de acordo com a frequência de ocorrência de cada intervalo.

Figura 6 – Exemplo de histograma de dados de velocidade do vento



Fonte: Elaborado pelo autor

3.4 Aplicação dos Métodos Determinísticos

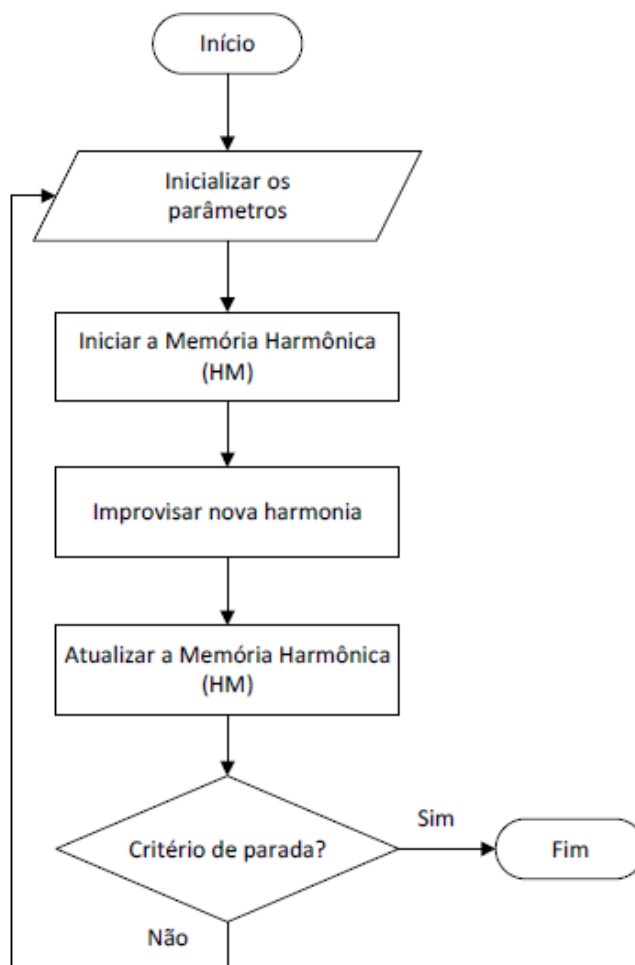
O Método dos Mínimos Quadrados -MMQ, Método do Momento -MM, Método da Energia Pedrão -MEP, Método Empírico -ME, Método da Máxima Verossimilhança -MMV, Método da Máxima Semelhança -MMS, Método do Qui-Quadrado -MQQ e Método da Energia Equivalente -MEE, descritos na Seção 2.2.2, foram aplicados com a finalidade de estimar os parâmetros da curva de distribuição Weibull. Cada método foi implementado em forma de uma função, com parâmetro de entrada sendo o vetor velocidade a ser ajustado.

3.5 Aplicação dos Métodos Heurísticos

Os métodos Busca Harmônica - HS, Busca Cuco - CSO, Pássaros Migratórios - MBO e Competição Imperialista - ICA, descritos na Seção 2.2.3, foram adaptados para que pudessem ser utilizados com os dados de velocidade do vento e com a finalidade de estimar os parâmetros da curva de distribuição Weibull. Os fluxogramas dos algoritmos dos métodos heurísticos são apresentados nas figuras a seguir.

A Figura 7 apresenta o fluxograma do algoritmo HS. Neste método cada harmonia representa um par k, c .

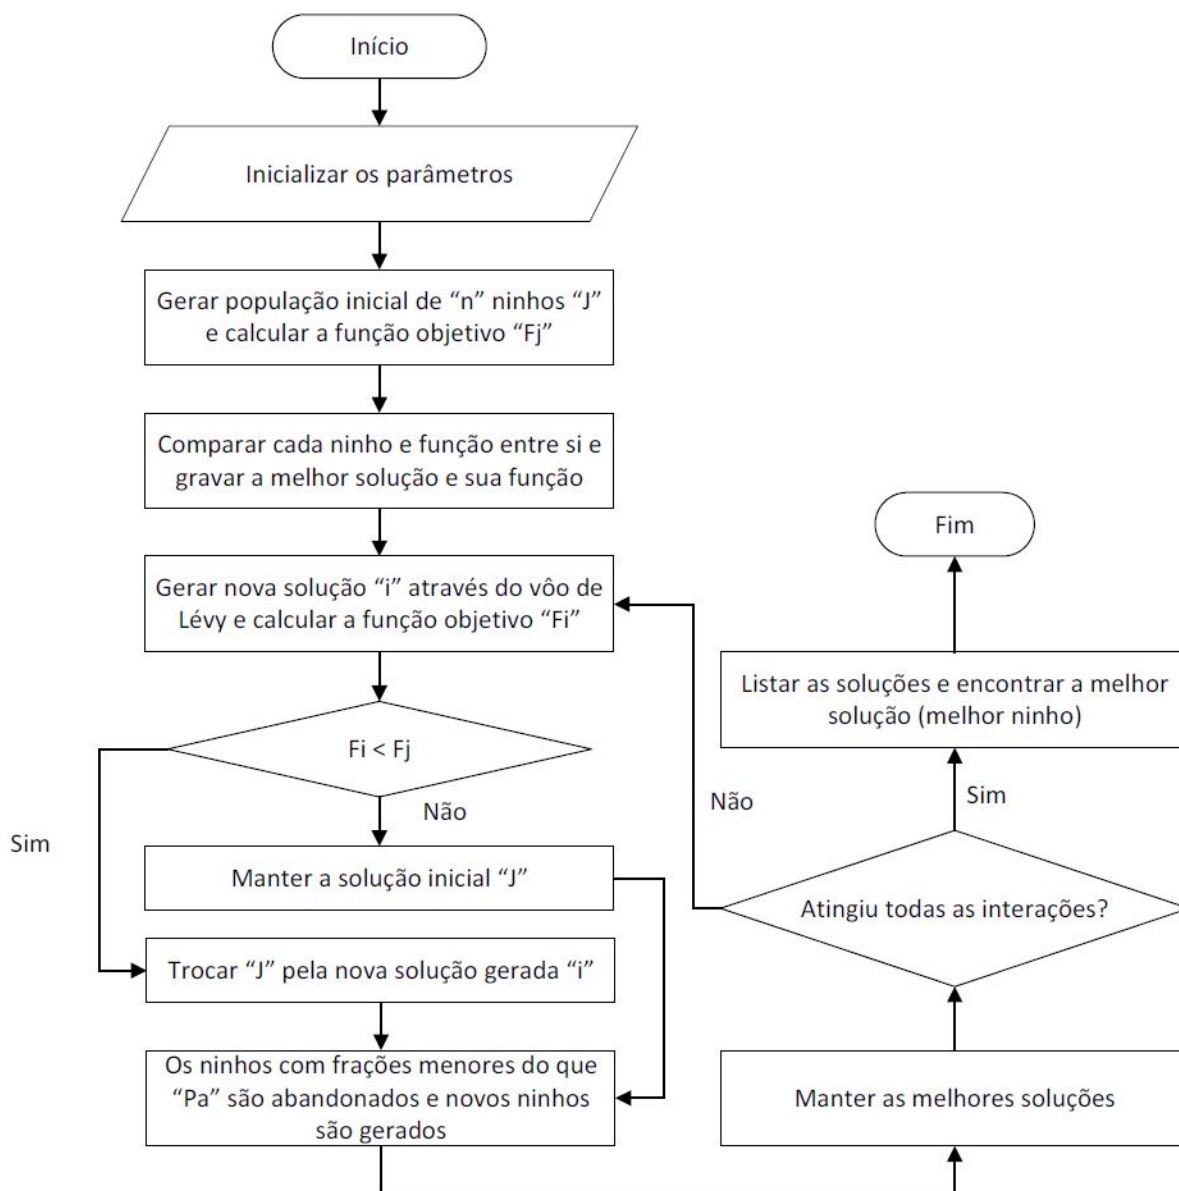
Figura 7 – Fluxograma do algoritmo HS



Fonte: Elaborado pelo autor

A Figura 8 apresenta o fluxograma do algoritmo CSO, onde cada ninho representa um par k, c .

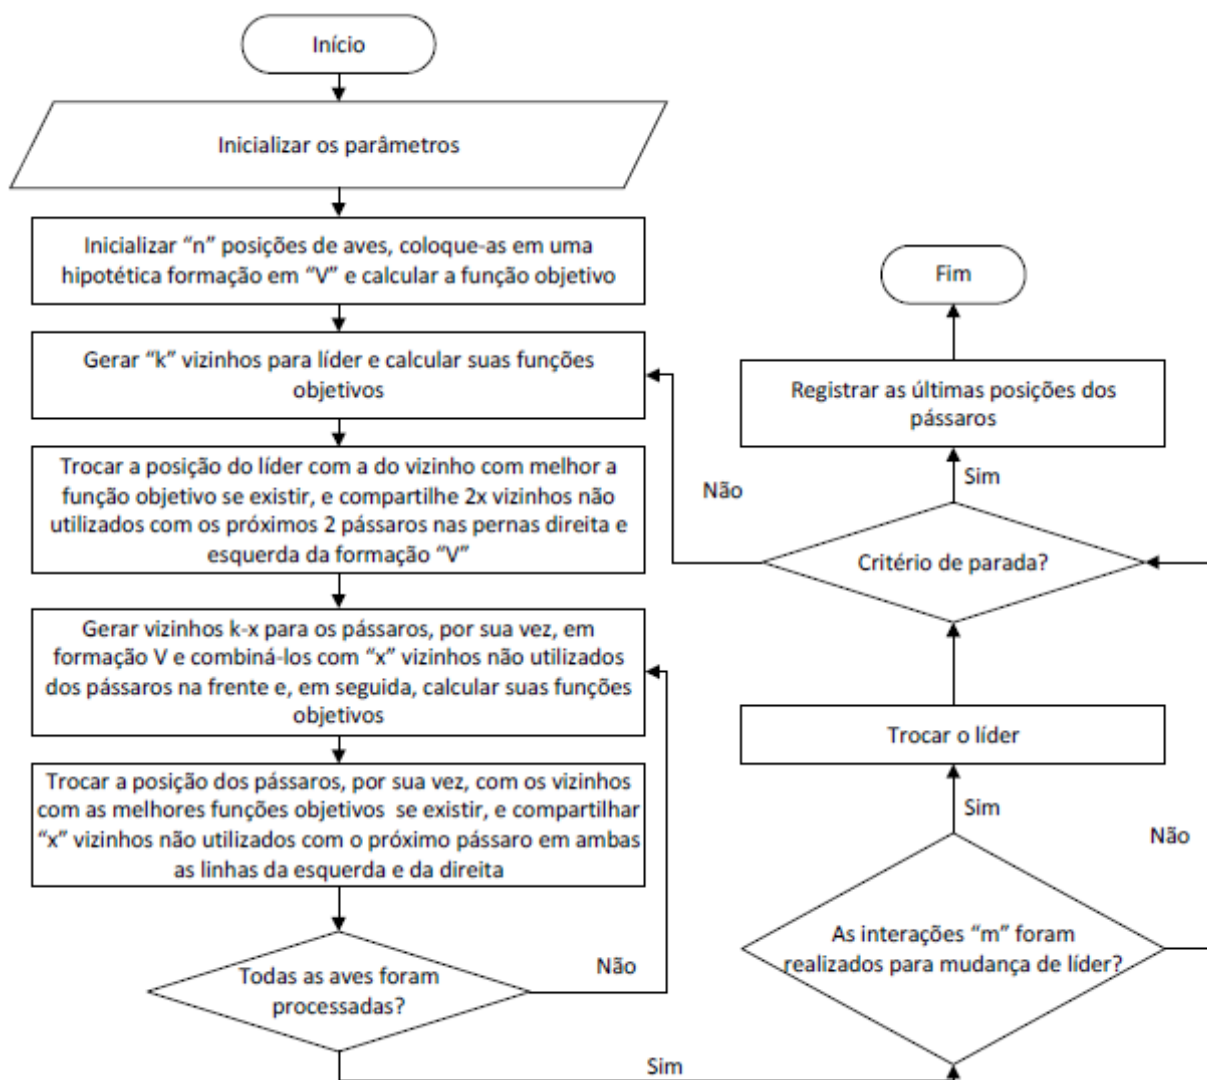
Figura 8 – Fluxograma do algoritmo CSO



Fonte: Elaborado pelo autor

O fluxograma do algoritmo MBO é apresentado na Figura 9. Neste método a posição de cada pássaro representa um par k, c .

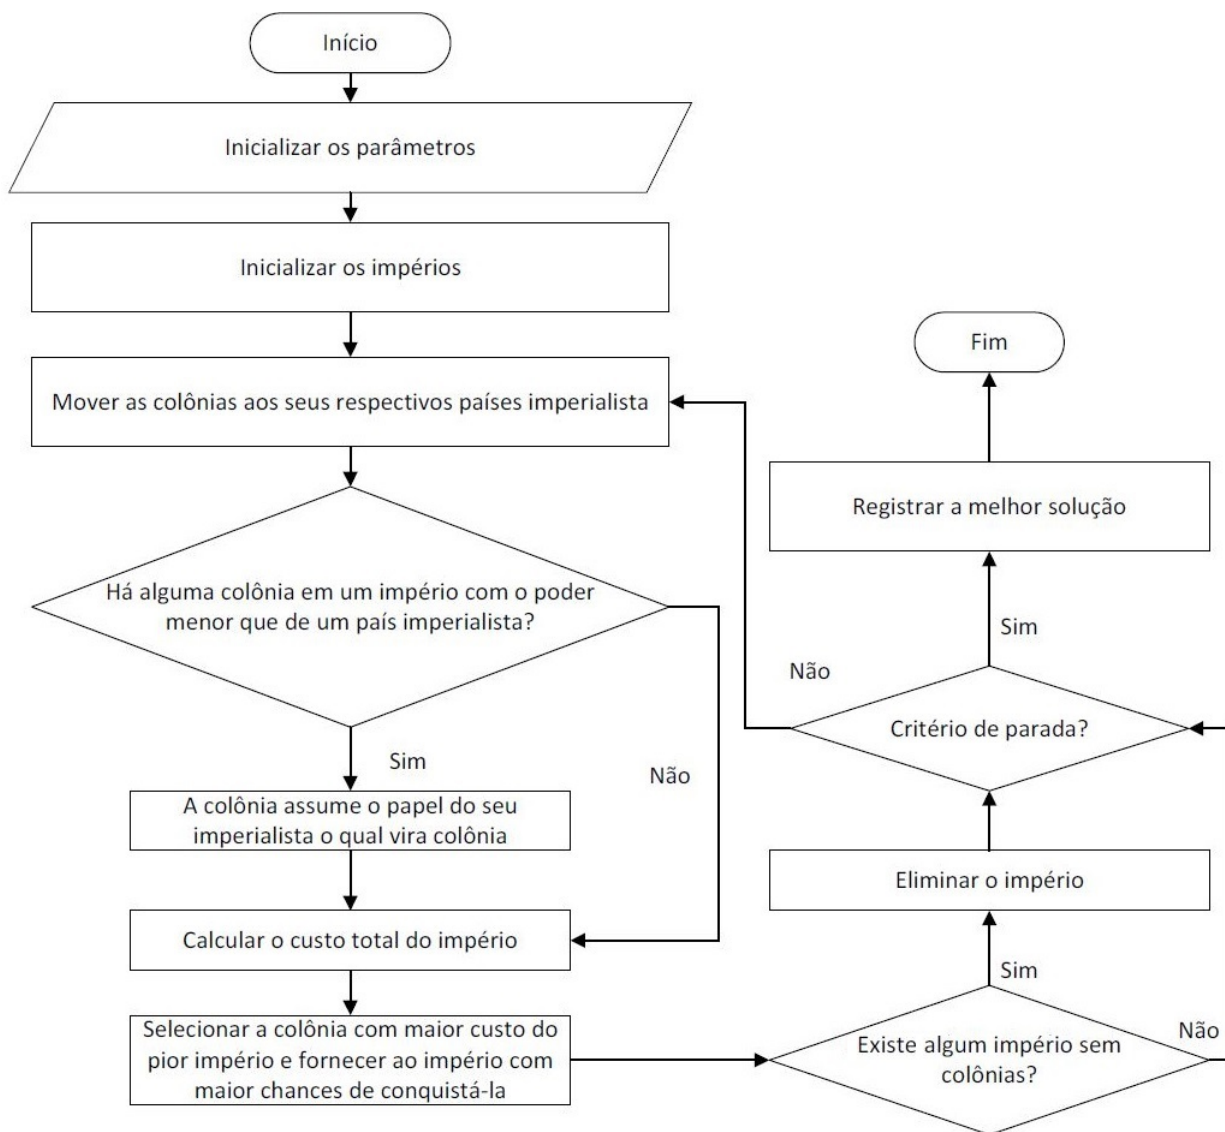
Figura 9 – Fluxograma do algoritmo MBO



Fonte: Elaborado pelo autor

O fluxograma do algoritmo ICA é apresentado na Figura 10. Neste método a posição de cada país representa um par k, c .

Figura 10 – Fluxograma do algoritmo ICA



Fonte: Elaborado pelo autor

3.6 Definição da Função Objetivo

Todo procedimento de otimização busca o melhor resultado de uma função para o cenário desejado, essa função recebe o nome de Função Objetivo. No caso dos métodos heurísticos utilizados, a função objetivo será atribuída, individualmente para cada região estudada, de forma a fazer com o que método apresente o melhor resultado possível. Serão analisadas três funções, sendo a terceira a soma das duas primeiras.

A primeira função, apresentada na Equação 3.1, representa a minimização da soma do erro quadrado aplicada aos valores de frequência de ocorrência 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.

A segunda, apresentada na Equação 3.2, representa o valor percentual do desvio da produção entre a curva e o histograma.

$$WPD^2 = \left[\left(\frac{P_{estimada} - P_{medida}}{P_{medida}} \right) .100 \right]^2 \quad (3.2)$$

Onde, de acordo com Jamil, Parsa e Majidi (1995), P_{medida} e $P_{estimada}$ são calculadas, respectivamente, de acordo com as Equações 3.3 e 3.4.

$$P_{medida} = \frac{1}{2} \rho . v^3 \quad (3.3)$$

$$P_{estimada} = \frac{1}{2} \rho . c^3 \Gamma \left(1 + \frac{3}{k} \right) \quad (3.4)$$

Onde ρ é a massa específica do ar, v é a velocidade do vento, Γ é a Função Gama (Equação 2.18) e k e c são os parâmetros estimados.

3.7 Processo de Parametrização

Com o objetivo de se obter o menor esforço computacional, reduzindo assim o tempo de processamento, que neste trabalho foi medido através da função $Rprof$, os métodos heurísticos foram analisados atribuindo-se diferentes valores para os seus principais parâmetros. Partindo dos valores apresentados na Tabela 1, os parâmetros foram variados dentro de um intervalo onde o limite inferior representa 50% do valor sugerido e o limite superior 150% desse mesmo valor de referência. Foi atribuído um passo de variação de 10%, aproximando, quando necessário, para um valor inteiro.

Sabe-se que cada método tem suas peculiaridades, no caso dos Pássaros Migratórios, devido à natureza do método, sabe-se que o parâmetro n deve ser um número ímpar. Diante disso, os valores do limite inferior e superior do intervalo e o passo de variação desse parâmetro foi aproximado para valores que garantissem essa particularidade. A Tabela 2 apresenta os valores máximos e mínimos e o passo de variação aplicados a cada parâmetro.

Tabela 2 – Intervalo e passo de variação aplicados aos parâmetros

Método	Parâmetro	Intervalo	Passo de variação
Busca Harmônia	N_h	3 - 9	1
Busca Cuco	N_n	25 - 75	5
Pássaros Migratórios	N_{pa}	27 - 77	6
Competição Imperialista	N_p	10 - 30	2

Fonte: Elaborado pelo autor

A definição do melhor valor para o parâmetro analisado se deu através da determinação do número de iterações que o método precisou realizar para atingir um resultado que não pudesse ser melhorado ao ponto da função objetivo apresentar variação nas seis primeiras casas decimais.

É importante salientar que a definição da função objetivo foi realizada antes do processo de parametrização, pois é esperado que, fixada a função, seu valor não apresente variação considerável à medida em que os parâmetros sejam variados. Assim, realizar a parametrização para cada uma das três funções objetivo analisadas e só depois definir qual delas apresenta o menor erro só tornaria o trabalho mais cansativo e não alteraria a função escolhida.

3.8 Testes Estatísticos

A qualidade do ajuste entre a curva gerada e o histograma foi avaliada através da raiz quadrada do erro quadrado médio, do erro médio absoluto e do coeficiente de determinação. Além destes, o valor percentual do desvio de produção entre a curva e o histograma (Equação 3.2) também foi avaliado. Adotou-se aqui o mesmo critério utilizado por Azevedo (2015), onde, o desvio na produção de potência deve ser sempre inferior a 2%.

3.8.1 Raiz Quadrada do Erro Quadrado Médio

A Raiz Quadrada do Erro Quadrado Médio, RMSE, do inglês *Root Mean Squared Error*, definida pela Equação 3.5, é uma análise preditiva e relata o grau de dispersão de duas variáveis correlacionadas em torno de um valor esperado médio. Ele relata a ocorrência de equívocos e, portanto, pequenos valores indicam maior confiança nos resultados dos elementos avaliados (ANDRADE et al., 2014).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i^{\text{calculado}} - y_i^{\text{medido}})^2}{n}} \quad (3.5)$$

3.8.2 Erro Absoluto Médio

De acordo com Mentzer e Bienstock (1998), o Erro Absoluto Médio, MAE, do inglês *Mean Absolute Error*, definido pela Equação 3.6 mede o afastamento médio das previsões em relação aos valores observados.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i^{\text{calculado}} - y_i^{\text{medido}}| \quad (3.6)$$

3.8.3 Coeficiente de Determinação

O coeficiente R^2 , definido pela Equação 3.7, é uma medida da capacidade do método para estimar corretamente as variáveis (ANDRADE et al., 2014).

$$R^2 = \frac{\sum_{i=1}^n (y_i^{\text{medido}} - \bar{y}^{\text{medido}})^2 - \sum_{i=1}^n (y_i^{\text{medido}} - y_i^{\text{calculado}})^2}{\sum_{i=1}^n (y_i^{\text{medido}} - \bar{y}^{\text{medido}})^2} \quad (3.7)$$

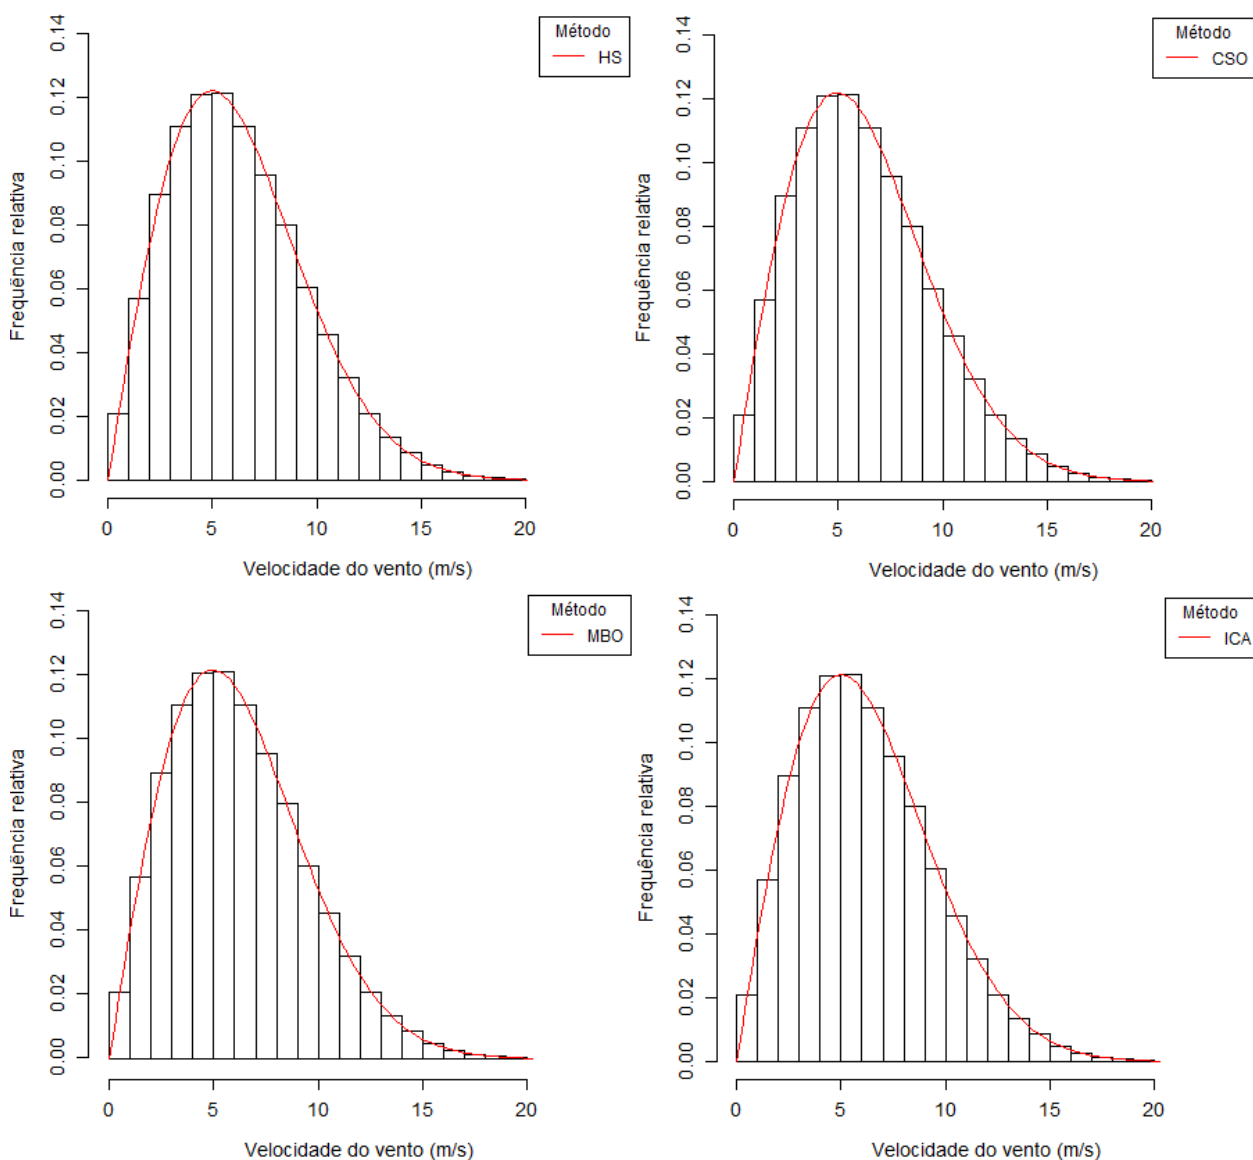
Onde, para os três casos, n é o número de amostras, $y_i^{\text{calculado}}$ e y_i^{medido} são, respectivamente, os valores encontrados para cada método e o valor paramétrico.

4 RESULTADOS E DISCUSSÃO

4.1 Validação dos Métodos Heurísticos

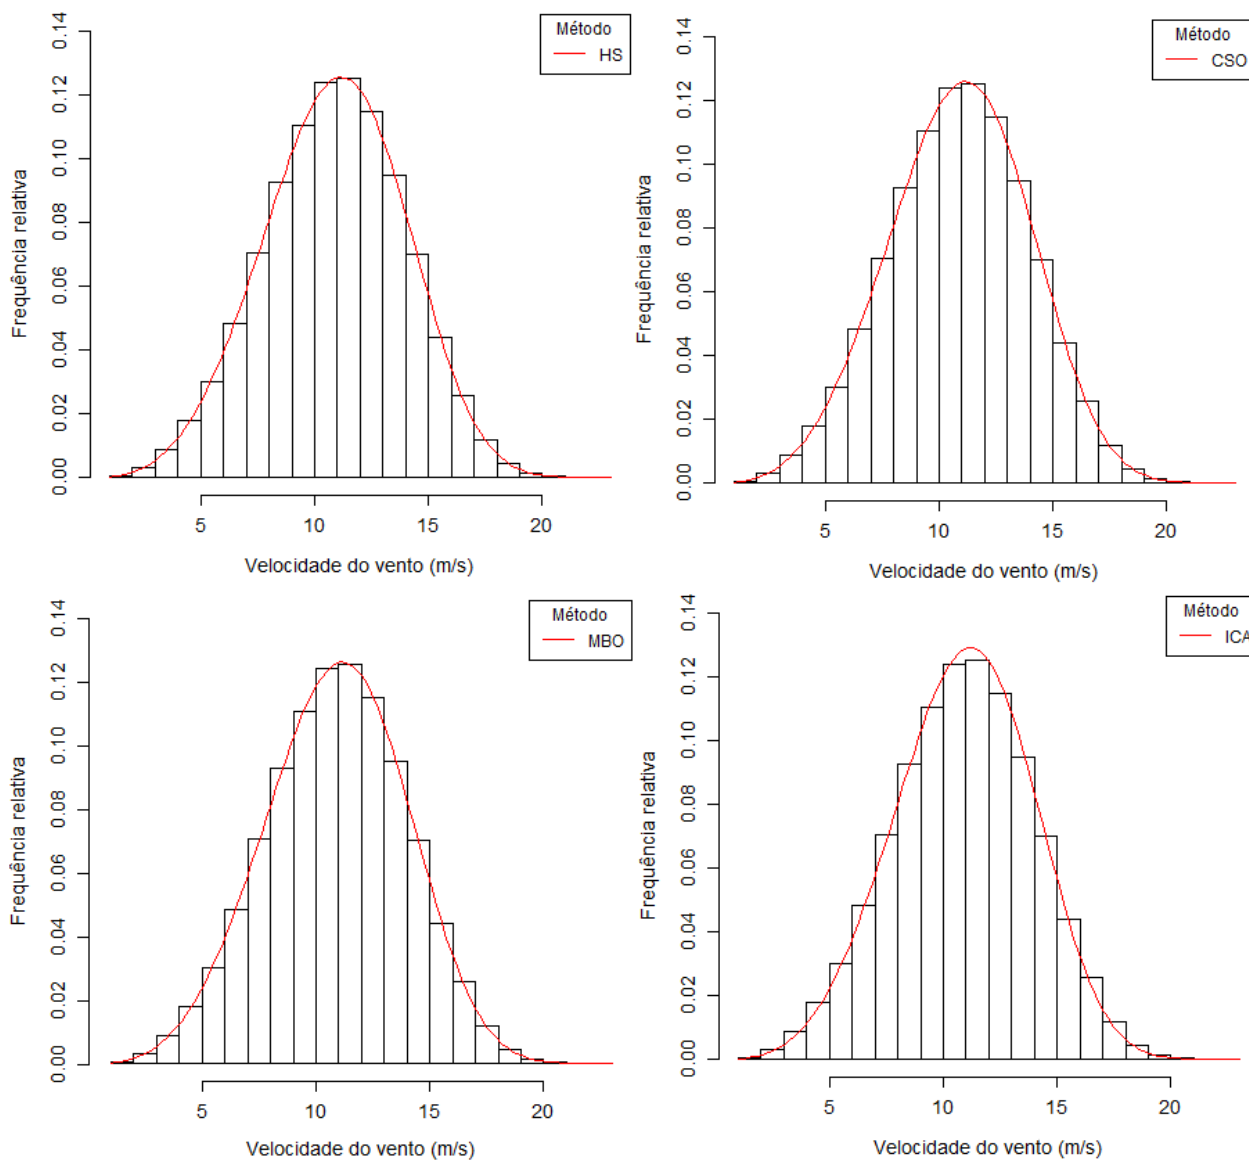
As Figuras a seguir apresentam o histograma de dados gerados a partir de valores conhecidos de k e c , a Figura 11 para $k=2$ e $c=7$ e a Figura 12 para $k=4$ e $c=12$. Os histogramas são apresentados juntamente com as curvas geradas de acordo com a Equação 2.5 e com os valores de k e c estimados a partir dos métodos HS, CSO, MBO e ICA.

Figura 11 – Regime de ventos característico aos parâmetros $k=2$ e $c=7$



Fonte: Elaborado pelo autor

Figura 12 – Regime de ventos característico aos parâmetros $k=4$ e $c=12$



Fonte: Elaborado pelo autor

As Figuras 11 e 12 mostraram que, para ambas as situações, os quatro métodos heurísticos analisados representaram com boa precisão o histograma. Ocorreu um erro, que pode ser desprezado, pois não compromete a qualidade do ajuste, quando o método ICA foi aplicado a série de dados geradas a partir de $k=4$ e $c=12$ (Figura 12). Para essa situação observa-se que o pico da curva atingiu uma frequência superior a maior frequência atingida pelo histograma.

As Tabelas 3 e 4 apresentam os resultados dos testes estatísticos descritos na Seção 3.8 para o procedimento de validação dos métodos heurísticos, conforme Seção 3.2.

Tabela 3 – Testes Estatísticos para $k=2$, $c=7$

Método	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
HS	2,0032	7,0286	0,000112	0,000378	0,999835	0,867298
CSO	1,9967	7,0159	0,000102	0,000348	0,999862	0,653152
MBO	1,9967	7,0159	0,000102	0,000349	0,999862	0,653152
ICA	1,9900	7,0367	0,000117	0,000399	0,999818	1,926858

Fonte: Elaborado pelo Autor

Tabela 4 – Testes Estatísticos para $k=4$, $c=12$

Método	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
HS	3,9657	12,0133	0,000092	0,000328	0,999902	0,432819
CSO	3,9725	12,0037	0,000085	0,000322	0,999916	0,160963
MBO	3,9725	12,0037	0,000085	0,000322	0,999916	0,160963
ICA	4,0811	12,0024	0,000312	0,001117	0,998858	0,360361

Fonte: Elaborado pelo Autor

De acordo com as Tabelas 3 e 4, para ambas as situações, os métodos conseguiram boa aproximação com os valores dos parâmetros, $k=2$, $c=7$ e $k=4$, $c=12$, a partir dos quais foram geradas as séries. Os testes RMSE e MAE apresentaram valores da ordem de 10^{-4} , chegando, em três momentos, a ordem de 10^{-5} . O teste R^2 foi sempre próximo de 1,0, sendo o valor mais distante igual a 0,998858. O desvio na produção (WPD) sempre inferior a 2%, sendo que, com exceção do ICA para a série 4 e 12, todos outros casos obtiveram resultados ainda mais desejáveis, com WPD inferior a 1%.

Portanto, os métodos Busca Harmônica - HS, Busca Cuco - CSO, Pássaros Migratórios - MBO e Competição Imperialista - ICA apresentaram resultados que os validam como métodos que podem ser utilizados para estimar os parâmetros da curva de distribuição de Weibull.

4.2 Determinação da Função Objetivo

Os métodos heurísticos foram analisados, com os parâmetros apresentados da Tabela 1, para cada Função Objetivo proposta. Os resultados são apresentados nas tabelas a seguir.

4.2.1 Estação PTR11 em Petrolina

As Tabelas de 5 a 8 apresentam os resultados do processo de definição da Função Objetivo para a região de Petrolina.

Tabela 5 – Determinação da Função Objetivo para a Busca Harmônica em PTR11

F. Objetivo	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
ϵ^2	3,2873	5,4770	0,001727	0,005012	0,992023	1,794528
<i>WPD</i>	3,4012	5,5311	0,001933	0,004752	0,990011	0,053781
$\epsilon^2 + WPD$	3,2814	5,5092	0,001759	0,005117	0,991733	0,007646

Fonte: Elaborado pelo Autor

Tabela 6 – Determinação da Função Objetivo para a Busca Cuco em PTR11

F. Objetivo	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
ϵ^2	3,2925	5,4774	0,001727	0,004988	0,992026	1,823873
<i>WPD</i>	9,6560	5,6506	0,027394	0,050733	1,006010	3,00E-09
$\epsilon^2 + WPD$	3,2784	5,5060	0,001754	0,005123	0,991779	0,138172

Fonte: Elaborado pelo Autor

Tabela 7 – Determinação da Função Objetivo para os Pássaros Migratórios em PTR11

F. Objetivo	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
ϵ^2	3,2925	5,4774	0,001727	0,004988	0,992026	1,823873
<i>WPD</i>	4,0961	5,610634	0,005190	0,013836	0,928001	1,109336E-31
$\epsilon^2 + WPD$	3,2784	5,5060	0,001754	0,005123	0,991779	0.138172

Fonte: Elaborado pelo Autor

Tabela 8 – Determinação da Função Objetivo para a Competição Imperialista em PTR11

F. Objetivo	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
ϵ^2	3,2928	5,4770	0,001727	0,004986	0,992026	1,849113
<i>WPD</i>	2,9179	5,4243	0,003020	0,007094	0,975625	0,056290
$\epsilon^2 + WPD$	3,2780	5,5058	0,001753	0,005124	0,991781	0,146332

Fonte: Elaborado pelo Autor

De acordo com as Tabelas 5, 6, 7 e 8, todos os métodos analisados apresentaram um melhor ajuste quando aplicados com a função objetivo representada na Equação 3.1. Para as três funções, os valores relativos ao WPD foram inferiores a 2%, no entanto, a função representada na Equação 3.1 foi a que apresentou o melhor ajuste para os testes RMSE e MAE e R^2 .

4.2.2 Estação SMS08 em São Martinho da Serra

As Tabelas de 9 a 12 apresentam os resultados do processo de definição da Função Objetivo para a região de São Martinho da Serra.

Tabela 9 – Determinação da Função Objetivo para a Busca Harmônica em SMS08

F. Objetivo	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
ϵ^2	2,8995	3,7099	0,001700	0,003763	0,995996	0,910862
<i>WPD</i>	1,9748	3,3632	0,011360	0,024123	0,821326	0,207821
$\epsilon^2 + WPD$	2,8993	3,6964	0,001735	0,003769	0,995832	0,180993

Fonte: Elaborado pelo Autor

Tabela 10 – Determinação da Função Objetivo para a Busca Cuco em SMS08

F. Objetivo	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
ϵ^2	2,9102	3,7173	0,001693	0,003700	0,99603	1,347609
<i>WPD</i>	10,2459	3,8522	0,037582	0,072107	0,955520	9,94E-10
$\epsilon^2 + WPD$	2,9185	3,7037	0,001712	0,003654	0,995941	0,106158

Fonte: Elaborado pelo Autor

Tabela 11 – Determinação da Função Objetivo para os Pássaros Migratórios em SMS08

F. Objetivo	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
ϵ^2	2,9102	3,7173	0,001693	0,003700	0,996033	1,347609
<i>WPD</i>	4,8462	3,8562	0,015293	0,034179	0,676181	1,24E-32
$\epsilon^2 + WPD$	2,9185	3,7037	0,001712	0,003654	0,995941	0,106158

Fonte: Elaborado pelo Autor

Tabela 12 – Determinação da Função Objetivo para a Competição Imperialista em SMS08

F. Objetivo	Parâmetros de Weibull		Análise estatística			WPD
	k	c	RMSE	MAE	R^2	
ϵ^2	2,9103	3,7170	0,0016923	0,003699	0,996033	1,315541
<i>WPD</i>	7,2691	3,8686	0,026699	0,052878	0,013072	0,060144
$\epsilon^2 + WPD$	2,9227	3,7028	0,001717	0,003629	0,995918	0,030164

Fonte: Elaborado pelo Autor

Para a estação SMS08, na região de São Martinho da Serra, os métodos Busca Harmônica (Tabela 9), Busca Cuco (Tabela 10), Pássaros Migratórios (Tabela 11) e Competição Imperialista (Tabela 12) apresentaram um ajuste mais adequado quando aplicados com a função objetivo representada na Equação 3.1. Mais uma vez, as três funções atingiram valores de WPD inferiores a 2%, porém, a função representada na Equação 3.1 foi a que atingiu o melhor ajuste para os testes RMSE e MAE e R^2 .

4.3 Processo de Parametrização

As Tabelas de 13 a 16 apresentam os resultados do processo de parametrização realizado de acordo com a descrição da Seção 4.3.

4.3.1 Busca Harmônica - HS

A Tabela 13 apresenta os resultados do processo de parametrização do método Busca Harmônica para as regiões de Petrolina e São Martinho da Serra.

Tabela 13 – Parametrização do método Busca Harmônica - HS

Número de harmonias N_h	Petrolina		São Martinho da Serra	
	Função Objetivo	N° de iterações	Função Objetivo	N° de iterações
3	0,000770	415	0,000573	782
4	0,000769	415	0,000562	730
5	0,000769	978	0,000580	781
6	0,000764	979	0,000567	467
7	0,000769	977	0,000563	978
8	0,000764	978	0,000573	781
9	0,000766	466	0,000572	574

Fonte: Elaborado pelo Autor

Observar-se na Tabela 13 que a Busca Harmônica é um método cujo o ajuste atingido e, principalmente, cujo número de iterações necessárias para que ele apresente seu melhor resultado, aquele como o menor valor da Função objetivo, é totalmente dependente do número de harmonias, seu principal parâmetro.

Para Petrolina, a Função objetivo atingiu em dois momentos seu menor valor, sendo que isto aconteceu com apenas 978 iterações quando foram aplicadas 8 harmonias. Já em São Martinho da Serra, a Função Objetivo atingiu seu menor valor, 0,000562, quando foram aplicadas um total de 4 harmonias. Para este método, em nenhuma das duas regiões analisadas, o número de harmonias de referência, conforme Tabela 1, foi aquele que apresentou o resultado com o menor número de iterações.

4.3.2 Busca Cuco - CSO

A Tabela 14 apresenta os resultados do processo de parametrização do método Busca Cuco para as regiões de Petrolina e São Martinho da Serra.

De acordo com a Tabela 14, a Busca Cuco é um método cujo o ajuste atingido é independente do número de ninhos, uma vez que o menor valor da Função Objetivo permaneceu inalterado. No entanto, o número de iterações necessárias para apresentar seu melhor resultado, aquele como o menor valor da Função objetivo, é totalmente dependente deste parâmetro.

O resultado foi obtido com o menor número de iteração com 65 ninhos, quando foram necessárias, apenas, 24 iterações na região de Petrolina e 30 em São Martinho da Serra. Estes valores representam menos da metade das iterações necessárias quando foram aplicados 50 ninhos, valor de referência, conforme Tabela 1.

Tabela 14 – Parametrização do método Busca Cuco - CSO

Número de ninhas N_n	Petrolina		São Martinho da Serra	
	Função Objetivo	N° de iterações	Função Objetivo	N° de iterações
25	0,000764	47	0,000562	56
30	0,000764	52	0,000562	71
35	0,000764	41	0,000562	47
40	0,000764	58	0,000562	46
45	0,000764	50	0,000562	41
50	0,000764	56	0,000562	70
55	0,000764	36	0,000562	68
60	0,000764	40	0,000562	68
65	0,000764	24	0,000562	30
70	0,000764	58	0,000562	72
75	0,000764	38	0,000562	57

Fonte: Elaborado pelo Autor

4.3.3 *Pássaros Migratórios - MBO*

A Tabela 15 apresenta os resultados do processo de parametrização do método Pássaros Migratórios para as regiões de Petrolina e São Martinho da Serra.

Tabela 15 – Parametrização do método Pássaros Migratórios - MBO

Número de pássaros N_{pa}	Petrolina		São Martinho da Serra	
	Função Objetivo	N° de iterações	Função Objetivo	N° de iterações
27	0,000764	27	0,000562	87
33	0,000764	30	0,000562	510
39	0,000764	28	0,000562	40
45	0,000764	18	0,000562	17
51	0,000764	20	0,000562	31
57	0,000764	106	0,000562	52
63	0,000764	24	0,000562	20
69	0,000764	32	0,000562	26
75	0,000764	19	0,000562	35

Fonte: Elaborado pelo Autor

De acordo com a Tabela 15 o ajuste atingido pelo método Pássaros Migratórios independe do número de pássaros, seu principal parâmetro, uma vez que o menor valor da Função Objetivo permaneceu inalterado. No entanto, o número de iterações necessárias para que ele

apresente seu melhor resultado, aquele como o menor valor da Função objetivo, é totalmente dependente deste parâmetro.

O resultado foi obtido com o menor número de iteração com 45 pássaros. Para este valor foram necessárias, apenas, 18 iterações para a região de Petrolina e 17 para São Martinho da Serra, 14 a menos do que as necessárias para atingir o mesmo resultado aplicando 51 pássaros, valor de referência, conforme Tabela 1.

4.3.4 *Competição Imperialista - ICA*

A Tabela 16 apresenta os resultados do processo de parametrização do método Competição Imperialista para as regiões de Petrolina e São Martinho da Serra.

Tabela 16 – Parametrização do método Competição Imperialista - ICA

Número de países N_p	Petrolina		São Martinho da Serra	
	Função Objetivo	N° de iterações	Função Objetivo	N° de iterações
10	0,000770	853	0,000579	362
12	0,000764	891	0,000578	785
14	0,000764	623	0,000580	805
16	0,000764	492	0,000577	621
18	0,000764	565	0,000576	580
20	0,000764	256	0,000578	944
22	0,000764	86	0,000576	669
24	0,000764	214	0,000576	527
26	0,000764	517	0,000576	644
28	0,000764	212	0,000576	412
30	0,000764	63	0,000576	815

Fonte: Elaborado pelo Autor

Ao analisar a Tabela 16, verifica-se que a Competição Imperialista é um método cujo o ajuste atingido e, principalmente, cujo número de iterações necessárias para apresentar seu melhor resultado, aquele como o menor valor da Função objetivo, é dependente do número de países, seu principal parâmetro.

Para Petrolina, a Função objetivo atingiu em vários momentos seu menor valor, 0,000764, no entanto, isso aconteceu com, apenas, 63 iterações quando foram aplicados 30 países. Em São Martinho da Serra a Função objetivo atingiu em cinco momentos seu menor valor, 0,000576. Para isso acontecer foram necessárias, por exemplo, 669 iterações com 22 países e 527 com 24 países, no entanto, com 28 países, foram necessárias, somente, 412 iterações.

Portanto, em nenhuma das regiões, o número de países de referência, 20, conforme Tabela 1, foi aquele utilizado quando o ICA apresentou o resultado com o menor número de iterações.

4.4 Comparação entre os métodos heurísticos e determinísticos

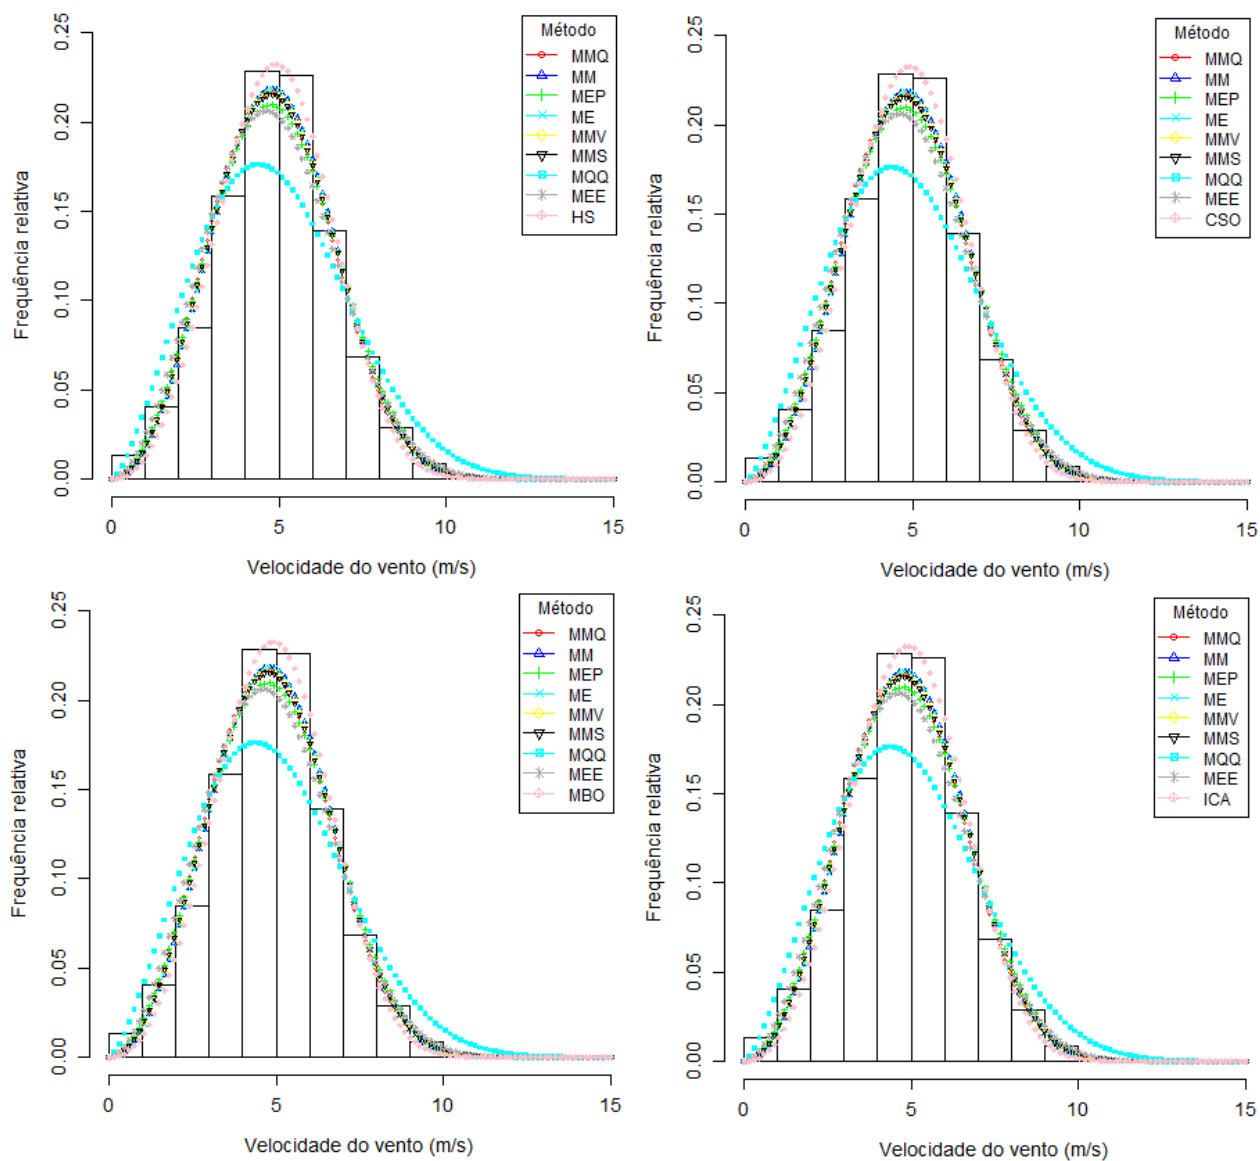
Após a escolha da função objetivo, realizada na Seção 4.2, e a determinação dos parâmetros a ser aplicados nos métodos heurísticos (Seção 4.3), os métodos Busca Harmônica - HS, Busca Cuco - CSO, Pássaros Migratórios - MBO e Competição Imperialista - ICA serão analisados e comparados com os seguintes métodos: Método dos Mínimos Quadrados - MMQ, Método do Momento - MM, Método da Energia Padrão - MEP, Método Empírico - ME, Método da Máxima Verossimilhança - MMV, Método da Máxima Semelhança - MMS, Método do Qui-Quadrado - MQQ e MEE - Método da Energia Equivalente, apresentados na Seção 2.2.2, e que são usualmente utilizados para estimar os parâmetros da curva de Weibull.

4.4.1 Petrolina

Com a finalidade de comparar separadamente, para a estação PTR11 na região de Petrolina, cada método heurístico analisado com os métodos determinísticos, a Figura 13 apresenta quatro histogramas de velocidade do vento com nove curvas sobrepostas a cada um deles. As curvas se comportam de acordo com a Equação 2.5, sendo uma formada a partir dos parâmetros, k e c , estimados pelo método heurístico em questão e as demais pelos métodos determinísticos.

Verifica-se na Figura 13 que o método MQQ não conseguiu representar o histograma de velocidade do vento para a região de Petrolina. A máxima frequência relativa alcançada por ele foi de 0,17, enquanto o histograma chegou a 0,23. As curvas geradas a partir dos demais métodos determinísticos ficaram próximas, com destaque para os métodos MMQ, MM, ME e MMS que alcançaram uma frequência relativa de 0,215 (próxima ao valor atingido pelo histograma). Os métodos heurísticos, que apresentaram curvas semelhantes, conseguiram representar com precisão o histograma, chegando à frequência de 0,235, próximo a velocidade de 5m/s.

Figura 13 – Comparação entre os métodos heurísticos e determinísticos - PTR11



Fonte: Elaborado pelo autor

A Tabela 17 apresenta os valores dos parâmetros da curva de distribuição de Weibull para a região de Petrolina, estimados pelos oito métodos determinísticos e os quatro métodos heurísticos analisados neste trabalho, bem como os resultados dos testes estatísticos e o valor percentual do desvio de produção entre a curva e o histograma, conforme Seção 3.8.

Tabela 17 – Comparação entre os métodos heurísticos e determinísticos - PTR11

Método	Parâmetros de Weibull		Análise estatística			WPD	
	k	c	RMSE	MAE	R^2		
Determinísticos	MMQ	2,9883	5,3996	0,002714	0,006299	0,980310	2,440259
	MM	3,0594	5,4666	0,002283	0,005948	0,986071	0,252696
	MEP	2,9212	5,4776	0,002959	0,007337	0,976598	2,870922
	ME	3,0596	5,4666	0,002282	0,005947	0,986082	0,249015
	MMV	3,0259	5,4536	0,002440	0,006082	0,984086	0,009484
	MMS	2,9981	5,4561	0,002570	0,006267	0,982346	0,512641
	MQQ	2,3840	5,5121	0,006427	0,016840	0,889590	17,962001
	MEE	2,8169	5,3952	0,003640	0,008797	0,964585	5,55e-14
Heurísticos	HS	3,2884	5,4793	0,001727	0,005013	0,992023	1,683615
	CSO	3,2922	5,4771	0,001727	0,004989	0,992026	1,839855
	MBO	3,2883	5,4768	0,001727	0,005007	0,992024	1,815059
	ICA	3,2907	5,4787	0,001727	0,005000	0,992025	1,737645

Fonte: Elaborado pelo Autor

Em relação ao valor percentual do desvio da produção - WPD, todos os métodos analisados, com exceção do MMQ, MEP e MQQ, obtiveram resultados inferiores a 2%, valor máximo admitido para os padrões de geração de energia, com destaque para os métodos MMV e MEE com 0,009484% e 5,55.10⁻¹⁴% respectivamente.

Analisando os testes estatísticos, observa-se que os métodos heurísticos apresentaram exatamente o mesmo valor para o RMSE, 0,001727, valor este menor que os apresentados pelos demais métodos. Com relação ao MAE, apresentaram resultados mais desejáveis que os alcançados pelos métodos determinísticos, com destaque para o CSO com 0,004989. Para o R^2 , os métodos heurísticos apresentaram resultados semelhantes, com variação, apenas, na sexta casa decimal, com destaque, mais uma vez, para o CSO com 0,992026.

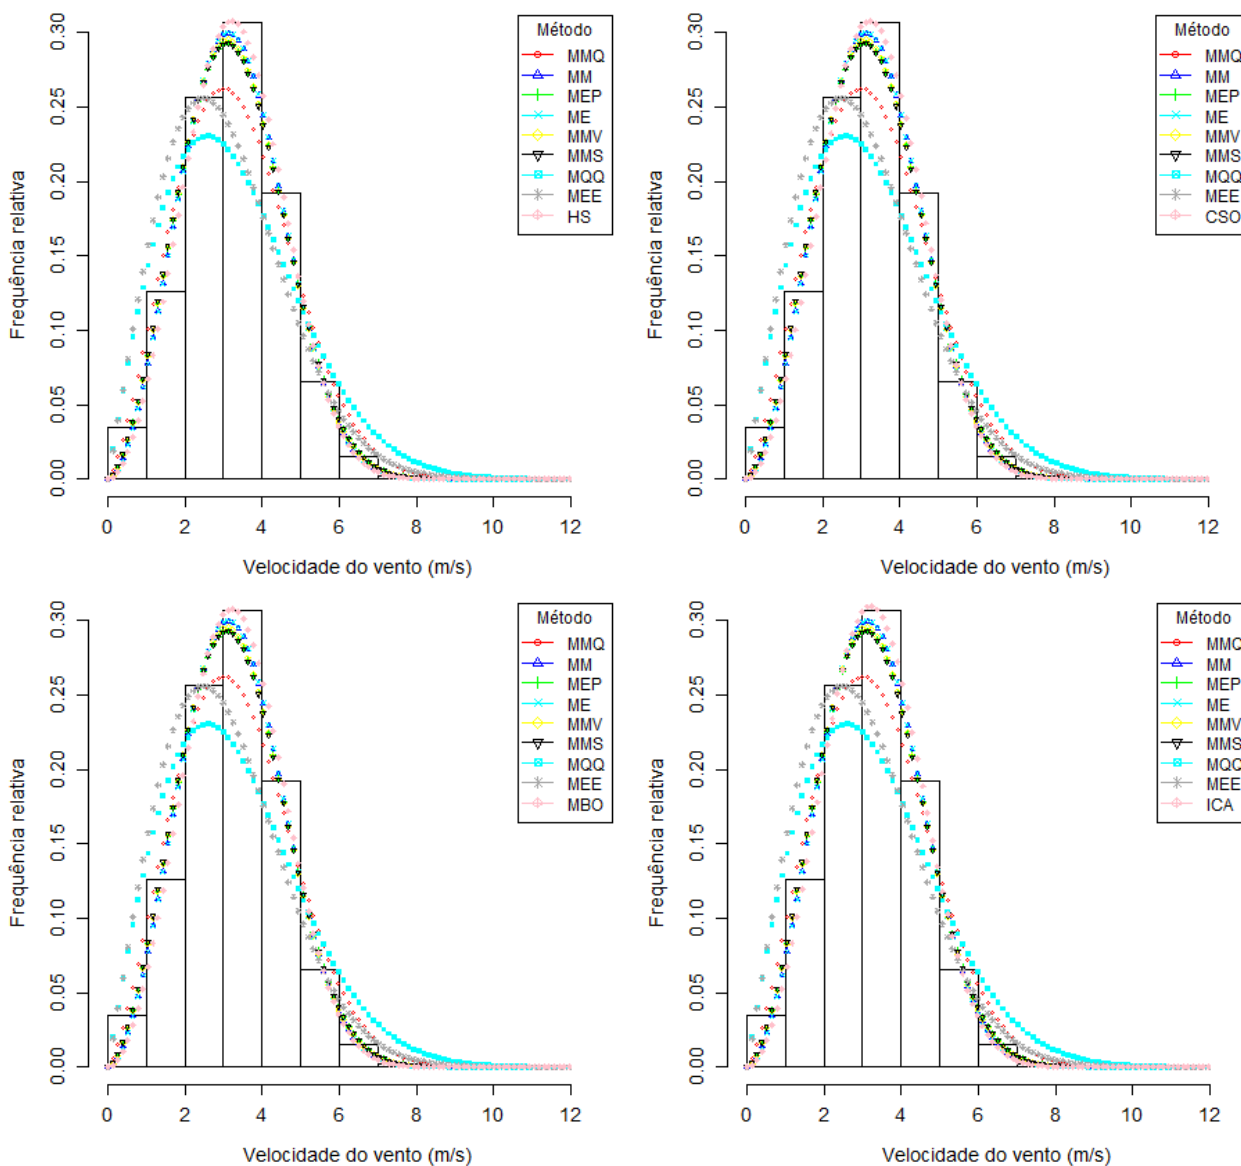
Portanto, fica evidenciado na Tabela 17 a superioridade dos métodos heurísticos em relação aos determinísticos quando o objetivo é estimar os parâmetros da curva de distribuição de Weibull para a região de Petrolina. Ainda de acordo com a Tabela 17, o método CSO, que estimou os valores $k = 3,2965$ e $c = 5,4774$ m/s, apresentou os resultados mais satisfatórios.

4.4.2 São Martinho da Serra

Com a finalidade de comparar separadamente, para a estação SMS08 na região de São Martinho da Serra, cada método heurístico analisado com os métodos determinísticos, a Figura 14 apresenta quatro histogramas de velocidade do vento com nove curvas sobrepostas a cada um deles. As curvas se comportam de acordo com a Equação 2.5, sendo uma formada

a partir dos parâmetros, k e c , estimados pelo método heurístico em questão e as demais pelos métodos determinísticos.

Figura 14 – Comparação entre os métodos heurísticos e determinísticos - SMS08



Fonte: Elaborado pelo autor

Verifica-se na Figura 14 que os métodos MMQ, MEE e MQQ não conseguiram representar o histograma de velocidade do vento para a região de São Martinho da Serra, uma vez estes não atingiram a frequência mais alta do histograma. Além disso, as curvas geradas a partir dos métodos MQQ e MEE apresentaram um deslocamento para a esquerda, ou seja, seus picos não se encontram entre 3 e 4m/s, intervalo de velocidade referente a frequência mais alta do histograma.

As curvas geradas a partir dos demais métodos determinísticos ficaram próximas, com destaque para os métodos ME e MM, que alcançaram maiores frequências. Os métodos heurísticos, que apresentaram curvas semelhantes, conseguiram representar com precisão o histograma, conseguindo, inclusive, coincidência entre a frequência mais elevada atingida por eles e o histograma.

A Tabela 18 apresenta os valores dos parâmetros da curva de distribuição de Weibull para a região de São Martino da Serra, estimados pelos oito métodos determinísticos e os quatro métodos heurísticos analisados, bem como os resultados dos testes estatísticos e o valor percentual do desvio de produção entre a curva e o histograma, conforme Seção 3.8.

Tabela 18 – Comparação entre os métodos heurísticos e determinísticos - SMS08

	Método	Parâmetros de Weibull		Análise estatística			WPD
		k	c	RMSE	MAE	R^2	
Determinísticos	MMQ	2,4119	3,7396	0,005247	0,011541	0,961880	14,946297
	MM	2,7760	3,6717	0,002251	0,005308	0,992983	0,080201
	MEP	2,7050	3,6751	0,002685	0,006282	0,990021	1,578068
	ME	2,7834	3,6714	0,002215	0,005209	0,993209	0,244181
	MMV	2,7188	3,6601	0,002666	0,006216	0,990161	0,059538
	MMS	2,6947	3,6663	0,002800	0,006508	0,989148	1,056168
	MQQ	1,9734	3,6871	0,010051	0,024919	0,860126	31,587672
	MEE	2,0574	3,4136	0,010163	0,021281	0,856988	1,11e-14
Heurísticos	HS	2,9074	3,7144	0,001694	0,003717	0,996029	1,155703
	CSO	2,9107	3,7192	0,001693	0,003697	0,996032	1,492709
	MBO	2,9092	3,7170	0,001693	0,003706	0,996033	1,336411
	ICA	2,9114	3,7165	0,001693	0,003694	0,996033	1,262870

Fonte: Elaborado pelo Autor

Em relação ao valor percentual do desvio da produção, os métodos analisados, com exceção do MMQ, com $WPD = 14,95$, e do MQQ, com $WPD = 31,59$, obtiveram resultados inferiores a 2%, com destaque entre os determinísticos para o MEE, com $WPD = 1,11.10^{-14}\%$. Entre os heurísticos destacou-se o ICA, com $WPD = 0,112258\%$.

Observa-se na análise estatística que em nenhum momento os métodos determinísticos apresentaram resultados superiores aos métodos heurísticos. Diferente do ocorrido para a região de Petrolina, os resultados mais satisfatórios foram atingidos pelo ICA, com $RMSE = 0,001693$, $MAE = 0,003694$ e $R^2 = 0,996033$.

Portanto, fica evidenciado na Tabela 18 a superioridade dos métodos heurísticos em relação aos determinísticos em estimar os parâmetros da curva de distribuição de Weibull

para a região de São Martinho da Serra. Para esta região, destacou-se o ICA que estimou os parâmetros $k = 2,9114$ e $c = 3,7165$ m/s.

4.5 Análise do tempo de processamento

A Seção 4.4 mostrou que, para ambas as regiões, as curvas de distribuição de Weibull geradas a partir dos parâmetros estimados pelos métodos heurísticos ajustou-se melhor ao histograma do que as curvas geradas a partir dos métodos determinísticos. Observou-se ainda que os resultados apresentados pelos métodos heurísticos são bastante próximos, com variação, muitas vezes, somente a partir da quarta casa decimal. Diante disso, e considerando que o tempo requerido por cada método para atingir o resultado apresentando deve ser avaliando quando da escolha de qual deles utilizar, a Tabela 19 apresenta os valores estimados dos parâmetros k e c para as regiões de Petrolina e São Martinho da Serra, bem como o tempo demandado para estimá-los.

Tabela 19 – Tempo de processamento dos métodos heurísticos

Método	Petrolina			São Martinho da Serra		
	k	c	tempo (s)	k	c	tempo (s)
HS	3,2884	5,4793	0,52	2,9074	3,7144	0,46
CSO	3,2922	5,4771	0,90	2,9107	3,7192	1,04
MBO	3,2883	5,4768	1,86	2,9092	3,7170	1,64
ICA	3,2907	5,4787	1,04	2,9114	3,7165	3,84

Fonte: Elaborado pelo Autor

Para a região de Petrolina, o método HS conseguiu estimar os valores dos parâmetros k e c em, apenas, 0,52 segundos, valor inferior a um terço do tempo requerido pelo método MBO, que necessitou de 1,86 segundos. Os métodos CSO e ICA requereram tempos intermediários, 0,90 e 1,04 segundos, respectivamente.

Em São Martinho da Serra, o tempo mais elevado, 3,84 segundos, foi demandado pelo ICA. Para essa região, mais uma vez o CSO requereu tempo intermediário, 1,04 segundos. Novamente o HS foi o método que apresentou o melhor desempenho, ou seja, aquele que conseguiu estimar os parâmetros k e c no menor tempo, somente, 0,46 segundos.

Acredita-se que o destacado desempenho do método Busca Harmônica frente aos demais métodos heurísticos, evidenciado na Tabela 19, é devido ao fato do algoritmo HS não conter complexos cálculos matemáticos. Nele todas as decisões são tomadas por meios aleatórios, ao contrário do que acontece com o Busca Cuco, Pássaros Migratórios e Competição Imperialista, que a cada iteração realiza uma quantidade considerável de cálculos, o que aumenta o tempo de processamento.

5 CONCLUSÃO

Neste trabalho, foram avaliados os métodos heurísticos Busca Harmônica (*Harmony Search* - HS), Busca Cuco (*Cuckoo Search Optimization* - CSO), Pássaros Migratórios (*Migrating Birds Optimization* - MBO) e Competição Imperialista (*Imperialist Competitive Algorithm* - ICA) frente a oito métodos tradicionais utilizados para estimar os parâmetros da curva de Weibull, nomeadamente, Método dos Mínimos Quadrados (MMQ), Método do Momento (MM), Método da Energia Pedrão (MEP), Método Empírico (ME), Método da Máxima Verossimilhança (MMV), Método da Máxima Semelhança (MMS), Método do Qui-Quadrado (MQQ) e Método da Energia Equivalente (MEE).

Os métodos foram implementados utilizando a linguagem R e aplicados às regiões de Petrolina e São Martinho da Serra. Foram gerados dois histogramas com dados anemométricos disponibilizados pelo Instituto Nacional de Pesquisas Espaciais em livre acesso através do Sistema Nacional de Organização de Dados Ambientais (SONDA). A qualidade do ajuste entre a curva, gerada a partir dos parâmetros estimados, e o histograma de dados foi determinada pelos testes estatísticos RMSE, MAPE, R^2 e pelo desvio de produção - WPD.

Os métodos heurísticos propostos foram validados através da criação de duas séries de dados aleatórios gerados a partir de valores conhecidos para os parâmetros k e c . Para a aplicação dos métodos HS, CSO, MBO e ICA, com os dados anemométricos do SONDA, foram analisadas três Funções Objetivo. Este procedimento visou determinar, através da análise dos testes estatísticos, com qual delas os métodos apresentariam o melhor ajuste. Em ambas as regiões, os quatro métodos apresentaram melhores resultados quando aplicados com a equação que busca a minimização da soma do erro quadrado. Além disso, com o objetivo de reduzir o esforço computacional e, portanto, o tempo de processamento, os métodos heurísticos foram parametrizados, ou seja, foram determinados os parâmetros ideais a serem utilizados por cada um deles nas diferentes regiões analisadas. Em todas as situações os parâmetros encontrados foram diferentes daqueles usados em trabalhos anteriores.

Com base nos valores apresentados, observou-se que os métodos propostos são eficazes e podem ser utilizados para estimar os parâmetros da curva de distribuição de Weibull em ambas as regiões. Os métodos heurísticos obtiveram melhor ajuste que os determinísticos, com destaque para o CSO na região de Petrolina, que estimou $k=3,2922$ e $c=5,4771$, e o ICA em São Martinho da Serra, com $k=2,9114$ e $c=3,7165$. Observou-se ainda que o método Busca Harmônica foi aquele que demandou o menor tempo, 0,52s em Petrolina e 0,46s em São Martinho da Serra, para estimar os parâmetros k e c . Isso se justifica pelo fato de que no algoritmo HS todas as decisões são tomadas por meios aleatórios, diferente do que ocorre com os demais métodos heurísticos, onde as decisões envolvem complexos cálculos matemáticos.

REFERÊNCIAS

- ABEEÓLICA. *Geração de energia eólica cresce 25% em 2017*. 2017. Disponível em: <<http://www.abeeolica.org.br/quem-somos/>>. Acesso em: 20 de setembro de 2017.
- ABEEÓLICA. *Histórico da energia eólica no Brasil*. 2017. Disponível em: <<http://www.abeeolica.org.br/noticias/geracao-de-energia-eolica-cresce-25-em-2017/>>. Acesso em: 20 de setembro de 2017.
- 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.
- ANDERSSON, M.; WALLANDER, J. Kin selection and reciprocity in flight formation. *Behavioral Ecology*, v. 15, p. 158–162, 2004.
- ANDRADE, C. F. de; NETO, H. F. M.; ROCHA, P. A. C.; SILVA, M. E. V. da. An efficiency comparison of numerical methods for determining weibull parameters for wind energy applications: A new approach applied to the northeast region of brazil. *Energy Conversion and Management*, v. 86, n. 0, p. 801 – 808, 2014.
- ANEEL. *Programa de Incentivo às Fontes Alternativas*. 2018. Disponível em: <<http://www.aneel.gov.br/proinfa>>. Acesso em: 02 de setembro de 2018.
- 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. 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.
- BADGEROW, J. P.; HAINSWORTH, F. R. Energy savings through formation flight? a re-examination of the vee formation. *Journal of Theoretical Biology*, v. 93, p. 41–52, 1981.
- 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.
- BROWN L. S. LIEBOVITCH, R. G. C. Levy flights in dove juv'hoansi foraging patterns. *Human Ecol*, n. 35, p. 129–138, 2007.

- CHANG, T. P. Performance comparison of six numerical methods in estimating weibull parameters for wind energy application. *Applied Energy*, v. 88, n. 1, p. 272 – 282, 2011.
- CUTTS, J. R. S. C. J. Energy savings in formation flight of pink-footed geese. *Journal of Experimental Biology*, v. 189, p. 251–261, 1994.
- DORVLO, A. S. Estimating wind speed distribution. *Energy Conversion and Management*, v. 43, n. 17, p. 2311 – 2318, 2002.
- 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.
- GEEM, Z. W.; KIM, J. H.; LOGANATHAN, G. A. New heuristic optimization algorithm: Harmony search. *Simulation*, v. 76, n. 2, p. 60–68, 2001.
- GHASEMI, A.; GHEYDI, M.; GOLKAR, M. J.; ESLAMI, M. Modeling of wind/environment/economic dispatch in power system and solving via an online learning meta-heuristic method. *Applied Soft Computing*, v. 43, p. 454–468, 2016.
- GONZÁLEZ, J. S.; GARCÍA Ángel L. T.; PAYÁN, M. B.; SANTOS, J. R.; RODRÍGUEZ Ángel G. G. Optimal wind-turbine micro-siting of offshore wind farms: A grid-like layout approach. *Applied Energy*, v. 200, p. 28–38, 2017.
- HAINSWORTH, F. R. Precision and dynamics of positioning by canada geese flying in formation. *Journal of Theoretical Biology*, v. 128, p. 445–462, 1987.
- HAJIBANDEH, N.; SHAFIE-KHAH, M.; OSÓRIO, G. J.; AGHAEI, J.; CATALÃO, J. P. A heuristic multi-objective multi-criteria demand response planning in a system with high penetration of wind power generators. *Applied Energy*, v. 212, p. 721–732, 2018.
- HENNESSEY JR., J. P. Wind power potential of alaska. *Journal of applied meteorology*, v. 16, n. 2, p. 119–128, 1977.
- HUMMEL, D.; BEUKENBERG, M. Aerodynamische interferenzeffekte beim formationsflug von vögeln. *Journal of Ornithology*, p. 15–24, 1989.
- INTERNATIONAL ELECTROTECHNICAL COMMISSION. *IEC 61400-1: Wind turbines - part 1: Design requirements*. 3. ed. [S.l.], 2005. 92 p.
- JAMIL, M.; PARSA, S.; MAJIDI, M. Wind power statistics and an evaluation of wind energy density. *Renewable Energy*, v. 6, p. 623–628, 1995.
- JIANG, H.; WANG, J.; WU, J.; GENG, W. Comparison of numerical methods and metaheuristic optimization algorithms for estimating parameters for wind energy potential assessment in low wind regions. *Renewable and Sustainable Energy Reviews*, v. 69, p. 1199–1217, 2017.
- 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.
- LISSAMAN, P. B. S.; SHOLLENBERGER, C. A. Formation flight of birds. *Science*, n. 168, p. 1003–1005, 1970.
- 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.
- MENTZER, J. T.; BIENSTOCK, C. C. *Sales Forecasting Management*. California: Sage: [s.n.], 1998.
- MORADI, M. H.; ZEINALZADEH, A.; MOHAMMADI, Y.; ABEDINI, M. An efficient hybrid method for solving the optimal sitting and sizing problem of dg and shunt capacitor banks simultaneously based on imperialist competitive algorithm and genetic algorithm. *Electrical Power and Energy Systems*, v. 54, p. 101–111, 2014.
- NREL. Fundamentals for conducting a successful monitoring program. prepared by aws scientific. *Wind Resource Assessment Handbook*, 1997.
- OSMAN, I. H.; LAPORTE, G. Metaheuristics: A bibliography. *Annals of Operational Research*, v. 63, p. 513–628, 1996.
- PAYNE, R. B.; SORENSON, M. D.; KLITZ, K. The cuckoos. *Oxford University Press*, 2015.
- PISHGAR-KOMLEH, S.; KEYHANI, A.; SEFEEDPARI, P. Wind speed and power density analysis based on weibull and rayleigh distributions (a case study: Firouzkoooh county of iran). *Renewable and Sustainable Energy Reviews*, v. 42, n. 0, p. 313 – 322, 2015.
- R-PROJECT. *The Comprehensive R Archive Network*. 2017. Disponível em: <<http://cran.r-project.org/>>. Acesso em: 19 de dezembro de 2017.
- REYNOLDS, M. A. F. A. Free-flight odor tracking in drosophila is consistent with an optimal intermittent scale-free search. *PLoS One*, 2007.
- ROCHA, P. A. C.; ; SOUSA, R. C. de; ANDRADE, C. F. de; SILVA, M. E. V. da. Comparison of seven numerical methods for determining weibull parameters for wind energy generation in the northeast region of brazil. *Applied Energy*, v. 19, n. 1, p. 395 – 400, 2012.
- RSTUDIO. *Take control of your R code*. 2017. Disponível em: <<http://www.rstudio.com>>. Acesso em: 19 de dezembro de 2017.

SALCEDO-SANZ, S.; GARCÍA-HERRERA, R.; CAMACHO-GÓMEZA, C.; AYBAR-RUIZ, A.; ALEXANDRE, E. Wind power field reconstruction from a reduced set of representative measuring points. *Applied Energy*, v. 228, p. 1111–1121, 2018.

SHU, Z. R.; LI, Q. S.; CHAN, P. Investigation of offshore wind energy potential in hong kong based on weibull distribution function. *Applied Energy*, v. 156, p. 362–373, 2015.

SILVA, G. *Características de vento da região nordeste: análise, modelagem e aplicações para projetos de centrais eólicas*. UFPE, 2003. 151 p. Dissertação — Universidade Federal de Pernambuco, Rio de Janeiro, 2003.

SOTO, R.; B.CRAWFORD; ALMONACID, B.; PAREDES, F. Efficient parallel sorting for migrating birds optimization when solving machine-part cell formation problems. *Scientific Programming*, v. 2016, p. 39p, 2016.

STUTZLE, T. *Local Search Algorithms for Combinatorial Problems—Analysis, Algorithms and New Applications*. Dissertação (Dissertationen zur Kunstliken Intelligenz), Augustin, Germany, 1999.

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

WAIS, P. Two and three-parameter weibull distribution in available wind power analysis. *Renewable Energy*, v. 103, p. 15–29, 2017.

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*, 2016.

WEIBULL, E. W. A statistical distribution function of wide applicability. *Journal Of Applied Mechanics*, Estocolmo, v. 18, p. 293–297, 1951.

WWEA. *Capacidade Instalada de Energia Eólica no Mundo*. 2017. Disponível em: <<http://www.wwindea.org/>>. Acesso em: 25 de setembro de 2017.

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.