



**XXIII SNTPEE**  
**SEMINÁRIO NACIONAL**  
**DE PRODUÇÃO E**  
**TRANSMISSÃO DE**  
**ENERGIA ELÉTRICA**

FI/GPT/09  
18 a 21 de Outubro de 2015  
Foz do Iguaçu - PR

## GRUPO II

### GRUPO DE ESTUDO DE PRODUÇÃO TÉRMICA E FONTES NÃO CONVENCIONAIS - GPT

#### TÉCNICA DE INTELIGÊNCIA COMPUTACIONAL APLICADA AO CÁLCULO DOS PARÂMETROS DA DISTRIBUIÇÃO DE WEIBULL: ESTUDO PARA O POTENCIAL EÓLICO DE PARNAÍBA-PI

Tatiane Carolyne Carneiro(\*) Sofia Pinheiro Melo Paulo Cesar M. de Carvalho Arthur Plínio de S. Braga

DEE - UFC

#### RESUMO

Buscando um aperfeiçoamento da análise do potencial de aproveitamento eólico, o presente artigo aplica a Otimização por Nuvem de Partículas para o cálculo dos parâmetros  $k$  e  $c$  que definem a distribuição de Weibull. A partir dos dados coletados por estação anemométrica em Parnaíba (PI), observa-se que esta técnica fornece um ajuste adequado da distribuição de Weibull aos histogramas de velocidade de vento, apresentando melhor desempenho em relação aos métodos numéricos tradicionalmente utilizados. Através do *RETScreen*, é verificado o impacto da otimização dos parâmetros na exatidão do cálculo da energia elétrica anual gerada em um parque eólico hipotético.

#### PALAVRAS-CHAVE

Parâmetros de Weibull, Otimização por Nuvem de Partículas, Métodos Numéricos

#### 1.0 - INTRODUÇÃO

A preocupação em torno de questões ambientais e do crescimento da demanda de energia impulsionou vários países a buscarem novas soluções para o fornecimento de energia elétrica e abrirem espaço para a inserção das energias renováveis, em especial a energia eólica. No Brasil, em virtude do seu elevado potencial hídrico, há uma forte dependência por usinas hidrelétricas na geração de energia elétrica. Entretanto, em situações adversas da natureza, como a falta de chuvas e a conseqüente redução do nível dos reservatórios hídricos, as usinas termelétricas são incorporadas ao sistema para atender à demanda do país, contribuindo para os altos preços da eletricidade. Neste contexto, com o aumento no risco de déficit de energia, o governo brasileiro tem investido na expansão e diversificação de sua matriz elétrica com fontes renováveis, buscando uma elevação da confiabilidade do sistema.

A geração eólica tem apresentado um crescimento bastante significativo no cenário brasileiro, em particular devido à forte complementaridade entre os períodos de chuva e vento, possibilitando que os parques eólicos supram a demanda de energia durante a estação seca, propiciando o acúmulo de água nos reservatórios das grandes hidrelétricas e reduzindo a utilização de geração térmica. O maior inconveniente da energia eólica, no entanto, é a sua intermitência, uma vez que os ventos não possuem velocidade constante, variando conforme as condições climáticas, resultando em uma incerteza na produção de eletricidade. Torna-se, portanto, necessário o aprofundamento das investigações sobre o regime dos ventos e a caracterização do potencial eólico nas regiões.

Existem várias distribuições probabilísticas de frequência utilizadas para representar os dados de velocidade do vento, sendo a distribuição de Weibull a mais utilizada na descrição do regime dos ventos. Métodos numéricos são tradicionalmente aplicados para o cálculo dos parâmetros de Weibull, no entanto, em alguns casos, não proporcionam um ajuste adequado aos histogramas de frequência da velocidade do vento. Assim, surge a necessidade de um aprimoramento na exatidão destes parâmetros, de modo a aperfeiçoar a análise do potencial de

(\*) Departamento de Engenharia Elétrica, Universidade Federal do Ceará  
Caixa Postal 6001, 60.455-760, Fortaleza, CE, Brasil – Email: tatianecarolyne@oi.com.br

aproveitamento eólico. A utilização de técnicas da Inteligência Computacional, tais como os Algoritmos Genéticos e Otimização por Nuvens de Partículas, podem otimizar o cálculo dos parâmetros de Weibull, garantindo uma melhor exatidão na determinação da eletricidade produzida pelas turbinas eólicas. O presente artigo tem como objetivo principal a aplicação do algoritmo da Otimização por Nuvem de Partículas para o cálculo dos parâmetros que definem a distribuição de Weibull, comparando-a com os métodos numéricos tradicionalmente utilizados, de modo a verificar seu impacto no cálculo da produção de eletricidade dos aerogeradores.

## 2.0 - ANÁLISE DE POTENCIAL EÓLICO

Atualmente, o estudo do regime de ventos é de grande interesse científico a nível mundial em virtude da necessidade de um melhor aproveitamento do potencial eólico. Na avaliação do potencial de uma região, a análise da velocidade do vento é de fundamental importância, determinando a atratividade de um projeto eólico.

A representação de dados de velocidade de vento através de distribuições de frequência tornou-se uma prática comum no setor eólico, tendo em vista que estas agregam inúmeros fatores que influenciam no comportamento do vento (1). O histograma da velocidade do vento é amplamente representado pela função de densidade de probabilidade de Weibull, em virtude desta apresentar um bom ajuste à distribuição de frequência dos dados de vento. O ajuste de distribuições estatísticas aos dados de velocidade de vento é uma das principais dificuldades enfrentadas nos estudos relacionados à potência dos ventos (2).

### 2.1 Distribuição de Weibull

A função de Weibull representa a probabilidade  $p(v)$  de ocorrer ao longo de um tempo  $t$  uma determinada velocidade de vento  $v$ . Esta função é calculada de acordo com a equação abaixo:

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

O parâmetro  $k$ , adimensional, é denominado fator de forma e está relacionado à variância da velocidade do vento em torno da velocidade média, especificando a forma da função de distribuição de Weibull. O parâmetro  $c$ , em m/s, é denominado de fator de escala e está relacionado à velocidade média do vento.

O fator de forma  $k$  é inversamente proporcional às variações da velocidade do vento, estando relacionado com a intensidade de turbulência. Assim, esse parâmetro revela a regularidade dos ventos, em termos de velocidade. Quanto maior o valor de  $k$ , menor a oscilação da velocidade (maior regularidade), menor a intensidade da turbulência e menor o espalhamento da curva da distribuição de frequência. Já o fator de escala  $c$  é proporcional à velocidade média da distribuição, logo os maiores fatores de escala correspondem a velocidades de vento mais altas (3).

### 2.2 Métodos Numéricos

Estão disponíveis na literatura vários tipos de métodos numéricos para estimativa dos parâmetros de Weibull como: Momento (M), Empírico (E), Máxima Verossimilhança (MV), Fator Padrão de Energia (FPE) e Energia Equivalente (EE).

O método M é baseado na iteração numérica das seguintes equações, sendo  $\bar{v}$  a velocidade média,  $\sigma$  o desvio padrão dos dados de velocidade de vento e  $\Gamma(x)$  a função Gamma.

$$\bar{v} = c \Gamma\left(1 + \frac{1}{k}\right) = \frac{1}{n} \sum_{i=1}^n v_i$$

$$\sigma = c \left[ \Gamma\left(1 + \frac{2}{k}\right) - \Gamma^2\left(1 + \frac{1}{k}\right) \right]^{\frac{1}{2}} = \left[ \frac{1}{n-1} \sum_{i=1}^n (v_i - \bar{v})^2 \right]^{\frac{1}{2}}$$

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

O método E é considerado como um caso especial do Momento. Os parâmetros são estimados através das equações:

$$k = \left(\frac{\bar{v}}{\bar{v}}\right)^{-1.084}$$

$$c = \frac{\bar{v}}{\Gamma\left(1 + \frac{1}{k}\right)}$$

O método da MV necessita de extensivas iterações numéricas para solução das equações, sendo  $v_i$  a velocidade do vento e  $n$  o número de medições.

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

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

O método FPE está relacionado aos dados médios da velocidade do vento, sendo  $E_{pf}$  o fator padrão de energia.

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

$$k = 1 + \frac{3.69}{E_{pf}^2}$$

$$c = \frac{\bar{v}}{\Gamma\left(1 + \frac{1}{k}\right)}$$

No método da EE, os parâmetros  $k$  e  $c$  são determinados utilizando as equações abaixo:

$$\sum_{i=1}^n \left[ W_{v_i} - e \left( \frac{(v_i - c) \left[ \Gamma\left(1 + \frac{3}{k}\right) \right]^{1/3}}{(v_m)^{1/3}} \right)^k + e \left( \frac{(v_i) \left[ \Gamma\left(1 + \frac{3}{k}\right) \right]^{1/3}}{(v_m)^{1/3}} \right)^k \right]^{1/3} = \sum_{i=1}^n (\varepsilon_{v_i})^2$$

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

onde  $W_{v_i}$  corresponde às frequências observadas da velocidade do vento,  $v_m^3$  à velocidade média do vento ao cubo e  $\varepsilon_{v_i}$  é o erro da aproximação.

### 2.3 Otimização por Nuvem de Partículas

Visando um melhor ajuste da distribuição de Weibull aos histogramas, técnicas de otimização podem ser utilizadas para o cálculo dos parâmetros  $k$  e  $c$ , permitindo uma maior aproximação da função com a curva real de distribuição de velocidade do vento. Na solução de diversos problemas de otimização, metodologias envolvendo técnicas de Inteligência Artificial são bastante utilizadas. As técnicas heurísticas de otimização englobam modelos probabilísticos a partir da observação de fenômenos naturais para encontrar a solução ótima de uma função. Existem diversos métodos heurísticos de otimização como os Algoritmos Genéticos, Busca Tabu, Método do Recozimento Simulado, Otimização por Colônia de Formigas, Colônia de Abelhas, Nuvem de Partículas.

A Otimização por Nuvem de Partículas, também denominado *PSO (Particle Swarm Optimization)*, é um método heurístico de otimização baseado na Inteligência de Enxame (*Swarm Intelligence*). Este termo é utilizado para designar sistemas de inteligência artificial em que o comportamento coletivo dos indivíduos em uma população segue um padrão capaz de resolver uma série de problemas. O *PSO* foi proposto inicialmente por Dr. Eberhart e Dr. Kennedy em 1995, inspirado no comportamento social de um conjunto de pássaros em vôo.

O algoritmo é modelado por partículas (pássaros) que voam conforme a sua própria experiência e a de outros membros da população (bando), formando uma nuvem de partículas em um espaço de busca de uma solução ótima. Para que o bando de pássaros sempre se aproxime do objetivo, utiliza-se a função de avaliação denominada *fitness*, que irá avaliar o desempenho das partículas para que o objetivo seja alcançado (4).

O *PSO* é iniciado com uma população de soluções aleatórias ou pré-estabelecidas em um espaço de busca. Para cada uma das soluções, que correspondem às partículas, é designada uma velocidade para que possa percorrer o espaço de soluções do problema na busca das melhores soluções. Existem 2 tipos de melhores soluções: *pbest* e *gbest*. A solução *pbest* está relacionada à melhor posição alcançada por cada partícula, já a *gbest* à melhor solução de todas as obtidas por qualquer partícula da população. Desse modo, a cada iteração e mudança de velocidade, as partículas voam em direção às posições *pbest* e *gbest* (5). Duas condições de parada do algoritmo são comumente utilizadas: pelo número pré-definido de iterações ou pela função objetivo (*fitness*), interrompendo o algoritmo quando for alcançado um valor pré-definido para a função e não houver mais melhorias (estagnação).

Três termos determinam o próximo movimento da partícula, como o *termo de inércia*, que força a partícula a mover-se na mesma direção, o *termo cognitivo*, que força a partícula a voltar a uma posição anterior que seja melhor do que a atual e o *termo de aprendizado social*, que força a partícula a seguir a direção de seus melhores vizinhos.

$$v(t+1) = \underbrace{w(t) * v(t)}_{\text{Inércia}} + \underbrace{a_1(t) * r_1 * (pbest(t) - x(t))}_{\text{Cognitivo}} + \underbrace{a_2(t) * r_2 * (gbest - x(t))}_{\text{Aprendizado Social}}$$

A equação acima é usada para calcular a nova velocidade da partícula de acordo com sua velocidade anterior e as distâncias entre sua posição atual  $x(t)$ , sua melhor posição ( $pbest$ ) e a melhor posição do grupo ( $gbest$ ). A sua nova posição é então dada de acordo com equação abaixo.

$$x(t+1) = x(t) + v(t+1)$$

Onde  $v$  é a velocidade da partícula,  $x$  é a posição da partícula,  $a_1$  e  $a_2$  são parâmetros cognitivo e social, respectivamente,  $r_1$  e  $r_2$  são números aleatórios no intervalo [0,1],  $pbest$  é a melhor posição em que a partícula já esteve,  $gbest$  é a melhor posição em que algum vizinho já esteve,  $w$  é o peso de inércia e  $t$  a iteração.

Uma vez que se deseja melhorar o ajuste da distribuição de Weibull aos histogramas, deve-se minimizar a diferença entre a função de Weibull e a curva de distribuição de velocidade do vento. Desse modo, a função objetivo  $\epsilon$  do algoritmo *PSO* a ser minimizada é dada por:

$$\epsilon(v_i) = \frac{1}{2} \sum_{i=0}^n (f_{real}(v_i) - f_{weibull}(v_i))^2$$

Onde  $f_{real}(v_i)$  é a frequência de ocorrência relativa a cada classe de velocidade do vento e  $f_{weibull}(v_i)$  é a função de densidade de probabilidade de Weibull relativa a cada classe de velocidade do vento e  $n$  é o número total de classes de velocidade de vento (intervalos de 1 m/s).

Com intuito de evitar a convergência prematura na fase inicial da busca e reforçar a convergência para a solução ótima global na fase final, o algoritmo *PSO* foi implementado considerando os coeficientes de aceleração (parâmetro cognitivo e social) e o peso de inércia variando por uma função não-linear durante o processo de busca, conforme proposto em (6), seguindo as expressões abaixo. Para o peso de inércia foi estabelecido o valor máximo de 0,9 e mínimo de 0,4. Os parâmetros cognitivo e social foram definidos com o valor máximo de 2,5 e mínimo de 0. Já os coeficientes de potência  $\alpha$ ,  $\beta$ ,  $\gamma$  foram atribuídos com 0,5, 1,5 e 1,0, respectivamente.

$$w(t) = \left(1 - \frac{t}{iter_{max}}\right)^{\alpha} (w_{max} - w_{min}) + w_{min}$$

$$a_1(t) = \left(1 - \frac{t}{iter_{max}}\right)^{\beta} (a_{1max} - a_{1min}) + a_{1min}$$

$$a_2(t) = \left(1 - \frac{t}{iter_{max}}\right)^{\gamma} (a_{2min} - a_{2max}) + a_{2max}$$

Onde  $w$  é o peso de inércia,  $a_1$  e  $a_2$  são os coeficientes de aceleração, representando os parâmetros cognitivo e social, respectivamente,  $iter_{max}$  é o número máximo de iterações definidas,  $w_{max}$  e  $w_{min}$  são os valores máximo e mínimo, respectivamente, do peso de inércia,  $a_{1,max}$  e  $a_{2,max}$  são os valores máximos e  $a_{1,min}$  e  $a_{2,min}$  os valores mínimos dos parâmetros cognitivo e social, respectivamente.

O PSO foi implementado com uma população aleatória de 50 partículas, sendo atribuída velocidade inicial nula para cada partícula. Com base nos fundamentos teóricos abordados, o funcionamento do algoritmo resume-se em cinco passos, conforme ilustrado na Figura 1.

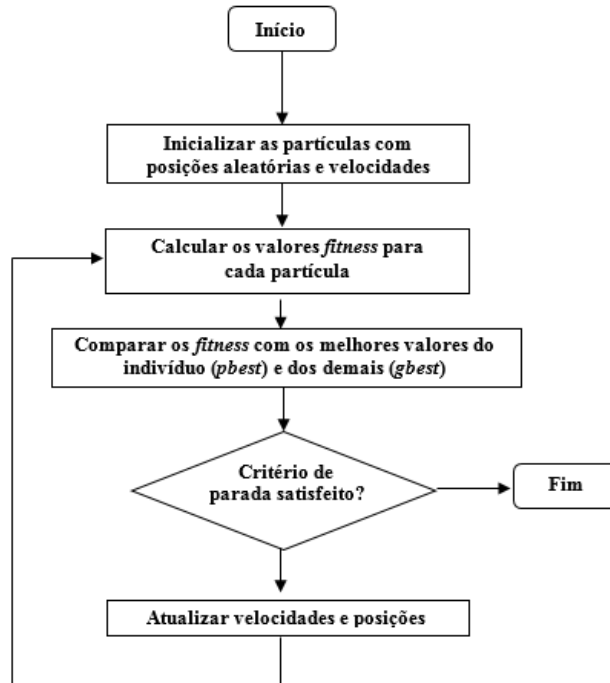


FIGURA 1 – Algoritmo PSO

#### 2.4 Testes Estatísticos

A análise comparativa da eficiência entre os métodos abordados compreende a aplicação de testes estatísticos. São apresentadas abaixo as equações que representam os três testes utilizados para avaliar a exatidão de cada método na estimativa dos parâmetros de Weibull:

- a) Raiz dos Erros Quadráticos Médios (RMSE)

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{N}}$$

- b) Correlação ( $r$ )

$$r = \frac{\sum_{i=1}^N (X_i - X_{med}) \cdot (Y_i - Y_{med})}{\sqrt{\sum_{i=1}^N (X_i - X_{med})^2 \cdot \sum_{i=1}^N (Y_i - Y_{med})^2}}$$

- c) Viés relativo (VR)

$$VR = \frac{X_{med} - Y_{med}}{Y_{med}}$$

Onde  $N$  é o número de observações,  $Y_i$  é a frequência dos dados observados de velocidade de vento,  $X_i$  é a frequência calculada através da distribuição de Weibull,  $X_{med}$  é a média dos valores  $X_i$  e  $Y_{med}$  a média dos valores  $Y_i$ . O melhor desempenho é dado para o método cujo valor de  $r$  é mais próximo de 1 e de RMSE e VR mais próximos de zero. Valores altos de correlação não significam, por si só, ajustes com alta precisão.

### 3.0 - METODOLOGIA

A presente pesquisa foi aplicada à estação anemométrica localizada no município de Parnaíba, Piauí, região Nordeste do Brasil. Por meio do projeto “Previsão de Potencial Eólico visando Operação Integrada Ótima de Unidades Geradoras de Eletricidade: estudo de caso para o Nordeste do Brasil”, financiado pelo CNPq, foi instalada a estação anemométrica no Instituto Federal de Parnaíba e, através de uma base de dados de velocidade, foi desenvolvido o estudo do potencial eólico da região. Os dados de vento foram medidos a cada 10 minutos durante o período de Agosto/2012 a Julho/2013.

Através do Matlab, foram calculados os parâmetros  $k$  e  $c$  de Weibull por meio do algoritmo da Otimização por Nuvem de Partículas, bem como dos cinco métodos numéricos detalhados anteriormente. De posse dos parâmetros, são traçadas as curvas das distribuições de Weibull, verificando o método que proporciona melhor ajuste da curva ao histograma. Por fim, buscando avaliar o impacto da otimização dos parâmetros na produção de eletricidade anual, é realizado o cálculo da eletricidade gerada através do *RETScreen*. São utilizados modelos de turbinas dos fabricantes Enercon, Vestas e Siemens, obtendo valores de potência (MW), energia elétrica entregue à rede elétrica (MWh) e fator de capacidade (%). As especificações das turbinas são apresentadas na Tabela 1.

TABELA 1 – Especificações das turbinas eólicas – *RETScreen*

Fabricante	ENERCON	VESTAS	SIEMENS
Potência Unitária (MW)	2,0	2,0	2,3
Modelo	E82 E2 2MW 78m	V80 2.0 MW 78m	SWT2.3-82 80m
Quantidade de Turbinas	20	20	20
Pot. Instalada (kW)	40.000	40.000	46.000
Altura do cubo (m)	78	78	80
Diâmetro do rotor (m)	82	80	82
Área de varredura (m <sup>2</sup> )	5.281	5.027	5.281

### 4.0 - RESULTADOS

#### 4.1 Execução do PSO

Foi executado o algoritmo PSO considerando a função objetivo  $\mathcal{E}$ , os parâmetros e as equações de velocidade e posição das partículas definidos anteriormente. São obtidos os valores de  $k$  e  $c$  para o período analisado e o valor minimizado da função objetivo.

Para o horizonte anual, por exemplo, o código implementado retornou os seguintes valores:  $k = 3,959$ ,  $c = 9,0033$  m/s, e  $\mathcal{E} = 0,0003$ . A função objetivo varia ao longo das iterações, sendo minimizada a 0,0003 em 120 iterações, como ilustrado na Figura 2. Observa-se que o erro (função objetivo) sofre variações ao longo das iterações até se estabilizar. Este comportamento se deve à exploração global e local de cada partícula no espaço de busca requerendo várias repetições para encontrar a solução ótima.

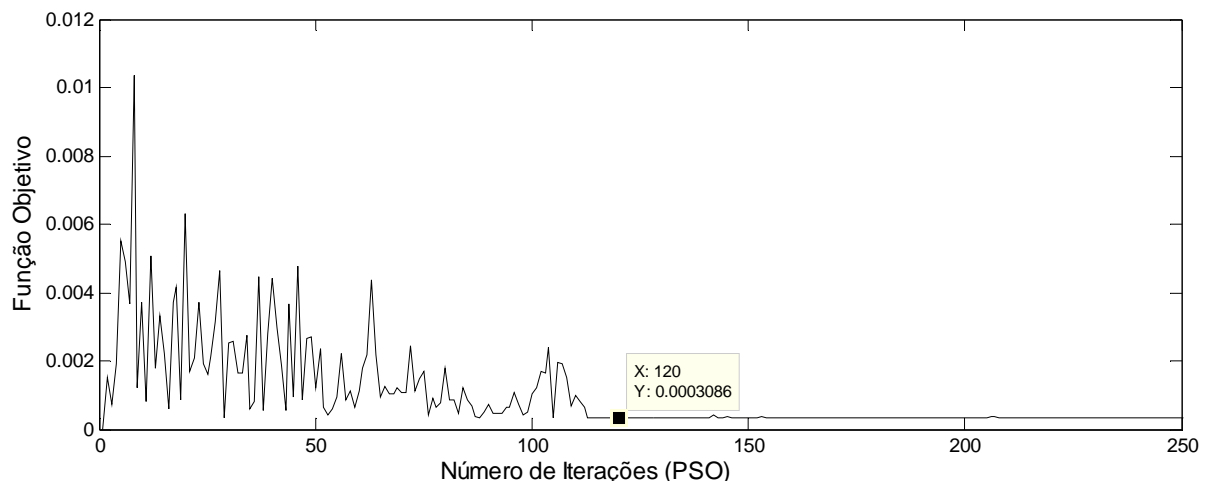


FIGURA 2 – Variação da função objetivo ao longo das iterações no espaço de busca PSO

#### 4.2 Aplicação da Distribuição de Weibull

A modelagem da distribuição de Weibull aos dados anuais de Parnaíba é analisada através do cálculo dos parâmetros de forma e escala para o *PSO* e para os cinco métodos numéricos anteriormente descritos: *EE*, *M*, *E*, *MV* e *FPE*.

De posse dos valores de  $k$  e  $c$  obtidos, são traçadas as curvas de Weibull que tendem a se ajustar aos histogramas dos dados de vento no período analisado, sendo possível observar qual método proporcionou melhor ajuste e que, portanto, melhor representa as condições de vento do local. A Figura 3 apresenta os ajustes das curvas de Weibull, para cada um dos seis métodos utilizados, ao histograma anual.

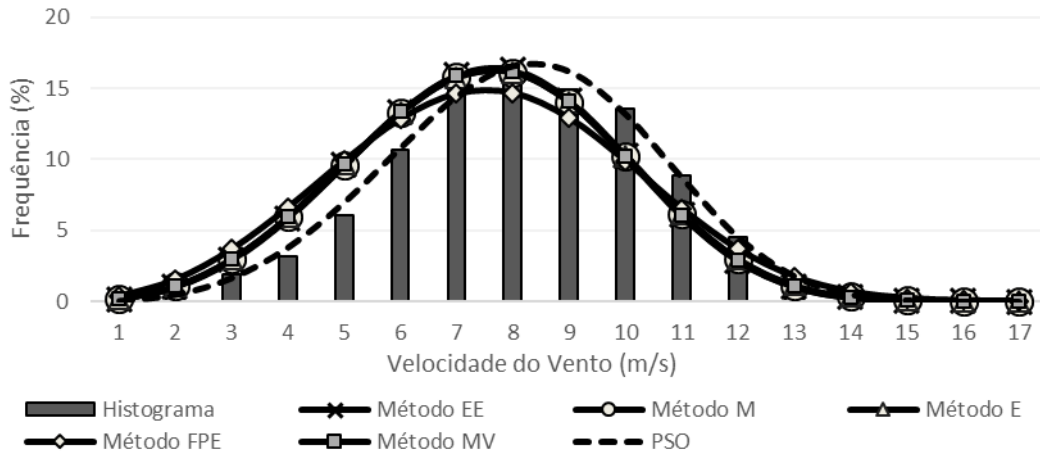


FIGURA 3 – Ajuste das curvas de Weibull ao histograma anual

Para analisar se a função de Weibull é adequada para descrever os dados de velocidade de vento de uma localidade, bem como comparar a eficiência entre os diferentes métodos de cálculo dos parâmetros, são aplicados os testes estatísticos. A Tabela 2 apresenta a aplicação dos testes *RMSE*,  $r$  e *VR* para cada um dos métodos utilizados.

TABELA 2 – Aplicação dos testes estatísticos, Parnaíba, anual

Métodos de Cálculo	Parâmetros Weibull		Testes Estatísticos		
	$k$	$c$ (m/s)	$r$	<i>RMSE</i>	<i>VR</i>
<i>PSO</i>	3,959	9,0033	0,9950	0,0060	0,000004
Energia Equivalente	3,597	8,3802	0,9582	0,0173	0,000014
Momento	3,559	8,3891	0,9579	0,0173	0,000015
Empírico	3,546	8,3907	0,9577	0,0173	0,000015
Máxima Verossimilhança	3,574	8,3654	0,9560	0,0177	0,000015
Fator Padrão de Energia	3,237	8,4301	0,9479	0,0193	0,000002

Avaliando cada método, pode-se afirmar que o *PSO* apresentou melhor desempenho, visto que possui a maior correlação e menores erros, obtendo assim o melhor ajuste ao histograma anual, com fator de forma  $k$  de 3,959 e fator de escala  $c$  de 9,0033 m/s. Quanto aos métodos numéricos, o melhor desempenho foi obtido pelo *EE*, seguido pelos *M*, *E*, *MV* e *FPE*.

#### 4.3 Avaliação da Geração de Energia Elétrica

Com intuito de avaliar quanto a otimização dos parâmetros de Weibull pode vir a reduzir os erros na estimação da energia elétrica anual gerada, foi utilizado o *RETScreen* para calcular a produção de eletricidade anual em um parque eólico hipotético, usando os diferentes valores de  $k$  e  $c$  calculados pelos métodos numéricos e pelo *PSO*. Os resultados obtidos são apresentados na Tabela 3, onde *MWh* corresponde à produção de eletricidade anual e % ao fator de capacidade calculado.

A determinação mais adequada da produção de energia elétrica é obtida através do método de melhor desempenho (*PSO*), cujos valores estimados de eletricidade gerada são menores em relação aos demais métodos, conforme é apresentado na Tabela 3. Desse modo, é interessante observar que os métodos numéricos que apresentam maiores

erros no cálculo dos parâmetros (pior desempenho) apresentam uma tendência em superestimar a energia elétrica gerada pelo parque eólico.

TABELA 3 – Análise da produção anual de energia elétrica, *RETSscreen*

		<i>PSO</i>	Energia Equivalente	Momento	Empírico	Máxima Verossimilhança	Fator Padrão de Energia
<b>Enercon</b>	<i>MWh</i>	122,67	123,16	123,22	123,23	123,20	123,60
	%	35	35,2	35,2	35,2	35,2	35,3
<b>Vestas</b>	<i>MWh</i>	103,66	104,55	104,65	104,69	104,61	105,49
	%	29,6	29,8	29,9	29,9	29,9	30,1
<b>Siemens</b>	<i>MWh</i>	114,05	115,17	115,29	115,33	115,24	116,36
	%	28,3	28,6	28,6	28,6	28,6	28,9

Observa-se que o cálculo da produção de energia elétrica entregue à rede (MWh) para os cinco métodos numéricos apresentou resultados bem próximos; no entanto, para o *PSO*, que apresentou melhor ajuste às condições de vento de Parnaíba, a diferença foi mais representativa. Para a turbina Siemens, verifica-se uma diferença de 2,315 MWh por ano na comparação entre a estimativa feita pelo *PSO* (melhor desempenho) com o Fator Padrão de Energia (pior desempenho). Para a turbina Vestas e Enercon, a diferença foi menos significativa, de 1,830 MWh e 0,929 MWh, respectivamente. Os resultados dos cálculos para a turbina Enercon revelaram um fator de capacidade em torno de 35% para Parnaíba, dentro da faixa média anual encontrada no mundo que oscila entre 22,5 e 35% (7).

## 5.0 - CONCLUSÃO

O presente estudo apresentou a aplicação do algoritmo *PSO* no cálculo dos parâmetros de Weibull, visando uma melhor capacidade de ajuste aos dados de velocidade do vento de Parnaíba. Os testes estatísticos indicaram que o método Energia Equivalente apresenta melhor desempenho em relação aos demais métodos numéricos e que o *PSO* proporciona o melhor desempenho dentre os métodos avaliados neste estudo. Observa-se que, enquanto o RMSE e  $r$  obtidos utilizando o Energia Equivalente apresentam 0,0173 e 95%, estes são reduzidos para 0,006 e 99% utilizando o *PSO*.

O cálculo da estimativa da eletricidade gerada, por meio do *RETSscreen*, mostrou que os métodos numéricos, além de apresentarem um menor desempenho no ajuste aos histogramas, apresentam uma tendência de superestimar os valores produzidos pelas turbinas eólicas anualmente, o que pode resultar em falsas estimativas.

A técnica *PSO* apresenta simplicidade de implementação, baixo custo computacional e capacidade de convergir à solução ótima global independentemente do tamanho ou complexidade do problema. Neste estudo, foram obtidos parâmetros da distribuição de Weibull que fornecem um ajuste adequado para o histograma de velocidade de vento de Parnaíba, assegurando a viabilidade desta técnica para a aplicação proposta, bem como a sua superioridade em relação aos tradicionais métodos numéricos.

## 6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) CARNEIRO, T. C. Caracterização de Potencial Eólico para Fins de Geração Eolielétrica: Estudo de Caso para Maracanaú (CE), Parnaíba (PI) e Petrolina (PE). Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal do Ceará, Fortaleza, 2014.
- (2) SANSIGOLO, C. A. Distribuições de Probabilidade de Velocidade e Potência do Vento. Revista Brasileira de Meteorologia, v.20, n.2, 207-214, 2005
- (3) CARVALHO, P.C.M. Geração Eólica. 146p. 1ª edição, Fortaleza – CE, Editora Imprensa Universitária, 2003.
- (4) CAMPOS, I. M. S. Computação evolucionária aplicada a problemas de otimização combinatória. Dissertação (Mestrado em Sistemas de Computação), Universidade Federal do Rio Grande do Norte, Natal, 2006.
- (5) OLIVEIRA, M.C.S., SILVA, T.L., ALOISE, D.J. Otimização por Nuvem de Partículas: Diferença entre Aplicações a Problemas Contínuos e Discretos. XXXVI SBPO – O Impacto da Pesquisa Operacional nas Novas Tendências Multidisciplinares, São João del-Rei, MG, 2004.
- (6) CHANG, T. P. Wind energy assessment incorporating particle swarm optimization method. Energy Conversion and Management 52, 2010.



(7) CONSELHO GLOBAL DE ENERGIA EÓLICA. Revolução Energética: A caminho do desenvolvimento limpo, 2013.

#### 7.0 - DADOS BIOGRÁFICOS

Tatiane Carolyne Carneiro nasceu em Mossoró no estado do Rio Grande do Norte, é engenheira ambiental pela Universidade Federal de Campina Grande (UFCG). É mestre em engenharia elétrica pela Universidade Federal do Ceará (UFC), durante o mestrado desenvolveu pesquisas onde se analisava técnicas estatísticas para avaliação de dados eólicos e para estudo do potencial eólico de localidades no Nordeste brasileiro. Atualmente é aluna do programa de doutorado em engenharia elétrica da Universidade Federal do Ceará (UFC), onde tem participado de pesquisas relacionadas com análise e aplicação de dados eólicos para previsão de potencial eólico utilizando técnicas de inteligência computacional.

Sofia Pinheiro Melo possui graduação em Engenharia Elétrica pela Universidade Federal do Ceará (2014). Tem experiência na área de Energia Eólica e desenvolve pesquisas relacionadas à aplicação de técnicas de Inteligência Computacional para análise dos dados de velocidade de vento.

Paulo Cesar Marques de Carvalho possui graduação em Engenharia Elétrica pela Universidade Federal do Ceará (1989), mestrado em Engenharia Elétrica pela Universidade Federal da Paraíba (1992) e doutorado em Engenharia Elétrica pela Universidade de Paderborn, Alemanha (1997). Atualmente é professor associado do Departamento de Engenharia Elétrica da Universidade Federal do Ceará. Tem atividades de ensino, pesquisa e extensão nos seguintes temas: geração fotovoltaica, geração eólica e biodigestores. Coordena o Laboratório de Energias Alternativas da UFC.

Arthur Plínio de S. Braga possui graduação em Engenharia Elétrica pela Universidade Federal do Ceará (1995), mestrado em Engenharia Elétrica pela Universidade de São Paulo (1998), doutorado em Engenharia Elétrica [São Carlos] pela Universidade de São Paulo (2004), pós-doutorado pela Universidade de São Paulo/São Carlos - USP/SC (2005) e pós-doutorado pela Universidade de São Paulo/São Carlos - USP/SC (2006). Atualmente é Professor Adjunto da Universidade Federal do Ceará. Tem experiência na área de Engenharia Elétrica, com ênfase em Redes Neurais, atuando principalmente nos seguintes temas: aprendizagem por reforço, agente autônomo, redes neurais, inteligência artificial, mapas auto-organizáveis.