

INTELIGÊNCIA COLETIVA PARA ESTIMAÇÃO DOS PARÂMETROS DE WEIBULL: ESTUDO DE CASO PARA AS REGIÕES SUL E NORDESTE DO BRASIL

Tatiane Carlyne Carneiro – tatiane.carolyne@ufma.br
Universidade Federal do Maranhão, Departamento de Ciência e Tecnologia
Paulo Cesar Marques de Carvalho – carvalho@dee.ufc.br
Universidade Federal do Ceará, Departamento de Engenharia Elétrica
Paulo Henrique Silva Lopes – phlopes1800@gmail.com
Universidade Federal do Maranhão, Departamento de Ciência e Tecnologia
Heron Alves dos Santos – santos.heron@gmail.com
Exército Brasileiro, 12ª Comissão Regional de Obras

Resumo. A Inteligência Coletiva é definida como qualquer esforço de solução distribuída de problemas de otimização e busca que seja inspirado no comportamento de insetos sociais e outras sociedades (formigas, pássaros, pedestres, etc). Sistemas coletivos buscam coordenar esforços individuais para alcançar objetivos comuns. A análise do comportamento da velocidade do vento é de fundamental importância na avaliação do potencial eólico, na estimação da energia gerada e do fator de capacidade de turbinas eólicas. O presente trabalho apresenta uma técnica de inteligência coletiva (PSO – Particle Swarm Optimization) e de cinco métodos numéricos para a estimação dos parâmetros de Weibull (Energia Equivalente, Empírico, Fator Padrão de Energia, Máxima Verossimilhança e Momento) e por fim o uso de testes estatísticos para a comparação entre essas seis formas de estimação dos parâmetros de Weibull. Foram usados dados de velocidade e direção do vento coletados de janeiro/2010 a dezembro/2010 para a cidade de São Martinho da Serra e dados de janeiro/2012 a dezembro/2012 para a cidade de Petrolina. A distribuição de Weibull é usado para aproximar os histogramas de velocidade do vento, utilizando os métodos já citados anteriormente para se estimar os parâmetros de escala e forma. Dos métodos que foram usados para a estimação dos parâmetros de Weibull o de inteligência coletiva foi o que obteve o melhor resultado dando valores que se ajustam quase que perfeitamente com os histogramas de velocidade do vento.

Palavras-chave: Energia eólica, Distribuição de Weibull, Velocidade do vento.

1. INTRODUÇÃO

O desafio de estabelecer matrizes elétricas e energéticas capazes de atender as crescentes demandas por energia e manter a segurança no suprimento vem sendo um desafio à nível mundial. O estabelecimento dessas matrizes é importante para o desenvolvimento social e econômico dos países, e ao mesmo para a redução dos impactos ambientais relacionados a geração de energia (PEREIRA et al., 2007).

No Brasil, a matriz elétrica é predominante composta por hidroelétricas (fonte renovável), que corresponde a 61,24% da energia gerada atualmente (AGENCIA NACIONAL DE ENERGIA ELÉTRICA, 2016). Uma limitação dessa fonte de geração de energia é a necessidade de grandes áreas para construção de reservatórios, regiões brasileiras com maior potencial hídrico estarem distantes dos centros de consumo, degradação do meio ambiente por inundações e linhas de transmissão, e custos ambientais e sociais cada vez maiores (MARRANGHELLO, 2004).

A energia eólica se torna bastante viável, pois além de ser renovável, tem o seu maior potencial nos períodos onde há baixa pluviometria, podendo assim suprir os déficits das hidroelétricas. Mas a energia eólica apresenta uma limitação relacionada a intermitência inerente ao recurso eólico. Os estudos das séries de velocidade do vento são importantes para entender o comportamento sazonal desses dados e poder contribuir para a caracterização do potencial eólico de regiões e ajudar nas tomadas de decisões.

Existem várias distribuições probabilísticas de frequência utilizadas para representar os dados de velocidade do vento (Weibull, Gama, Normal, Log-Normal), sendo a distribuição de Weibull a mais utilizada na descrição do regime dos ventos. No cálculo dos parâmetros de Weibull, vários métodos numéricos podem ser aplicados de modo a garantir resultados precisos. Entretanto, estudos têm mostrado que, em alguns casos, a distribuição de Weibull não tem se ajustado bem aos histogramas. Assim, surge a necessidade de um aprimoramento na precisão destes parâmetros, de modo a permitir uma maior aproximação com a distribuição real, aperfeiçoando a análise do potencial de aproveitamento eólico (CARNEIRO, 2014; CARNEIRO et al., 2016).

Nesse contexto, o uso de técnicas de otimização advindas da Inteligência Computacional pode otimizar a determinação dos parâmetros de Weibull, visando uma melhor precisão no ajuste das curvas e, conseqüentemente, uma redução dos erros na estimativa da eletricidade produzida pelas turbinas eólicas.

Otimização por Nuvem de Partícula é um algoritmo matemático de busca e otimização baseado no comportamento de pássaros em revoadas. As partículas se movimentam em um espaço de busca com uma certa velocidade V , usando experiência própria e a experiência das outras partículas.

Os objetivos deste trabalho são Utilizar a técnica da Otimização por Nuvem de Partículas (PSO) para o cálculo dos parâmetros k e c da distribuição de *Weibull* e usar testes estatísticos para comparar o PSO com cinco métodos numéricos tradicionalmente utilizados.

2. TÉCNICA DE INTELIGÊNCIA COLETIVA

2.1 Otimização por Nuvem de Partículas (PSO - Particle Swarm Optimization)

Buscando um melhor ajuste da distribuição de *Weibull* aos histogramas, métodos alternativos são utilizados para otimização do cálculo dos parâmetros k e c , permitindo uma maior aproximação da função com a curva real de distribuição de velocidade do vento e garantindo, conseqüentemente, uma maior precisão na determinação da energia anual gerada.

Na solução de diversos problemas de otimização, metodologias envolvendo técnicas de Inteligência Artificial (IA) são bastante utilizadas (ANTUNES, 2011). As técnicas heurísticas de otimização englobam modelos probabilísticos a partir da observação de fenômenos naturais para encontrar a solução ótima de uma função. Embora estes métodos de otimização não garantam que a solução é a melhor solução possível dentre as existentes, convergem rapidamente para uma solução muito próxima da ótima (MEDEIROS *et al.*, 2012).

Existem diversos métodos heurísticos de otimização como os Algoritmos Genéticos, Busca Tabu, Método do Recozimento Simulado, Colônia de Formigas, Colônia de Abelhas, Nuvem de Partículas. Neste trabalho, será aplicado o algoritmo de Nuvem de Partículas (Particle Swarm Optimization - PSO), objetivando encontrar novos valores dos parâmetros k e c que possibilitem um melhor ajuste para curva de distribuição de *Weibull*, obtendo melhor desempenho para o sistema em estudo.

A Otimização por Nuvem de Partículas (Particle Swarm Optimization - PSO) é uma técnica de otimização evolucionária desenvolvida por Dr. Eberhart e Dr. Kennedy em 1995, inspirada no comportamento social de um conjunto de pássaros em voo com seu movimento localmente aleatório, mas globalmente determinado (HU, 2006).

Supõe-se que um conjunto de pássaros esteja procurando aleatoriamente a única fonte de alimento existente em um dado espaço. Todos os pássaros não sabem onde o alimento está, porém sabem quão longe ele está a cada iteração. Neste contexto, a melhor estratégia é seguir o pássaro mais próximo do alimento, conforme apresentado na técnica PSO, em que cada solução (partícula) é um pássaro que voa através do espaço de busca seguindo as melhores partículas.

De modo semelhante aos Algoritmos Genéticos (AGs), PSO é iniciado com uma população de soluções aleatórias ou pré-estabelecidas, em um espaço de busca n -dimensional. No entanto, ao contrário dos AGs, para cada uma das soluções, que correspondem às partículas, é designada uma velocidade aleatória 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* (OLIVEIRA *et al.*, 2004)

A técnica PSO tem sido bastante eficiente na solução de problemas contínuos não-lineares e pouco explorada em problemas discretos. A fácil implementação do algoritmo e o ajuste de poucos parâmetros são algumas das vantagens desta técnica, sendo bastante aplicada na otimização de funções, em redes neurais artificiais, sistemas de lógica *Fuzzy*, dentre outras áreas, uma vez que gera resultados de forma mais rápida em relação aos demais métodos.

- Estrutura do PSO

PSO não utiliza operadores genéticos, diferentemente dos AGs. Cada partícula voa conforme a sua própria experiência e a outros membros do enxame, formando uma população de partículas em um espaço de busca de um ótimo local, em que as respectivas posições locais das partículas estão associadas aos valores da função objetivo.

No algoritmo, as partículas são lançadas inicialmente dentro do espaço de busca, tendo cada uma as seguintes características:

- Uma posição e uma velocidade;
- Conhecimento de sua posição e o valor da função objetivo para esta posição;
- Conhecimento sobre seus vizinhos (vizinhança): a melhor posição encontrada e o valor da sua função objetivo;
- Armazenamento de sua melhor posição encontrada.

Em cada espaço de tempo, o comportamento de uma partícula é determinado dentre três possíveis escolhas: a) seguir seu próprio caminho; b) seguir para sua melhor posição encontrada; c) seguir para a melhor posição encontrada por algum de seus vizinhos. A condição de parada é ultrapassar o limite de número de iterações pré-definido ou quando 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.

Após encontrar os dois melhores valores, a partícula atualiza sua velocidade e posição seguindo com as seguintes equações:

$$v(t+1) = (\underbrace{w}_{\text{Inércia}} * v(t)) + (\underbrace{c1 * r1}_{\text{Cognitivo}} * (p(t) - x(t))) + (\underbrace{c2 * r2}_{\text{Aprendizado social}} * (g(t) - x(t))) \quad (1)$$

$$x(t+1) = x(t) + v(t+1) \quad (2)$$

Onde:

v(t) é a velocidade da partícula;
 x(t) é a posição da partícula;
 c1 e c2 são parâmetros cognitivo e social;
 r1 e r2 são números aleatórios entre 0 e 1;
 p(x) é a melhor posição em que a partícula já esteve;
 g(x) é a melhor posição em que algum vizinho já esteve;
 w é o peso de inércia.

A Equação 1 é usada para calcular a nova velocidade da partícula de acordo com sua velocidade anterior e as distâncias entre sua posição atual, sua melhor posição e a melhor posição do grupo. A sua nova posição é então dada de acordo com equação 2. O desempenho de cada partícula está medido de acordo com uma função de aptidão pré-definida que é relacionada ao problema a ser resolvido.

O peso de inércia w é empregado para controlar o impacto da velocidade anterior na velocidade atual, assim influenciando as habilidades de exploração global e local das partículas. Um peso de inércia maior facilita exploração global (procurando novas áreas), enquanto um peso de inércia menor tende a facilitar exploração local para refinar a área de procura atual. A seleção satisfatória do peso de inércia w pode prover um equilíbrio entre habilidades de exploração global e local, e assim pode requerer menos repetições, em média, para encontrar o valor ótimo.

Desse modo, o funcionamento do algoritmo resume-se em seis etapas:

1. Inicialização de uma população de partículas com posições e velocidades aleatórias em um espaço de busca d-dimensional.
2. Para cada partícula, avalia-se a função de fitness encontrado e a otimização desejada em d variáveis.
3. Compara-se o fitness e o *pbest* da partícula. Se o valor atual for melhor que o *pbest* então, o valor do *pbest* é substituído pelo valor do fitness encontrado, e a posição do *pbest* pela posição atual no espaço d-dimensional.
4. O valor do fitness é comparado com os melhores valores encontrados em toda a população. Se o valor atual for melhor que o *gbest*, então o *gbest* é modificado para o índice e valor da partícula atual.
5. Modifica-se então a velocidade e posição da partícula de acordo com as equações 1 e 2, respectivamente.
6. Executa-se um loop para o passo 2 até que um critério seja encontrado: normalmente, um fitness suficiente ou número máximo de iterações pré-estabelecido.

3. METODOLOGIA

A metodologia adotada para neste trabalho consiste na utilização de dados estatísticos para a caracterização das series temporais de velocidade e direção do vento nas cidades de Petrolina - PE e São Martinho da Serra - RS. Todos os procedimentos aqui adotados foram desenvolvidos com o auxílio das ferramentas computacionais *MATLAB*, *Microsoft Excel*.

3.1 Área de Estudo

Esta pesquisa foi aplicada à duas estações anemométricas localizada nos municípios de Petrolina – Pernambuco e São Martinho da Serra - Rio Grande do Sul. As cidades estão localizadas em diferentes regiões do Brasil, Nordeste e Sul do País, conforme as Figuras 1 e 2.

Figura 1 – Localização do município de Petrolina.



Fonte: <http://pt.wikipedia.org/wiki/Petrolina>.

Petrolina é um município brasileiro pertencente ao Estado de Pernambuco, Região Nordeste do País. Distante 712 km a oeste da capital Recife. Possui uma extensão territorial de 4.561,872 km², estando 244,8 km² em perímetro urbano e os 4.317,072 km² restantes integrando a zona rural. Segundo dados do Instituto Brasileiro de Geografia e Estatística, o IBGE, em 2014 sua população foi estimada em 326.017 habitantes. É o quinto maior município do Estado e o segundo do interior pernambucano, atrás apenas de Caruaru.

Figura 2 – Localização do município de São Martinho da Serra.



Fonte: https://pt.wikipedia.org/wiki/S%C3%A3o_Martinho_da_Serra.

São Martinho da Serra é um município brasileiro do estado do Rio Grande do Sul. O Município está localizado na Região Central do Estado, distante 333 quilômetros de Porto Alegre por via rodoviária. Seu acesso principal é através ERS 516, que liga o Município à Cidade de Santa Maria, em aproximadamente 22 km. Sua população foi estimada em 3.201 habitantes. É um município essencialmente agrícola, baseado na produção de soja, milho, feijão, arroz, trigo.

3.2 Aquisição dos Dados de Vento

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 do Sertão Pernambucano, localizada no município de Petrolina e, através de uma base de dados de velocidade, foi desenvolvido o estudo do potencial eólico da região. Os dados de vento são medidos a cada 10 minutos durante o período de Janeiro/2012 a Dezembro/2012.

As medições de velocidade foram realizadas através de anemômetro do modelo NRG 40c, instalado a 78 metros de altura. Para o armazenamento dos dados, foi utilizado o *Data Logger* NRG Symphonie-plus, programado para realizar registros em intervalos de 10 minutos, com uma taxa de amostragem de 0,5 Hz e com faixa de medição entre 0 a 96 m/s. Conectado ao *Data Logger*, um *ipack* realiza a transmissão dos dados diariamente via GPRS, sendo este alimentado por um painel solar, enquanto que a alimentação do *Logger* é realizada por baterias.

Desse modo, os dados de vento obtidos a partir deste sistema de aquisição de dados serão utilizados para estudo do aproveitamento elioelétrico na localidade apresentada.

Os dados anemométricos referentes ao município de São Martinho da Serra – Rio Grande do Sul foram obtidos da base de dados Sistema de Organização Nacional de Dados Ambientais (SONDA). Esse sistema parte de um projeto do Instituto Nacional de Pesquisas Espaciais (INPE) para implementação de infraestrutura física e de recursos humanos destinada a levantar e melhorar a base de dados dos recursos de energia solar e eólica no Brasil (<http://sonda.ccst.inpe.br/>). Os dados de vento são medidos a cada 10 minutos durante o período de janeiro/2010 a dezembro/2010.

3.3 Métodos Numéricos para Estimação dos Parâmetros de Weibull

Para se estimar os parâmetros que seriam usados na distribuição estatística de *Weibull* para o semestre e ano foram utilizados cinco métodos numéricos. O detalhamento matemático de alguns métodos numéricos para estimação dos parâmetros de *Weibull* e a forma de avaliá-los é descrito abaixo.

O método M determina os parâmetros k e c por meio das Equações 3 e 4 (CHANG, 2011).

$$\bar{v} = c \Gamma\left(1 + \frac{1}{k}\right) \quad (3)$$

$$\sigma = c \left[\Gamma\left(1 + \frac{2}{k}\right) - \Gamma^2\left(1 + \frac{1}{k}\right) \right]^{1/2} \quad (4)$$

Onde \bar{v} e σ são a velocidade média e o desvio padrão dos dados observados de velocidade do vento, respectivamente.

O método E é um caso alternativo ao M e é determinado com o uso das Equações 5 e 6 (CHANG, 2011).

$$k = \left(\frac{\sigma}{\bar{v}}\right)^{-1,086} \quad (5)$$

$$\bar{v} = c \Gamma\left(1 + \frac{1}{k}\right) \quad (6)$$

O método FPE está relacionado com a média dos dados de velocidade de vento e é definido pelas Equações 7, 8 e 9 (AKDAG *et al.*, 2009).

$$E_{pf} = \frac{\overline{v^3}}{(\bar{v})^3} \quad (7)$$

$$k = 1 + \frac{3,69}{(E_{pf})^2} \quad (8)$$

$$\bar{v} = c \Gamma\left(1 + \frac{1}{k}\right) \quad (9)$$

Onde E_{pf} é o fator padrão de energia.

O método EE foi desenvolvido por Silva (2003), motivado na busca por parâmetros de *Weibull* capazes de tornar o ajuste da distribuição adequado aos recursos eólicos encontrados no Nordeste do Brasil. Esses parâmetros são estimados a partir da equivalência entre a densidade de energia da curva teórica e a densidade de energia dos dados observados.

No método EE, os parâmetros de *Weibull* são determinados com base nas Equações 10 e 11.

$$\sum_{i=1}^n \left[W_{v_i} - e^{-\left\{ \frac{(v_i-1) \left[\Gamma\left(1 + \frac{3}{k}\right) \right]^{1/3}}{v^3} \right\}^k} + e^{-\left\{ \frac{(v_i) \left[\Gamma\left(1 + \frac{3}{k}\right) \right]^{1/3}}{v^3} \right\}^k} \right]^2 = \sum_{i=1}^n \varepsilon_{v_i}^2 \quad (10)$$

$$c = \frac{(\bar{v})^3}{\Gamma\left(1 + \frac{3}{k}\right)} \quad (11)$$

Onde W_{v_i} é a frequência de ocorrência para cada intervalo, $\overline{v^3}$ é o cubo da velocidade média do vento e ε_{v_i} é o erro de aproximação.

O método MV necessita de iterações numéricas para determinar os parâmetros das distribuições. Neste método, os parâmetros k e c de *Weibull* são determinados de acordo com as Equações 12 e 13 (STEVENS; SMULDERS, 1979).

$$k = \left[\frac{\sum_{i=1}^n v_i^k \ln(v_i)}{\sum_{i=1}^n v_i^k} - \frac{\sum_{i=1}^n \ln(v_i)}{n} \right]^{-1} \quad (12)$$

$$c = \left(\frac{1}{n} \sum_{i=1}^n v_i^k \right)^{\frac{1}{k}} \quad (13)$$

Onde n é o número de medições e v_i é a velocidade do vento.

A distribuição de *Weibull* (com o auxílio dos métodos numéricos descritos acima para o cálculo dos parâmetros k e c) foi ajustado ao horizonte anual.

3.4 Algoritmo PSO – Particle Swarm Optimization

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 ε do algoritmo *PSO* a ser minimizada é dada por:

$$\varepsilon(v_i) = \frac{1}{2} \sum_{i=0}^n (f_{real}(v_i) - f_{Weibull}(v_i))^2 \quad (14)$$

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* (Equação 14) 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).

$$f_{Weibull}(v) = \frac{k}{c} \cdot \left(\frac{v}{c}\right)^{k-1} \cdot e^{-\left(\frac{v}{c}\right)^k} \quad (15)$$

O *PSO* foi implementado com uma população aleatória de 50 partículas, sendo atribuída velocidade nula para cada partícula. 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 peso de inércia e os coeficientes de aceleração (parâmetro cognitivo e social) variam não-linearmente durante a busca, conforme proposto em Chang (2010), seguindo as expressões 16, 17 e 18. 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 α , β , γ foram atribuídos com 0,5, 1,5 e 1,0, respectivamente.

$$w(j) = \left(1 - \frac{j}{iter_{max}}\right)^{\alpha} (w_{max} - w_{min}) + w_{min} \quad (16)$$

$$a_1(j) = \left(1 - \frac{j}{iter_{max}}\right)^{\beta} (a_{1_{max}} - a_{1_{min}}) + a_{1_{min}} \quad (17)$$

$$a_2(j) = \left(1 - \frac{j}{iter_{max}}\right)^{\gamma} (a_{2_{min}} - a_{2_{max}}) + a_{2_{max}} \quad (18)$$

As novas posições e velocidades das partículas para a iteração j são determinadas a partir das equações 19 e 20.

$$v_i(j+1) = (w(j) \times v_i(j)) + a_1(j) \times r_1 \times (pbest_i(j) - x_i(j)) + a_2(j) \times r_2 \times (leader - x_i(j)) \quad (19)$$

$$x_i(j+1) = x_i(j) + v_i(j+1) \quad (20)$$

para $i = 1, 2, \dots, 50$ partículas

Onde w é o peso de inércia, a_1 e a_2 são os coeficientes de aceleração, representando os parâmetros cognitivo e social, respectivamente, r_1 e r_2 são números aleatórios no intervalo $[0,1]$, $iter_{max}$ 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. As melhores posições são dadas por $pbest$ (local) e $leader$ (global).

O algoritmo *PSO* foi implementado para os horizontes anuais, obtendo valores de k e c correspondentes a cada período que minimizam a função objetivo \mathcal{E} , aproximando a função de *Weibull* ao histograma de velocidades de vento.

3.4 Testes Estatísticos

Os métodos foram avaliados com o auxílio dos seguintes parâmetros: a) coeficiente de correlação (r); b) viés relativo (VR); e c) erro médio quadrático (RMSE), definidos nas Equações 21, 22 e 23.

$$r = \frac{\sum_i^N (X_i - X_{med}) \cdot (Y_i - Y_{med})}{\sqrt{\sum_i^N (X_i - X_{med})^2 \cdot (Y_i - Y_{med})^2}} \quad (21)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{N}} \quad (22)$$

$$VR = \frac{X_{med} - Y_{med}}{Y_{med}} \quad (23)$$

Onde X_{med} é o valor médio do conjunto de frequências reais, Y_i é o valor calculado da frequência de *Weibull*, Y_{med} é o valor médio do conjunto das frequências de *Weibull* e N é o número total de dados.

Estes testes avaliam a eficiência dos métodos, sendo possível compará-los e verificar o melhor ajuste para o período analisado. A qualidade do ajuste da curva de *Weibull* também pode ser aferida graficamente, ilustrando a que melhor descreve o comportamento da série de dados de vento, ou seja, a que apresenta maior proximidade entre as frequências reais e as de *Weibull*. Os resultados dos testes foram obtidos com auxílio do *Matlab*.

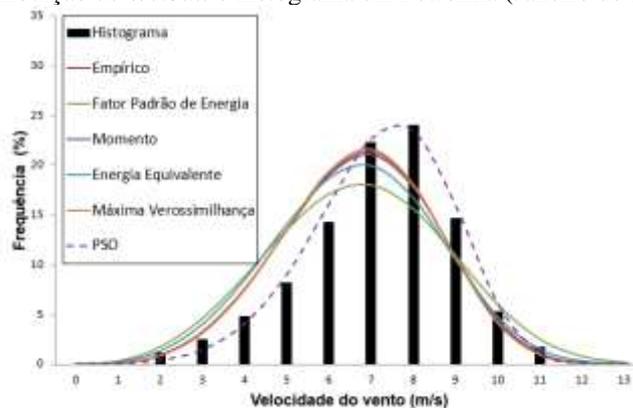
O melhor desempenho é dado para o método cujo valor de r é mais próximo de 1 e os de RMSE e VR mais próximos de zero, desse modo, valores altos de correlação não significam, por si só, ajustes com alta precisão. Por exemplo, um sistema com um viés muito alto, mesmo que possua correlação igual à unidade ($r = 1$), fornecerá ajustes de baixa precisão, embora seja possível remover este viés através de modelos estatísticos. Um sistema perfeito teria $RMSE = 0$, $r = 1$ e $VR = 0$.

4. RESULTADOS E DISCUSSÕES

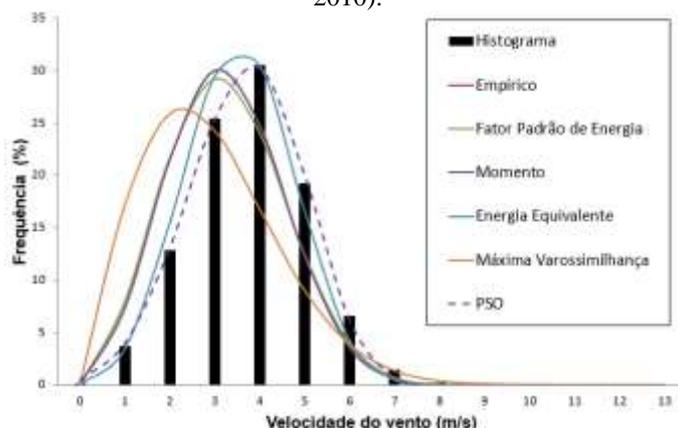
4.2 Cálculo dos Parâmetros de Weibull: Diferentes Métodos

As Figuras 3 e 4 apresentam os ajustes das curvas de *Weibull* encontradas para cada um dos seis métodos utilizados (Empírico, Fator Padrão de Energia, Momento, Energia Equivalente, Máxima Verossimilhança e *PSO*) e os respectivos histogramas anuais dos dados da velocidade do vento coletados para Petrolina e São Martinho da Serra, respectivamente.

Figura 3 - Curvas de distribuição de *Weibull* e histograma em Petrolina (Janeiro de 2012 a Dezembro de 2012).



Fonte: Elaborado pelos autores.

Figura 4 - Curvas de distribuição de *Weibull* e histograma em São Martinho da Serra (Janeiro de 2010 a Dezembro de 2010).

Fonte: Elaborado pelos autores.

Observados os ajustes obtidos pelos diferentes métodos utilizados na análise, os mesmos apresentam diferentes níveis de coincidência com o Histograma. Nas duas localidades, os métodos numéricos apresentaram ajustes não satisfatórios aos dados analisados. No entanto, o método heurístico, PSO, apresentou valores de k e c que propuseram uma melhor adaptação aos histogramas dos dados.

Comparando-se os cinco métodos numéricos utilizados e o PSO, pode-se observar que o PSO apresentou o melhor desempenho para a estimativa dos parâmetros de *Weibull*. Em São Martinho da Serra o método da Energia Equivalente também obteve um ajuste razoável. Este resultado confirma as expectativas, uma vez que o método PSO é o mais completo e apresenta mais eficácia na otimização por processos iterativos. As Tabelas 1 e 2 mostram a aplicação dos testes estatísticos (RMSE, R e VR).

Tabela 1 - Aplicações dos testes estatísticos para Petrolina – PE.

Métodos Numéricos	Parâmetros de <i>Weibull</i>		Testes Estatísticos		
	k	C	R	RMSE	VR
Energia Equivalente	3,8477	7,3377	0,6103	0,0680	0,2312
Máxima Verossimilhança	4,194	7,3672	0,6254	0,0686	0,2308
Momento	4,152	7,3871	0,6332	0,0676	0,2307
Empírico	4,1018	7,3909	0,6344	0,0672	0,2310
Fator Padrão de Energia	3,5046	7,4557	0,6405	0,0635	0,2305
PSO	5,7335	8,9009	0,9936	0,0084	0,0769

Fonte: Elaborado pelos autores.

Tabela 2 – Aplicações dos testes estatísticos para São Martinho da Serra – RS.

Métodos Numéricos	Parâmetros de <i>Weibull</i>		Testes Estatísticos		
	k	C	R	RMSE	VR
Energia Equivalente	3,3109	3,9639	0,6921	0,0839	0,0772
Máxima Verossimilhança	2,001	3,2586	0,4388	0,1152	0,0599
Momento	2,777	3,6622	0,6097	0,0993	0,0762
Empírico	2,7787	3,6601	0,3523	0,0994	0,0762
Fator Padrão de Energia	2,6858	3,6645	0,3523	0,0983	0,0758
PSO	4,114	5,1633	0,9916	0,0039	0,0770

Fonte: Elaborado pelos autores.

De acordo com os testes estatísticos, o método PSO é o que apresenta melhor desempenho (apresentando as maiores correlações e menores erros), uma vez que mostra o melhor ajuste nas Figuras 3 e 4. Em segundo, em São Martinho da Serra ficou o método de Energia Equivalente, que apresentou um desempenho superior aos outros métodos numéricos.

O método da Energia Equivalente foi desenvolvido para otimizar a aplicação da função de densidade de *Weibull* para os dados de vento coletados na região Nordeste do Brasil, no entanto, adaptado a regiões litorâneas (alta variabilidade nos dados), por esta razão o método não teve bom desempenho em nenhuma das localidades estudadas nesta pesquisa.

5. CONCLUSÃO

Com o crescente desenvolvimento e a grande necessidade dos centros urbanos por uma maior oferta de energia elétrica. Usinas hidroelétricas apesar de terem um potencial de geração grande de energia, contribuí e muito para a intensificação dos impactos ambientais. Dessa forma, tem-se buscado novas maneiras de geração e complementação elétrica por fontes menos poluentes. Os incentivos do governo brasileiro na implantação de fontes alternativas de energia permitiram que o cenário brasileiro venha caminhando para um futuro cada vez menos dependentes do uso de geração térmica de energia.

Com o objetivo de ter informações confiáveis para a viabilidade de fontes de energia alternativa, o presente estudo fez uma análise da eficácia de métodos numéricos e o de inteligência artificial para que os parâmetros de *Weibull* fossem calculados com o maior grau de precisão possível.

Comparando os métodos utilizados para a estimativa dos parâmetros k e c da distribuição de *Weibull*, o método PSO obteve os melhores resultados quando comparados aos métodos numéricos.

Levando-se em conta os cinco métodos numéricos e o PSO utilizados para a estimativa dos parâmetros da distribuição de *Weibull*, o Método PSO mostra os melhores resultados para as duas localidades, apresentando alta correlação, baixo erro e viés relativo próximo de 0.

Para Petrolina, localizada muito longe da costa, apenas o PSO obteve parâmetros satisfatórios. Em São Martinho da Serra, além do Método PSO, o método da energia equivalente obteve um resultado razoável, superior aos outros métodos numéricos estudados.

Agradecimentos

Ao CNPq pelo financiamento do Projeto “Previsão de potencial eólico visando operação integrada ótima de unidades geradoras de eletricidade: estudo de caso para o Nordeste do Brasil”.

2.5 Referências

- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL: Disponível em: < <http://www.aneel.gov.br> >. Acesso em: 10 de junho de 2016.
- AKDAG S.A., DINLER A. A new method to estimate Weibull parameters for wind energy applications. *Energy Conversion and Management* 50, 2009.
- ANTUNES, F. Algoritmo de sistema de formigas aplicado ao planejamento da operação de sistemas hidrotérmicos de potência. 2011. Dissertação. (Mestrado em Energia), Universidade Federal do ABC, Santo André - SP, 2011.
- 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.
- CARNEIRO, T. C.; MELO, S. P.; CARVALHO, P. C. M.; BRAGA, A. P. S. Particle Swarm Optimization method for estimation of Weibull parameters: A case study for the Brazilian Northeast region. *Renewable Energy*, 86, 751-759, 2016.
- CHANG, T. P. Wind energy assessment incorporating particle swarm optimization method. *Energy Conversion and Management* 52, 2011.
- HU, X.: Particle Swarm Optimization. Disponível em: < <http://www.swarmintelligence.org/> > (2006). Acesso em: 20 de setembro de 2017.
- MARRANGHELLO, M. e Consul, R. A. Uso da Energia Eólica no Estado do Rio Grande do Sul. *Revista do Centro de Tecnologia da Ulbra. Rio Grande do Sul: ULBRA*, vol. 5, nº1, 2004.
- MEDEIROS G.F., KRIPKA M. Algumas Aplicações de Métodos Heurísticos na Otimização de Estruturas. *Revista CIATEC - UPF*, vol.4 (1), p.p.19-32, 2012.
- OLIVEIRA, M.C.S., SILVA, T.L., ALOISE, D.J. Otimização por Nuvem de Partículas: Diferença entre Aplicações a Problemas Contínuos e Discretos, 2004.
- PEREIRA, E. B., GUARNIERE, R. A., MARTINS, F. R. O Aproveitamento da Energia Eólica, *Revista Brasileira de Ensino de Física*, v. 30, n. 1, 2007.
- PREFEITURA DE PETROLINA: Disponível em: < <http://www.petroлина.pe.gov.br/peolina2015/acidade.php> > Acesso em: 12 de março de 2016.
- PREFEITURA DE SÃO MARTINHO DA SERRA: Disponível em: < <http://www.saomartinhodaserra.rs.gov.br/?pg=historia> >. Acesso em: 12 de março de 2016.
- STEVENS M. J., SMULDERS P. T. The estimation of the parameters of the Weibull wind speed distribution for wind energy utilization purposes. *Wind Eng*; 3:132–45, 1979.
- TRUCCOLO, Elaine Cristina. Assessment of the wind behavior in the northern coast of Santa Catarina. *Revista Brasileira de meteorologia*. v. 26, n. 03, p. 451-460, 2011.

COLLECTIVE INTELLIGENCE FOR ESTIMATING WEIBULL PARAMETERS: CASE STUDY FOR THE SOUTH AND NORTHEAST REGIONS OF BRAZIL

Abstract. *Collective Intelligence is defined as any effort of distributed solution of problems of optimization and search that is inspired by the behavior of social insects and other societies (ants, birds, pedestrians, etc.). Collective systems*

seek to coordinate individual efforts to achieve common goals. The analysis of the wind speed behavior is of fundamental importance in the evaluation of the wind potential, in the estimation of the generated energy and the capacity factor of wind turbines. The present work presents a Particle Swarm Optimization (PSO) technique and five numerical methods for the estimation of Weibull parameters (Equivalent, Empirical, Standard Energy Factor, Maximum Likelihood and Moment) parameters and finally the use of statistical tests for the comparison between these six forms of estimation of the Weibull parameters. Wind speed and direction were collected from January 2010 to December 2010 for the city of São Martinho da Serra and data from January 2012 to December 2012 for the city of Petrolina. The Weibull distribution is used to approximate the wind speed histograms, using the previously mentioned methods to estimate the parameters of scale and shape. Of the methods that were used for the estimation of the parameters of Weibull the collective intelligence was the one that obtained the best result giving values that fit almost perfectly with the histograms of wind speed.

Key words: *Wind energy, Weibull distribution, Wind speed.*