

ALGORITMO QPSO APLICADO AO PROBLEMA DE DESPACHO ECONÔMICO DINÂMICO DE ENERGIA ELÉTRICA COM A INCLUSÃO DA ENERGIA EÓLICA

André Carlos dos Santos Cantanhede*. Vicente Leonardo Paucar.**
Raimundo Nonato Diniz Costa Filho***

*Universidade Federal do Maranhão- Campus São Luís
(e-mail: andr3cantanhede@gmail.com).

**Universidade Federal do Maranhão- Campus São Luís (e-mail:
lpaucar@ieee.org)

*** Universidade Federal do Maranhão- Campus Balsas
(e-mail: raimundo.diniz@ieee.org)

Abstract: The increasing penetration rates of wind power in electrical power systems bring challenges to the problem of dynamic economic dispatch (DED). Dynamic economic dispatch problem or DED is a complex optimization problem and is extension of static economic dispatch problem which is used to determine the generation scheduling of the generators units so as to meet the predicted load demand over a time horizon at minimum operating cost under ramp rate constraints and other constraints. In this context, this article proposes the application of the QPSO (Quantum Particle Swarm Optimization) algorithm to solve the electrical energy DED problem with the insertion of wind energy. The wind generation cost model is presented based on a probabilistic analytical model of wind farm power output considering wake effect. The presented methodology is validated in a test system of 10 thermal units and the solutions found by the QPSO were compared with the specialized literature.

Resumo: As crescentes taxas de penetração da energia eólica nos sistemas elétricos de potência trazem desafios para o problema do despacho econômico dinâmico. O problema de despacho econômico dinâmico ou DED é um problema de otimização complexo e é uma extensão do problema estático de despacho econômico que é usado para determinar o programa de geração das unidades geradoras, a fim de atender à demanda de carga prevista ao longo de um horizonte de tempo a um custo operacional mínimo sob restrições de taxa de rampa e outras restrições. Neste contexto, este artigo propõe a aplicação do algoritmo QPSO (*Quantum Particle Swarm Optimization*) para solucionar o DED de energia elétrica com a inserção de energia eólica. O modelo de custo de geração eólica é apresentado com base em um modelo analítico probabilístico de produção de energia eólica, considerando o efeito de esteira. A metodologia apresentada é validada em um sistema teste de 10 unidades térmicas e as soluções encontradas pelo QPSO foram comparadas com a literatura especializada.

Keywords: QPSO; Wind power; Dynamic Economic Dispatch; Electric Power System.

Palavras-chaves: QPSO; Energia Eólica; Despacho Econômico Dinâmico; Sistemas Elétricos de Potência.

1. INTRODUÇÃO

O problema de alocação das demandas dos consumidores entre as centrais geradoras térmicas de forma econômica, segura e confiável tem sido estudado desde 1920 ou até mesmo antes (Xia 2010), ao qual tem sido formulado como um problema de minimização ou maximização, de uma função objetivo, como de custo de geração como (Kheshti 2017), emissão de poluentes (Basu 2019) ou de lucros (Attaviriyanupap 2004), com limite de demanda e outras restrições em um determinado tempo. Porém, a maior parte dessas publicações foi realizada com Despacho Econômico Estático (DEE), que leva em conta apenas a demanda em um tempo simples. Em contrapartida, o problema do Despacho Econômico Dinâmico (DED) considera um número finito de intervalos de despacho acoplados com a previsão de carga para providenciar uma trajetória de geração ótima seguindo uma demanda variável de carga (Coelho e Mariani 2006). O problema de despacho econômico dinâmico é imprescindível para o controle em tempo real de sistemas de geração (Nanjundappan 2016),

graças a sua capacidade de ser capaz de adaptar a demandas futuras sem comprometer a vida útil dos geradores.

Recentemente, o problema de despacho econômico tem se tornado ainda mais desafiador, com o aumento de geração de energias renováveis. Em 2018, no Brasil, houve um aumento na geração eólica de 14,4%. Por outro lado, as gerações por gás natural, derivados de petróleo e carvão caíram 16,7%, 25,4% e 12,6%, respectivamente (Brasil 2019). Isso mostra a tendência de aumento no uso da energia eólica. No entanto, a energia eólica possui, comparada às tecnologias de geração convencional, uma característica inerente de incerteza (Shi et al. 2014), na qual pode causar problemas na confiabilidade e segurança na entrega da demanda energética.

A incerteza está diretamente ligada ao vento e ao gerador eólico. Segundo (Horn 2010), as turbulências naturais, geradas pela rugosidade do local, e as turbulências geradas pela própria fazenda eólica geram uma queda de rendimento. Além disso, (Neumeister e Silva 2014) afirmam que o rendimento dos

geradores eólicos não é o mesmo em todas as velocidades do vento, possuindo uma velocidade mínima para vencer as forças de atrito e uma limitação de velocidade máxima, em que a potência extraída se mantém constante. Estes efeitos de esteira de vento (*wake effect*) geram custos, quantificada de acordo com a dificuldade de alocação de outros recursos para atender a demanda.

O problema de DED pode ser formulado como um problema de otimização não linear, não convexo e não diferenciável, o que dificulta sua resolução através de métodos analíticos (Lima 2019). Segundo Xia (2010), as técnicas de otimização podem ser classificadas em analíticas, que possuem como base técnicas de matemática programadas, e as técnicas de inteligência artificial (IA), que utilizam uma população para chegar à solução do problema.

Nesse contexto, na literatura especializada, algumas técnicas de IA foram empregadas para resolver o problema DED com a presença de energia eólica. Em (Lee 2011) um algoritmo genético com características quânticas é apresentado para solucionar o DED, mas os custos das usinas eólicas não são considerados, simplificando assim o problema. Em (Farhate El-Hawary 2010), utilizam o algoritmo BFA (*Bacterial Foraging Algorithm*) adaptativo para resolver o despacho econômico com a presença de parques eólicos, mas a carga do sistema utilizado não varia com o tempo e os parques eólicos são modelados somente no balanço de carga e por meio de sua disponibilidade. Em (Liang et al. 2018) um despacho econômico estático com energia eólica é resolvido por um algoritmo baseado na metaheurística dos morcegos, mapas caóticos e no conceito de buraco negro, entretanto não foi considerado os efeitos dos pontos de válvula na função custo dos geradores térmicos.

Desta maneira, este artigo apresenta um problema DED incorporando o custo das usinas eólicas. O custo da energia eólica é baseado em um modelo analítico-probabilístico considerado o efeito de esteira. O referido problema foi solucionado através do algoritmo PSO (Kennedy e Eberhart 1995) com características quânticas, denominado de QPSO (*Quantum Particle Swarm Optimization*).

As seções deste artigo estão organizadas da seguinte forma. Na seção 2, é apresentado o problema de despacho econômico dinâmico junto com sua formulação. Na seção 3, é modelado o custo de geração das fazendas eólicas e adicionada ao problema. Na seção 4, é descrito o QPSO e sua implementação. Na seção 5, é apresentado o sistema teste e os resultados da simulação. E por fim, na seção 6, são apresentadas as conclusões deste artigo.

2. DESPACHO ECONÔMICO DINÂMICO

Nesta seção é apresentada a formulação matemática do problema DED.

2.1 Modelo do custo de geração das unidades térmicas

O custo do combustível de cada unidade térmica é caracterizado na forma de uma função quadrática mais o valor

absoluto de um termo senoidal correspondente ao efeito do ponto da válvula.

$$F_{it}(P_{it}) = a_i + b_i P_{it} + c_i P_{it}^2 + \left| d_i \sin \left(e_i (P_i^{min} - P_{it}) \right) \right| \quad (1)$$

Onde F_{it} é a função custo de uma unidade i ; P_{it} é a potência produzida pelo gerador i no tempo t ; a_i, b_i, c_i, d_i , e e_i são os coeficientes do custo dos geradores.

2.2 Restrições

a) Balanço de potência.

A potência total gerada deve ser igual ao total da demanda (P_{Dt}) mais as perdas na transmissão (P_{Lt}), dentro do intervalo de tempo T .

$$\sum_{i=1}^N P_{it} - P_{Dt} - P_{Lt} = 0, \quad t \in T \quad (2)$$

$$P_{Lt} = \sum_{i=1}^n \sum_{j=1}^n P_i^t B_{ij} P_j^t, \quad t \in T, \quad i \in N, \quad j \in N \quad (3)$$

Onde B_{ij} é a matriz de perdas na transmissão.

b) Limites de Potência de Operação

A potência gerada em cada gerador deve estar dentro dos limites máximos (P_i^{max}) e mínimos de geração (P_i^{min}).

$$P_i^{min} \leq P_{it} \leq P_i^{max}, \quad i \in N, \quad t \in T \quad (4)$$

c) Limites de Rampas dos Geradores

A variação de potência nos geradores térmicos deve estar dentro de um limite de segurança, para evitar tensão de risco na caldeira e equipamentos de combustão. Sendo o limite de elevação (UR_i) e de diminuição (DR_i) da potência gerada expressadas matematicamente como:

$$\begin{aligned} P_{it} - P_{i(t-1)} &\leq UR_i, & i \in N, & \quad t \in T \\ P_{i(t-1)} - P_{it} &\leq DR_i, & i \in N, & \quad t \in T \end{aligned} \quad (5)$$

2.3 Modelo do custo de geração das usinas eólicas

Para considerar as incertezas da geração de sistemas eólicas, a função de densidade de probabilidade é usada no sistema (Ebeed et al. 2020). Para isso, é necessário determinar vários parâmetros de modelos de distribuição para estimar a distribuição de probabilidade da velocidade do vento. Os modelos de distribuição incluem Weibull, Rayleigh, lognormal, gaussiana, gamma, Erlang e Kernel. O modelo de distribuição de Weibull de dois parâmetros é o mais popular, por utilizar os parâmetros históricos dos dados da velocidade do vento, tornando-o simples e preciso (Quin e Xion 2011).

Neste artigo, um modelo probabilístico analítico, apresentado por Shi et al. (2014) é empregado para descrever a geração elétrica de uma usina eólica. Ademais, este modelo será

aplicado para modelar o custo das usinas eólicas (Liu et al. 2015).

A relação entre a velocidade do vento e a potência mecânica extraída do vento da turbina eólica pode ser descrita em (6) (Shi et al. 2014).

$$P_w = \begin{cases} 0 & v < \frac{v_{ci}}{\xi_w} \text{ ou } v \geq v_{co} \\ \left(\frac{(v * \xi_w)^3 - v_{ci}^3}{v_r^3 - v_{ci}^3} \right) P_{wr} & \frac{v_{ci}}{\xi_w} \leq v < \frac{v_r}{\xi_w} \\ P_{wr} & \frac{v_r}{\xi_w} \leq v < v_{co} \end{cases} \quad (6)$$

Onde ξ_w é o coeficiente do efeito de esteira de toda a usina eólica, P_{wr} é a potência nominal do gerador eólico, v é velocidade do vento, v_{ci} é a velocidade *cut-in* do aerogerador, v_{co} é a velocidade *cut-out* do aerogerador e v_r é a velocidade nominal da turbina.

Combinando o modelo da turbina eólica e a função densidade do vento de forma analítica, demonstrada por Shi et al. (2014), pode-se chegar à fórmula da função densidade da fazenda eólica, dada por (7).

$$\varphi_p(P_w) = \begin{cases} 0 & P_w < 0, P_w > P_{wr} \\ \phi_p(0) \cdot \delta(P_w) & P_w = 0 \\ \omega \cdot \mu \cdot \gamma & 0 < P_w < P_{wr} \\ \phi_p(P_{wr}) \cdot \delta(P_w - P_{wr}) & P_w = P_{wr} \end{cases} \quad (7)$$

Onde k é o parâmetro de forma, c é o parâmetro de escala da distribuição de Weibull e ω , μ e γ são apresentados em (8).

$$\omega = \frac{1}{\xi_w c} \left(\frac{\sqrt[3]{\frac{P_w}{P_{wr}} (v_r^3 - v_{ci}^3) + v_{ci}^3}}{\xi_w c} \right)^{k-1}$$

$$\mu = \exp \left[- \left(\frac{\sqrt[3]{\frac{P_w}{P_{wr}} (v_r^3 - v_{ci}^3) + v_{ci}^3}}{\xi_w c} \right)^k \right] \quad (8)$$

$$\gamma = \frac{v_r^3 - v_{ci}^3}{3P_{wr}} \left(\frac{P_w}{P_{wr}} (v_r^3 - v_{ci}^3) + v_{ci}^3 \right)^{-\frac{2}{3}}$$

A energia eólica possui incertezas e volatilidade devido a difícil previsão das correntes de vento. Por isso, muitas vezes a usina eólica não gera o esperado. Para manter o suprimento com segurança um custo adicional será gerado devido a entrada de sistemas auxiliares. A probabilidade de possuir uma geração abaixo ou acima do esperado pode ser deduzida como:

$$\phi_p(P_w < P_{wfs}) = \phi_{p1} = \phi_p(0) + \int_0^{P_{wfs}} \varphi_p(P_w) dP_w$$

$$\phi_p(P_w \geq P_{wfs}) = \phi_{p2} = \phi_p(P_{wr}) + \int_{P_{wfs}}^{P_{wr}} \varphi_p(P_w) dP_w \quad (9)$$

Se a energia eólica disponível é menor que a planejada (P_{wfs}), o custo relacionado a esta subprodução pode ser quantificada considerando a probabilidade da falta de energia, a capacidade de restauração da potência e a dificuldade de operação de despacho (Liu et al. 2015). Para quantificar o custo da produção abaixo do esperado temos:

$$C_{w-}(P_{wfs}) = \sum_{t=1}^T \delta_{w-} \phi_{p1} \cdot (P_{wfs}(t) - E_{w1}) \Delta T \quad (10)$$

Onde δ_{w-} é o coeficiente que de dificuldade de operação; $E_{w1} = E_w(P_w(t) | P_w(t) < P_{wfs}(t))$ e $E_{w2} = E_w(P_w(t) | P_w(t) > P_{wfs}(t))$ refletem a diferença entre a potência gerada e a potência planejada.

$$E_{w1} = \frac{\int_0^{P_{wfs}(t)^-} P_w \varphi_p(P_w) dP_w}{\phi_{p1}}, \quad P_{wfs}(t) > 0 \quad (11)$$

Semelhantemente, o custo da potência extra gerada pela fazenda eólica é por (12).

$$C_{w+}(P_{wfs}) = \sum_{t=1}^T \delta_{w+} \phi_{p2} \cdot (E_{w2} - P_{wfs}(t)) \Delta T \quad (12)$$

$$E_{w2} = \frac{\int_{P_{wfs}(t)^+}^{P_{wr}} P_w \varphi_p(P_w) dP_w + \phi_{p2} P_{wr}}{\phi_{p2}}, \quad P_{wfs}(t) < P_{wr} \quad (13)$$

Então o custo total de geração das usinas eólicas é dado pela expressão (14).

$$C_w(P_{wfs}) = C_{w-}(P_{wfs}) + C_{w+}(P_{wfs}) \quad (14)$$

2.4 Problema de otimização

Definidos os custos das usinas térmicas em (1) e das usinas eólicas em (14) pode-se definir o problema do despacho econômico dinâmico de energia elétrica com a inclusão da energia eólica através da equação (15) levando em consideração as perdas na transmissão através (3) e as restrições expressas por (4), (5) e (16).

$$\min C = \left[\sum_{t=1}^T \sum_{i=1}^N F_{it}(P_{it}) \right] + C_w(P_{wfs}) \quad (15)$$

$$\sum_{i=1}^N P_{it} - P_{Dt} - P_{Lt} + P_w = 0, \quad t \in T \quad (16)$$

3. OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS COM COMPORTAMENTO QUÁNTICO

A metaheurística PSO (*Particle Swarm Optimization*) é uma técnica de otimização estocástica baseada em populações e desenvolvida por Kennedy e Eberhart (1995). A técnica foi inspirada no comportamento coletivo de bandos de pássaros e cardumes de peixes em busca de alimentos em uma determinada região (Serapião 2009).

A principal desvantagem do algoritmo PSO é a não garantia da convergência global. No clássico PSO (CPSO), uma partícula é descrita pelo seu vetor posição x_i e vetor velocidade v_i , que determinam a trajetória da partícula. O comportamento dinâmico da partícula é amplamente divergente no CPSO, pois os valores exatos de x_i e v_i não podem ser determinados simultaneamente. No mundo quântico, o termo trajetória não tem sentido, pois x_i e v_i não podem ser determinados simultaneamente (princípio da incerteza). O modelo quântico do PSO ou QPSO, os estados das partículas são descritos pela função onda $\Psi(x, t)$ em vez da posição e velocidade. Empregando o Método de Monte Carlo, as partículas se movem de acordo com (17) (Sun et al. 2011).

$$x_{ij}^{t+1} = \begin{cases} p_{ij}^t + \alpha \times |C_j^t - X_{ij}^t| \times \ln(1/u), & \text{se } r_1 > 0.5 \\ p_{ij}^t - \alpha \times |C_j^t - X_{ij}^t| \times \ln(1/u), & \text{se } r_1 \leq 0.5 \end{cases} \quad (17)$$

Onde u é um número uniformemente aleatório, t é a iteração corrente e C é a média dos $Pbest$ de todas as partículas dado por (18).

$$C^t = \left(\frac{1}{N_p} \sum_{i=1}^{N_p} Pbest_{i,1}^t, \dots, \frac{1}{N_p} \sum_{i=1}^{N_p} Pbest_{i,dim}^t \right) \quad (18)$$

O parâmetro α é conhecido como coeficiente de contração-expansão (CE), ao qual é muito importante no controle da velocidade da convergência do QPSO. Em geral, o valor de α diminui de maneira linear de α_1 até α_0 como apresenta a equação (19).

$$\alpha^t = \alpha_0 + \frac{(\alpha_1 - \alpha_0) \times (t_{max} - t)}{t_{max}} \quad (19)$$

O vetor p_{ij} é denominado de atrator local e neste trabalho duas maneiras de calcular suas coordenadas foram utilizadas. As equações (20) e (21) (Coelho e Alotto2008) apresentam as duas forma de calcular o vetor atrator local.

$$p_{ij} = \varphi Pbest_{ij} + (1 - \varphi) Gbest_j \quad (20)$$

$$p_{ij} = (c_1 Pbest_{ij} + c_2 Gbest_j) / (c_1 + c_2) \quad (21)$$

Onde φ , c_1 e c_2 são números uniformemente aleatórios.

O procedimento básico do QPSO é apresentado na Tabela1.

Tabela 1. Procedimento do QPSO

<p>Função objetivo $f(x)$, $x = (x_1, x_2, \dots, x_{dim})$ Inicializar a posição x_{ij} das N_p partículas. Calcular o <i>fitness</i> e extrair $Pbest$ e $Gbest$. Enquanto ($t \leq t_{max}$) Atualizar α. Para $i = 1$ até N_p Faça Para $j = 1$ até dim Faça $\varphi = rand(0,1)$ $u = rand(0,1)$ Calcular p_{ij}</p>
--

<p>Atualiza a posição da partícula x_{ij}. Se $x_{ij} > ub_j \rightarrow x_{ij} = ub_j$. Fim Se Se $x_{ij} < lb_j \rightarrow x_{ij} = lb_j$. Fim Se Fim Para Fim Para Calcular o <i>fitness</i> e extrair $Pbest$ e $Gbest$. Fim Enquanto Retornar $x^* = Gbest$ e $f^* = f(Gbest)$.</p>

4. RESULTADOS

Neste artigo, os testes foram realizados com a ajuda do software MatLab® e um computador com processador i5-7200 e 4 GB de memória RAM. O sistema teste utilizado possui 10 unidades térmicas e seus dados foram retirados de (Pattanaiket al 2018), além da matriz de coeficientes de perda do sistema (B_{ij}). Este sistema leva em consideração bancos de capacitores em paralelo às barras, assim o despacho desconsidera as capacidades de potência reativa das fontes e adicionam o seu custo diretamente na função objetivo. A carga varia a cada 1h durante 24h e a sua dinâmica é apresentada em Fig. 1. Os parâmetros de entrada do algoritmo QPSO utilizado nas simulações foram: $\alpha_1 = 1$; $\alpha_0 = 0,5$; $t_{max} = 100$ e $N_p = 100$. O algoritmo foi executado 100 vezes com o objetivo de obter a média e o melhor resultado. Duas estratégias foram empregadas no cálculo do atrator local, utilizando as equações (20) e (21) aplicando a equação (17). O parque eólico (ou usina eólica) utilizado possui 300 turbinas, cada uma com potência nominal de 2MW. As velocidades do vento nominal, de *cut in* e *cut outs* são iguais a, respectivamente, 10,28 m/s; 2m/s e 25 m/s. A curva de velocidade do vento empregada neste trabalho é baseada em medidas do vento de um ano na cidade de Parnaíba – PI retirado do Instituto Nacional de Meteorologia (2020), resultando na curva, de melhor ajuste, com fator de forma e de escala 3,19 e 1,93 respectivamente. Dois cenários foram simulados: (1) sistema teste sem usina eólica e (2) sistema teste com usina eólica.

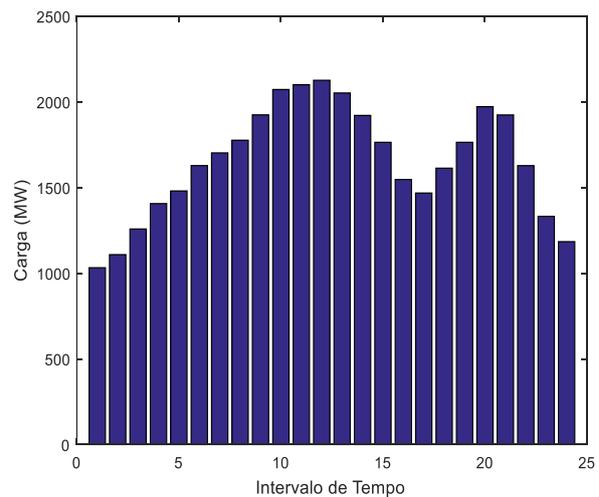


Fig. 1 Curva de Carga do Sistema teste

6. CONCLUSÕES

Este artigo demonstrou a integração de sistemas de geração térmica e eólica impactando o custo de geração de energia elétrica. Para avaliar o custo foi utilizado a solução de um problema de DED considerando os efeitos de ponto de válvula e perdas do sistema de transmissão, além de aspectos físicos das fazendas eólicas e naturais do vento. Para a resolução do problema de DED foram utilizados algoritmos QPSO com diferentes atratores, que garante convergência global para problemas complexos de despacho. A simulação demonstrou a diminuição do custo de produção ao associar, e priorizar o despacho, da energia eólica, além de demonstrar que a diminuição das incertezas inerentes a este problema gera maiores economias. Ademais, foram feitas comparações entre técnicas de otimização, demonstrando que o QPSO se mostra competitivo diante de outros algoritmos, apresentando resultado melhor minimização do problema estudado. Por fim, foi feito uma comparação de resultados entre duas maneiras de calcular as coordenadas do QPSO. Para trabalhos futuros será necessário trabalhos em que envolvem outros tipos de geração renováveis tanto quanto o estudo de sistemas que diminuem a diferença entre a potência prevista e a potência gerada em fazendas eólicas, além da aplicação do QPSO em sistemas mais robustos em comparação a outros algoritmos de otimização.

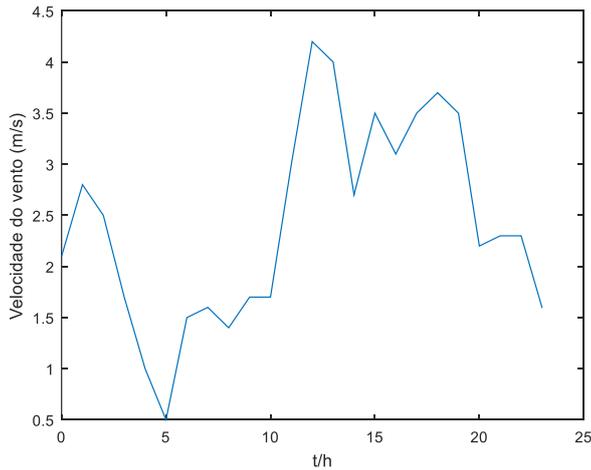


Fig. 2 Curva de previsão da velocidade do vento

O tempo médio de execução do algoritmo QPSO foi de 90 segundos e após a execução do mesmo foi obtido os resultados apresentados nas Tabelas 2 e 3. As Tabelas 2 e 3 apresentam os resultados dos custos utilizando as duas estratégias do cálculo do atrator local e as potências de saída das unidades de geração, respectivamente.

A Tabela 3 exibe as potências das unidades térmicas e da usina eólica equivalente ao melhor resultado obtido dentre as duas estratégias para o cálculo do atrator local. Observando a Tabela 2, pode-se concluir que a estratégia 2 (veja a equação (20)) apresentou o melhor resultado para o problema DED com e sem a inclusão da energia eólica. Também, o QPSO apresentou melhores resultados comparado com (Pattanaiket *al* 2018). A referência (Pattanaiket *al* 2018) utilizou o mesmo sistema teste (não foi utilizado a energia eólica nesta referência), a mesma curva de carga e um melhorado algoritmo genético com codificação real. O GA de (Pattanaiket *al* 2018) foi executado 100 vezes, 300 iterações e 100 o tamanho da população. A referida referência obteve o resultado de $2,5846 \times 10^6$ (\$) e o melhor resultado obtido pelo QPSO foi de $2,478 \times 10^6$ (\$). Isso torna o QPSO um algoritmo muito competitivo no campo das metaheurísticas.

Tabela 2. Custo total do DED

p_{ij}		$\sum \sum F_{it}(P_{it})$ (\$)	$C_w(P_{wfs})$	Total (\$)
(20)	Sem a usina eólica	2.481.115,41	-	2.481.115,41
	Com a usina eólica	2.467.442,20	1.904,00	2.469.346,20
(21)	Sem a usina eólica	2.478.157,68	-	2.478.157,68
	Com a usina eólica	2.465.064,43	1.904,00	2.466.968,43

Tabela 3. Potências Geradas das Usinas sem e com as usinas eólicas

(horas)	Caso 1: Usinas térmicas (MW)										Caso 2: Usinas térmicas e usinas eólicas (MW)										Eólica
	1	2	3	4	5	6	7	8	9	10	1	2	3	4	5	6	7	8	9	10	
1	150,0	135,0	73,0	183,5	171,7	121,1	130,0	52,2	21,4	16,7	150,2	135,0	79,1	121,3	223,5	132,2	130,0	49,4	20,0	10,3	4,1
2	150,0	136,3	199,4	120,9	171,9	120,8	52,5	120,0	49,7	10,0	150,0	135,0	184,1	120,3	173,8	126,1	130,0	47,0	52,4	10,8	1,6
3	150,0	135,0	184,2	223,9	223,9	122,6	130,0	85,3	20,8	10,0	150,0	135,0	262,2	182,5	181,9	129,9	93,0	120,0	20,9	10,5	0,0
4	150,0	135,0	297,5	217,9	222,9	104,3	130,0	120,0	53,2	10,4	150,0	135,1	272,4	172,6	228,4	141,0	129,3	120,0	80,0	11,9	0,0
5	150,0	135,0	324,5	250,5	177,6	122,6	130,0	120,0	65,9	42,9	150,0	135,0	239,0	278,1	240,4	160,0	126,0	120,0	27,7	42,5	0,0
6	150,0	156,9	334,0	265,0	236,0	160,0	130,0	120,0	80,0	43,7	168,2	135,0	323,3	265,3	243,0	159,2	129,3	120,0	80,0	51,9	0,0
7	167,8	228,8	319,2	300,0	235,9	141,2	124,9	120,0	69,6	48,2	150,0	214,7	336,9	300,0	243,0	160,0	130,0	120,0	54,2	45,5	0,0
8	226,7	221,9	340,0	296,2	225,7	160,0	124,9	120,0	76,7	41,5	207,5	317,4	334,2	222,4	242,7	158,0	125,7	113,7	72,6	41,2	0,0
9	285,9	311,6	321,5	300,0	243,0	160,0	126,2	120,0	73,3	53,0	222,4	371,7	340,0	300,0	242,5	159,6	129,4	119,8	54,9	54,1	0,0
10	334,5	396,2	339,9	298,9	242,8	159,5	130,0	119,8	79,8	55,0	300,4	426,9	340,0	300,0	243,0	160,0	129,9	120,0	80,0	55,0	0,0
11	368,0	396,8	340,0	300,0	243,0	160,0	130,0	120,0	79,9	55,0	361,2	396,8	340,0	300,0	243,0	160,0	130,0	120,0	80,0	55,0	6,0
12	379,9	433,4	340,0	300,0	243,0	160,0	130,0	120,0	80,0	55,0	321,1	465,9	340,0	300,0	243,0	160,0	129,6	120,0	80,0	55,0	24,2
13	303,0	424,7	340,0	299,9	243,0	160,0	129,9	119,9	80,0	55,0	242,6	462,9	340,0	300,0	243,0	160,0	130,0	120,0	80,0	55,0	20,3
14	269,9	307,0	340,0	300,0	241,1	156,1	129,2	120,0	80,0	51,4	247,8	314,7	340,0	299,9	242,8	160,0	129,8	120,0	80,0	55,0	3,2
15	173,1	288,2	319,6	300,0	243,0	160,0	130,0	120,0	56,0	44,6	235,6	219,1	324,4	295,4	243,0	160,0	130,0	110,1	48,1	54,9	12,1
16	150,5	135,3	319,3	300,0	239,6	157,9	83,4	120,0	77,2	13,4	150,0	135,0	317,8	276,3	222,4	147,3	130,0	119,7	52,2	38,5	7,1
17	150,0	135,0	302,0	266,2	220,4	125,6	130,0	120,0	25,5	44,2	150,0	135,0	296,4	270,7	238,2	130,6	130,0	120,0	24,8	10,0	12,1
18	150,0	135,0	325,2	299,4	235,3	160,0	130,0	120,0	76,7	43,5	191,3	135,0	304,6	299,2	221,2	148,9	130,0	105,8	80,0	43,7	15,1
19	220,4	218,8	329,6	292,4	239,9	160,0	130,0	120,0	75,2	48,3	150,0	301,6	330,7	300,0	242,5	158,7	128,9	120,0	75,2	13,7	12,1
20	303,5	315,7	340,0	298,7	243,0	160,0	130,0	120,0	80,0	54,8	230,2	393,4	338,2	299,1	243,0	158,8	130,0	120,0	79,5	54,6	0,0
21	242,8	333,9	332,8	300,0	241,7	160,0	128,5	120,0	78,6	55,0	227,2	378,7	338,3	300,0	243,0	160,0	129,5	119,2	80,0	17,9	0,3
22	150,0	151,3	313,4	300,0	243,0	160,0	127,5	120,0	56,1	54,4	150,0	135,0	333,9	300,0	223,3	159,0	130,0	116,6	80,0	47,0	0,3
23	150,1	135,0	275,5	180,9	222,6	160,0	129,6	47,6	51,7	10,0	150,0	135,0	269,6	175,4	220,8	134,8	130,0	86,2	52,0	10,0	0,0
24	150,7	135,0	183,8	190,8	222,6	160,0	57,1	47,0	51,2	10,0	150,0	135,0	181,1	122,6	222,2	130,4	129,6	47,6	80,0	10,0	0,0

REFERÊNCIAS

- Attaviriyapap, P., Kita, H., Tanaka, E. and Hasegawa, J. (2004). A fuzzy-optimization approach to dynamic economic dispatch considering uncertainties. In *IEEE Transactions on Power Systems*, 19(3), pp.1299-1307.
- Basu, M. (2019). Multi-area dynamic economic emission dispatch of hydro-wind-thermal power system. In *Renewable Energy Focus*, 28, pp.11-35.
- Brasil, 2019. *Anuário Estatístico de Energia Elétrica 2019: Ano base 2018*.
- Coelho, L. S. and Alotto, P. (2008). Global optimization of electromagnetic devices using na exponential quantum-behaved particle swarm optimizer. *IEEE Transactions on Magnetics*, 44, pp. 1074-1077.
- Coelho, L. S. e Mariani, V. C. (2006). Evolução diferencial híbrida com programação quadrática aplicada ao problema de despacho econômico de energia elétrica. *Revista Controle e Automação*, 17, pp. 409-423.
- Ebeed, M., Alhejji, A., Kamel, S., & Jurado, F. (2020). Solving the Optimal Reactive Power Dispatch Using Marine Predators Algorithm Considering the Uncertainties in Load and Wind-Solar Generation Systems. *Energies*, 13(17), 4316.
- Farhat, I. A., and El-Hawary, M. E. (2010). Dynamic adaptive bacterial foraging algorithm for optimum economic dispatch with valve-point effects and wind power. *IET generation, transmission&distribution*, 4(9), 989-999.
- Horn, D.A. (2010). *Análise numérica da esteira aerodinâmica formada por uma turbina eólica com dimensionamento ótimo de Betz*. Dissertação de Mestrado, Escola de Engenharia da Universidade Federal do Rio Grande do Sul, Porto Alegre.
- Instituto Nacional de Meteorologia, *Estação automática: parnaíba-a308*, Instituto Nacional de Meteorologia, viewed 16 May 2020, <<http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesAutomaticas>>
- Kennedy, J., and Eberhart, R. C. (1995). Particle swarm optimization. In *Proceedings of IEEE International Conference on Neural Networks*, 1942–1948.
- Kheshti, M., Kang, X., Bie, Z., Jiao, Z. and Wang, X. (2017). An effective lightning flash algorithm solution to large scale non-convex economic dispatch with valve-point and multiple fuel options on generation units. In *Energy*, 129, 1-15.
- Lee, J. C., Lin, W. M., Liao, G. C., & Tsao, T. P. (2011). Quantum genetic algorithm for dynamic economic dispatch with valve-point effects and including wind power system. *International Journal of Electrical Power & Energy Systems*, 33(2), 189-197.
- Lee, K. Y., and Park, J. B. (2006). Application of particle swarm optimization to economic dispatch problem: advantages and disadvantages. In *2006 IEEE PES Power Systems Conference and Exposition*. IEEE. 188-192.
- Liang, H., Yungang, L., Li, F., and Man, Y. (2018). A hybrid bat algorithm for economic dispatch with random wind power. In *IEEE Transactions on Power Systems*, 33 (5), 5052-5061.
- Lima, J.P.D. (2019). *Um método de busca tabu direcionada a pontos singulares e o problema de despacho econômico com pontos de válvula*. Dissertação de Mestrado, Universidade Estadual Paulista. Faculdade de Engenharia, Bauru.
- Liu, Y. J., Shi, L. B., Wang, R., and Yao, L. Z. (2015). Study on the dynamic economic dispatch for a wind-hydro hybrid power system. In *International Conference on Renewable Power Generation*. RPG 2015. IET. 1-6
- Nanjundappan, D. (2016). Hybrid weighted probabilistic neural network and biogeography based optimization for dynamic economic dispatch of integrated multiple-fuel and wind power plants. In *International Journal of Electrical Power & Energy Systems*, 77, 385-394.
- Pattanaik, J. K., Basu, M., and Dash, D. P. (2018). Improved real coded genetic algorithm for dynamic economic dispatch. In *Journal of Electrical Systems and Information Technology*, 5(3), 349-362.
- Qin, Z., Li, W., & Xiong, X. (2011). Estimating wind speed probability distribution using kernel density method. *Electric Power Systems Research*, 81(12), 2139-2146.
- Serapião, A. B. S. (2009). Fundamentos de otimização por inteligência de enxames: uma visão geral. In *Revista Controle & Automação*, 20, 271-304.
- Shi, L. B., Weng, Z. X., Yao, L. Z., and Ni, Y. X. (2014). An analytical solution for wind farm power output. In *IEEE Transactions on Power Systems*, 29(6), 3122-3123.
- Sun, J., Feng, B., and Xu, W. (2004). Particle swarm optimization with particles having quantum behavior. In *Proceedings of Congress on Evolutionary Computation*, pp. 326–331.
- Xia, X. and Elaiw A. M. (2010). Optimal dynamic economic dispatch of generation: A review. In *Electric power systems research*. 80.8. 975-986.