



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

**COMPARAÇÃO DO DESEMPENHO DE DIFERENTES MODELOS DE
DISTRIBUIÇÃO DE PROBABILIDADE APLICADOS A DADOS DE VELOCIDADE
DE VENTO *ONSHORE* E *OFFSHORE* NA REGIÃO DO NORDESTE BRASILEIRO**

DAVI RIBEIRO LINS

FORTALEZA

2021

DAVI RIBEIRO LINS

COMPARAÇÃO DO DESEMPENHO DE DIFERENTES MODELOS DE DISTRIBUIÇÃO
DE PROBABILIDADE APLICADOS A DADOS DE VELOCIDADE DE VENTO
ONSHORE E OFFSHORE NA REGIÃO DO NORDESTE BRASILEIRO

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

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

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

FORTALEZA

2021

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)

L731c Lins, Davi Ribeiro.

Comparação do desempenho de diferentes modelos de distribuição de probabilidade aplicados a dados de velocidade de vento onshore e offshore na região do Nordeste brasileiro / Davi Ribeiro Lins. – 2021.
72 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Mecânica, Fortaleza, 2021.

Orientação: Profa. Dra. Carla Freitas de Andrade.

Coorientação: Prof. Dr. Paulo Alexandre Costa Rocha.

1. Energia eólica offshore. 2. Modelagem da velocidade de vento. 3. Distribuições de velocidade de vento não-convencionais. 4. Análise estatísticas de múltiplos critérios. I. Título.

CDD 620.1

DAVI RIBEIRO LINS

COMPARAÇÃO DO DESEMPENHO DE DIFERENTES MODELOS DE DISTRIBUIÇÃO DE PROBABILIDADE APLICADOS A DADOS DE VELOCIDADE DE VENTO ONSHORE E OFFSHORE NA REGIÃO DO NORDESTE BRASILEIRO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica, do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial para a obtenção do Título de Mestre em Engenharia Mecânica. Área de Concentração: Processos, Equipamentos e Sistemas para Energias Renováveis.

Aprovada em 06/04/2021

BANCA EXAMINADORA

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

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

Prof. Dr. André Valente Bueno
Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco de Assis de Souza Filho
Universidade Federal do Ceará (UFC)

Aos meus pais, Rita e Darival.

A minha avó Lilita (*in memorian*).

A Edith (*in memorian*).

AGRADECIMENTOS

Agradeço a Deus pelas oportunidades de crescimento humano, de aprendizado e por fazer-me corajoso com Sua presença nas coisas simples e inesperadas, tanto nos momentos bons como nos ruins. Agradeço aos meus pais pelo amor e pela dedicação e porque, ainda que estejam longe, são a minha maior segurança nessa vida.

Agradeço aos meus irmãos Juliana e Jorge, que são minhas fontes de inspiração e que fazem os meus passos pelo mundo muito mais felizes, tendo mérito em todas as etapas que já concluí.

Agradeço à Prof^ª. Dr^ª. Carla Freitas e ao Prof. Dr. Paulo Alexandre pelas orientações, pelos ensinamentos e por terem acreditado nesse trabalho até o final.

Agradeço aos meus amigos de Campos Sales, Crato e Fortaleza, que sempre estiveram torcendo por mim e vibrando por cada pequena conquista que alcancei.

Agradeço aos meus colegas de curso e ao Valdi, pela ajuda e pelo companheirismo, em especial ao meu colega Kevin Guedes pelo apoio nas fases iniciais da dissertação.

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

“Toda pessoa sempre é as marcas das lições diárias
de outras tantas pessoas.” (Gonzaguinha)

RESUMO

O objetivo dessa dissertação é avaliar a diferença de desempenho apresentada por diferentes modelos de distribuição quando aplicados aos dados de velocidade de vento *onshore* e *offshore*, onde os dados *onshore* foram medidos em duas estações localizadas no Nordeste brasileiro, e os dados *offshore* foram medidos por duas boias oceânicas localizadas no Atlântico Sul. Foram utilizadas cinco distribuições na modelagem da velocidade de vento, sendo elas: Distribuição de Weibull (W), Distribuição Nakagami (N), Distribuição de Lindley Generalizada Estendida (EGL), Distribuição Gamma Generalizada (GG) e Distribuição de Valor Extremo Generalizado (GEV). Os parâmetros das distribuições foram estimados utilizando os seguintes métodos determinísticos: Método da Máxima Verossimilhança (MLE), Método da Máxima Verossimilhança Modificado (MMLE) e o Método dos Momentos Multiobjetivos (MUOM). Além disso, três testes estatísticos foram utilizados na escolha do modelo que apresentou o melhor ajuste aos dados, sendo eles: Teste de Kolmogorov-Smirnov (KS), Desvio de Assimetria e Curtose (DSK) e o Critério de Informação de Akaike (AIC). Os resultados desses testes foram normalizados e unificados em um parâmetro chamado de Erro Total (ET), onde quanto mais próximo de zero esse ET melhor é a precisão da distribuição. Em ambas as localidades *onshore*, devido ao padrão apresentado pelos resultados, a conclusão obtida foi que as distribuições de três parâmetros EGL e GG foram, no geral, superiores às demais distribuições. Nos dados de vento *offshore* da boia 1, as distribuições EGL_{MLE} (ET = 0), W_{MUOM} (ET = 0,085504) e GG_{MLE} (ET = 0,130876) apresentaram as melhores precisões no ajuste ao histograma, já nos dados obtidos pela boia 2, as melhores precisões foram obtidas pelas distribuições EGL_{MLE} (ET = 0), GG_{MLE} (ET = 0,052179) e W_{MUOM} (ET = 0,058615). Para todas as quatro localidades, a combinação distribuição – método GEV_{MMLE} apresentou os Erros Totais mais altos e, conseqüentemente, os piores ajustes. De acordo com os resultados, não existe um modelo de distribuição único que seja mais apropriado para ajustar-se a um conjunto de dados de velocidade de vento, sendo sempre necessário aplicar um estudo pra saber qual das distribuições disponíveis é a mais apropriada para o caso em questão, sendo também necessário verificar qual método de estimativa de parâmetro é o mais adequado para determinada distribuição.

Palavras chaves: Energia eólica *offshore*, Modelagem da velocidade de vento, Distribuições de velocidade de vento não-convencionais, Análise estatística de múltiplos critérios.

ABSTRACT

The objective of this dissertation is to evaluate the performance difference presented by different distribution models when applied to the onshore and offshore wind speed data, where the onshore data were measured at two stations located in Northeast Brazil, and the offshore data were measured by two ocean buoys located in the South Atlantic. Five distributions were used to model wind speed, namely: Weibull Distribution (W), Nakagami Distribution (N), Extended Generalized Lindley Distribution (EGL), Generalized Gamma Distribution (GG) and Generalized Extreme Value Distribution (GEV). The distribution parameters were estimated using the following numerical methods: Maximum Likelihood Method (MLE), Modified Maximum Likelihood Method (MMLE) and the Method of Multi-objective Moments (MUOM). In addition, three goodness of fit tests were used to choose the model that presented the best fit to the data, namely: Kolmogorov-Smirnov test (KS), Asymmetry Deviation and Kurtosis (DSK) and the Akaike Information Criterion (AIC). The results of these tests were normalized and unified in a parameter called Total Error (ET), where the closer to zero this ET the better the accuracy of the distribution. In both onshore locations, due to the pattern presented by the results, the only conclusion obtained was that the three parameters distributions EGL and GG were, in general, superior to the other distributions. In the offshore wind data from buoy 1, the EGL_{MLE} (ET = 0), W_{MUOM} (ET = 0.085504) and GG_{MLE} (ET = 0.130876) distributions showed the best precision in adjusting the histogram. According to the results of buoy 2, the best precision was obtained by the EGL_{MLE} (ET = 0), GG_{MLE} (ET = 0.052179) and W_{MUOM} (ET = 0.058615) distributions. For all four locations, the distribution GEV_{MMLE} presented the highest Total Errors (ET) and, consequently, the worst precisions. According to the results, there is no single distribution model that is more appropriate to fit a set of wind speed data, and it is always necessary to apply a study to know which of the available distributions is the most appropriate for the case in question, being also necessary to verify which parameter estimation method is the most suitable for a given distribution.

Keywords: Offshore wind power, Wind speed modeling, Non-conventional wind speed distributions, Multi-criteria statistical analysis.

LISTA DE FIGURAS

Figura 1: Histograma de velocidade do vento	23
Figura 2: Localização das quatro localidades onde foram feitas as medições	35
Figura 3: Fluxograma da metodologia	40
Figura 4: Distribuições obtidas pelo método MLE (SCR – 25)	44
Figura 5: Distribuições obtidas pelo método MMLE (SCR – 25).....	44
Figura 6: Distribuições obtidas pelo método MUOM (SCR – 25).....	45
Figura 7: Distribuições obtidas pelo método MLE (PT – 11)	48
Figura 8: Distribuições obtidas pelo método MMLE (PT – 11)	48
Figura 9: Distribuições obtidas pelo método MUOM (PT – 11).....	49
Figura 10: Distribuições obtidas pelo método MLE (Boia 1)	52
Figura 11: Distribuições obtidas pelo método MMLE (Boia 1).....	52
Figura 12: Distribuições obtidas pelo método MUOM (Boia 1).....	53
Figura 13: Distribuições obtidas pelo método MLE (Boia 2)	56
Figura 14: Distribuições obtidas pelo método MMLE (Boia 2).....	56
Figura 15: Distribuições obtidas pelo método MUOM (Boia 2).....	57

LISTA DE TABELAS

Tabela 1: Coordenadas geográficas, altitude em relação ao nível do solo, intervalos de medição e períodos de medição	36
Tabela 2: Resultado da análise estatística SCR-25.....	41
Tabela 3: Resultado da análise estatística PT-11	46
Tabela 4: Resultado da análise estatística Boia Oceânica 1	50
Tabela 5: Resultado da análise estatística Boia Oceânica 2	54
Tabela 6: Posição das distribuições nos ranques de cada localidade	58

LISTA DE GRÁFICOS

Gráfico 1: Médias mensais de velocidade de vento	36
Gráfico 2: Erro Total das distribuições da Tabela (2)	43
Gráfico 3: Erro Total das distribuições da Tabela (3)	47
Gráfico 4: Erro Total das distribuições da Tabela (4)	51
Gráfico 5: Erro Total das distribuições da Tabela (5)	55
Gráfico 6: Representação gráfica dos dados da Tabela (6)	58

LISTA DE ABREVIATURAS E SIGLAS

W	Distribuição de Weibull
N	Distribuição Nakagami
EGL	Distribuição Lindley Generalizada Estendida (<i>Extended Generalized Lindley</i>)
GEV	Distribuição Valor Extremo Generalizada (<i>Generalized Extreme Value</i>)
GG	Distribuição Gamma Generalizada
L	Distribuição Lindley
GL	Distribuição Lindley Generalizada (<i>Generalized Lindley</i>)
MLE	Método da Máxima Verossimilhança (<i>Maximum Likelihood Estimation</i>)
MMLE	Método da Máxima Verossimilhança Modificada (<i>Modified Maximum Likelihood Estimation</i>)
MUOM	Método dos Momentos Multiobjetivos (<i>Method of Multi-Objective Moments</i>)
KS	Teste de Kolmogorov-Smirnov
DSK	Desvio de Assimetria e Curtose (<i>Deviation of Skewness and Kurtosis</i>)
AIC	Critério de Informação de Akaike (<i>Akaike Information Criterion</i>)
DS	Desvia de Assimetria (<i>Deviation of Skewness</i>)
DK	Desvio de Curtose (<i>Deviation of Kurtosis</i>)
GWEC	Conselho Geral de Energia Eólica (<i>Global Wind Energy Council</i>)
SONDA	Sistema de Organização de Dados Ambientais
INPE	Instituto Nacional de Pesquisas Espaciais
SCR-25	Estação de coleta de dados em São João do Cariri - PB
PIRATA	<i>Pilot Research Moored Array in the Tropical Atlantic</i>
ATLAS	Sistema de aquisição de linha de temperatura autônoma (<i>Autonomous Temperature Line Acquisition System</i>)
ET	Erro Total

LISTA DE SÍMBOLOS

ρ	Massa específica do ar
v	Velocidade do vento
A	Área do rotor do aerogerador
\bar{P}_W	Potência média de saída
$f(v)$	Função densidade de probabilidade
$F(v)$	Função de distribuição acumulada
k	Parâmetro de forma
c	Parâmetro de escala
p	Segundo parâmetro de forma
$\Gamma()$	Função Gamma
I	Função indicadora
γ_1	Assimetria de uma distribuição de probabilidade
γ_2	Curtose de uma distribuição de probabilidade
g_1	Assimetria empírica
g_2	Curtose empírica

SUMÁRIO

1 INTRODUÇÃO.....	16
1.1 Objetivos.....	18
2 FUNDAMENTAÇÃO TEÓRICA	20
2.1 Recurso eólico	20
2.1.1 Recurso eólico offshore.....	21
2.1.2 Modelagem do recurso eólico	21
2.2 Modelos de distribuição de velocidade do vento.....	23
2.2.1 Distribuição de Weibull.....	24
2.2.2 Distribuição Nakagami (N)	25
2.2.3 Distribuição de Lindley Generalizada Estendida (EGL).....	26
2.2.4 Distribuição Gamma Generalizada.....	27
2.2.5 Distribuição de Valor Extremo Generalizado	27
2.3 Métodos para estimar os parâmetros das distribuições	28
2.3.1 Método da máxima verossimilhança	28
2.3.2 Método da máxima verossimilhança modificado.....	29
2.3.3 Método dos momentos multiobjetivos	29
2.4 Testes estatísticos de desempenho.....	31
2.4.1 Teste de Kolmogorov-Smirnov	31
2.4.2 Critério de informação de Akaike	32
2.4.3 Desvio de assimetria e curtose	32
3 METODOLOGIA.....	34
3.1 Linguagem de programação R.....	34
3.2 Dados de velocidade do vento	34
3.2.1 Dados de velocidade de vento onshore	37
3.2.2 Dados de velocidade de vento offshore.....	37
3.3 Aplicação dos métodos determinísticos e dos testes estatísticos.....	38
4 RESULTADOS E DISCUSSÃO	41

4.1 Estação de São João do Cariri - Paraíba (SCR – 25).....	41
4.2 Estação de Petrolina – Pernambuco (PT - 11).....	46
4.3 Boia Oceânica 1 – Atlântico Sul (ATLAS).....	50
4.4 Boia Oceânica 2 – Atlântico Sul (ATLAS).....	54
4.5 Comparação dos resultados finais de todos os dados de velocidade de vento	57
5 CONCLUSÃO.....	61
REFERÊNCIAS	63
APÊNDICE A: Parâmetros das distribuições de probabilidade.....	68

1 INTRODUÇÃO

Mudanças climáticas decorrentes do aquecimento global e a crescente demanda de energia são preocupações atuais da sociedade, e estimularam a busca por fontes de energia alternativas aos combustíveis fósseis e que não emitam poluentes. As primeiras pesquisas em energias alternativas e renováveis tiveram início após a crise do petróleo na década de setenta, que deixou evidente a elevada dependência mundial aos combustíveis fósseis na época (LAUBER, 2015)

Dentre as fontes de energia renováveis, a energia eólica tem se destacado nos últimos anos com elevado crescimento em diferentes regiões do planeta. O Brasil apresenta um grande potencial a ser explorado, com destaque para a região Nordeste onde a energia eólica, por apresentar seu máximo potencial em períodos de baixos níveis de reservatórios, viabiliza uma complementaridade sazonal quando aliado ao regime hídrico (FREITAS *et al.*, 2020).

Em 2019, as novas instalações de energia eólica globais ultrapassaram 60 GW, um aumento de 18% comparado com 2018, fazendo a capacidade total instalada chegar a 650 GW, 10% a mais comparado com o ano de 2018. No mercado de energia eólica *onshore*, as novas instalações alcançaram 54,2 GW, enquanto que o mercado de energia eólica *offshore* as novas instalações passaram a marca de 6 GW, fazendo com que 2019 fosse o melhor ano para o mercado *offshore* (GWEC, 2020). No Brasil, em 2019, foram instalados 38 novos parques eólicos, que representam um total 744,96 MW de nova capacidade. Os estados que foram contemplados com essas novas instalações foram Rio Grande do Norte, Maranhão e a Bahia. Com esses empreendimentos, o Brasil atingiu uma potência eólica instalada de 15,45 GW, que representa 9,1% da matriz elétrica brasileira (ABBEÓLICA, 2020).

A geração eolielétrica *onshore* é mais barata do que a geração *offshore*, mas a tendência é que os locais viáveis para exploração do potencial eólico *onshore* se tornem cada vez mais escassos. Nesse cenário, os ventos *offshore* são uma alternativa aos ventos *onshore*, pois apresentam ventos mais fortes, mais constantes e menor intensidade de turbulência. Como a implantação de parques eólicos *offshore* são mais caros do que os parques *onshore*, se faz necessário estudos para conhecer o real potencial eólico *offshore* e identificar as melhores regiões para instalação de um parque eólico (SOUKISSIAN, 2013).

Antes de iniciar o aproveitamento do potencial eólico em determinada região, é preciso levar em consideração vários fatores, entre eles a escolha da distribuição de probabilidade que apresenta o melhor ajuste em relação aos dados históricos de velocidade de

vento da região em questão. Com esses dados será possível avaliar o real potencial eólico e viabilidade da instalação de um parque eólico (MASSERAN, 2018). Historicamente, a distribuição de Weibull foi a mais utilizada, mas estudos recentes vêm mostrando que existem distribuições que apresentam melhores resultados na caracterização de certos regimes de vento (KANTAR *et al.*, 2018). Dessa forma, é essencial um estudo com diferentes distribuições para determinar qual apresenta melhor precisão para determinada região.

Uma etapa importante no processo de caracterização do regime de ventos é a determinação dos parâmetros das distribuições, que se não forem estimados de forma precisa acarretarão desvios nos ajustes das distribuições, que são dependentes desses parâmetros (ARIES *et al.*, 2017). Os métodos utilizados para obtenção desses parâmetros podem ser divididos em dois grupos: os Métodos Determinísticos e os Métodos de Otimização Metaheurísticos. Os métodos determinísticos são utilizados na avaliação de potencial eólico devido à sua robustez e simplicidade de aplicação. De acordo com a literatura, os métodos determinísticos são utilizados em distribuições convencionais de dois parâmetros, como, por exemplo, a distribuição de Weibull, e não sendo comum a sua aplicação em distribuições não tradicionais com mais de dois parâmetros. Tais fatos podem ser observados nos estudos realizados por Gugliani *et al.* (2018), Usta *et al.* (2018) e Kantar *et al.* (2018).

Devido ao alto interesse na geração eólicoelétrica *offshore*, vários estudos, tais como Li *et al.* (2020), Krishnamoorthy *et al.* (2020), He *et al.* (2020), Tavares *et al.* (2020), Yu *et al.* (2019), Al-Nassar *et al.* (2018), Li e Yu (2018) e Amirinia *et al.* (2017), vêm sendo publicados com o intuito de investigar como se comporta e como pode ser aproveitado da forma mais eficiente os ventos *offshore*. No entanto, revisando a literatura citada, observa-se que todos, com exceção de Krishnamoorthy *et al.* (2020) e Yu *et al.* (2019), fazem uso apenas da distribuição de Weibull para ajustar-se aos dados de velocidade de vento *offshore*. Guedes *et al.* (2020), demonstraram que apesar de ser a mais utilizada, a distribuição de Weibull não apresenta os melhores ajustes aos dados de velocidade de vento quando comparada com distribuições de três parâmetros.

Diante disso, nessa dissertação, foi feita uma comparação do desempenho de cinco distribuições de probabilidade quando essas são aplicadas a diferentes dados de velocidade de vento *offshore* e *onshore*. Foram utilizadas as seguintes distribuições: Distribuição de Weibull (W), Distribuição Nakagami (N), Distribuição de Lindley Generalizada Estendida (EGL), Distribuição Gamma Generalizada (GG) e Distribuição de Valor Extremo Generalizado (GEV), sendo Weibull e Nakagami as únicas distribuições com apenas dois parâmetros e o restante sendo de três parâmetros. Os métodos utilizados na obtenção dos parâmetros de forma e escala

das distribuições foram: Método da Máxima Verossimilhança (MLE), Método da Máxima Verossimilhança Modificado (MMLE) e o Método dos Momentos Multiobjetivos (MUOM), sendo todos os três métodos determinísticos. A qualidade dos resultados foi avaliada através de testes estatísticos utilizados nesse tipo de análise, sendo eles, Teste de Kolmogorov-Smirnov (KS), Desvio de Assimetria e Curtose (DSK) e o Critério de Informação de Akaike (AIC). Os métodos determinísticos e os testes estatísticos foram implementados e calculados utilizando a linguagem de programação R através do ambiente de desenvolvimento integrado RStudio.

1.1 Objetivos

O objetivo dessa dissertação é avaliar a diferença de desempenho de cinco distribuições de probabilidade W, N, EGL, GEV e GG quando essas são utilizadas para ajustar-se à dados de velocidade de vento de quatro localidades diferentes na região Nordeste, sendo duas *onshore* e duas *offshore*, e fazendo uso de três métodos determinísticos para obter os parâmetros dessas distribuições. O objetivos específicos são:

- Implementar em linguagem R os métodos determinísticos MLE, MMLE e MUOM;
- Obter e tratar os dados de velocidade de vento de duas estações *offshore*, fornecidos pelo projeto PIRATA (*Pilot Research Moored Array in the Tropical Atlantic*), ambas localizadas no oceano Atlântico próximas ao litoral da região Nordeste do Brasil;
- Obter e tratar os dados de velocidade de vento de duas regiões *onshore*, fornecidos pelo Sistema de Organização Nacional de Dados Ambientais (SONDA), sendo elas as regiões de São João do Cariri – PB e Petrolina – PE, ambas localizadas na região Nordeste do Brasil;
- Obter os parâmetros de forma e escala das cinco distribuições W, N, EGL, GEV e GG através da aplicação dos três métodos determinísticos nos dados de velocidade de vento das duas regiões *offshore* e das duas regiões *onshore*;
- Ajustar as distribuições, junto com seus parâmetros obtidos, aos histogramas de velocidade de vento das quatro localidades;
- Quantificar a qualidade dos ajustes através dos testes estatísticos KS, DSK e AIC;

- Determinar, através dos resultados obtidos pelos testes estatísticos, os conjuntos distribuição-método de estimativa dos parâmetros que proporcionaram as melhores precisões nas quatro regiões;
- Confrontar os resultados obtidos nas quatro localidades, afim de avaliar a diferença de desempenho apresentada pelas distribuições quando aplicadas a dados de velocidade de vento *offshore* e *onshore*.

Na seção fundamentação teórica são abordados os principais conceitos que formam a base da presente dissertação, uma introdução ao recurso eólico e como aproveitá-lo, as distribuições de probabilidade que foram aplicadas aos dados de velocidade de vento, os métodos de estimativa de parâmetro e os testes estatísticos utilizados. Na seção metodologia são apresentados os dados de velocidade de vento utilizados e todos os procedimentos realizados para a obtenção dos resultados, a utilização dos métodos determinísticos e dos testes estatísticos.

Na seção resultados e discussão, os resultados são apresentados e analisados individualmente por cada uma das quatro localidades e no final o desempenho das distribuições em todas as localidades são confrontados e comparados. Na seção conclusão é feita uma apresentação geral do que a dissertação se propõe e as conclusões obtidas na seção resultados e discussão são apresentadas.

2 FUNDAMENTAÇÃO TEÓRICA

A seção fundamentação teórica está dividida em quatro subseções. Na primeira subseção é apresentado o recurso eólico, suas características e a forma de modelar esse recurso. Na segunda subseção são apresentadas as distribuições de probabilidade utilizadas e o estado da arte do uso dessas distribuições em análises estatísticas de velocidade de vento. Na terceira subseção são apresentados os métodos determinísticos utilizados na estimativa dos parâmetros. Na última subseção, os testes estatísticos usados para medir a qualidade dos resultados são apresentados.

2.1 Recurso eólico

O vento é causado por diferenças de pressão atmosféricas existentes. Quando ocorre essa diferença de pressão, o ar se move de uma região de alta pressão para uma região de baixa pressão, resultando em ventos de variadas velocidades. Com o planeta Terra em rotação, o ar também é desviado pelo efeito Coriolis, exceto na linha do Equador. No geral, os dois maiores causadores dos padrões de vento em grande escala são a diferença de aquecimento que ocorre entre o Equador e os polos e a rotação do planeta (MAKARIEVA *et al.*, 2013). O vento é utilizado para movimentar as pás das turbinas eólicas, convertendo a energia cinética contida nas massas de ar em energia de rotação, que depois é transformada em energia elétrica ou utilizada para trabalhos mecânicos em moinhos (MANWELL *et al.*, 2009).

A superfície da Terra varia consideravelmente, com grandes oceanos e continentes. Essas diferentes superfícies influenciam na circulação dos ventos devido às variações nos campos de pressão e diferentes quantidades de radiação absorvida por cada tipo de superfície. Características geográficas locais de relevo e de vegetação também influenciam a forma como os ventos circulam, a vegetação, por exemplo, aumenta a rugosidade da superfície reduzindo a energia cinética contida nas massas de ar. Esse é uma das grandes razões pela qual os maiores potenciais eólicos *onshore* geralmente encontram-se nas áreas litorâneas. Entretanto, o que vai determinar o real potencial de produção energética de uma região e atestar a viabilidade da construção de um parque eólico é a modelagem do recurso eólico, que faz uso das distribuições de probabilidade para caracterizar o comportamento dos ventos (MANWELL *et al.*, 2009).

2.1.1 Recurso eólico offshore

O recurso eólico *offshore* tem suas próprias vantagens e desvantagens. Existem estudos apontando as vantagens da energia eólica *offshore* (TAVARES *et al.*, 2020), (BILGILI *et al.*, 2011), devido ao seu maior potencial causado pelos ventos mais fortes, menos turbulência e menos rugosidade superficial do que as localidades no continente. Além de todas essas vantagens, como a água tem capacidade térmica muito maior do que a superfície terrestre, o ciclo diurno e noturno cria menos variação na temperatura superficial, reduzindo diretamente as variações na estabilidade atmosférica e no cisalhamento do vento (BROWER, 2012). Os parques eólicos *offshore* também têm a vantagem de não gerar distúrbios aos moradores locais (LANDENBURG, 2009), e também tem uma vantagem econômica do menor custo do terreno (IRENA, 2012). Além de todas essas vantagens, a energia eólica *offshore* vem com suas próprias desvantagens, principalmente concentradas nos aspectos econômicos, como o alto custo das fundações marítimas, o custo de integração à rede elétrica e os maiores custos de construção e manutenção (ARMIRINIA *et al.*, 2017). Dificuldades técnicas e potenciais impactos ambientais causados pelo setor de energia renovável *offshore* podem ser superados através de novas políticas que estimulem o setor (APPIOTT *et al.*, 2014).

Essa dissertação busca comparar o desempenho de cinco distribuições de probabilidade quando essas são aplicadas a diferentes dados de velocidade de vento *offshore* e *onshore*. Os parâmetros dessa distribuições forma obtidos através de três métodos determinísticos, sendo eles o MLE, MMLE e o MUOM, e a qualidade dos resultados foi verificada a partir de três testes estatísticos, sendo eles o KS, DSK e AIC.

2.1.2 Modelagem do recurso eólico

A velocidade do vento é a principal variável na estimativa do potencial de produção de energia eólica de uma dada região. É possível observar pela Equação (1) que a potência produzida é diretamente proporcional ao cubo da velocidade do vento (MANWELL *et al.*, 2009)

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

Onde ρ é a massa específica do ar (kg/m^3), v a velocidade do vento (m/s) e A a área (m^2) varrida pelas pás do rotor de um aerogerador. A velocidade é uma variável aleatória

contínua, e a distribuição da velocidade do vento depende de vários fatores como temperatura, relevo e vegetação.

São necessários métodos sistemáticos de medição e análise para uma correta estimativa do potencial eólico de uma região. De acordo com a norma IEC 61400-1 (2005), é necessário um intervalo mínimo de medição para uma adequada caracterização do regime de vento. Esse intervalo precisa abranger as variações das características do vento e tem que, no mínimo, corresponder ao período de um ano.

O fator mais importante na determinação da potência de saída de uma turbina eólica é a distribuição de velocidade do vento, mas existem outros fatores que também influenciam a potência de saída, como exemplo pode-se citar: curva de potência do aerogerador, densidade do ar, turbulência e altura do rotor (AKDAG e GULER, 2015).

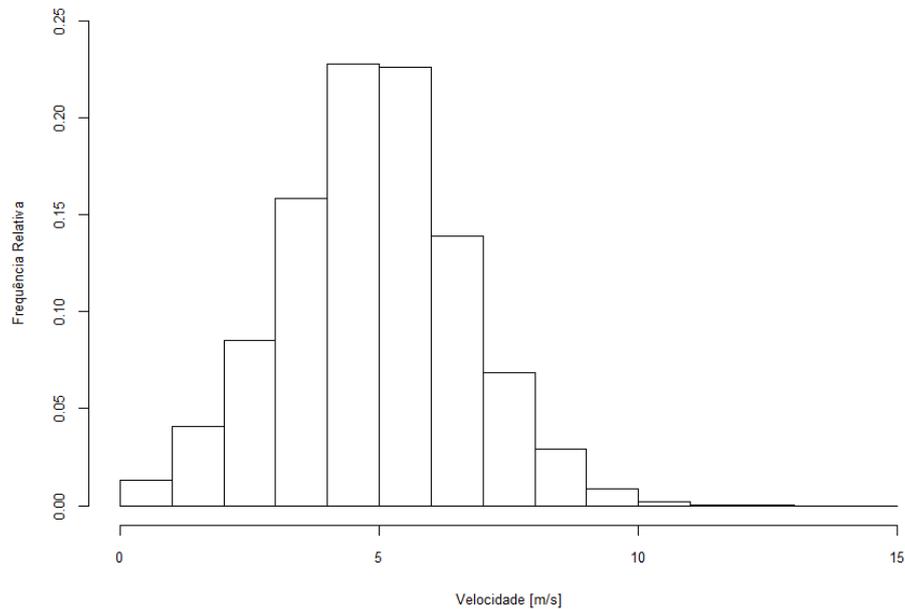
Na Equação (2), que representa a potência média (\bar{W}) gerada por uma turbina eólica, é possível observar a importância da função de densidade de probabilidade $f(v)$ no cálculo da potência gerada por uma turbina eólica (MANWELL *et al.*, 2009).

$$\bar{P}_W = \int_0^{\infty} P_W(v)f(v)dv \quad (2)$$

Onde P_W é a potência de saída do aerogerador em função da velocidade do vento (m/s) e $f(v)$ é a função de distribuição de probabilidade. Sendo a potência de saída P_W conhecida com precisão pelo fabricante, a maior fonte de incertezas na estimativa da potência gerada por uma turbina eólica encontra-se na escolha da função de distribuição de velocidade do vento $f(v)$ (MORGAN *et al.*, 2011). Dessa forma, é necessário que o modelo de distribuição que melhor se adequa ao conjunto de dados de velocidade de vento seja determinado. Quanto melhor for a precisão do ajuste dessa distribuição aos dados de velocidade, mais facilmente será mensurado o potencial e a viabilidade de um parque eólico, reduzindo as incertezas existentes.

Uma forma de representar os dados históricos de velocidade de vento de uma determinada região é através de um histograma, como na Figura (1). A distribuição de probabilidade que melhor consegue acompanhar a curva do histograma é a distribuição que fornecerá o melhor ajuste e, conseqüentemente, a melhor precisão.

Figura 1: Histograma de velocidade do vento



Fonte: Elaborado pelo autor

As distribuições de densidade de probabilidade contém parâmetros de forma e escala que precisam ser calculados. Os métodos utilizados nesses cálculos, que são apresentados na seção 2.3, utilizam como base os dados históricos de velocidade de vento da região de interesse.

2.2 Modelos de distribuição de velocidade do vento

Krishnamoorthy *et al.* (2020) utilizaram distribuições com diferentes números de parâmetros para avaliar o potencial eólico *offshore* e *onshore* na Índia. Dentre as distribuições de dois parâmetros, Nakagami e Weibull apresentaram os melhores resultados, respectivamente. Yu *et al.* (2019) analisaram as características dos ventos *offshore* na baía de Bohai, China, usando as seguintes distribuições: Weibull, Nakagami, Rician e Rayleigh. Dentre essas quatro distribuições, a de Nakagami apresentou o melhor desempenho naquela região.

Guedes (2020) avaliou o desempenho de métodos de otimização metaheurísticos no cálculo dos parâmetros de distribuições de dois e três parâmetros. As distribuições de três parâmetros apresentaram os melhores resultados diante das de dois parâmetros, com destaque para as distribuições de Lindley Generalizada Estendida (EGL), Gamma Generalizada (GG) e

Valor Extremo Generalizado (GEV). As distribuições de Weibull (W) e Nakagami (N) apresentaram os melhores resultados entre as distribuições de dois parâmetros.

A escolha das distribuições utilizadas nessa dissertação foi feita baseada nos resultados apresentados pelo estudo de Guedes (2020), tendo sido selecionadas as três melhores distribuições de três parâmetros e as duas melhores distribuições de dois parâmetros, mas, ao invés de métodos de otimização metaheurísticos, utilizaram-se métodos determinísticos no cálculo dos parâmetros. Nessa dissertação, também foram utilizados dados de velocidade de vento *offshore*, diferentemente de Guedes (2020) que fez uso apenas dados de vento *onshore*.

A seguir, são apresentadas as distribuições que foram selecionadas para caracterizar a frequência das velocidades do vento. Essas distribuições são a de Weibull (W), Nakagami (N), Lindley Generalizada Estendida (EGL), Gamma Generalizada (GG) e Valor Extremo Generalizado (GEV).

2.2.1 Distribuição de Weibull

A função densidade probabilidade de Weibull (W), com dois parâmetros, é muito utilizada na análise de dados de velocidade de vento, e pode se ajustar a diferentes formas de frequência de velocidade de vento com bons resultados (JIANG *et al.*, 2017). Entretanto, não é muito adequada quando a probabilidade de velocidades de vento nula é alta, nesse caso, uma distribuição de três parâmetros, que consegue melhor considerar os efeitos desses valores nulos, pode fornecer melhores resultados (WAIS, 2017). A função densidade probabilidade e a função de distribuição cumulativa são expressas pelas Equações (3) e (4), respectivamente (MANWELL *et al.*, 2009).

$$f(v) = \left(\frac{k}{c}\right) \left(\frac{v}{c}\right)^{k-1} \exp\left[-\left(\frac{v}{c}\right)^k\right] \quad (3)$$

$$F(v) = 1 - \exp\left[-\left(\frac{v}{c}\right)^k\right] \quad (4)$$

Onde k representa o parâmetro de forma, c o parâmetro de escala e v a velocidade do vento (m/s).

Alguns métodos determinísticos, como, por exemplo, o MOUM, usam os momentos teóricos das distribuições nos seus cálculos. Segundo Usta *et al.* (2018), a Equação

(5) representa o momento teórico da W, onde k representa o parâmetro de forma, c o parâmetro de escala, r o grau do momento e $\Gamma()$ é a função Gamma (GUGLIANI *et al.*, 2018).

$$E(V^r) = c^r \Gamma\left(1 + \frac{r}{k}\right) \quad (5)$$

Celik e Kolhe (2013) mostraram que apesar de várias novas distribuições terem sido propostas para analisar os dados de velocidade de vento, a distribuição de Weibull ainda é a mais frequente na literatura. Entretanto, nem sempre a distribuição de Weibull apresenta os melhores ajustes. De acordo com Guedes (2020), as distribuições de Lindley Generalizada Extendida, Gamma Generalizada e Valor Extremo Generalizado apresentaram ajustes mais precisos em relação à Weibull para todos os casos testados.

2.2.2 Distribuição Nakagami (N)

Nakagami é uma distribuição que foi proposta por Nakagami (1960). Foi utilizada por Parsons (1992) na modelagem da atenuação de sinais sem fio atravessando múltiplos caminhos e por Sanchez-Iborra *et al.* (2013) no estudo do impacto da deterioração de canais nas comunicações sem fio. Foi utilizada na análise de distribuição de velocidade de vento por Alavi *et al.* (2016) e Aries *et al.* (2018). Em Guedes (2020), a distribuição de Nakagami, junto com Weibull, apresentou os melhores resultados entre as distribuições de dois parâmetros.

A função densidade probabilidade e a função de distribuição cumulativa de Nakagami são expressas pelas Equações (6) e (7), respectivamente (ARIES *et al.*, 2018).

$$f(v) = \frac{2k^k}{\Gamma(k)c^k} v^{2k-1} e\left(-\frac{k}{c}v^2\right) \quad (6)$$

$$F(v) = \frac{\gamma\left(k, \frac{k}{c}v^2\right)}{\Gamma(k)} \quad (7)$$

Onde k representa o parâmetro de forma, c o parâmetro de escala, v a velocidade do vento (m/s) e $\Gamma()$ é a função Gamma.

2.2.3 Distribuição de Lindley Generalizada Estendida (EGL)

Lindley (1958) propôs inicialmente a Distribuição de Lindley como uma mistura da distribuição exponencial com a distribuição exponencial de comprimento enviesado. Distribuições com mais de dois parâmetros oferecem um melhor ajuste comparado com as de dois ou menos parâmetros. Como a distribuição de Lindley tem apenas um parâmetro, diferentes versões generalizadas dessa distribuição foram formuladas.

Nadarajah *et al.* (2011) propuseram uma forma generalizada de Lindley, chamada de Distribuição de Lindley Generalizada (GL). Bhati *et al.* (2016) formularam uma versão da GL, com três parâmetros, dois de forma e um de escala, chamada de Lindley Generalizada Estendida (EGL). Kantar *et al.* (2018) utilizaram a EGL para modelar a distribuição da velocidade de vento. Os resultados mostraram que a EGL é flexível para se ajustar a diferentes formas de dados de velocidade de vento. A função densidade probabilidade e a função de distribuição cumulativa são expressas pelas Equações (8) e (9), respectivamente (KANTAR *et al.*, 2018).

$$f(v) = \frac{k^2 p c (1+vc)^{2p-1} e^{k-k(1+vc)^p}}{k+1} \quad (8)$$

$$F(v) = 1 - \frac{e^{k-k(1+vc)^p} (1+k(1+vc)^p)}{k+1} \quad (9)$$

Onde k representa o parâmetro de forma, p o segundo parâmetro de forma, c o parâmetro de escala e v a velocidade do vento (m/s).

Segundo Kantar *et al.* (2018), a Equação (10) representa o momento teórico da EGL, onde r representa o grau do momento.

$$E(V^r) = \frac{e^k p k^2 c}{1+k} I(r, p, k) \quad (10)$$

Sendo $I(r, p, k)$ uma função dada pela Equação (11):

$$I(r, p, k) = \frac{1}{p c^{r+1}} \sum_{i=0}^r \binom{r}{i} (-1)^{r-i} k^{-\frac{i}{p}-2} \Gamma\left(\frac{i}{p} + 2, k\right) \quad (11)$$

2.2.4 Distribuição Gamma Generalizada

A Distribuição Gamma Generalizada (GG) é obtida através da generalização da Equação (3). Essa distribuição tem como objetivo superar as restrições que a distribuição de Weibull tem devido ter apenas um parâmetro de forma. O segundo parâmetro de forma tem como função melhorar a flexibilidade da distribuição (KISS e JÁNOSI, 2008). A função densidade probabilidade e a função de distribuição cumulativa são expressas pelas Equações (12) e (13), respectivamente (MORGAN *et al.*, 2011).

$$f(v) = pv^{kp-1} \frac{\exp\left(-\frac{v}{c}\right)^p}{c^{kp} \Gamma(k)} \quad (12)$$

$$F(v) = \gamma\left(k, \left(\frac{v}{c}\right)^p\right) \quad (13)$$

Onde k representa o primeiro parâmetro de forma, p o segundo parâmetro de forma, c o parâmetro de escala e v a velocidade do vento (m/s). A função Gamma $\Gamma(k)$ é necessária para normalização e γ representa a função Gamma incompleta.

Segundo Kiss e Jánosí (2008), a Equação (14) representa o momento teórico da GG, onde r representa o grau do momento.

$$E(V^r) = c^r \frac{\Gamma\left(\frac{k+r}{p}\right)}{\Gamma\left(\frac{k}{p}\right)} \quad (14)$$

2.2.5 Distribuição de Valor Extremo Generalizado

Aries *et al.* (2018) analisaram a exatidão de diferentes distribuições de probabilidade para modelar a velocidade do vento em 4 estações diferentes, localizadas na Argélia, com o objetivo de minimizar as incertezas na estimativa do potencial eólico. De acordo com os critérios utilizados por Aries *et al.* (2018), a Distribuição Valor Extremo Generalizado (GEV) mostrou-se bastante apropriada comparada com as outras distribuições utilizadas.

Mohammadi *et al.* (2017) também aplicaram a GEV, comparando-a com outras distribuições, para estimar o potencial eólico utilizando dados de velocidade de vento de várias

regiões do Canadá. De acordo com os resultados, a GEV mostrou-se bastante efetiva nas estimativas da distribuição de velocidade de vento e de densidade de potência.

A GEV é uma combinação das distribuições de extremo valor de Weibull, Gumbel e Fréchet. A função densidade probabilidade e a função de distribuição cumulativa são expressas pelas Equações (15) e (16), respectivamente (ARIES *et al.*, 2018).

$$f(v) = \frac{e^{\left[-\left(1 - \frac{k(v-u)}{c}\right)^{\frac{1}{k}}\right]}}{c} \left[1 - \frac{k(v-u)}{c}\right]^{\frac{1}{k}-1} \quad (15)$$

$$F(v) = e^{\left[-\left(1 - \frac{k(v-u)}{c}\right)^{\frac{1}{k}}\right]} \quad (16)$$

Onde k representa o parâmetro de forma, μ o parâmetro de localização, c o parâmetro de escala e v a velocidade do vento (m/s).

Os parâmetros de forma e escala das quatro distribuições apresentadas foram calculados através de três métodos determinísticos, que são apresentados na seção seguinte.

2.3 Métodos para estimar os parâmetros das distribuições

Nesta seção são apresentados os três métodos determinísticos que foram utilizados para estimar os parâmetros de forma e escala das distribuições da seção anterior. Os métodos determinísticos são métodos que, dada uma entrada específica, sempre produziram a mesma saída, e são geralmente mais fáceis e rápidos de aplicar (SIDHU, 2019). Esses métodos foram implementados em um ambiente computacional e em uma linguagem de programação chamada R.

2.3.1 Método da máxima verossimilhança

O método da máxima verossimilhança (*Maximum Likelihood Estimation* - MLE), como estimativa para os parâmetros de Weibull, foi proposto por Stevens e Smulders (1979). O objetivo do método é encontrar valores de parâmetros que maximizem a função de verossimilhança logarítmica dos dados observados, ou seja, os valores que melhor representem os dados. As estimativas foram obtidas resolvendo o sistema formado pelas Equações (17), (18)

e (19), simultaneamente, para as três incógnitas k , c e p , através de um método numérico (USTA *et al.*, 2018). Os sistemas de equações foram resolvidos no ambiente computacional R através do método de Nelder-Mead, que foi utilizado por Usta *et al.* (2018) em um cálculo de mesma natureza.

$$\frac{\partial \ln L(k, c, p)}{\partial k} = 0 \quad (17)$$

$$\frac{\partial \ln L(k, c, p)}{\partial c} = 0 \quad (18)$$

$$\frac{\partial \ln L(k, c, p)}{\partial p} = 0 \quad (19)$$

Onde $\ln L(k, c, p) = \ln f(v)$ e $f(v)$ é a função densidade probabilidade da distribuição.

2.3.2 Método da máxima verossimilhança modificado

Quando os dados de velocidade de vento estão em um formato de distribuição de frequência, ou seja, distribuído em grupos devido aos valores repetitivos, o método da máxima verossimilhança modificada (*Modified Maximum Likelihood Estimation* - MMLE) pode ser aplicado para estimar os parâmetros das distribuições. A metodologia é similar ao MLE e utiliza os mesmos métodos numéricos do MLE para resolver os sistemas de equações (ANDRADE *et al.*, 2014). Dessa forma, os dados de velocidade de vento são divididos em grupos de valores repetidos e posteriormente sistema formado pelas Equações (17), (18) e (19) é resolvido para esses grupos de valores.

2.3.3 Método dos momentos multiobjetivos

A média e a variância são os primeiros dois momentos estatísticos, e fornecem informações sobre a localização e dispersão dos dados, respectivamente. Já o terceiro momento mede a assimetria e a forma da distribuição. Usta *et al.* (2018) propuseram o uso do primeiro, segundo e terceiro momento para estimar os parâmetros de Weibull, diferentemente do método dos momentos que só utiliza os dois primeiros momentos. Essa nova abordagem, chamada de

método dos momentos multiobjetivos (MUOM), busca minimizar os desvios quadrados entre os três momentos teóricos e seus relativos empíricos.

Dessa forma, o método dos momentos multiobjetivos é projetado como uma minimização da função multiobjetivo baseada nos três primeiros momentos, e é expresso com o método da soma ponderada, como mostrado a seguir para Weibull, segundo Usta *et al.* (2019):

$$\lambda_1 \left(c\Gamma \left(1 + \frac{1}{k} \right) - \bar{v} \right)^2 + \lambda_2 \left(c^2\Gamma \left(1 + \frac{2}{k} \right) - \overline{v^2} \right)^2 + \lambda_3 \left(c^3\Gamma \left(1 + \frac{3}{k} \right) - \overline{v^3} \right)^2 \quad (20)$$

Onde os λ_1 , λ_2 e λ_3 são os pesos, escolhidos de uma forma que satisfaça $\lambda_1 + \lambda_2 + \lambda_3 = 1$, e o *r*th momento empírico é mostrado na Equação (21).

$$\bar{v}_r = \sum_{i=1}^n \frac{v_i^r}{n} \quad (21)$$

O método das somas ponderadas transforma múltiplos objetivos em uma única função objetivo, somando todas as funções objetivo ponderadas. O peso de cada função depende da importância de cada uma no contexto de cada problema. Usta *et al.* (2018) sugerem o uso do mesmo peso de um terço para cada função objetivo.

O método de Nelder-Mead, que é um método de minimização de funções e que não requer o uso de derivadas, é usado para minimizar as funções objetivo da Equação (20) para estimar os parâmetros de Weibull.

Dessa forma, essa dissertação expande o uso do método dos momentos multiobjetivos, que inicialmente havia sido formulado para ser utilizado na distribuição de Weibull, para a distribuição de Nakagami e para as três distribuições de três parâmetros usadas nesse trabalho.

A Equação (20), que se encontra na forma original para a distribuição de Weibull, foi adaptada para as outras quatro distribuições, gerando a Equação (22), que representa a forma genérica da Equação (20) para qualquer distribuição. Através do ambiente computacional R, a Equação (22) foi resolvida para todas as distribuições usando a função *optim*, que é uma função de otimização própria do R, através do método de Nelder-Mead, proposto por Usta *et al.* (2018).

$$\lambda_1 (E(V^1) - \bar{v})^2 + \lambda_2 (E(V^2) - \overline{v^2})^2 + \lambda_3 (E(V^3) - \overline{v^3})^2 \quad (22)$$

Onde os λ_1, λ_2 e λ_3 são os pesos, escolhidos de uma forma que satisfaça $\lambda_1 + \lambda_2 + \lambda_3 = 1$ e $E(V^r)$ representa os momentos teóricos das distribuições.

2.4 Testes estatísticos de desempenho

Diversos testes estatísticos podem ser utilizados para selecionar o modelo de distribuição que melhor se ajusta aos dados de velocidade de vento, como exemplo pode-se citar: Teste de Kolmogorov-Smirnov (*KS - Kolmogorov-Smirnov test*), Critério de informação de Akaike (*AIC - Akaike Information Criterion*), Critério de informação Bayesiano (*BIC - Bayesian Information Criterion*), Desvio de Assimetria e Curtose (*DSK - Deviation of skewness and kurtosis*), Erro quadrático médio (*MSE*), Raíz quadrada do erro quadrático médio (*RMSE*) e Coeficiente de determinação (R^2).

Segundo Masseran (2018), é possível que os resultados possam variar de um modelo para o outro, ou seja, é possível que um modelo de distribuição seja o melhor em um critério estatístico, em quanto outro modelo seja melhor em outro critério. Além disso, deve-se enfatizar que não existe um consenso de qual é o melhor critério para definir o modelo de distribuição que apresenta o melhor ajuste (KANTAR *et al.*, 2018).

Devido serem os mais frequentes na literatura estudada, nesta dissertação, são utilizados os seguintes testes estatísticos: KS - Kolmogorov-Smirnov, AIC - Critério de informação de Akaike e DSK - Desvio de Assimetria e Curtose.

2.4.1 Teste de Kolmogorov-Smirnov

O teste KS calcula a maior diferença entre a função de distribuição empírica F dos dados e a função de distribuição cumulativa do modelo \hat{F} através da Equação (23), e tem como objetivo determinar qual modelo apresenta o melhor ajuste aos dados (OUARDA *et al.*, 2016).

$$KS = \max_{1 \leq i \leq n} |F_i - \hat{F}_i| \quad (23)$$

Onde

$$F_i = \frac{1}{n} \sum_{t=1}^n I_{X_t \leq x} \quad (24)$$

Na qual $I_{X_i \leq x}$ representa a função indicadora. Se $X_i \leq x$ essa função terá o valor de 1, e 0 se não. Quanto menor for o valor de KS melhor será o ajuste obtido pelo modelo de distribuição.

2.4.2 Critério de informação de Akaike

O teste AIC mede a quantidade de informações perdidas quando um modelo de distribuição é ajustado a um conjunto de dados e seu cálculo é feito a partir da Equação (25), onde L é a função semelhança e n_p é o número de parâmetros do modelo (KANTAR *et al.*, 2018).

$$AIC = -2 \log(L) + 2n_p \quad (25)$$

2.4.3 Desvio de assimetria e curtose

O teste DSK avalia a precisão de um modelo de distribuição baseado nas medidas de similaridade entre as características de forma, que são a assimetria e curtose no teste em questão, do modelo ajustado e da distribuição empírica de dados (MASSERAN, 2018). A assimetria γ_1 e a curtose γ_2 são calculadas, respectivamente, pelas Equações (26) e (27).

$$\gamma_1 = E \left[\left(\frac{X-\mu}{\sigma} \right)^3 \right] = \frac{E(X^3) - 3E(X^2)\mu + 3E(X)\mu^2 - E^3(X)}{[sd(X)]^3} \quad (26)$$

$$\gamma_2 = E \left[\left(\frac{X-\mu}{\sigma} \right)^4 \right] = \frac{E(X^4) - 4E(X^3)\mu + 6E(X^2)\mu^2 - 4E(X)\mu^3 + \mu^4}{[sd(X)]^4} \quad (27)$$

Onde:

$$E(X^n) = \int_{-\infty}^{\infty} x^n f(x) dx \quad (28)$$

$$\mu = E(X) \quad (29)$$

$$sd(X) = \sqrt{E(X^2) - [E(X)]^2} \quad (30)$$

Sendo $f(x)$ a função de distribuição de probabilidade.

A assimetria empírica g_1 e a curtose empírica g_2 dos dados de velocidade de vento podem ser calculadas, respectivamente, pelas Equações (31) e (32), onde \bar{x} representa a média dos valores de velocidade e s o desvio padrão (JUNG *et al.*, 2017).

$$g_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)s^3} \quad (31)$$

$$g_2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)s^4} \quad (32)$$

Finalmente, o teste DSK é calculado através da Equação (33). Valores baixos de DSK significam uma boa qualidade no ajuste (MASSERAN, 2018).

$$DSK = \sqrt{(DS)^2 \cdot (DK)^2} \quad (33)$$

Onde,

$$DS = \gamma_1 - g_1 \quad (34)$$

$$DK = \gamma_2 - g_2 \quad (35)$$

Sendo DS o desvio entre a assimetria teórica e empírica e DK o desvio entre a curtose teórica e empírica.

3 METODOLOGIA

Nesta seção são apresentados os dados utilizados, suas características, as localidades *onshore* e *offshore* onde foram medidos e os tratamentos feitos nos dados. Os procedimentos realizados para obtenção dos resultados e a forma como foram aplicados também são mostrados.

3.1 Linguagem de programação R

Os algoritmos dos métodos determinísticos foram implementados utilizando a linguagem de programação R através do ambiente de desenvolvimento integrado RStudio. O R é uma linguagem e um ambiente computacional, que fornece uma ampla variedade de técnicas estatísticas (modelagem linear e não linear, testes estatísticos clássicos, análise de séries temporais, classificação, agrupamento) e gráficas. O R é disponível como software livre sob os termos da GNU General Public License da Free Software Foundation no formato de código-fonte (R-PROJECT, 2020).

O RStudio é uma interface de desenvolvimento integrado para utilização da linguagem R. Tem como principal vantagem agilizar o uso da linguagem, disponibilizando bibliotecas e organizando o ambiente de trabalho de forma produtiva (RSTUDIO, 2020).

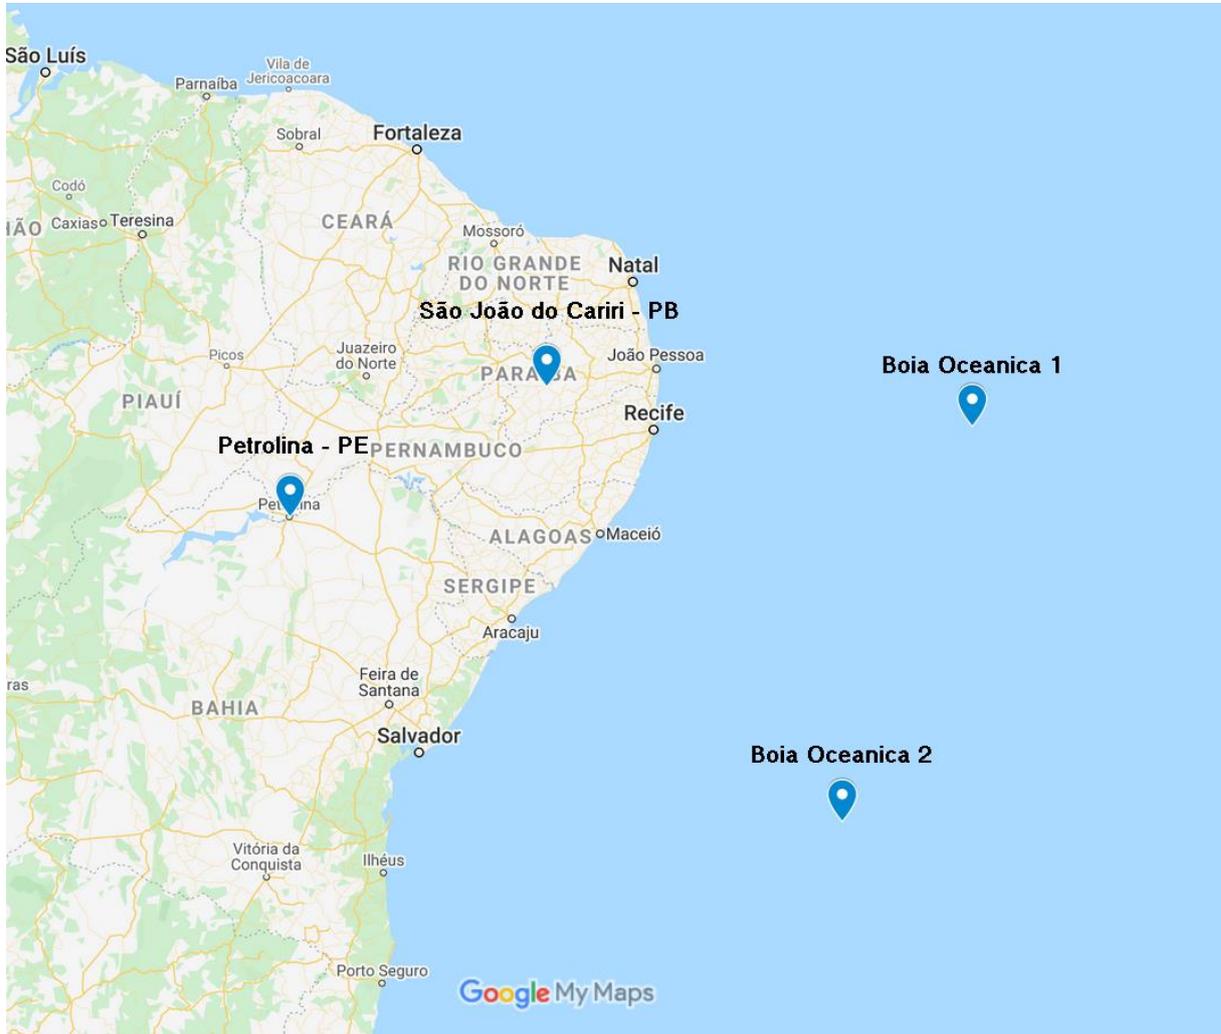
3.2 Dados de velocidade do vento

Nesta dissertação, são utilizados quatro conjuntos de dados anemométricos, dois conjuntos de dados sendo *onshore*, onde as velocidades são medidas na costa marítima ou no interior do continente, e os outros dois conjuntos sendo de dados *offshore*, onde as velocidades são medidas em alto mar.

Todos os conjuntos de dados foram obtidos na região Nordeste. Figura (2) mostra a localização das estações anemométricas, em São João do Cariri-PB e em Petrolina-PE, onde foram obtidos os dados de velocidade de vento *onshore*, e das duas boias oceânicas tipo ATLAS (*Autonomous Temperature Line Acquisition System*), ancoradas no Atlântico Sul, onde foram obtidos os dados de velocidades de vento *offshore*. O Nordeste foi escolhido como foco dessa dissertação devido ser a região com um bom cenário para geração de energia eólica, com

aproximadamente 86% de toda a capacidade instalada de energia eólica do país, segundo o Boletim Anual de Geração Eólica da ABEEólica (2019).

Figura 2: Localização das quatro localidades onde foram feitas as medições



Fonte: Google Maps, 2020.

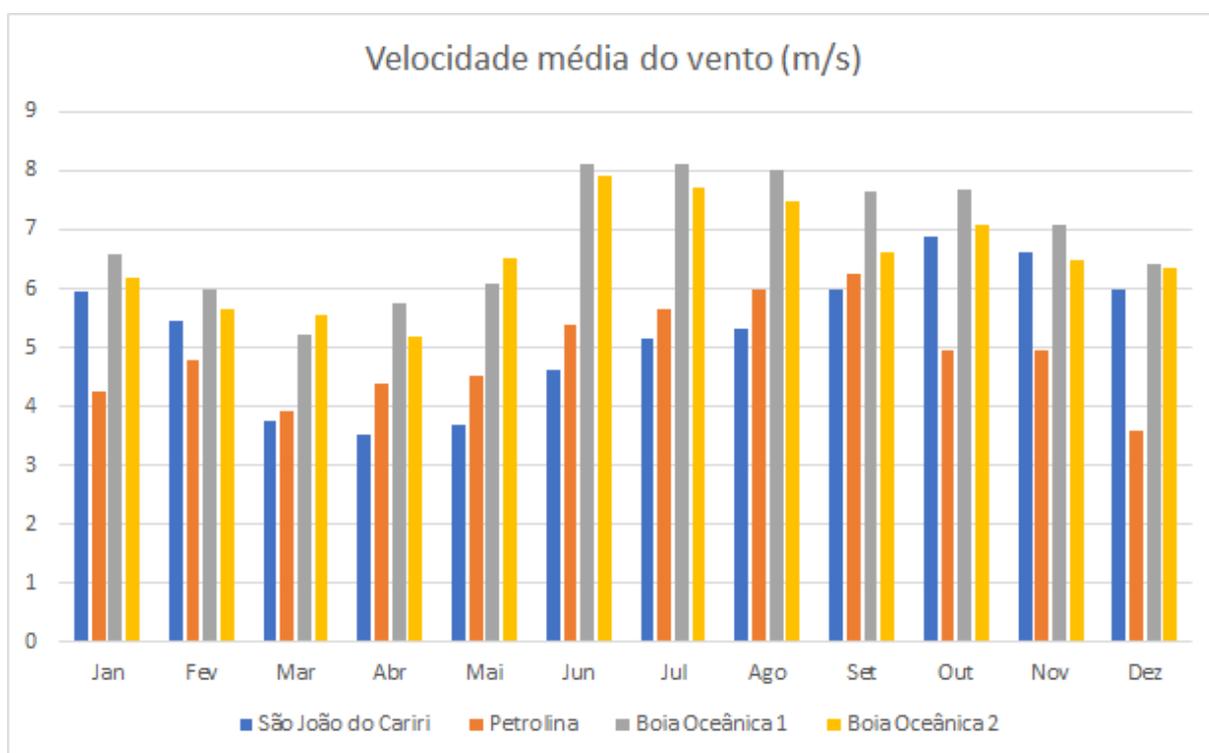
Na Tabela (1), são fornecidas as coordenadas geográficas dos locais de medição e outras informações sobre os dados utilizados e as médias mensais de velocidade de vento dos dados são apresentadas no Gráfico (1).

No tratamento dos dados, foi utilizado um algoritmo para remover valores suspeitos (valores não numéricos, excessivos e negativos). Em todos os dados de velocidade de vento analisados, os valores suspeitos foram menos de 1%, que resultou em aproveitamentos maiores que 99%, demonstrando a confiabilidade dos dados.

Tabela 1: Coordenadas geográficas, altitude em relação ao nível do solo, intervalos de medição e períodos de medição

Localidade	Latitude (°)	Longitude (°)	Altitude (m)	Intervalo de medição (min)	Período de medição
São João do Cariri - PB	07° 22'S	36° 31'O	718	10	01-01-2008 a 31-12-2008
Petrolina - PE	09°S	40°22'S O	387	10	01-01-2010 a 31-12-2010
Boia 1 - Atlântico	08°S	30°O	0	10	01-01-2008 a 31-12-2008
Boia 2 - Atlântico	14°S	32°O	0	10	01-01-2008 a 31-12-2008

Gráfico 1: Médias mensais de velocidade de vento



3.2.1 Dados de velocidade de vento onshore

Os dois conjuntos de dados de velocidade de vento *onshore* utilizados foram obtidos pela estação SCR-25, localizada no município de São João do Cariri, estado da Paraíba, e pela estação PT-11, localizada no município de Petrolina, estado do Pernambuco, ambas na região Nordeste, e estão disponíveis no endereço eletrônico do Sistema de Organização Nacional de Dados Ambientais (SONDA), projeto do Instituto Nacional de Pesquisas Espaciais (INPE). A estação SCR-25 situa-se a uma altitude de 718 metros e tem 2008 como ano de medição, já a estação PT-11 situa-se a uma altitude de 387 metros e tem 2010 como ano de medição, em ambas as localidades o clima é predominantemente semiárido, marcado pelo baixo volume pluviométrico e pela baixa umidade. Os anos de 2008 e 2010 foram escolhidos para as estações SCR-25 e PT-11, respectivamente, pois esses eram os anos mais atuais que apresentavam os dados completos. Os dados de velocidade foram medidos a uma altura de 50 metros do nível do solo, numa resolução temporal de 10 minutos, onde os dados são referentes a média de velocidade de vento apresentada nesses 10 minutos, outras informações referentes aos dados estão disponíveis na Tabela (1).

3.2.2 Dados de velocidade de vento offshore

Os dados de velocidade de vento *offshore* utilizados foram obtidos por duas boias oceânicas no Atlântico Sul, e foram disponibilizados pelo projeto PIRATA (*Pilot Research Moored Array in the Tropical Atlantic*), que é mantido através de uma rede cooperação multinacional entre o Brasil, França e Estados Unidos. Esse projeto tem como objetivo ampliar o conhecimento sobre a variabilidade oceano-atmosfera no oceano Atlântico Tropical (Bourlès *et al.*, 2008).

As boias oceânicas utilizadas são do tipo ATLAS (*Autonomous Temperature Line Acquisition System*) ancoradas. Os dados de velocidade de vento foram medidos a uma altura de 4 metros do nível do mar, numa resolução temporal de 10 minutos, durante o período de um ano, tendo o ano de 2008 como referência, onde os dados são referentes a média de velocidade de vento apresentada nesses 10 minutos, outras informações referentes aos dados estão disponíveis na Tabela (1).

Como o anemômetro instalado nas boias oceânicas mede a velocidade do vento 4 metros acima do nível do mar e as estações terrestres medem os dados *onshore* 50 metros acima do nível do solo, se fez necessário extrapolar os dados *offshore* para uma altura de 50 metros.

A lei logarítmica é muito utilizada na extrapolação da velocidade do vento de uma altura de referência para uma determinada altura desejada. A extrapolação logarítmica é definida pela Equação (36) (MANWELL *et al.*, 2009).

$$U_{log}(z) = \frac{\ln\left(\frac{z}{z_0}\right)}{\ln\left(\frac{z_m}{z_0}\right)} * U(z_m) \quad (36)$$

Onde, $U_{log}(z)$ é a velocidade do vento extrapolada a uma altura z (m/s), z a altura para qual a velocidade será extrapolada (m), z_0 é a rugosidade da superfície adjacente (m), z_m é a altura em que foram realizadas as medições na boia (m) e $U(z_m)$ é a velocidade do vento na altura que foram realizadas as medições (m/s).

Em regiões de mar aberto, na ausência de obstáculos físicos, o vento sofre, primordialmente, o efeito da rugosidade da superfície oceânica. Nesses casos, considera-se uma rugosidade da superfície oceânica constante de $z_0 = 0,0002$ metros (LANDBERG *et al.*, 2003). Dessa forma, os valores de velocidade de vento *offshore* foram convertidos de acordo com a Equação (36), que foi implementada em linguagem R através do RStudio, para uma altura de 50 metros, usando os valores de $z = 50$ m, $z_0 = 0,0002$ m, $z_m = 4$ m e $U(z_m)$ sendo os valores fornecidos pelas boias em metros por segundo.

3.3 Aplicação dos métodos determinísticos e dos testes estatísticos

Todos os métodos desse trabalho foram implementados em linguagem R através do ambiente de desenvolvimento integrado RStudio. No caso do método MLE, foi utilizada a função *mle*, pertencente à biblioteca *stats4* (R Core Team, 2020). No método MMLE, que se trata de uma modificação do método MLE, os dados foram divididos em um formato de distribuição de frequência, para posteriormente ser aplicado o método. Já no método MUOM, a Equação (22) foi implementada no RStudio e resolvida para cada distribuição através da função de otimização *optim*, pertencente à biblioteca *stats* (R Core Team, 2020).

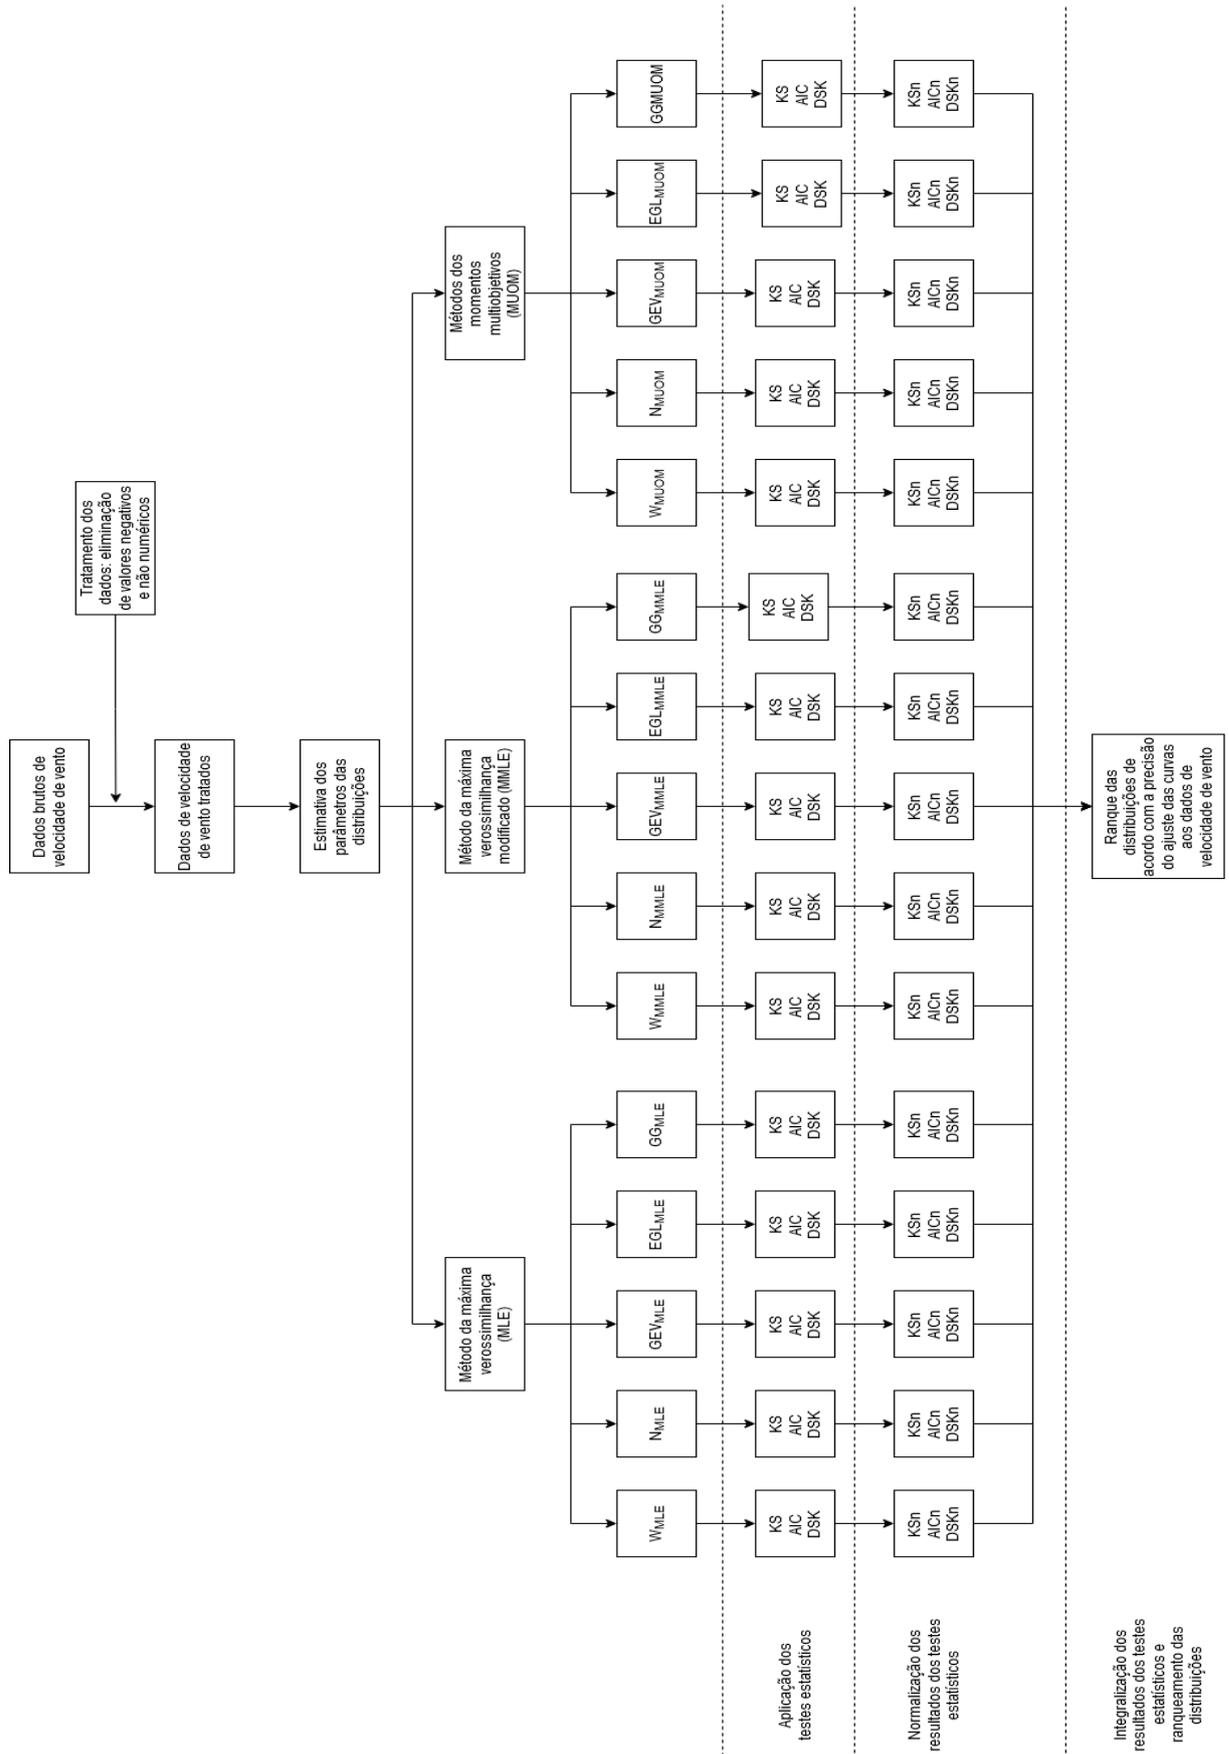
Nessa parte, aos dados de velocidade de vento foram aplicados os três métodos determinísticos (MLE, MMLE e MUOM) para determinar os parâmetros das cinco distribuições de probabilidade (W, N, EGL, GEV e GG). Esse procedimento resultou em quinze combinações de distribuições, que foram nomeadas como: W_{MLE} , W_{MMLE} , W_{MUOM} , N_{MLE} ,

N_{MMLE} , N_{MOUM} , EGL_{MLE} , EGL_{MMLE} , EGL_{MOUM} , GEV_{MLE} , GEV_{MMLE} , GEV_{MOUM} , GG_{MLE} , GG_{MMLE} e GG_{MOUM} . Ao final, para cada uma das quatro localidades, foram obtidas quinze combinações de distribuições, e a todas essas quinze combinações foram aplicados os três testes estatísticos (KS, AIC e DSK). A Figura (3) apresenta um fluxograma da metodologia, mostrando todos as etapas e procedimentos realizados em cada conjunto de dados para a obtenção dos resultados finais.

Como cada teste estatístico pode gerar diferentes resultados, foi utilizado um parâmetro chamado de Erro Total (ET) para classificar as distribuições de acordo com a sua precisão. Em cada um dos quatro conjuntos de dados, os resultados dos três testes estatísticos foram normalizados numa escala entre 0 e 1 e posteriormente o resultado dos testes de cada distribuição foi somado, gerando o Erro Total (ET) de cada distribuição, um total de 15 Erros Totais para cada conjunto de dados. Dessa forma, quanto mais próximo de zero for o ET, mais preciso é o ajuste dessa distribuição, e quanto mais perto o ET estiver de 3, menos preciso é o ajuste dessa distribuição. A Equação (37) mostra como foi feito o cálculo dos Erros Totais (ET), onde KS_n , AIC_n , e DSK_n representam os resultados dos testes estatísticos normalizados.

$$ET = KS_n + AIC_n + DSK_n \quad (37)$$

Figura 3: Fluxograma da metodologia



4 RESULTADOS E DISCUSSÃO

Os resultados de cada localidade são apresentados e discutidos separadamente, posteriormente os resultados são unificados e discutidos na subseção 4.6.

4.1 Estação de São João do Cariri - Paraíba (SCR – 25)

Com os parâmetros das distribuições estimados pelos três métodos determinísticos, foram aplicados os testes estatísticos *KS*, *AIC* e *DSK*. Os resultados dos testes, o Erro Total (ET) e posição de cada combinação de distribuição são apresentados na Tabela (2). Os valores dos parâmetros obtidos são apresentados separadamente no Apêndice A.

Tabela 2: Resultado da análise estatística SCR-25

Distribuição	Método	<i>KS</i>	<i>AIC</i>	<i>DSK</i>	ET	Ranque
W	MLE	0,0188	238020,5	0,1135	0,5315	9
	MMLE	0,0183	238031,4	0,1039	0,5146	8
	MUOM	0,0187	238219,9	0,0762	0,5593	10
N	MLE	0,0285	238798,9	0,2638	1,0626	13
	MMLE	0,0261	238839,4	0,2510	0,9919	11
	MUOM	0,0305	240065,9	0,2027	1,3816	14
GEV	MLE	0,0174	237592,4	0,0001	0,3555	6
	MMLE	0,0419	241556,8	2,8885	3,0000	15
	MUOM	0,0199	237796,3	0,0541	0,4999	7
EGL	MLE	0,0146	236949,9	0,0055	0,1302	4
	MMLE	0,0139	236950,6	0,0048	0,1052	3
	MUOM	0,0174	237030,2	0,0413	0,2486	5
GG	MLE	0,0110	236940,9	0,0012	0,0106	2
	MMLE	0,0107	236958,7	0,0006	0,0040	1
	MUOM	0,0255	239149,5	0,1379	0,9997	12

Analisando a Tabela (2), é possível constatar o que foi dito anteriormente sobre o fato de os testes estatísticos poderem apresentar resultados diferentes, pois os testes estatísticos obtiveram diferentes distribuições como melhores resultados, sendo elas: GG_{MMLE} , no teste *KS*, GG_{MLE} no teste *AIC* e GEV_{MLE} no teste *DSK*. Dessa forma, é possível perceber a importância

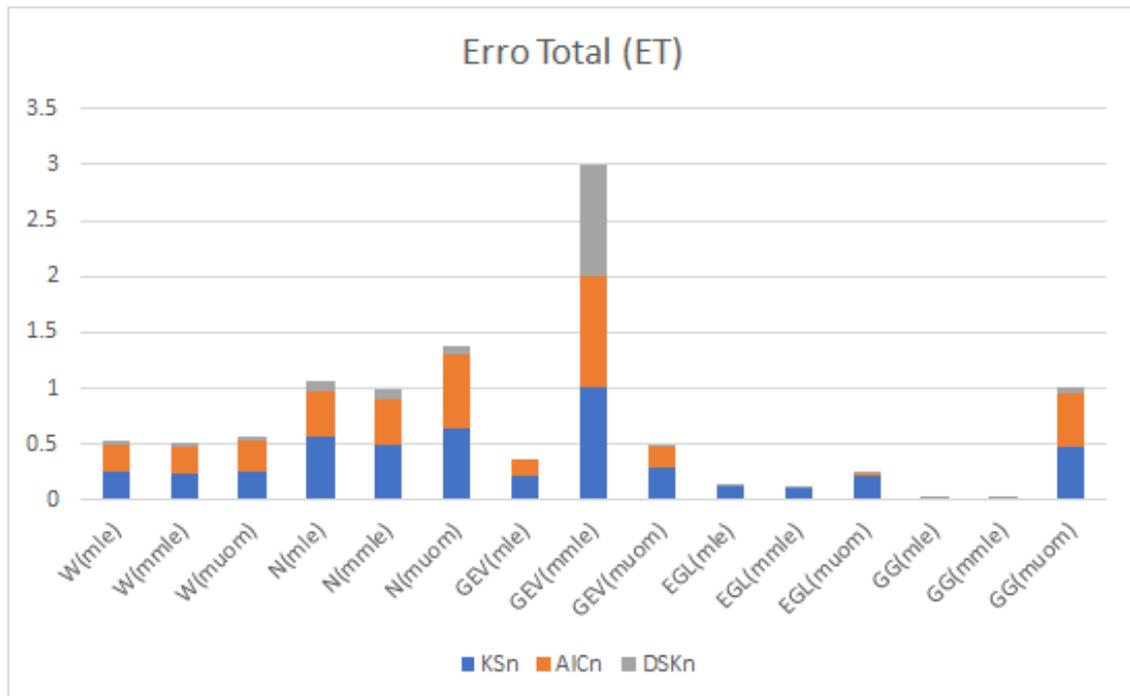
da utilização do ET, pois sem ele não seria possível definir a combinação de distribuição ótima, que nesse caso foi a GG_{MMLE} com $ET = 0.004005$, essa mesma apareceu na quarta posição no teste AIC , na segunda posição no teste DSK e em primeiro apenas no teste KS . De acordo com o ET, a segunda e a terceira posições ficaram com as distribuições GG_{MLE} ($ET = 0.010644$) e EGL_{MMLE} ($ET = 0.105203$), respectivamente.

Observando a Tabela (2), pode-se verificar a superioridade das distribuições de três parâmetros sobre as de dois parâmetros. De acordo com o ET, a distribuição de dois parâmetros mais bem colocada no ranque foi o W_{MMLE} ($ET = 0.514569$), encontrando-se na posição 8. Entre as distribuições de dois parâmetros, foi possível verificar a superioridade de W sobre N em todos os três métodos determinísticos utilizados. Já entre as distribuições de três parâmetros, a GEV foi a que apresentou o pior desempenho, com destaque para o modelo GEV_{MMLE} , que ficou em último lugar em todos os testes estatísticos com $ET = 3$, maior ET possível.

Entre os métodos, o MLE, com $ET = 2,090430$, e o MUOM, com $ET = 3.689178$, foram os que apresentaram maiores ET, com o MLE apresentando um desempenho superior. Evidenciando que o MLE, entre os métodos determinísticos, é um método robusto tanto para distribuições de dois como de três parâmetros. O ET dos métodos foi calculado somando os ETs de todas as suas distribuições.

No Gráfico (2), estão apresentados os Erros Totais da Tabela (2) na forma de gráfico de barras, nela é possível visualizar a influência de cada teste estatístico no Erro Total de cada distribuição, como, por exemplo, o fato de todas as distribuições terem pouco erro no teste DSK , com exceção do GEV_{MMLE} .

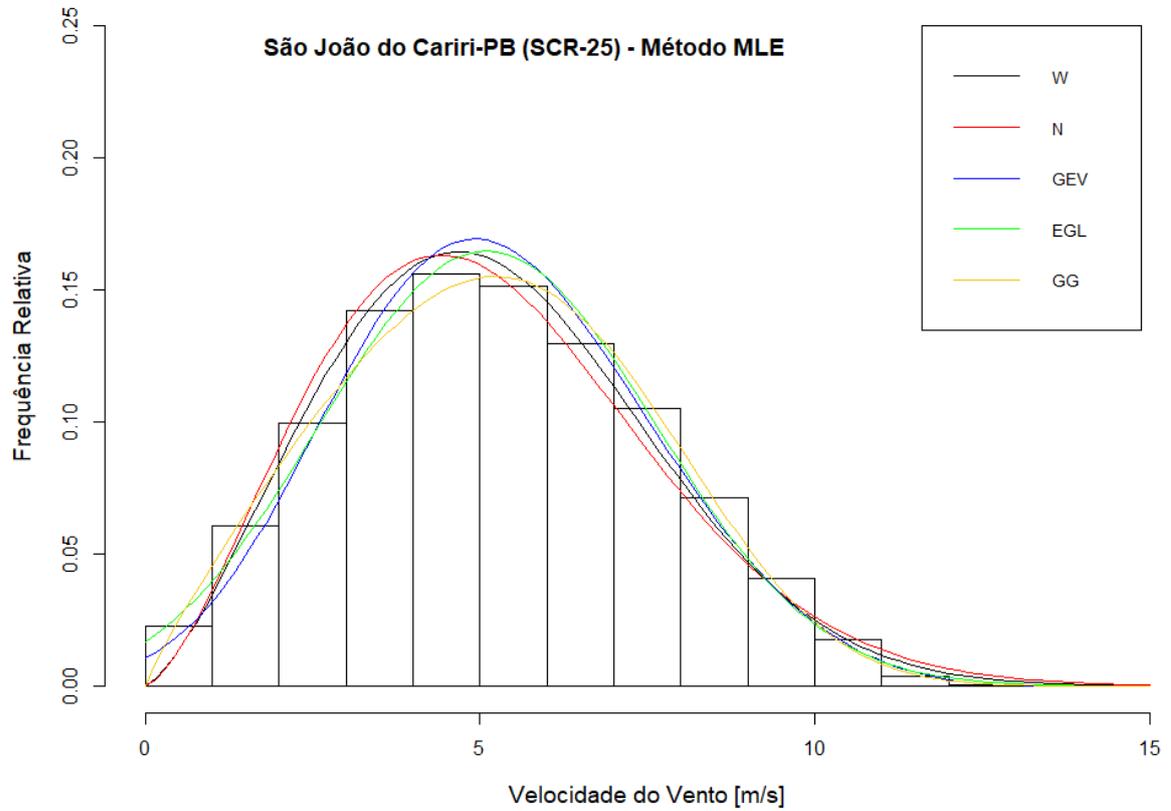
Gráfico 2: Erro Total das distribuições da Tabela (2)



Fonte: Elaborado pelo autor.

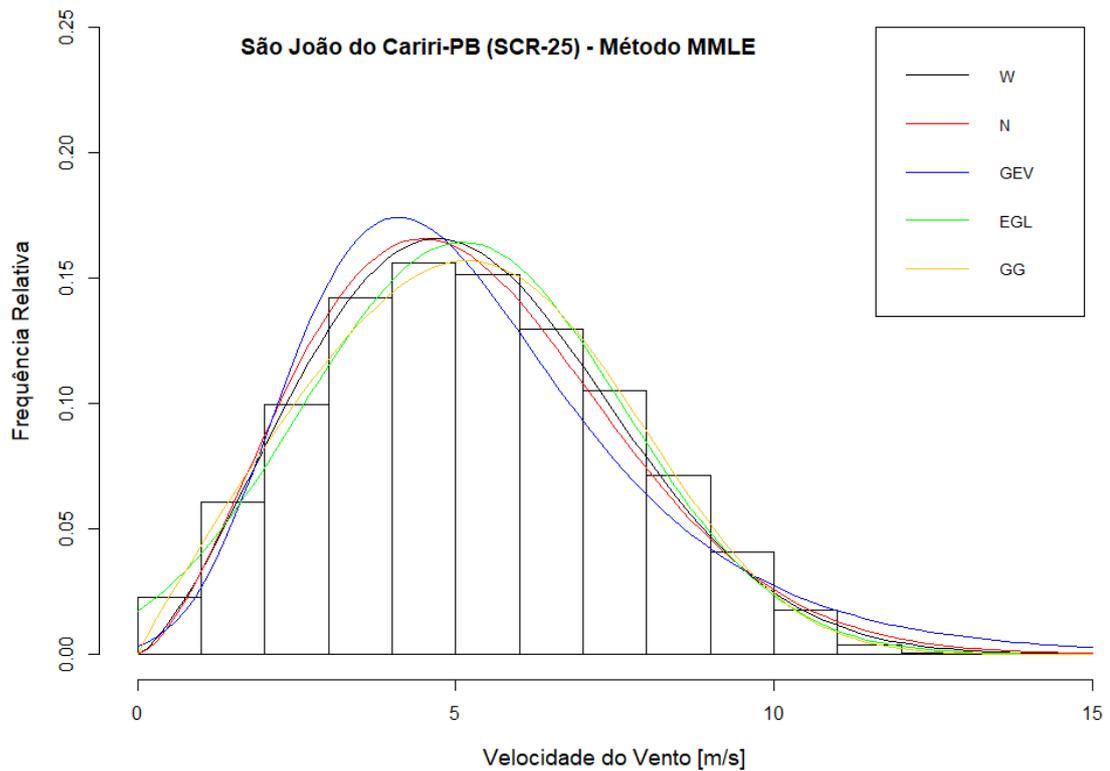
As Figuras (4), (5) e (6) apresentam graficamente os ajustes de todas as combinações de distribuições da Tabela (2) ao histograma de velocidade de vento da estação SCR-25 de São João do Cariri, Paraíba. Cada Figura apresenta os resultados obtidos por um método de estimativa diferente.

Figura 4: Distribuições obtidas pelo método MLE (SCR – 25)



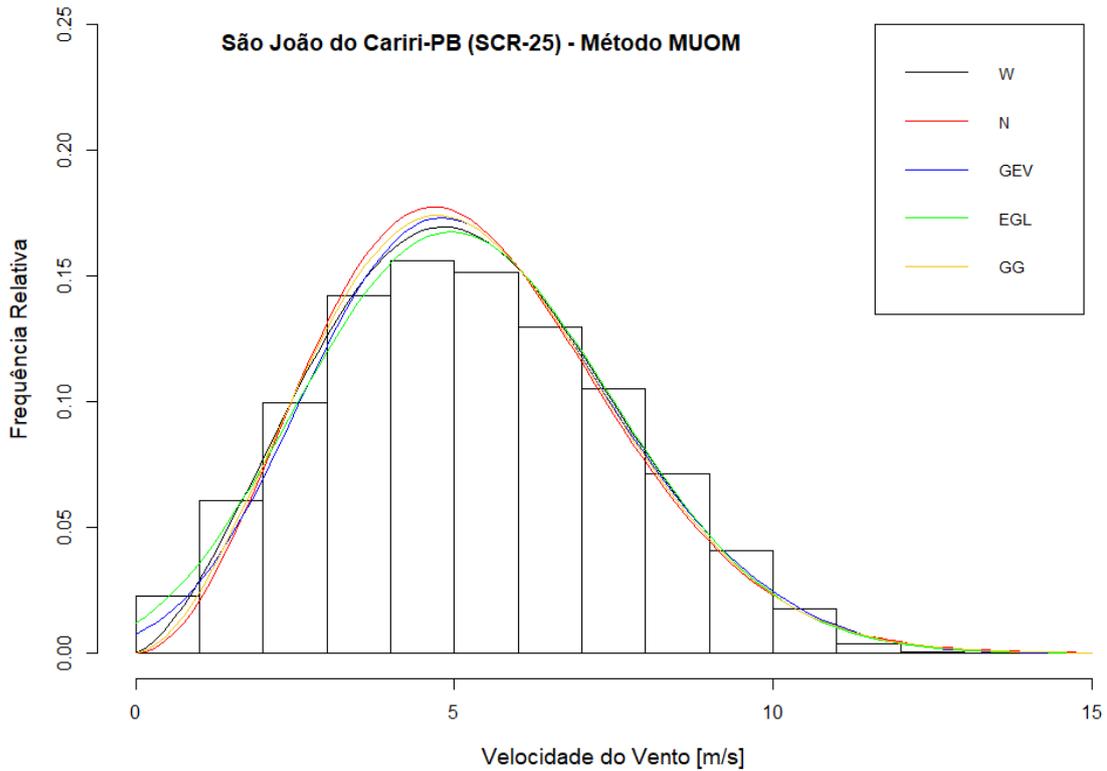
Fonte: Elaborado pelo autor.

Figura 5: Distribuições obtidas pelo método MMLE (SCR – 25)



Fonte: Elaborado pelo autor.

Figura 6: Distribuições obtidas pelo método MUOM (SCR – 25)



Fonte: Elaborado pelo autor.

Analisando as Figuras (4), (5) e (6), pode-se ver o porquê das distribuições GG_{MMLE} , GG_{MLE} terem obtido os melhores ajustes, pois elas são as únicas distribuições que não ultrapassam o pico de frequência relativa dos histogramas de velocidade de vento. Na Figura (5), é possível observar o comportamento da distribuição que apresentou o pior ajuste, a GEV_{MMLE} , onde o pico da curva acontece numa velocidade inferior ao do pico do histograma e a uma frequência relativa superior, e em velocidades superiores a 6 m/s, essa distribuição apresenta frequências inferiores às do histograma. Na Figura (6), o comportamento das curvas das distribuições no método MUOM apresentaram comportamento parecido, com um pico de frequência relativa superior ao pico do histograma e com a EGL_{MUOM} ($ET = 0.248586$) apresentando o melhor ajuste entre elas.

Dessa forma, as Figuras (4), (5) e (6) demonstram graficamente os resultados apresentados na Tabela (2), onde foi possível verificar a superioridade das distribuições de três parâmetros, sobretudo a GG e a EGL, sobre as de dois parâmetros.

4.2 Estação de Petrolina – Pernambuco (PT - 11)

Nesta seção, é analisado o desempenho dos modelos de distribuição quando estes são aplicados aos dados de velocidade de vento *onshore* da estação PT-11, localizada no município de Petrolina, estado do Pernambuco, e medidos durante o ano de 2010. Os resultados dos testes estatísticos, os Erros Totais e a posição de cada combinação de distribuição são apresentadas na Tabela (3). Os valores dos parâmetros obtidos são apresentados separadamente no Apêndice A.

Tabela 3: Resultado da análise estatística PT-11

Distribuição	Método	KS	AIC	DSK	ET	Ranque
W	MLE	0,0273	208373,2	0,0329	0,3528	9
	MMLE	0,0241	208380,9	0,0297	0,2900	7
	MUOM	0,0197	208413,9	0,0254	0,2059	4
N	MLE	0,0485	210121,4	0,0129	0,9918	14
	MMLE	0,0426	210172,1	0,0145	0,8843	13
	MUOM	0,0272	211113,9	0,0178	0,7119	11
GEV	MLE	0,0377	209678,9	0,0404	0,7338	12
	MMLE	0,0684	214772,6	2,4929	3,0000	15
	MUOM	0,0197	208551,7	0,0195	0,2223	5
EGL	MLE	0,0171	207336,4	0,0065	0,0041	2
	MMLE	0,0169	207336,5	0,0072	0,0016	1
	MUOM	0,0191	207688,7	0,0262	0,0975	3
GG	MLE	0,0269	208219,3	0,0033	0,3129	8
	MMLE	0,0234	208241,4	0,0099	0,2498	6
	MUOM	0,0236	210103	0,0376	0,5139	10

De acordo com a Tabela (3), a distribuição que apresentou os ajustes mais precisos foi a EGL que ficou com os três melhores resultados, com a EGL_{MMLE} (ET = 0.001579) em primeiro lugar, a EGL_{MLE} (ET = 0.004157) em segundo lugar e a EGL_{MUOM} (ET = 0.097492) em terceiro lugar. Diferentemente do que aconteceu com os dados de São João do Cariri, a distribuição GG não apresentou os melhores resultados, demonstrando que o desempenho das distribuições é dependente da natureza dos dados. Novamente, como aconteceu nos resultados

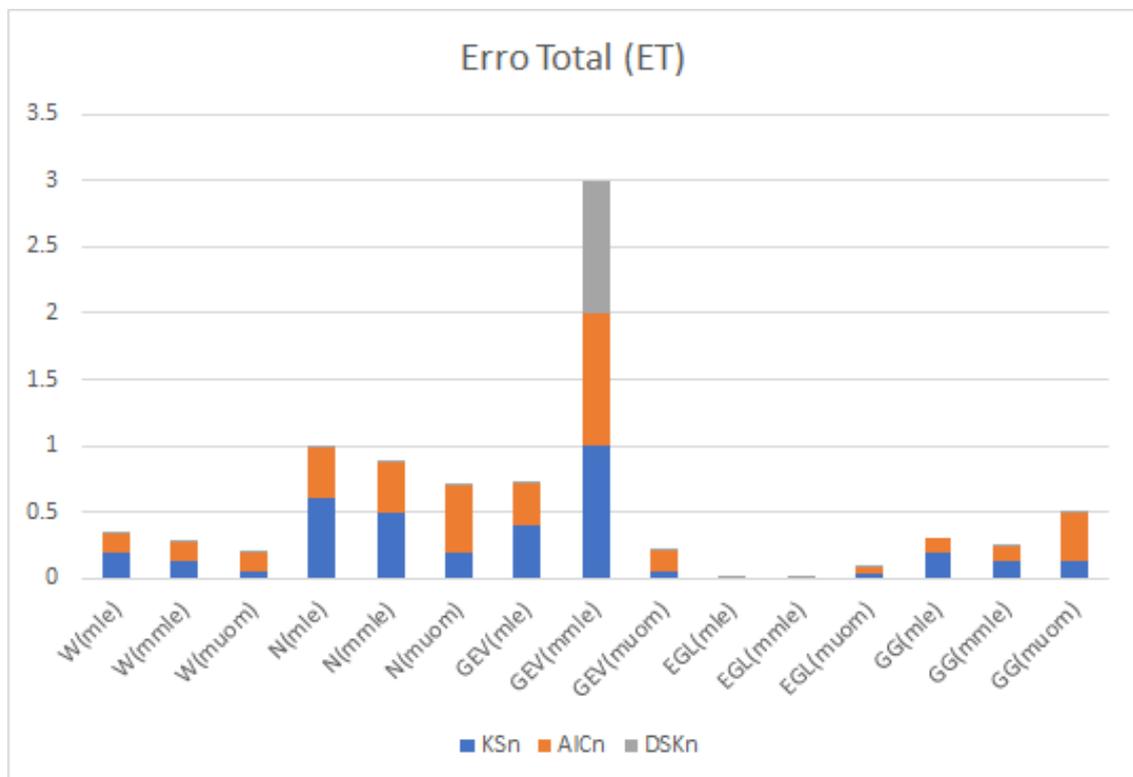
de São João do Cariri, a distribuição que apresentou os piores desempenhos nos três testes estatísticos foi a GEV_{MMLE} com um Erro Total = 3, maior erro possível.

Com exceção da distribuição EGL, que ocupou as três primeiras posições no ranque, não houve uma superioridade das distribuições de três parâmetros (GEV e GG) sobre as de dois parâmetros (W e N). Entre as distribuições de dois parâmetros, Weibull, com as posições 4, 7 e 9 no ranque, novamente se mostrou mais precisa do que Nakagami, com as posições 11, 13 e 14 no ranque.

O método MUOM, com $ET = 1,751465$, apresentou no geral os melhores desempenhos, seguido pelo MLE, com $ET = 2,395514$. O MMLE, apesar de ser o método utilizado para estimar os parâmetros da distribuição EGL_{MMLE} que apresentou o ajuste mais preciso, apresentou o pior desempenho geral, com um $ET = 4,425728$. O ET dos métodos foi calculado somando os ETs de todas as suas distribuições.

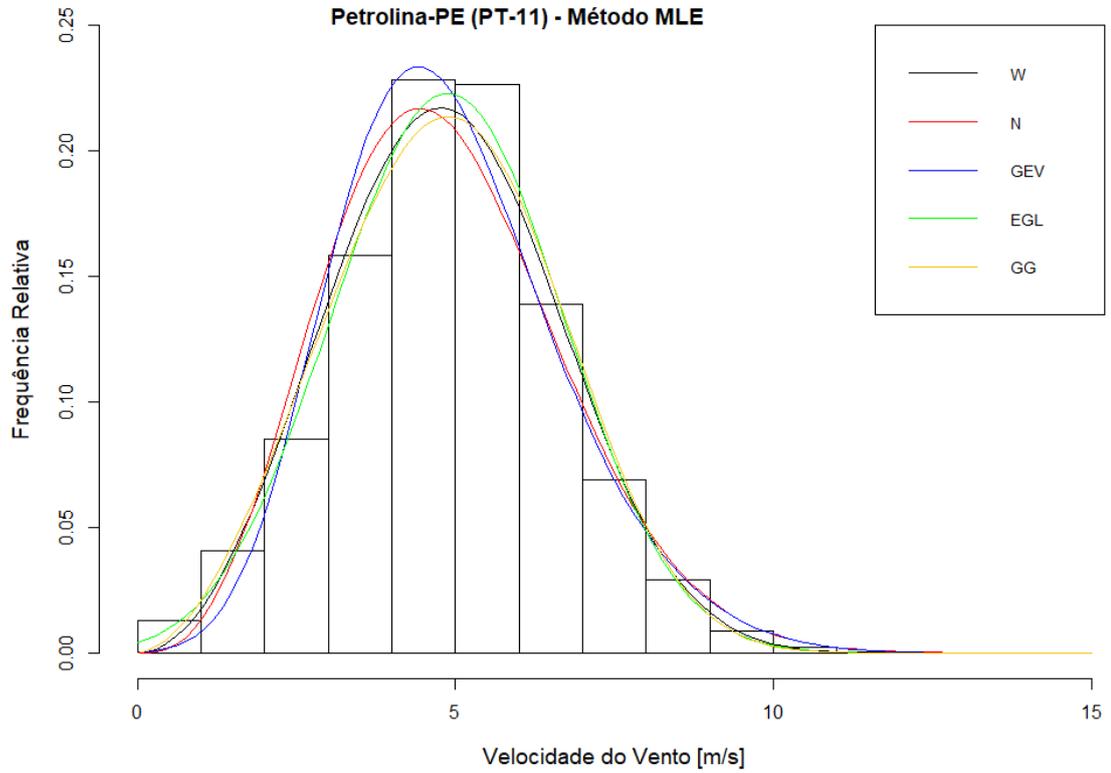
O Gráfico (3) apresenta os Erros Totais da Tabela (3) na forma de gráfico de barras, nela é novamente possível observar como a distribuição GEV_{MMLE} tem o maior erro nos três testes estatísticos, principalmente com o teste *DSK*.

Gráfico 3: Erro Total das distribuições da Tabela (3)



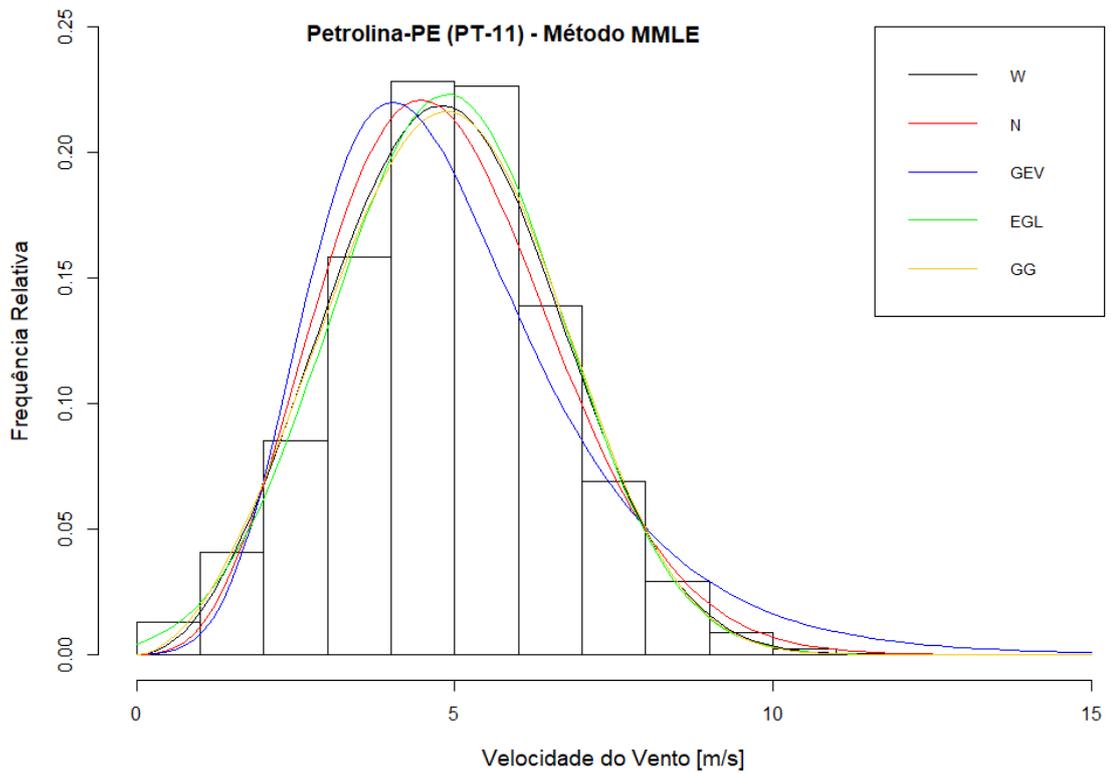
Fonte: Elaborado pelo autor.

Figura 7: Distribuições obtidas pelo método MLE (PT – 11)



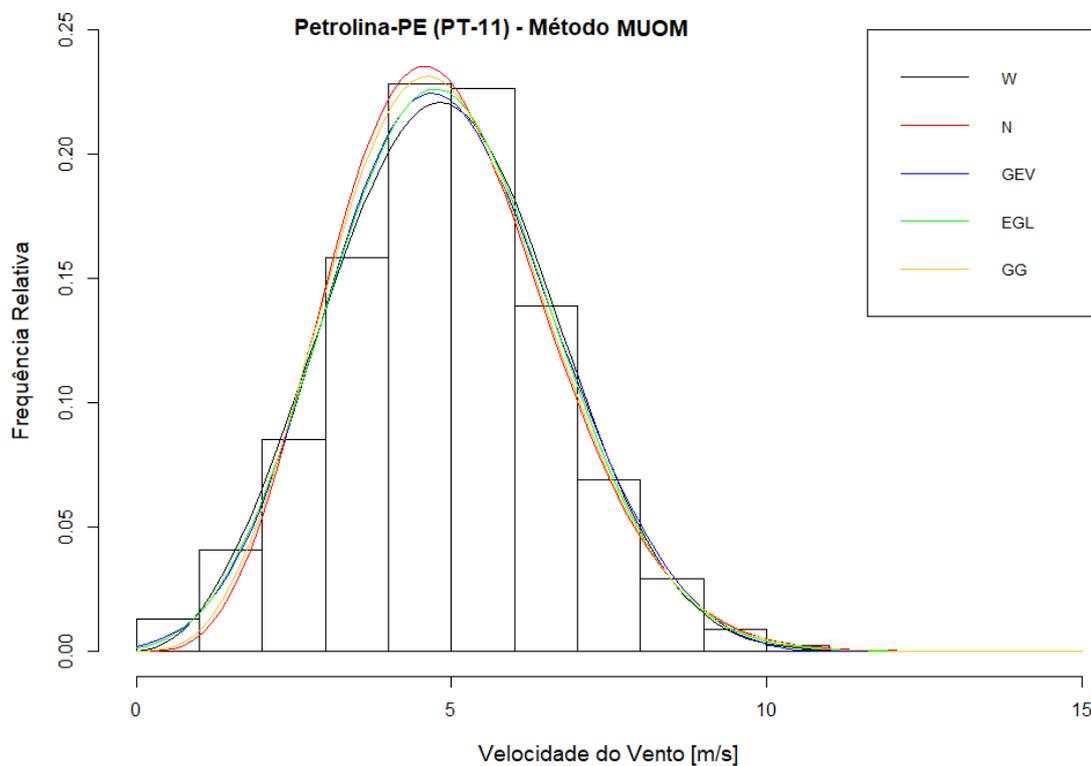
Fonte: Elaborado pelo autor.

Figura 8: Distribuições obtidas pelo método MMLE (PT – 11)



Fonte: Elaborado pelo autor.

Figura 9: Distribuições obtidas pelo método MUOM (PT – 11)



Fonte: Elaborado pelo autor.

Nas Figuras (7), (8) e (9), observado o ajuste das distribuições EGL_{MMLE} , EGL_{MLE} e EGL_{MUOM} , que ficaram em primeiro, segundo e terceiro lugar, respectivamente, pode-se verificar que os picos de frequência dessas curvas são os que mais se aproximam do pico de frequência do histograma dos dados. Na Figura (7), a distribuição GEV_{MLE} , que ficou na posição 12 no ranque ($ET = 0.73379$), apresenta um pico de frequência consideravelmente superior às outras curvas da mesma figura. Na Figura (8), a distribuição GEV_{MMLE} , que ficou em último lugar no ranque ($ET = 3$), apresenta um pico de frequência à uma velocidade inferior ao do pico de frequência do histograma, afastando a curva GEV_{MMLE} das demais. Na Figura (9), onde o método MUOM foi utilizado, as curvas das distribuições apresentam um padrão bastante parecido, com diferenças apenas nas frequências relativas máximas atingidas. Dessa forma, podemos verificar que os resultados apresentados nas Figuras (7), (8) e (9) coincidem com as informações apresentadas na Tabela (3) e no Gráfico (3).

4.3 Boia Oceânica 1 – Atlântico Sul (ATLAS)

Nessa seção, é analisado o desempenho das distribuições e dos métodos no ajuste aos dados de velocidade de vento *offshore* da boia oceânica 1, situada no Atlântico Sul. Os resultados dos testes estatísticos, os Erros Totais e a posição de cada combinação de distribuição são apresentadas na Tabela (4). Os valores dos parâmetros obtidos são apresentados separadamente no Apêndice A.

Tabela 4: Resultado da análise estatística Boia Oceânica 1

Distribuição	Método	KS	AIC	DSK	ET	Ranque
W	MLE	0,0292	228294,6	0,0157	0,1353	4
	MMLE	0,0373	228344,7	0,0143	0,2747	9
	MUOM	0,0262	228313,7	0,0109	0,0855	2
N	MLE	0,0495	231048,7	0,1189	0,7134	13
	MMLE	0,0376	231099,9	0,1184	0,5171	11
	MUOM	0,0337	231774,2	0,1153	0,5012	10
GEV	MLE	0,0422	231254,4	0,1816	0,6273	12
	MMLE	0,0829	241438,7	2,9903	3,0000	15
	MUOM	0,0311	229734,1	0,0034	0,2703	8
EGL	MLE	0,0232	227879,1	0,0029	0	1
	MMLE	0,0341	227933,4	0,0068	0,1879	6
	MUOM	0,0725	230171,1	0,1254	1,0349	14
GG	MLE	0,0288	228292,6	0,0219	0,1309	3
	MMLE	0,0354	228344,5	0,0251	0,2465	7
	MUOM	0,0243	229516,1	0,1149	0,1769	5

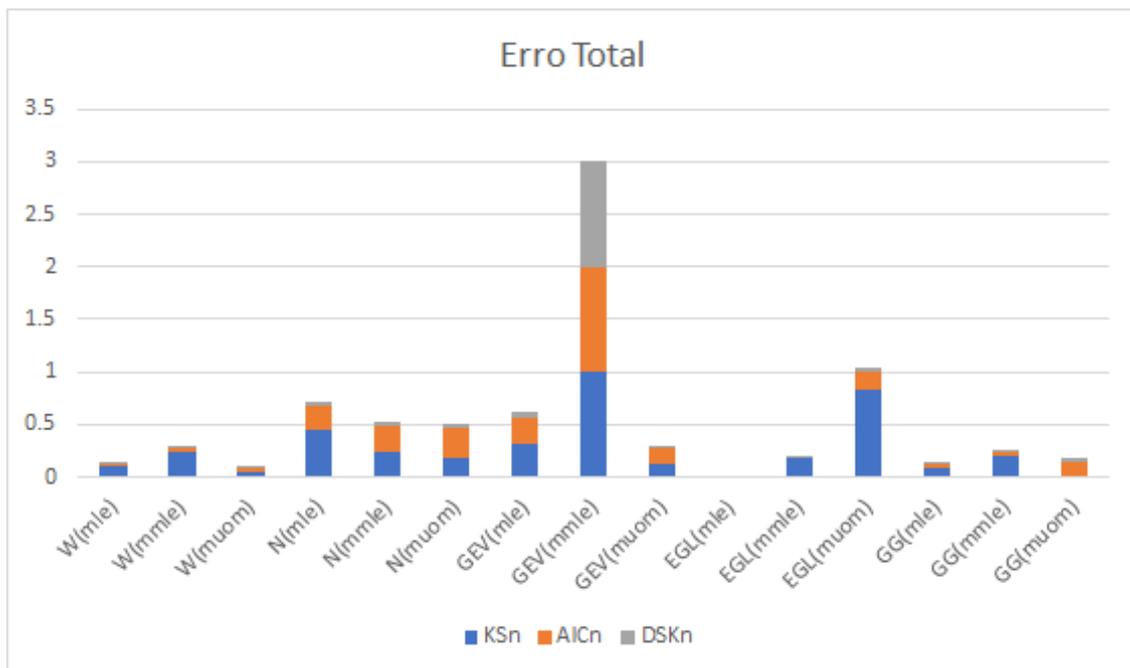
De acordo com os dados da Tabela (4), a distribuição que apresentou melhor ajuste foi o EGL_{MLE} com $ET = 0$, menor Erro Total possível, pois esse modelo de distribuição ficou em primeiro em todos os testes estatísticos. O segundo melhor ajuste foi o W_{MUOM} com $ET = 0,085504$ e o terceiro foi o GG_{MLE} com $ET = 0,130876$. Com os dados dessa boia oceânica, os melhores ajustes ficaram bastantes divididos entre as distribuições EGL, W e GG, com destaque para o bom desempenho de W frente a distribuições de três parâmetros. No entanto, a distribuição N continuou apresentando resultados bem inferiores, apresentando desempenho

superior apenas às distribuições GEV_{MMLE} e GEV_{MLE} , que ficaram em último e penúltimo lugar, respectivamente, com ênfase para o fato de GEV_{MMLE} novamente ter ficado em último em todos os testes estatísticos, com $ET = 3$.

Em relação aos métodos, o MLE, com um $ET = 1,606863$, novamente apresentou os melhores ajustes, seguido do método MUOM em segundo lugar, com um $ET = 2,068814$, colocando o MMLE na última posição dos métodos, com um $ET = 4,226285$. O ET dos métodos foi calculado somando os ETs de todas as suas distribuições

O Gráfico (4) representa graficamente os Erros Totais das distribuições da Tabela (4). A distribuição EGL_{MLE} apresentou um Erro Total (ET) igual a zero pois a mesma obteve o melhor desempenho nos três testes estatísticos, e como os valores dos testes foram normalizados o ET obtido foi zero.

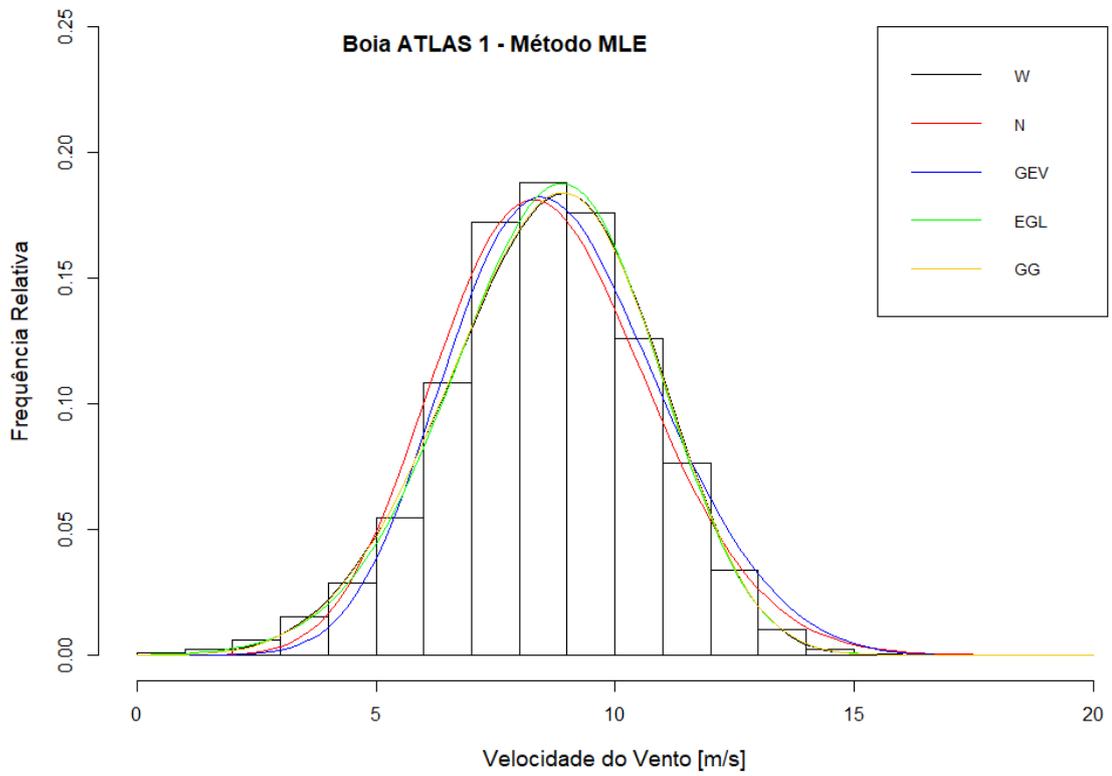
Gráfico 4: Erro Total das distribuições da Tabela (4)



Fonte: Elaborado pelo autor

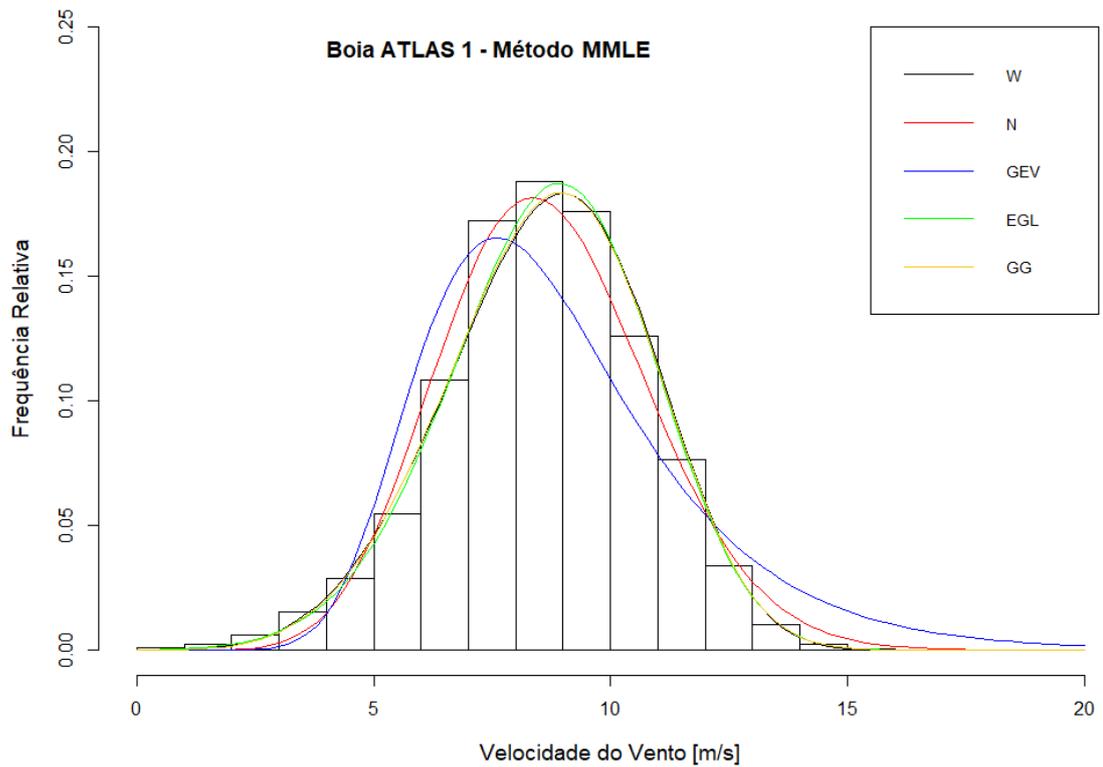
As Figuras (14), (15) e (16) apresentam graficamente os ajustes de todas as combinações de distribuições da Tabela (4) ao histograma de velocidade de vento da boia oceânica 1. As curvas apresentadas estão divididas pelo método utilizado para facilitar a visualização.

Figura 10: Distribuições obtidas pelo método MLE (Boia 1)



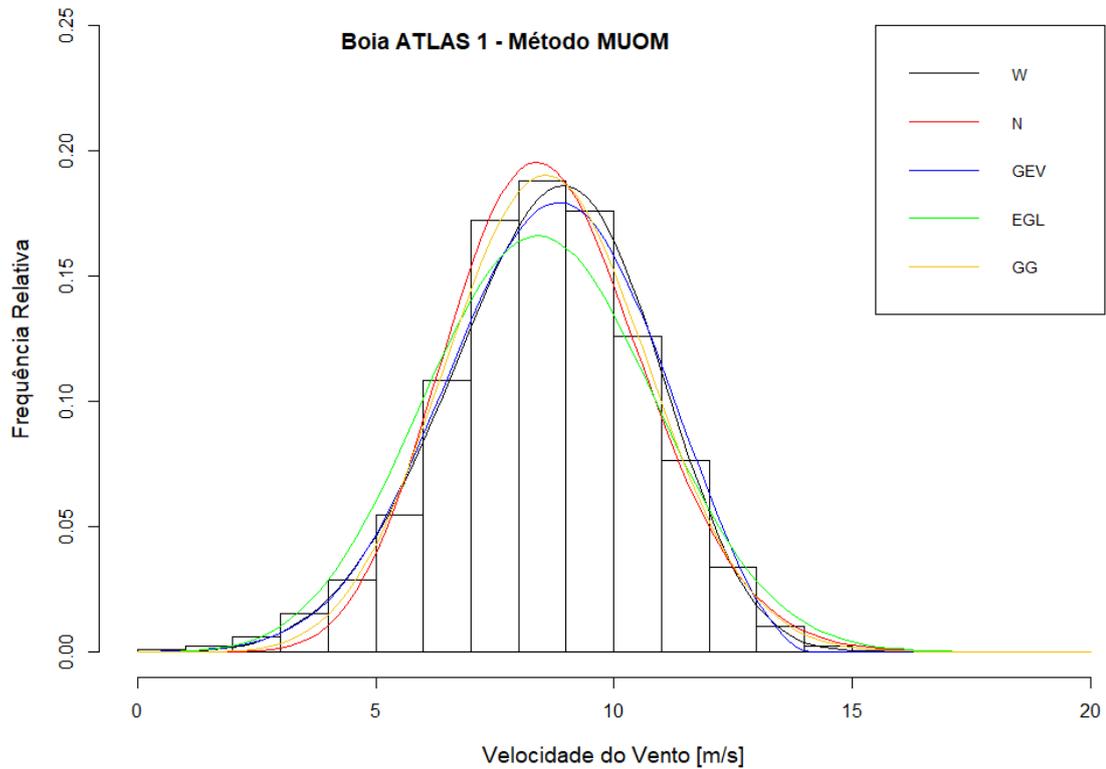
Fonte: Elaborado pelo autor.

Figura 11: Distribuições obtidas pelo método MMLE (Boia 1)



Fonte: Elaborado pelo autor.

Figura 12: Distribuições obtidas pelo método MUOM (Boia 1)



Fonte: Elaborado pelo autor.

Na Figura (10), pode-se visualizar o comportamento da distribuição que apresentou o melhor desempenho, a EGL_{MLE} , que acompanha as frequências relativas do histograma ao longo de todas as velocidades de vento. Já na Figura (11), observa-se o comportamento da distribuição que apresentou o pior ajuste, GEV_{MLE} , que em nenhum momento acompanha as frequências relativas do histograma. Na Figura (12), pode-se ver como W_{MUOM} , que obteve o segundo melhor resultado, acompanha bem as frequências relativas do histograma ao longo de todas as velocidades, e também é possível visualizar a curva da distribuição EGL_{MUOM} , que ficou na penúltima posição com um $ET = 0.130876$. Portanto, constata-se que as Figuras (10), (11) e (12) estão de acordo com os resultados apresentados na Tabela (4).

4.4 Boia Oceânica 2 – Atlântico Sul (ATLAS)

Nessa seção, são analisados os resultados obtidos pelos dados de velocidade de vento *offshore* da boia oceânica 2, localizada no Atlântico Sul e tendo o ano de 2008 como base. Os resultados dos testes estatísticos, os Erros Totais e a posição de cada combinação de distribuição são apresentadas na Tabela (5). Os valores dos parâmetros obtidos são apresentados separadamente no Apêndice A.

Tabela 5: Resultado da análise estatística Boia Oceânica 2

Distribuição	Método	KS	AIC	DSK	ET	Ranque
W	MLE	0,0289	230221,9	0,0124	0,0613	4
	MMLE	0,0406	230271,4	0,0142	0,1819	7
	MUOM	0,0286	230222,2	0,0127	0,0586	3
N	MLE	0,0517	231766,0	0,0182	0,4392	11
	MMLE	0,0387	231825,1	0,0184	0,3173	9
	MUOM	0,0353	232169,8	0,0187	0,3175	10
GEV	MLE	0,1266	233567,9	0,0562	1,3686	14
	MMLE	0,0782	240205,8	2,9212	2,5220	15
	MUOM	0,0314	230783,3	0,0365	0,1488	6
EGL	MLE	0,0253	229994,1	0,0019	0	1
	MMLE	0,0351	230045,0	0,0044	0,1020	5
	MUOM	0,0703	231454,4	0,0479	0,6025	13
GG	MLE	0,0289	230148,7	0,0067	0,0529	2
	MMLE	0,0716	231172,7	0,0045	0,5728	12
	MUOM	0,0329	231106,9	0,0395	0,1972	8

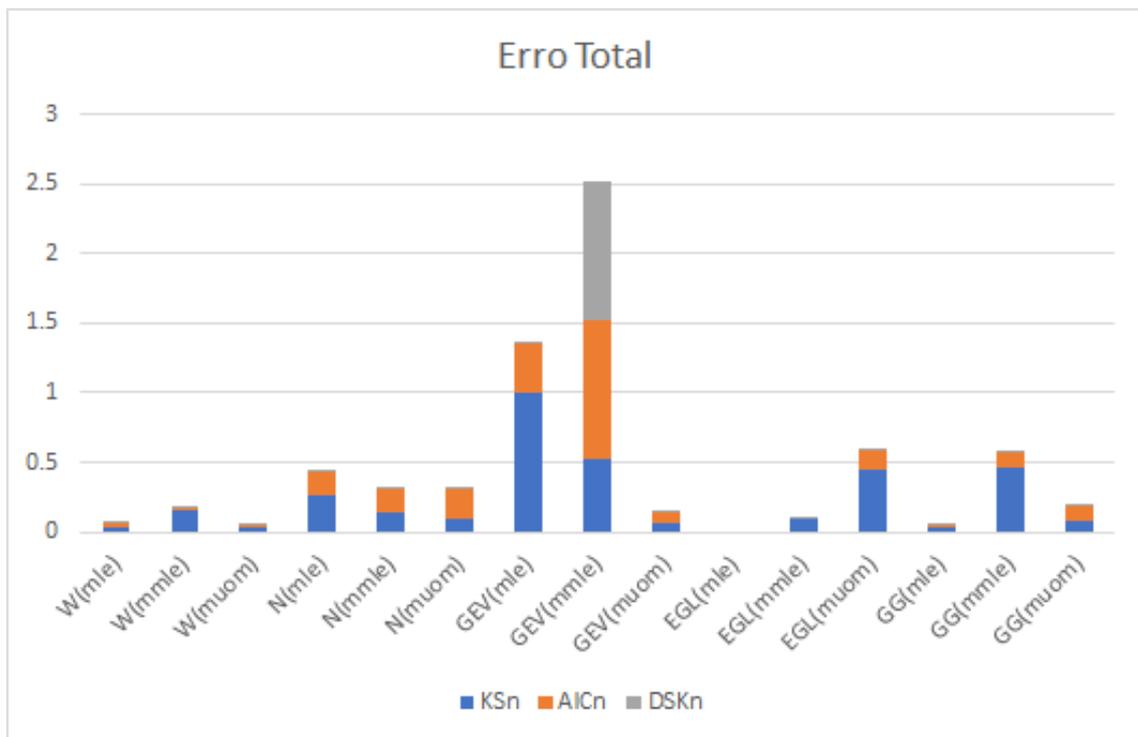
De acordo com a da Tabela (5), a distribuição que apresentou melhor ajuste foi novamente o EGL_{MLE} com $ET = 0$, menor Erro Total possível, pois essa distribuição ficou em primeiro em todos os testes estatísticos. O segundo melhor ajuste foi o GG_{MLE} com $ET = 0.052179$ e o terceiro foi o W_{MUOM} com $ET = 0.058615$. A distribuição GEV não apresentou bom desempenho, com o GEV_{MMLE} novamente apresentando o pior ajuste, com um $ET = 2.522029$, e com o GEV_{MLE} ficando na penúltima posição, com um $ET = 1.368565$. A melhor posição obtida pela distribuição GEV foi o sexto lugar com o GEV_{MUOM} . A distribuição W

apresentou um bom desempenho, com as W_{MUOM} , W_{MLE} e W_{MMLE} nas posições 3, 4 e 7, respectivamente. Entre as distribuições de dois parâmetros, Nakagami novamente apresentou os menores desempenhos, com N_{MMLE} , N_{MUOM} e N_{MLE} nas posições 9, 10 e 11, respectivamente.

No caso dos métodos, o MUOM, com um $ET = 1,324658$, apresentou os melhores ajustes, seguido do método MLE em segundo lugar, com um $ET = 1,921253$, e com o MMLE na última posição, com um $ET = 3,696033$. O método MLE ficou em segundo lugar devido ao fato da distribuição GEV_{MLE} ter apresentado um elevado Erro Total de 1.368565, fazendo com que o ET do método subisse. O ET dos métodos foi calculado somando os ETs de todas as suas distribuições

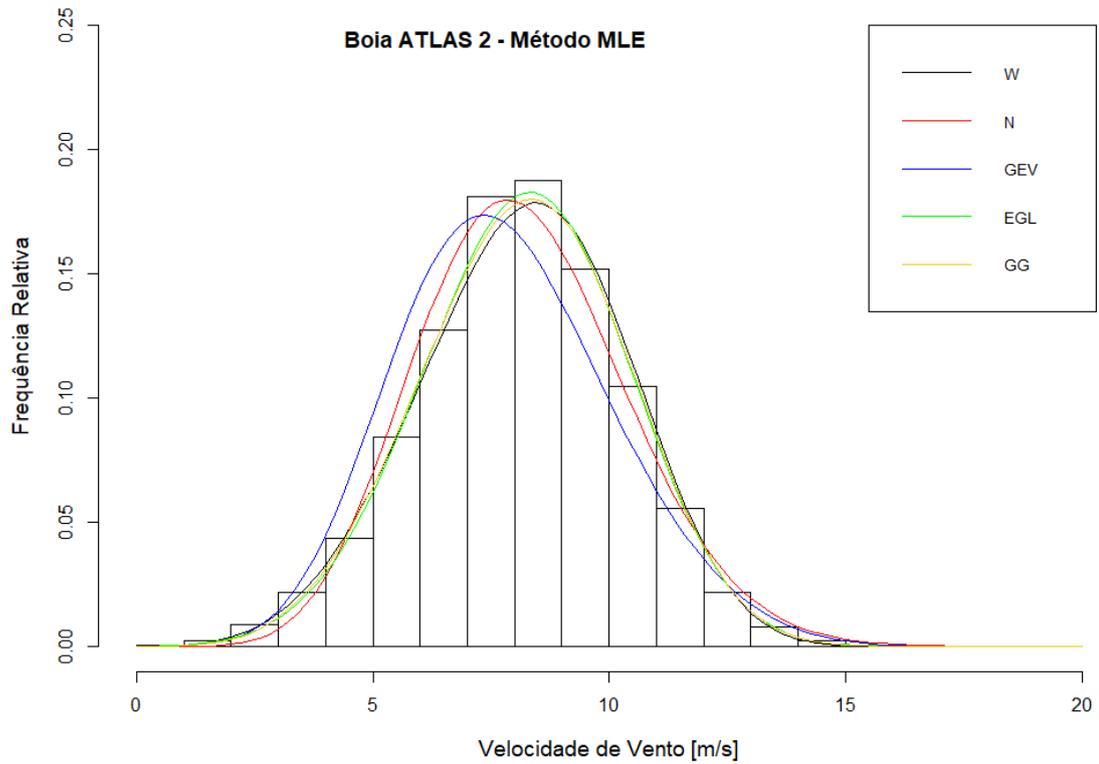
O Gráfico (5) apresenta em forma de um gráfico de barras os Erros Totais das distribuições da Tabela (5). Pela primeira vez o GEV_{MMLE} não ficou em último em todos os testes estatísticos, pois nesse caso a distribuição que ficou em último no teste KS foi a GEV_{MLE} .

Gráfico 5: Erro Total das distribuições da Tabela (5)



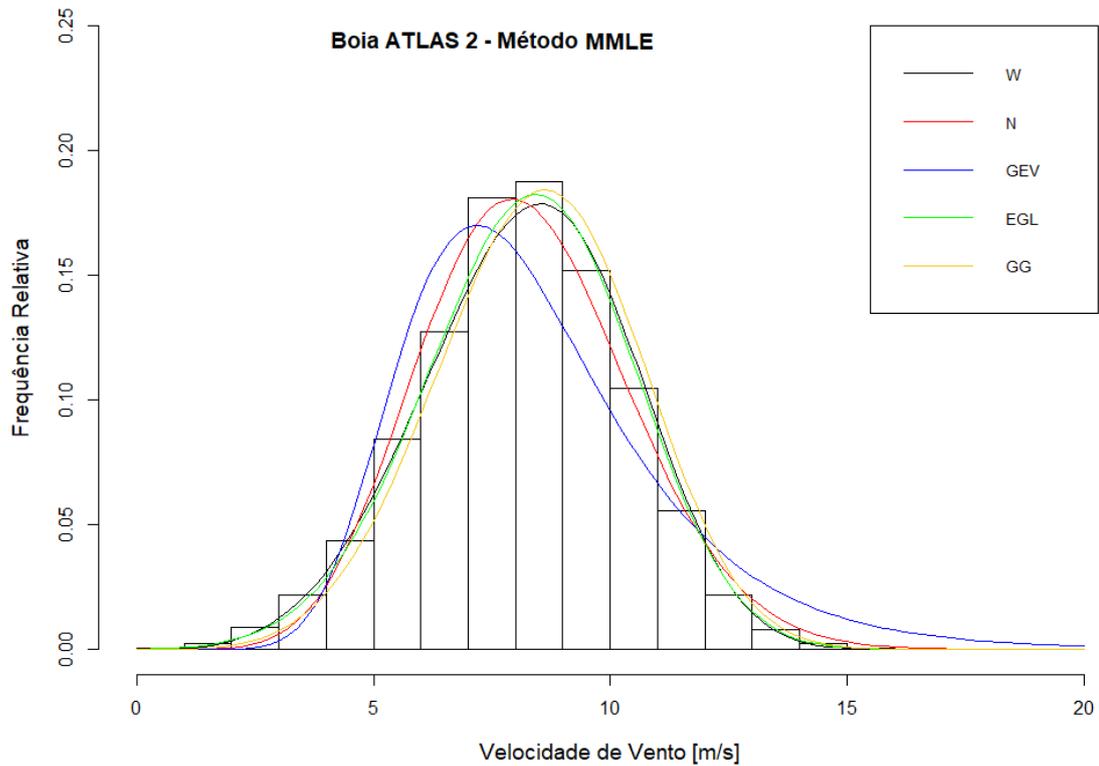
Fonte: Elaborado pelo autor

Figura 13: Distribuições obtidas pelo método MLE (Boia 2)



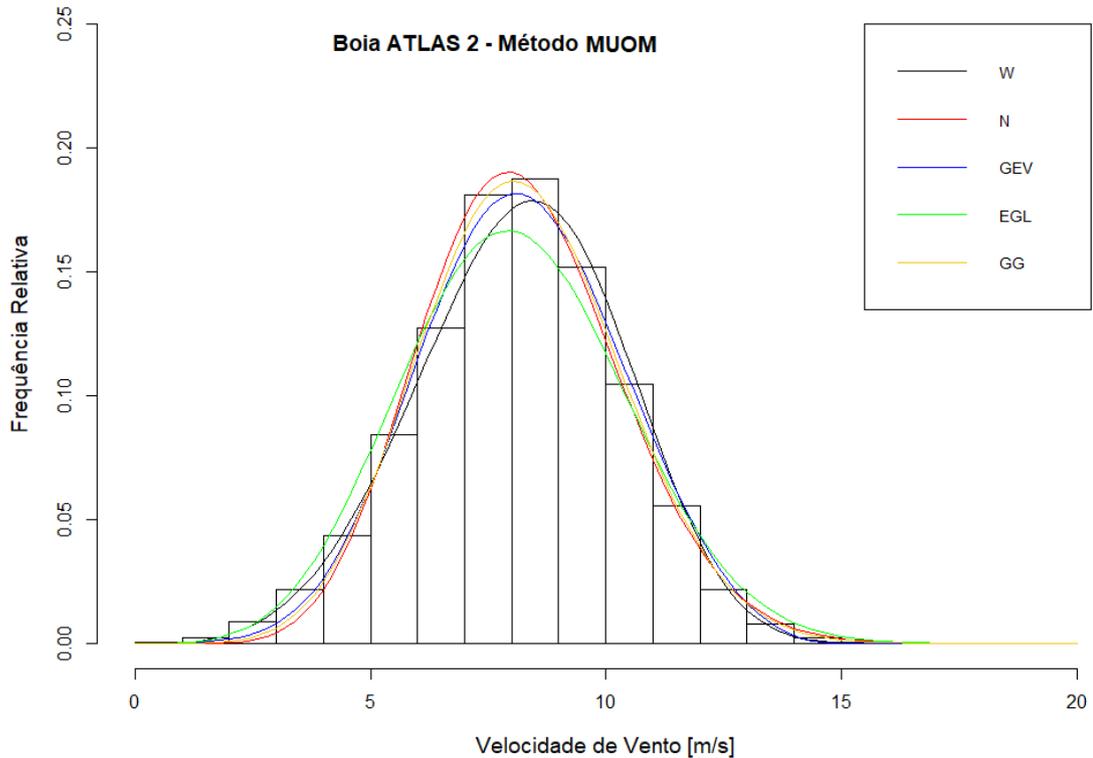
Fonte: Elaborado pelo autor.

Figura 14: Distribuições obtidas pelo método MMLE (Boia 2)



Fonte: Elaborado pelo autor.

Figura 15: Distribuições obtidas pelo método MUOM (Boia 2)



Fonte: Elaborado pelo autor.

Analisando a Figura (13), pode-se observar o comportamento das curvas EGL_{MLE} e GG_{MLE} , que ficaram em primeiro e em segundo lugar no ranque, respectivamente, elas acompanham o histograma por toda a faixa de velocidade de vento. Esse mesmo fenômeno é observado na Figura (15) com o W_{MUOM} . A distribuição GEV nas Figuras (13) e (14) apresenta um padrão em suas curvas, onde elas se posicionam à esquerda do histograma, as distribuições GEV_{MMLE} e GEV_{MLE} ficaram na última e na penúltima posição, respectivamente. Nas mesmas Figuras (13) e (14), as curvas da distribuição N também apresentam um posicionamento à esquerda, mas sendo menos acentuado do que o da GEV.

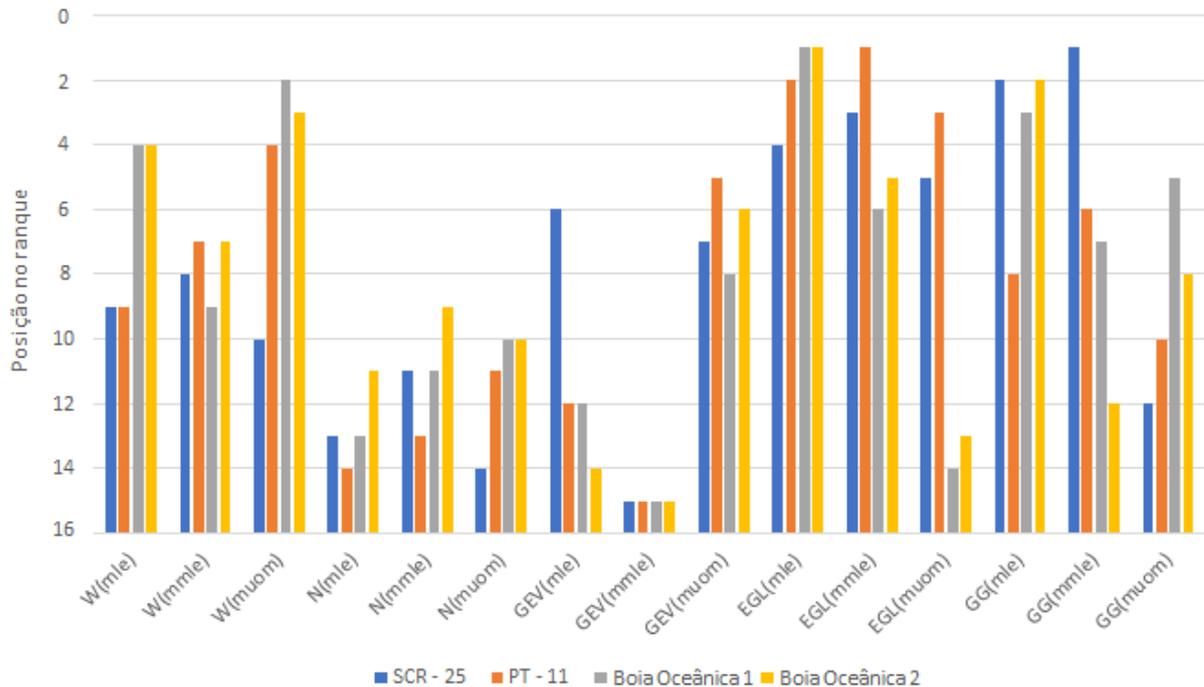
4.5 Comparação dos resultados finais de todos os dados de velocidade de vento

Nessa seção, os resultados discutidos nas seções 4.1, 4.2, 4.3 e 4.4 foram unificados na Tabela (6), que apresenta as posições de todas as distribuições nos ranques de cada conjunto de dados. O Gráfico (6) apresenta as informações contidas na Tabela (6).

Tabela 6: Posição das distribuições nos ranques de cada localidade

Distribuição	Método	SCR - 25	PT - 11	Boia 1	Boia 2
W	MLE	9	9	4	4
	MMLE	8	7	9	7
	MUOM	10	4	2	3
N	MLE	13	14	13	11
	MMLE	11	13	11	9
	MUOM	14	11	10	10
GEV	MLE	6	12	12	14
	MMLE	15	15	15	15
	MUOM	7	5	8	6
EGL	MLE	4	2	1	1
	MMLE	3	1	6	5
	MUOM	5	3	14	13
GG	MLE	2	8	3	2
	MMLE	1	6	7	12
	MUOM	12	10	5	8

Gráfico 6: Representação gráfica dos dados da Tabela (6)



Fonte: Elaborado pelo autor

De acordo com a Tabela (6) e com o Gráfico (6), as distribuições W_{MLE} e W_{MUOM} apresentaram um bom desempenho nas duas localidades *offshore*, apesar de não terem tido o mesmo desempenho nas localidades *onshore*. Já a W_{MMLE} apresentou um desempenho constante nas quatro localidades. As distribuições N_{MLE} , N_{MMLE} e N_{MUOM} tiveram o mesmo desempenho em todas as localidades, e mostraram não terem uma boa precisão independentemente de os dados serem *onshore* ou *offshore*.

A distribuição GEV_{MLE} , com exceção do sexto lugar na estação SCR – 25, não apresentou um bom desempenho nas outras três localidades. O GEV_{MMLE} apresentou o pior ajuste em todas as quatro localidades, demonstrando que a combinação da distribuição GEV com o método de estimativa MMLE não é apropriado. A GEV_{MUOM} obteve os melhores desempenhos entre as distribuições GEV, sendo a melhor colocação a posição 5 na estação PT – 11. Entre as distribuições de três parâmetros a GEV foi a que apresentou os maiores Erros Totais e, conseqüentemente, os piores ajustes.

As distribuições EGL e GG foram as que obtiveram as melhores colocações, com a EGL_{MLE} ficando em primeiro nas duas boias oceânicas e em segundo na estação PT – 11. A GG_{MMLE} ficou em primeiro na estação SCR – 25 e a GG_{MLE} ficou em segundo na estação SCR – 25 e na boia oceânica 2. A EGL_{MUOM} , apesar de um quinto e terceiro lugar nas estações *onshore*, nas boias *offshore*, ficou nas posições 14 e 13, demonstrando que essa combinação de distribuição EGL e método MUOM é mais apropriado para dados de vento *onshore*.

Analisando os resultados de Guedes (2020), observa-se certas similaridades, como o fato de as distribuições de três parâmetros terem apresentado maiores precisões quando comparadas com as de dois parâmetros, com destaque para as distribuições EGL e GG que também apresentaram os melhores desempenhos nas duas localidades usadas por Guedes (2020). Entre as distribuições de dois parâmetros, Weibull também apresentou as melhores precisões, segundo os resultados apresentados por Guedes (2020). Não foi possível fazer comparações com os resultados obtidos pelos artigos que utilizaram dados *offshore*, pois esses trabalhos fizeram uso apenas da distribuição de Weibull na análise dos dados de velocidade de vento.

Apesar de tudo que foi discutido anteriormente, não é possível afirmar que uma determinada distribuição apresenta um melhor desempenho quando aplicada a dados *onshore* ou *offshore*, pois a precisão de uma distribuição é bastante dependente do método utilizado para estimar os seus parâmetros, como é possível observar nos resultados apresentados pela boia 1, onde a distribuição EGL ficou em primeiro quando teve seus parâmetros estimados pelo método MLE, enquanto que a mesma ficou na penúltima posição com o método MUOM. Entretanto,

verifica-se que algumas distribuições como a EGL_{MLE} e a EGL_{MMLE} apresentaram bom desempenho em todas as localidades, e que distribuições como GEV_{MMLE} , N_{MLE} , N_{MMLE} e N_{MUOM} obtiveram pouca precisão em todas as localidades, independente delas serem *onshore* ou *offshore*.

5 CONCLUSÃO

Na presente dissertação foi verificado o desempenho de cinco distribuições de probabilidade, sendo elas: Weibull (W), Nakagami (N), Lindley Generalizada Estendida (EGL), Valor Extremo Generalizado (GEV) e Gamma Generalizada (GG), quando essas são utilizadas para ajustar-se à dados de velocidade de vento de quatro localidades na região Nordeste, sendo duas *onshore*, localizadas nos municípios de São João do Cariri - PB e Petrolina - PE, e duas *offshore*, localizadas no Atlântico Sul, e fazendo uso de três métodos determinísticos para obter os parâmetros dessas distribuições.

Obteve-se como resultado da combinação de três métodos e cinco distribuições, quinze modelos de distribuição, que tiveram a qualidade dos seus ajustes medidas pelos testes estatísticos Kolmogorov-Smirnov (*KS – Kolmogorov Smirnov Test*), Critério de informação de Akaike (*AIC – Akaike Information Criterion*) e Desvio de Assimetria e Curtose (*DSK – Deviation of Skewness and Kurtosis*). Os resultados desses testes estatísticos foram normalizados e unificados em um parâmetro chamado Erro Total (ET), que varia entre 0 e 3, onde quanto mais próximo de zero o valor do ET mais preciso é o ajuste da distribuição. A aplicação do ET foi necessária pois os testes estatísticos apresentaram resultados diferentes entre eles. Finalmente, as distribuições foram ranqueadas para cada localidade nas Tabelas (2), (3), (4) e (5), de acordo com ET de cada distribuição.

Analisando comparativamente as distribuições através dos ranques, foi possível verificar a concordância dos resultados das Tabelas (2), (3), (4) e (5) com as análises gráficas dos ajustes feitas a partir das Figuras (4) - (15). Observando as figuras, é possível verificar quais modelos apresentavam curvas com os melhores e os piores ajustes ao histograma de velocidade, e o resultado dessa verificação foi ao encontro com os resultados definidos a partir do Erro Total (ET), dessa forma, demonstrando a utilidade de unificar os resultados dos testes quando se usa mais de um teste estatístico.

Em relação aos dados da estação SCR – 25, em São João do Cariri, as distribuições GG_{MMLE} (ET = 0,004005), GG_{MLE} (ET = 0,010644) e EGL_{MMLE} (ET = 0,105203) ficaram em primeiro, o segundo e o terceiro lugar, respectivamente, no ranque de desempenho. Na estação PT – 11, em Petrolina, os melhores ajustes ficaram com as distribuições EGL_{MMLE} (ET = 0,001579), EGL_{MLE} (ET = 0,004157) e EGL_{MUOM} (ET = 0,097492), respectivamente. Em ambas as estações *onshore*, SCR – 25 e PT – 11, a distribuição GEV_{MMLE} apresentou o pior desempenho, com um ET = 3. Na boia oceânica 1, as melhores precisões foram apresentadas

pelas distribuições EGL_{MLE} ($ET = 0$), W_{MUOM} ($ET = 0,085504$) e GG_{MLE} ($ET = 0,130876$), respectivamente. Já na boia oceânica 2, as distribuições com melhor desempenho foram a EGL_{MLE} ($ET = 0$), EGL_{MLE} ($ET = 0,052179$) e W_{MUOM} ($ET = 0,058615$), respectivamente. O modelo de distribuição GEV_{MMLE} também apresentou o pior desempenho nas duas boias oceânicas, com um $ET = 3$ na boia 1, e um $ET = 2,522029$ na boia 2.

Em relação às distribuições, a EGL e a GG obtiveram, no geral, os melhores desempenhos, apesar da EGL_{MUOM} e da GG_{MUOM} não terem apresentado bons ajustes com os dados *offshore* e *onshore*, respectivamente. A distribuição W só obteve um bom desempenho com o método MUOM nos dados offshore, quando a W_{MUOM} ficou na segunda e na terceira posição nas boias 1 e 2, respectivamente. A distribuição de dois parâmetros N, no geral, não apresentou um bom desempenho e não superou a W, também de dois parâmetros, em nenhuma localidade. A distribuição GEV não teve boa precisão, com destaque para o fato de a GEV_{MMLE} ter ficado em último em todas as quatro localidades. No entanto, deve-se levar em consideração o fato de o desempenho das distribuições ser influenciado pelo método de estimativa de parâmetros utilizado e pela natureza dos dados de velocidade de vento.

Nas localidades *offshore*, pode-se concluir que houve um padrão nos resultados, onde as distribuições EGL_{MLE} , GG_{MLE} e W_{MUOM} apresentaram as melhores precisões no ajuste ao histograma. Nas localidades *onshore*, devido ao padrão apresentado pelos resultados, foi possível concluir que as distribuições de três parâmetros foram, no geral, superiores às de dois parâmetros. Entretanto, para todos as quatro localidades, *offshore* e *onshore*, pode-se concluir que a combinação distribuição – método GEV_{MMLE} apresentou os piores ajustes. Dessa forma, conclui-se que não existe uma distribuição única que seja mais apropriada para ajustar-se a um histograma de velocidade, sendo necessário sempre aplicar um estudo pra saber qual das distribuições disponíveis é a mais apropriada para cada caso em questão.

REFERÊNCIAS

ABEEÓLICA, 2020. *Associação Brasileira de Energia Eólica*. 2020. Disponível em: <<http://abeeolica.org.br/>>. Acesso em: 10 de janeiro de 2021.

AKDAG, S. A.; GULER, O. A novel energy pattern factor method for wind speed distribution parameter estimation. *Energy Conversion and Management*, v. 106, p. 1124 – 1133, 2015. ISSN 0196-8904.

AL-NASSAR, W. K. et al. Feasibility of offshore wind energy as an alternative source for the state of Kuwait. *Energy*, v. 169, p. 783-796, 2019.

ALAVI, O.; MOHAMMADI, K.; MOSTAFAEIPOUR, A. Evaluating the suitability of wind speed probability distribution models: A case of study of east and southeast parts of iran. *Energy Conversion and Management*, v. 119, p. 101 – 108, 2016. ISSN 0196-8904.

AMIRINIA, Gholamreza; MAFI, Somayeh; MAZAHARI, Said. Offshore wind resource assessment of Persian Gulf using uncertainty analysis and GIS. *Renewable Energy*, v. 113, p. 915-929, 2017.

ANDRADE, C. F. DE, MAIA NETO, H. F., COSTA ROCHA, P. A., & VIEIRA DA SILVA, M. E. (2014). 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*, 86, 801–808. <https://doi.org/10.1016/j.enconman.2014.06.046>.

APPIOTT, Joseph; DHANJU, Amardeep; CICIN-SAIN, Biliana. Encouraging renewable energy in the offshore environment. *Ocean & coastal management*, v. 90, p. 58-64, 2014.

ARIES, N.; BOUDIA, S. M.; OUNIS, H. Deep assessment of wind speed distribution models: A case study of four sites in algeria. *Energy Conversion and Management*, v. 155, p. 78 – 90, 2018. ISSN 0196-8904.

BHATI, M.A. MALIK, K.K. JOSE, A New 3-parameter Extension of Generalized Lindley Distribution, arXiv:1601.01045, 2016, pp. 1e15 (2016).

BILGILI, Mehmet; YASAR, Abdulkadir; SIMSEK, Erdogan. Offshore wind power development in Europe and its comparison with onshore counterpart. *Renewable and Sustainable Energy Reviews*, v. 15, n. 2, p. 905-915, 2011.

BOURLÈS, Bernard et al. The PIRATA program: History, accomplishments, and future directions. *Bulletin of the American Meteorological Society*, v. 89, n. 8, p. 1111-1126, 2008.

BROWER, Michael. Wind resource assessment: a practical guide to developing a wind project. John Wiley & Sons, 2012.

CELIK AN, KOLHE M. Generalized feed-forward based method for wind energy prediction. *Applied Energy* 2013; 101:582–8. ISSN: 0306-2619.

FREITAS, Breno Bezerra et al. Scenarios for Ceará's electricity generation matrix in 2050. *Ciência e Natura*, v. 42, p. 63, 2020.

GUEDES, Kevin S. et al. Performance analysis of metaheuristic optimization algorithms in estimating the parameters of several wind speed distributions. *Applied Energy*, v. 268, p. 114952, 2020.

GUGLIANI, G. K. et al. New methods to assess wind resources in terms of wind speed, load, power and direction. *Renewable Energy*, v. 129, p. 168-182, 2018.

GWEC. *Global Wind Energy Council*. 2020. Disponível em: <<https://gwec.net/>>. Acesso em: 27 de maio de 2020.

HE, Junyi et al. Spatiotemporal analysis of offshore wind field characteristics and energy potential in Hong Kong. *Energy*, v. 201, p. 117622, 2020.

IEC 61400 PART 12-1. *Power performance measurement of electricity producing wind turbines*. 3. ed. Genebra, Suíça, 2005.

IRENA. *International Renewable Energy Agency*. 2020. Disponível em: <<https://irena.org/>>. Acesso em: 14 de junho de 2020.

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. ISSN 1364-0321.

JUNG, C.; SCHINDLER, D.; LAIBLE, J.; BUCHHOLZ, A. Introducing a system of wind speed distributions for modeling properties of wind speed regimes around the world. *Energy Conversion and Management*, v. 144, p. 181 – 192, 2017. ISSN 0196-8904.

KANTAR, Y. M.; USTA, I.; ARIK, I.; YENILMEZ, I. Wind speed analysis using the extended generalized lindley distribution. *Renewable Energy*, v. 118, p. 1024 – 1030, 2018. ISSN 0960-1481.

KISS, P.; JÁNOSI, I. M. Comprehensive empirical analysis of era-40 surface wind speed

distribution over europe. *Energy Conversion and Management*, v. 49, n. 8, p. 2142 – 2151, 2008. ISSN 0196-8904.

KRISHNAMOORTHY, R. et al. An Assessment of Onshore and Offshore Wind Energy Potential in India Using Moth Flame Optimization. *Energies*, v. 13, n. 12, p. 1-41, 2020.

LADENBURG, Jacob. Visual impact assessment of offshore wind farms and prior experience. *Applied Energy*, v. 86, n. 3, p. 380-387, 2009.

LANDBERG, L., MYLLERUP, L., RATHMANN, O., PETERSEN, E. L., JØRGENSEN, B. H., BADGER, J., & MORTENSEN, N. G. (2003). Wind resource estimation - an overview. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology*, 6(3), 261-271.

LAUBER, Volkmar. The political economy of renewable energy. *International Encyclopedia of the Social and Behavioral Sciences*, 2nd edition. Elsevier, 2015. p. 367-373.

LI, Jiale; YU, Xiong Bill. Onshore and offshore wind energy potential assessment near Lake Erie shoreline: a spatial and temporal analysis. *Energy*, v. 147, p. 1092-1107, 2018.

LI, Yi et al. Comparative study of onshore and offshore wind characteristics and wind energy potentials: A case study for southeast coastal region of China. *Sustainable Energy Technologies and Assessments*, v. 39, p. 100711, 2020.

LINDLEY, D.V. Fiducial distribution and Bayes' theorem, *J. R. Stat. Soc.* 20 (1958) 102e107.

MAKARIEVA, Anastassia M. et al. Where do winds come from? A new theory on how water vapor condensation influences atmospheric pressure and dynamics. *Atmospheric Chemistry and Physics*, v. 13, n. 2, p. 1039-1056, 2013.

MANWELL, J. F., MCGOWAN, J. G., & ROGERS, A. L. (2009). *Wind energy explained: Theory, design and application*. Chichester, U.K: Wiley.

MASSERAN, N. Integrated approach for the determination of an accurate wind-speed distribution model. *Energy Conversion and Management*, v. 173, p. 56 – 64, 2018. ISSN 0196-8904.

MOHAMMADI, K.; ALAVI, O.; MCGOWAN, J. G. Use of birnbaum-saunders distribution for estimating wind speed and wind power probability distributions: A review. *Energy Conversion and Management*, v. 143, p. 109 – 122, 2017. ISSN 0196-8904.

MORGAN, E. C.; LACKNER, M.; VOGEL, R. M.; BAISE, L. G. Probability distributions for offshore wind speeds. *Energy Conversion and Management*, v. 52, n. 1, p. 15 – 26, 2011. ISSN 0196-8904.

NADARAJAH, S., BAKOUCH, H. S., & TAHMASBI, R. (2011). A generalized Lindley distribution. *Sankhya B*, 73(2), 331–359. <https://doi.org/10.1007/s13571-011-0025-9>.

NAKAGAMI, M. (1960). The m-Distribution—A General Formula of Intensity Distribution of Rapid Fading. *Statistical Methods in Radio Wave Propagation* (pp. 3–36). Elsevier. <https://doi.org/10.1016/b978-0-08-009306-2.50005-4>.

OUARDA, T.; CHARRON, C.; CHEBANA, F. Review of criteria for the selection of probability distributions for wind speed data and introduction of the moment and l-moment ratio diagram methods, with a case study. *Energy Conversion and Management*, v. 124, p. 247 – 265, 2016. ISSN 0196-8904.

PARSONS, J.D. (1992). *The mobile radio propagation channel*. Chichester, U.K: Wiley.

PIRATA. *Pilot Research Moored Array in the Tropical Atlantic*. 2020. Disponível em: <<https://www.pmel.noaa.gov/>>. Acesso em: 14 de junho de 2020.

R Core Team, 2020. *Package Stats. R: A language and environment for statistical computing*. 2020.

R-PROJECT. 2020. Disponível em: <<https://www.r-project.org/about.html>>. Acesso em: 27 de maio de 2020.

RSTUDIO, 2020. Disponível em: <<https://rstudio.com/about/>>. Acesso em: 27 de maio de 2020.

SANCHEZ-IBORRA, R., CANO, M.-D., & GARCIA-HARO, J. (2013). Performance evaluation of QoE in VoIP traffic under fading channels. *2013 World Congress on Computer and Information Technology (WCCIT)*. <https://doi.org/10.1109/wccit.2013.6618721>.

SANTOS, L. F. dos. *Parametrização e Aplicação de Métodos Heurísticos no Ajuste da Curva de Distribuição de Weibull em Energia Eólica*. 82 p. Dissertação (Mestrado em Engenharia Mecânica) — Universidade Federal do Ceará, Fortaleza, 2018.

SIDHU, MANJIT SINGH. (2019). *Advanced Technology-Assisted Problem Solving in Engineering Education: Emerging Research and Opportunities*. IGI Global.

SONDA. Sistema de Organização Nacional de Dados Ambientais. 2020. Disponível em: <<http://sonda.ccst.inpe.br/>>. Acesso em: 14 de junho de 2020.

STEVENS, M.J.M., AND P.T. SMULDERS. The Estimation of the Parameters of the Weibull Wind Speed Distribution for Wind Energy Utilization Purposes. *Wind Engineering*, vol. 3, no. 2, 1979, pp. 132–145.

TAVARES, Luiz Filipe de A. et al. Assessment of the offshore wind technical potential for the Brazilian Southeast and South regions. *Energy*, v. 196, p. 117097, 2020.

USTA, I.; ARIK, I.; YENILMEZ, I.; KANTAR, Y. M. A new estimation approach based on moments for estimating weibull parameters in wind power applications. *Energy Conversion and Management*, v. 164, p. 570 – 578, 2018. ISSN 0196-8904.

WAIS, P. A review of Weibull functions in wind sector. *Renewable and Sustainable Energy Reviews*, 70, 1099–1107. <https://doi.org/10.1016/j.rser.2016.12.014> (2017). ISSN: 1364-0321.

YU, Jianxing et al. Assessment of offshore wind characteristics and wind energy potential in Bohai Bay, China. *Energies*, v. 12, n. 15, p. 2879, 2019.

APÊNDICE A: Parâmetros das distribuições de probabilidade.

Tabela 6: Parâmetros obtidos para SCR-25

Método	Distribuição	k	c	p	u
MLE	W	2,372348	5,893867	-	-
	N	1,238926	32,874812	-	-
	GEV	-0,231187	2,238083	-	4,360791
	EGL	0,170376	0,229321	2,937391	-
	GG	0,499640	7,704041	3,758427	-
MMLE	W	2,399406	5,904964	-	-
	N	1,283371	32,875470	-	-
	GEV	0,001000	2,111970	-	4,095779
	EGL	0,174585	0,222942	2,965575	-
	GG	0,539890	7,539846	3,585653	-
MUOM	W	2,490498	5,939824	-	-
	N	1,500663	32,869512	-	-
	GEV	-0,190834	2,167186	-	4,361987
	EGL	0,119865	0,378299	2,450334	-
	GG	1,250050	5,260644	2,204835	-

Tabela 7: Parâmetros obtidos para PT-11

Método	Distribuição	k	c	p	u
MLE	W	3,026071	5,453699	-	-
	N	1,873844	26,918002	-	-
	GEV	-0,140203	1,591528	-	4,178999
	EGL	0,060063	0,379754	3,178275	-
	GG	0,795912	5,938947	3,477976	-
MMLE	W	3,054446	5,459926	-	-
	N	1,951132	26,909802	-	-
	GEV	0,001000	1,672413	-	4,022256
	EGL	0,060567	0,376019	3,189995	-
	GG	0,853764	5,799702	3,361229	-
MUOM	W	3,091873	5,469723	-	-
	N	2,232645	26,911208	-	-
	GEV	-0,238417	1,689810	-	4,245262
	EGL	0,023649	0,883287	2,563542	-
	GG	1,795330	4,042718	2,237818	-

Tabela 8: Parâmetros obtidos para a boia oceânica 1

Método	Distribuição	k	c	p	u
MLE	W	4,583333	9,423227	-	-
	N	3,961876	78,769055	-	-
	GEV	-0,205492	2,065480	-	7,983762
	EGL	0,011613	0,209152	4,796792	-
	GG	1,041091	9,317230	4,473959	-
MMLE	W	4,602311	9,488871	-	-
	N	4,041329	79,863112	-	-
	GEV	0,001000	2,224493	-	7,599654
	EGL	0,010000	0,228707	4,658163	-
	GG	1,072900	9,303164	4,413000	-
MUOM	W	4,649915	9,429461	-	-
	N	4,630715	78,778680	-	-
	GEV	-0,356548	2,206948	-	7,942358
	EGL	0,000868	1,521228	2,877365	-
	GG	2,327286	6,752993	2,860084	-

Tabela 9: Parâmetros obtidos para a boia oceânica 2

Método	Distribuição	k	c	p	u
MLE	W	4,238879	9,005918	-	-
	N	3,544009	71,843607	-	-
	GEV	-0,190945	2,160256	-	6,900483
	EGL	0,007078	0,408379	3,711339	-
	GG	1,204372	8,483723	3,800292	-
MMLE	W	4,277550	9,074031	-	-
	N	3,632919	72,939580	-	-
	GEV	0,001000	2,163809	-	7,180702
	EGL	0,010000	0,316668	3,972260	-
	GG	1,336674	8,474387	3,774890	-
MUOM	W	4,245781	9,004431	-	-
	N	3,984955	71,85000	-	-
	GEV	-0,272791	2,112154	-	7,454214
	EGL	0,000279	3,248112	2,637949	-
	GG	2,603984	5,859594	2,492991	-

