



**XXIV SNPTEE
SEMINÁRIO NACIONAL DE PRODUÇÃO E
TRANSMISSÃO DE ENERGIA ELÉTRICA**

CB/GCR/15

22 a 25 de outubro de 2017
Curitiba - PR

GRUPO -GCR

GRUPO DE ESTUDO DE COMERCIALIZAÇÃO, ECONOMIA E REGULAÇÃO DE ENERGIA ELÉTRICA - GCR

**TOMADA DE DECISÃO EM PROJETOS EÓLICOS:
ALGORITMOS METAHEURÍSTICOS COMO FERRAMENTA
PARA ALOCAÇÃO ÓTIMA DA QUANTIDADE DE ENERGIA VENDIDA**

Eduardo Sodré (*)
Eletrobras Chesf
POLI - UPE

Antonio C. da Costa Perrelli
Eletrobras Chesf
POLI - UPE

Alcides Codeceira Neto
Eletrobras Chesf
POLI - UPE

RESUMO

Este trabalho propõe a aplicação de algoritmos de otimização estocástica para a escolha econômica ótima da quantidade da energia vendida e do preço de venda em um empreendimento eólico fictício participando de um leilão de energia reserva. Esta otimização estocástica maximiza a TIR do empreendimento através da métrica de risco $VaR_{95\%}$, utilizando uma técnica metaheurística para a solução desse problema. As regras de contabilização da energia entregue ao CER (Contrato de Energia Reserva) com suas respectivas penalidades foram consideradas no algoritmo. Esta escolha da quantidade vendida e do preço “*bidado*”, impactará diretamente a receita operacional bruta do empreendimento e a viabilidade econômico-financeira da decisão.

PALAVRAS-CHAVE

Taxa Interna de Retorno, Otimização Estocástica, Técnica Metaheurística, Energia Eólica, VaR (Value at Risk)

1.0 - INTRODUÇÃO

A correta análise e precificação dos riscos é de extrema importância na avaliação de novos investimentos em geração no Setor Elétrico Brasileiro. Neste sentido, este trabalho propõe realizar um estudo de viabilidade técnico-econômica que leve em consideração as incertezas nas variáveis chaves do fluxo de caixa de um empreendimento eólico que venda sua energia em um LER (Leilão de Energia Reserva). Neste trabalho será ilustrado como calcular o prêmio de risco do empreendimento (sobrepço), verificando o impacto das incertezas sobre o retorno do investimento.

O termo “risco” pode ser definido como a probabilidade do resultado efetivo ser maior ou menor do que o pretendido, sendo uma mistura de perigo e oportunidade. Embora teoricamente a TMA já deva conter o risco percebido pelo detentor do capital no negócio específico, a análise de risco sob a perspectiva da firma pode servir de instrumento estratégico e evitar que decisões incompletas, que não remuneram o detentor de capital pela TMA requerida, sejam realizadas e impactem os negócios da própria firma.

Os estudos executados na CHESF visando à possibilidade de concorrer com projetos de energia eólica e solar nos próximos leilões de energia a serem promovidos pelo Governo Federal, exigem a necessidade de se conduzir corretamente as análises de risco. Nesse contexto, é crucial para a viabilidade do negócio, compreender os recursos eólico e solar numa escala de longo prazo. O conhecimento da quantidade, do tempo e da variabilidade desse recurso, tem influência direta sobre os cálculos da energia elétrica produzida e, portanto, sobre o fluxo de receita do negócio (1).

Entre as incertezas associadas a um empreendimento de energia eólica, temos como exemplo: geração anual, grau de alavancagem, prazo de construção, investimento, meio ambiente, índices macroeconômicos, entre outros. Apesar

(*) Rua Delmiro Gouveia, n° 333 – sala C234 - Bloco C – CEP 50761-901 Recife, PE, – Brasil
Tel: (+55 81) 3229-3248 – Email: easodre@chesf.gov.br

da quantificação exata do risco total assumido por uma empresa em determinado empreendimento ser bastante laboriosa, pode-se dizer que é imprescindível.

As principais variáveis de interesse para a modelagem estocástica são: a geração eólica anual e a distribuição de probabilidade do atraso de obra. Após a modelagem destas variáveis são sorteados valores baseados nas suas distribuições de probabilidades. Este conjunto de valores amostrados constitui um cenário aleatório, para o qual será realizada uma análise financeira, obtendo-se um conjunto de indicadores financeiros condicionados a este cenário. A partir da análise desses cenários é possível calcular o histograma de indicadores financeiros, tais como, a Taxa Interna de Retorno (TIR), Valor Presente Líquido (VPL), etc.

A simulação de Monte Carlo realizada para este trabalho utilizou-se da Linguagem de Programação R, com a modelagem da geração eólica anual como uma variável estocástica (2). Não foi modelado neste trabalho o atraso de obra como uma variável estocástica. Com a simulação de Monte Carlo pode-se quantificar a métrica de risco denominada Value-at-Risk (VaR) para várias ofertas de quantidade e preço nos LER (Leilão de Energia Reserva).

Através da Simulação de Monte Carlo e de uma Técnica Metaheurística de Otimização, conseguiu-se determinar qual o melhor tipo de contratação para maximização da métrica $VaR_{95\%}$. A maximização da $VaR_{95\%}$ tem como objetivo principal determinar o verdadeiro impacto da geração de energia eólica anual na economia e na rentabilidade do negócio.

Um empreendimento de energia eólica depende da velocidade do vento para gerar receita. Sendo esta velocidade uma variável aleatória, a probabilidade de excedência de 50% é quantificada e informada pelo certificador como P50 e a probabilidade de excedência de 90% como P90. O fator de capacidade a P50 é utilizado como parâmetro oficial de geração e o P90 como parâmetro oficial de energia contratada.

Para cada fator de capacidade informado na certificação há um determinado grau de incerteza associado que não é utilizado sob a ótica determinística. Se o Parque A tem fator de capacidade P50 de 55%, por exemplo, e possui uma incerteza certificada de 15% e o Parque B tem fator de capacidade P50 de 50% com incerteza de 7%, considerando que as demais características necessárias para simulação são idênticas entre os Parques, a maior TIR advinda da simulação do Parque A pode não ser a melhor escolha. Pois embora, a energia do Parque A seja maior do que a do Parque B, o Parque A terá maior risco associado à geração do que o Parque B.

As técnicas meta-heurísticas já são conhecidas a bastante tempo entre a comunidade que trabalha com a solução de problemas reais de otimização, utilizando softwares, tais como, Crystal Ball, @RISK e ModelRisk (3). Mas só recentemente ela tem sido utilizada em problemas de otimização e análise de risco para comercialização de energia elétrica no Brasil (4, 5).

Com a utilização das técnicas meta-heurísticas não há necessidade de contorcionismos esdrúxulos para transformar a função objetivo e as restrições do problema em funções lineares e garantir a convexidade/concavidade. Outra grande vantagem das técnicas meta-heurísticas é a facilidade de implementação computacional. Sendo assim, não há necessidade também da utilização de programas comerciais para solução dos problemas de otimização linear, tal como, o FICO Xpress Optimization Suite. Neste trabalho o problema de otimização foi resolvido programando-se o código na linguagem de Programação R, o que comprova a facilidade da abordagem.

2.0 – OTIMIZAÇÃO METAHEURÍSTICA

Algoritmos Genéticos formam um subconjunto das técnicas metaheurísticas, e são baseados nos processos de organismos biológicos. Eles usam operações encontradas na genética natural no sentido de “pesquisar a solução através de espaços de busca. Através da adaptação deste processo natural para resolver problemas científicos, os Algoritmos Genéticos são capazes de desenvolver soluções para problemas matemáticos.

Essa técnica permite que uma população composta de muitos indivíduos possa “evoluir” através do uso de regras de seleção especificadas, para um estado que maximiza ou minimiza a função objetivo. Este método foi desenvolvido por John Holland em 1975, e tornou-se popular por um de seus estudantes, David Goldberg (6). Atualmente as técnicas de Algoritmos Genéticos têm sido empregadas largamente para otimização de sistemas equações que representam problemas práticos.

Algumas das vantagens do uso de Algoritmos Genéticos estão descritas a seguir:

- Otimizam sistemas matemáticos com o uso de parâmetros discretos ou contínuos;
- Não requerem o uso de derivadas, como nas técnicas convencionais;
- São adequadas para a computação paralela;
- São facilmente implementáveis.

A interpretação dos resultados dá-se através da análise dos valores atribuídos à função objetivo à medida em que o modelo computacional vai sendo processado. Os indicadores mais significativos na solução do problema constituem

a função objetivo do conjunto de parâmetros, os quais são os melhores (ou piores) indicadores em cada geração de indivíduos e a média da função objetivo de toda a população considerada. Nos Algoritmos Genéticos uma geração é definida como o período de tempo entre diferentes aplicações dos operadores genéticos. Já uma população é definida como os vários conjuntos de diferentes parâmetros considerados na aplicação do algoritmo.

Tendo em vista que os Algoritmos Genéticos são baseados em processos randômicos, não há uma demonstração analítica da “qualidade” da solução encontrada. Eles consideram muitos pontos em um espaço de procura, simultaneamente, e portanto, possuem uma chance reduzida de convergência para um ótimo local. Nas técnicas de procura convencionais um ponto singular é considerado com base em alguma regra de decisão. Estes métodos podem ser perigosos em um espaço de procura com muitos máximos ou mínimos, tendo em vista que eles podem convergir para um ótimo local. Contudo, Algoritmos Genéticos geram populações inteiras de pontos, testam cada ponto independentemente e, então, combinam qualidades dos pontos existentes de forma a produzir uma nova população “melhorada” composta de novos pontos. Este método conduz a uma procura global maior no domínio considerado.

Há dois tipos de Algoritmos Genéticos: o Algoritmo Genético binário e o Algoritmo Genético de ponto flutuante, também conhecido como Algoritmo Genético Contínuo ou Algoritmo Genético Real. Ambos algoritmos possuem o mesmo caminho para recombinação genética e seleção natural. Os Algoritmos Genéticos binários representam parâmetros por meio de um vetor binário codificado de zeros (0) e uns (1), e trabalham com esses vetores binários para resolver o problema de otimização. Já os Algoritmos Genéticos contínuos trabalham com números reais para resolver o problema de otimização. Diversas comparações entre os Algoritmos Genéticos binários e os Algoritmos Genéticos contínuos têm mostrado melhor performance para os últimos, de acordo com Michalewicz (7). Contudo, a obtenção da performance do modelo usando-se estes dois tipos de Algoritmos Genéticos depende muito do problema e dos detalhes do algoritmo a ser usado.

Os procedimentos básicos que descrevem um Algoritmo Genético estão apresentados a seguir:

1. Definição dos parâmetros e da função objetivo;
2. Criação da população original;
3. Avaliação da função objetivo para a população inteira;
4. Seleção dos indivíduos para reprodução;
5. Reprodução;
6. Mutação;
7. Avaliação da função objetivo dos novos indivíduos;
8. Elitismo
9. Se a convergência for alcançada, parar; senão retornar para o passo 3.

2.1 Definição dos Parâmetros da Função Objetivo

Um indivíduo é definido como um vetor de parâmetros a ser otimizado, os quais inicializam o processo. Se o indivíduo tem N_{par} parâmetros dados por $p_1, p_2, p_3, \dots, p_{N_{par}}$, então os indivíduos são escritos como um vetor com $1 \times N_{par}$ elementos. Os parâmetros $p_1, p_2, p_3, \dots, p_{N_{par}}$ são conhecidos como cromossomos de um dado indivíduo. Cada indivíduo possui uma “aptidão”, a qual é determinado pela avaliação da função objetivo $F = f(p_1, p_2, p_3, \dots, p_{N_{par}})$.

2.2 População Inicial

Uma matriz representa a população inicial de N_{ipop} indivíduos, com cada linha da matriz representando um indivíduo em particular, o qual possui N_{par} cromossomos. Esta matriz da população inicial com $N_{ipop} \times N_{par}$ cromossomos é formada aleatoriamente. Cada cromossomo em um dado indivíduo é calculado de acordo com a seguinte equação:

$$\text{Cromossomo}(i, j) = l_{inf} + (l_{sup} - l_{inf}) * \text{random}(0, 1)$$

onde: $1 \leq i \leq N_{ipop}$; $1 \leq j \leq N_{par}$; $\text{random}(0, 1)$ é uma função randômica que gera números randômicos entre 0 e 1; l_{inf} é o limite inferior do intervalo de validação do cromossomo; l_{sup} é o limite superior do intervalo de validação do cromossomo.

Uma maior população inicial de indivíduos permite que o algoritmo avalie melhor a função objetivo. O tamanho da população inicial e o número de gerações que o algoritmo precisa para convergir são dados importantes na condução da técnica de Algoritmos Genéticos.

2.3 Seleção

O objetivo do operador seleção consiste em escolher os indivíduos da referida população que criará novos indivíduos para a próxima geração, e quantos novos indivíduos serão criados. Neste estudo foi empregado o método de seleção

da “roleta”. Com a criação da população inicial de indivíduos e a avaliação de cada um desses indivíduos através da função objetivo, os N_{ipop} indivíduos são ordenados em ordem crescente de suas “aptidões”.

Para as populações de indivíduos seguintes, as quais serão geradas ao longo do processo computacional, o número de indivíduos N_{pop} dessas gerações seguintes é geralmente menor que o número de indivíduos definido na população inicial. Alguns dos melhores indivíduos da população inicial (N_{bons}) são então selecionados para reprodução, a depender da taxa de reprodução. Com a geração dos novos indivíduos (N_{novos}), através do operador reprodução, uma população temporária composta dos indivíduos anteriormente criados e dos novos indivíduos é considerada, quando então os piores indivíduos dessa população temporária são removidos. A partir de então o tamanho da população de indivíduos em cada geração fica constante (N_{pop}). Dos N_{pop} indivíduos de cada geração, N_{bons} indivíduos são selecionados para reprodução. Cada par de indivíduos produz dois novos indivíduos, os quais possuem traços de cada um dos pais, os quais também podem fazer parte da próxima geração. Este processo de seleção natural é aplicado a cada iteração do algoritmo para permitir que a população de indivíduos evolua de forma a gerar aqueles que possuem a melhor função objetivo.

O método de seleção da “roleta” assinala probabilidades aos indivíduos no processo de reprodução, de acordo com a função objetivo. Um indivíduo com o melhor valor da função objetivo terá maior probabilidade para reproduzir. Para o cálculo desta probabilidade, um número aleatório determina o indivíduo a ser selecionado. Este método permite a seleção do indivíduo n baseado na definição da probabilidade relativa. A probabilidade relativa é um valor que representa a probabilidade de um indivíduo ser selecionado para reprodução, a qual é calculada pela equação:

$$R_{fit\ n} = Fit_n / \sum Fit_i, \text{ para } 1 \leq i \leq n$$

onde: $R_{fit\ n}$ é a probabilidade do indivíduo n , calculada em função da soma de todos as “aptidões” da população inteira; Fit_n é a “aptidão” do indivíduo n .

Procedendo o ranqueamento de todos os indivíduos de uma dada população, com suas respectivas probabilidades relativas, calcula-se a probabilidade acumulada para cada indivíduo através da equação:

$$C_{fit\ n} = \sum R_{fit\ i}, \text{ para } 1 \leq i \leq n-1$$

onde: $C_{fit\ n}$ é a probabilidade acumulada do indivíduo n ; e $R_{fit\ i}$ é a probabilidade relativa do indivíduo i .

A probabilidade acumulada de cada indivíduo é usada para a seleção do indivíduo a ser um “pai” no processo de reprodução. O procedimento inclui o sorteio de um número randômico entre zero e um, a partir do qual, começando do topo da lista de indivíduos, busca-se o primeiro indivíduo com uma probabilidade acumulada maior que o valor do número randômico gerado. Este procedimento ocorre um certo número de vezes, a depender da probabilidade de reprodução, que é um dado de entrada para o algoritmo.

2.4 Reprodução

O operador reprodução permite a criação de novos indivíduos a partir de pares de indivíduos selecionados no processo de seleção. A reprodução é o primeiro passo do Algoritmo Genético no sentido de explorar a função objetivo. Quando do uso de Algoritmos Genéticos de ponto flutuante, o qual é o método computacional empregado neste artigo técnico, muitos procedimentos diferentes têm sido utilizados. Neste artigo técnico foi empregado o procedimento de cruzamento linear.

Nos Algoritmos Genéticos de ponto flutuante os valores dos cromossomos de dois indivíduos “pai” são combinados para formar novos valores de cromossomos, que por sua vez formarão os novos indivíduos. Neste artigo estão sendo usadas as equações a seguir para combinar os valores dos cromossomos dos indivíduos “pais” para então obter dois novos cromossomos para os dois novos indivíduos.

$$C_{novo1} = \beta * c_{p1n} + (1 - \beta) * c_{p2n}$$

$$C_{novo2} = (1 - \beta) * c_{p1n} + \beta * c_{p2n}$$

onde:

β é um número randômico entre zero e um;

C_{novo} é o n -ésimo cromossomo de um novo indivíduo;

c_{p1n} é o n -ésimo cromossomo de um dos indivíduos “pai”;

c_{p2n} é o n -ésimo cromossomo do outro indivíduo “pai”.

Observa-se, através das equações acima, que o cromossomo correspondente no segundo novo indivíduo formado é o complemento do respectivo cromossomo no primeiro indivíduo formado com o uso do operador reprodução. Este método levou a bons resultados em várias otimizações de sistemas propostos por Michalewicz (7). Este processo de combinação linear é realizado para todos os cromossomos do indivíduo, podendo o valor de β ser o mesmo na avaliação de cada cromossomo de um indivíduo “pai”, ou ser diferente para cada cromossomo a ser analisado. Este

método combina a informação dos dois indivíduos “pais” e escolhe valores de cromossomos entre aqueles definidos dentro dos limites estabelecidos para cada cromossomo dos indivíduos “pais”. No caso dos novos cromossomos originados na formação dos novos indivíduos extrapolarem os limites estabelecidos para cada cromossomo, estes serão descartados, mantendo-se, assim, os valores dos cromossomos dos indivíduos “pais” para este ponto do processo em análise.

2.5 Mutação

O objetivo do operador mutação é o de buscar novos pontos no espaço de procura a ser avaliado. Quando o cromossomo de um indivíduo é escolhido para mutação, uma escolha randômica é realizada para alguns dos cromossomos dos indivíduos da população de indivíduos em análise. O número de mutações a ocorrer depende da probabilidade de mutação, valor este definido como um parâmetro de entrada para o algoritmo. O operador mutação é introduzido no Algoritmo Genético para forçar o processo a explorar outras áreas da superfície da função objetivo. É relevante salientar que o número de vezes em que este operador atua dependerá da taxa de probabilidade de mutação especificada, a qual deve ser um valor muito pequeno, aqui considerado inferior a 8%.

A técnica de Mutação empregada neste trabalho foi a Mutação Gaussiana (8), cuja principal característica é a procura de cromossomos de forma mais ampla no espaço de soluções baseado numa distribuição normal com valor médio igual ao valor do cromossomo que sofrerá a mutação e desvio padrão igual a 5%.

2.6 Elitismo

O elitismo é uma forma de preservar os melhores indivíduos e garantir que estes sejam propagados nas gerações posteriores, garantindo assim que seus cromossomos possam ser compartilhados em futuros indivíduos.

3.0 – REGRAS DO LEILÃO RESERVA

As Regras do Leilão Reserva consideradas neste trabalho são conforme a Nota Técnica EPE-DEE-NT-081/2014 – r0 (9).

A produção eólica anual deverá ser apurada ao final de cada ano contratual, e deve ser contabilizada no centro de gravidade do submercado onde o empreendimento for conectado. A produção contabilizada no centro de gravidade é igual à produção medida no ponto de conexão da usina com a Rede deduzida das perdas correspondentes na rede básica, segundo as regras e procedimentos de comercialização da CCEE.

O saldo dos desvios da produção anual em relação à obrigação contratual deverá ser acumulado ao longo de cada quadriênio. O saldo anual acumulado deverá ser limitado a uma margem inferior de 10% abaixo da obrigação contratual de produção e a uma margem superior de 30% acima da obrigação contratual.

O saldo anual positivo acima da margem superior deverá ser reembolsado ao gerador pelo valor de 70% do preço do contrato em 12 parcelas mensais uniformes no ano contratual seguinte. O saldo anual negativo, que ultrapassar o limite da margem inferior, deverá ser valorado pelo preço do contrato acrescido de 15% e ressarcidos à Conta de Energia de Reserva – CONER em 12 parcelas mensais uniformes no ano contratual seguinte

O saldo quadrienal a maior de desvios acumulados da produção, apurado ao final de cada quadriênio, poderá ser total ou parcialmente repassado para o quadriênio seguinte ou cedido para outro empreendimento, desde que este tenha sido contratado no mesmo leilão de energia reserva.

Após a opção de repasse e/ou de cessão de energia elétrica de reserva, o saldo residual positivo do quadriênio deverá ser ressarcido ao empreendedor, valorado ao preço contratado, e o valor dividido em 24 parcelas mensais nos dois primeiros anos contratuais do quadriênio em curso ao preço vigente do contrato nestes anos.

Após eventual recebimento de energia elétrica de reserva por meio de cessão, o saldo residual negativo do quadriênio deverá ser ressarcido à CONER em 12 parcelas mensais no primeiro ano contratual do quadriênio em curso, valorado ao preço vigente do contrato acrescido de 6%

Neste trabalho está sendo considerado que o saldo quadrienal a maior será integralmente ressarcido ao empreendedor.

4.0 – RESULTADOS

Esta simulação é realizada pela inserção da distribuição de probabilidade da geração de energia num modelo de cálculo financeiro. Com isto, o MWh de geração eólica não é um valor determinado e constante, mas sim uma distribuição de probabilidades de acordo com a Certificação da Produção Anual de Energia.

As certificações determinam a distribuição de probabilidades da energia gerada através de uma distribuição normal. Todos os parâmetros necessários para a construção da curva normal (média e desvio padrão) são informados na certificação. Os valores de energia certificados são referentes à produção anual de energia bruta de longo prazo. Para o cálculo da produção anual de energia bruta são incorporadas:

- as perdas por interferência aerodinâmica entre rotores de turbinas;
- e 1.3% de perdas por degradação das pás e perdas de desempenho

A Garantia Física de Energia é calculada a partir da produção que é excedida com uma probabilidade de ocorrência de 90% (P90) para um período de variabilidade futura de 20 anos, sendo ainda descontadas:

- a taxa de indisponibilidade forçada (TEIF = 1.5%);
- a taxa de indisponibilidade programada (TEIP = 1.7%);
- e as perdas elétricas até o ponto de conexão (2.5%).

O cálculo da TIR de um empreendimento eólico passa então a ser um cálculo da Distribuição de Probabilidades da TIR do empreendimento. Pode-se ver um cálculo deste tipo apresentado na Figura 1. Também está sendo apresentado na Figura 1. o VaR_{95%} desta Distribuição de Probabilidade de TIR (VaR_{95%} = 12.95%).

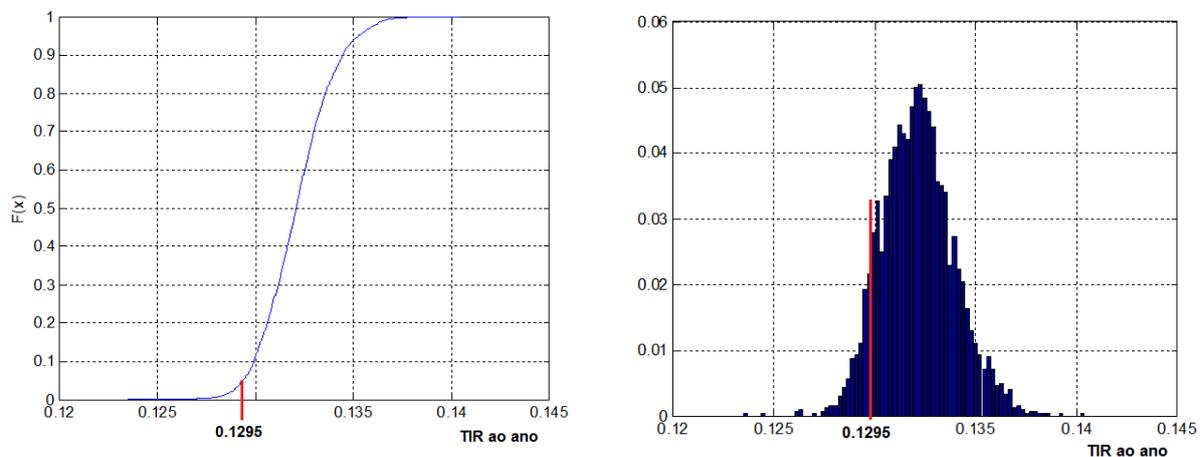


FIGURA 1 – Distribuição de Probabilidade da TIR

Os dados do Parque eólico considerado neste trabalho estão apresentados na Tabela 1.

Tabela 1 – Dados do Parque Eólico

Potência Instalada	32.0 MW
Energia à P50	15.0 Mwmed
Desvio Padrão	11.0%
Garantia Física	12.46 Mwmed

Os parâmetros para otimização estocástica através do Algoritmo Genético implementado estão apresentados na Tabela 2.

Tabela 2 – Parâmetros para Otimização Estocástica

Número de Gerações	80
Tamanho da População	24
Taxa de Mutação	8%
Desvio Padrão da Mutação	5%
Número de Simulações de Monte Carlo	3,000.00
Limite Superior do Preço de Venda da Energia	228.00 R\$/MWh
Limite Inferior do Preço de Venda da Energia	22.80 R\$/MWh
Limite Superior da Energia Vendida	12.46 Mwmed
Limite Inferior da Energia Vendida	1.25 Mwmed

Vale ressaltar que o limite superior para energia vendida foi considerado neste algoritmo como sendo igual à Garantia Física, por uma questão de simplificação didática. Este não é o procedimento correto, pois a contabilização da energia produzida deve ser efetuada no centro de gravidade do submercado onde o empreendimento for conectado.

O indivíduo da otimização AG considerado foi um indivíduo de dois valores, ou seja um vetor de 1 linha e 2 colunas, onde o primeiro elemento do vetor era a quantidade de energia vendida e o segundo elemento do vetor era o preço “*bidado*” no leilão.

A solução ótima do problema de Otimização Estocástica encontrada pelo Algoritmo Genético está apresentada na Tabela 3.

Quantidade de Energia Vendida	12.43 Mwmed
Preço de Venda da Energia	227.59 R\$/MWh

Esta solução ótima apresenta uma $VaR_{95\%} = 15.76\%$, conforme Figura 2.

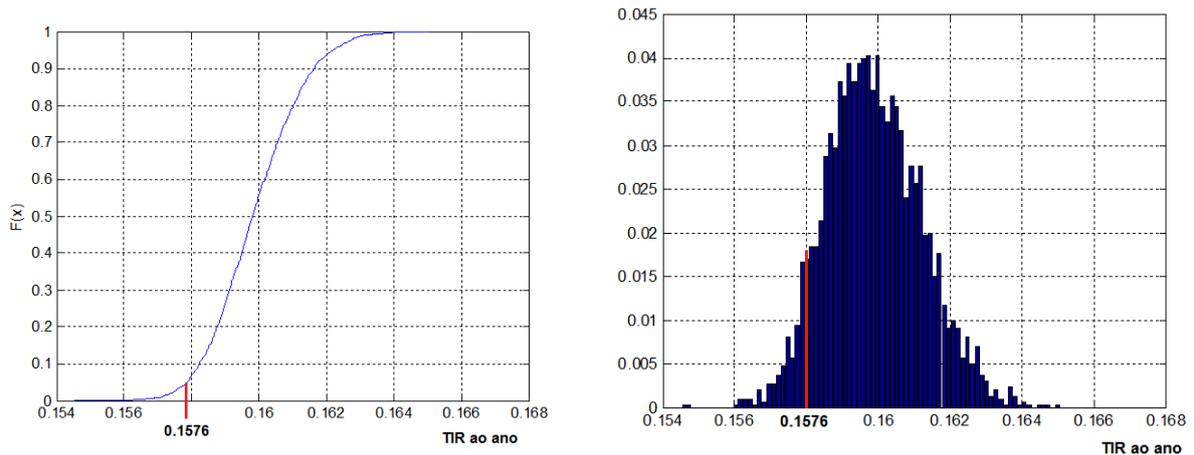


FIGURA 2 – Distribuição de Probabilidade da TIR para a Solução Ótima

Na Figura 3. pode ser observado o desempenho do Algoritmo Genético (AG), com critério de parada em 80 gerações. Conforme o número de gerações evolui, o AG obtém sucessivamente um melhor indivíduo (solução) para cada uma das populações que estão evoluindo. O melhor indivíduo de cada população é aquele que apresenta o máximo $VaR_{95\%}$. Ao final das iterações das 80 gerações o melhor indivíduo da população final é aquele que é a solução ótima do problema.

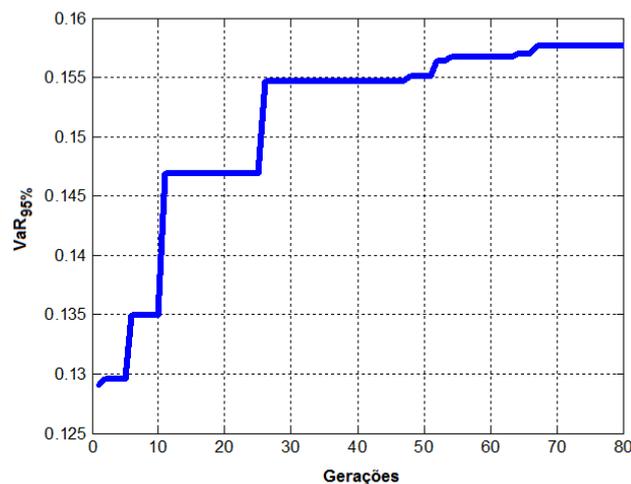


FIGURA 3 – Desempenho do Algoritmo Genético

5.0 - CONCLUSÕES

A grande vantagem da ferramenta desenvolvida neste trabalho é poder implementar uma gestão de Análise de Risco de uma forma objetiva, prática e direta na análise da viabilidade técnica-econômica dos projetos eólicos. Esta

ferramenta pode ser estendida facilmente para os projetos fotovoltaicos e termosolares e para quaisquer regras de penalidades de qualquer leilão específico.

Outra extensão valiosa para o algoritmo desenvolvido é ter em mãos uma ferramenta computacional para calcular um preço de “bid” de leilão dada uma análise de seus concorrentes no certame. Outra vantagem da ferramenta é comparar através do cálculo do $VaR_{95\%}$ qual seria o melhor leilão para vender a energia do seu parque eólico, por exemplo, comparar as vantagens entre um leilão reserva ou um leilão de energia nova. Também deve ser lembrado a análise da melhor quantidade ofertada nos leilões de desconstrução de energia reserva. Vale ressaltar que esta ferramenta computacional pode servir também para resolver o problema de alocação das turbinas de um complexo eólico em vários parques diferentes, entre os vários contratos ganhos em diversos leilões pelo empreendedor. Este é um problema que normalmente os empreendedores enfrentam ao solicitarem suas revisões de outorga de autorização pelo sistema ACATI da ANEEL.

Também é importante destacar a facilidade de implementação e utilização das técnicas metaheurísticas para solução de problemas de otimização estocástica. Acreditamos que a abordagem dos problemas de otimização estocástica, para comercialização de energia no ACL ou em leilões do ACR, através de técnicas meta-heurísticas irá consolidar-se como padrão para as empresas de energia elétrica no Brasil.

6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) - Bruno Fanzeres, Alexandre Street, e Luiz Augusto Barroso, “**Contracting Strategies for Renewable Generators: A Hybrid Stochastic and Robust Optimization Approach**”, IEEE Transactions on Power Systems, Vol. 30, No. 4, July 2015.
- (2) - R Core Team (2016). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- (3) - Satyajith Amaran, Nikolaos V. Sahinidis, Bikram Sharda, and Scott J. Bury, “**Simulation Optimization: a Review of Algorithms and Applications**”, Annals of Operations Research, May 2016, Volume 240, Issue 1, pp 351–380, Springer.
- (4) - Juan G. Lazo Lazo, Delberis Araujo Lima e Karla Figueiredo, “**Análise de Um Modelo Inteligente de Contratação de Energia Elétrica no Curto Prazo para Distribuidoras**”, Revista Controle & Automação / Vol.23 no.6 / Novembro e Dezembro, 2012.
- (5) - M. Fampa and W. Pimentel, “**An Application of Genetic Algorithm to a Bidding Problem in Electricity Markets**”, International Transactions in Operational Research, 22 (2015), 97–111, Wiley.
- (6) David E. Goldberg, “**Genetic Algorithms in Search, Optimization and Machine Learning**”, 1989, Reading, Massachusetts, Addison Wesley.
- (7) Zbigniew Michalewicz, “**Genetic Algorithms + Data Structures = Evolution Programs**” - Third, Revised and Extended Edition”, 1996, Springer-Verlag.
- (8) - Silas G. Tenório e Eduardo Sodré, “**Otimização de Contratação de Energia Eólica em Mercados "Day-ahead" Utilizando Algoritmos Genéticos**”, XVII ERIAC – Encuentro Regional Iberoamericano del CIGRE, 21 al 25 de mayo del 2017, Ciudad del Este – Paraguay.
- (9) – EPE, “**Leilão de Contratação de Energia de Reserva - Metodologia de Contabilização da Produção de Energia de Empreendimentos Eólicos**”, No DEE-NT-081/2014-r0, 29 de maio de 2014.

7.0 - DADOS BIOGRÁFICOS

Eduardo Sodré, possui Doutorado em Engenharia Elétrica pela Universidade Federal de Campina Grande em 2006 (Conceito CAPES 6) e Mestrado em Engenharia Elétrica pela Universidade Federal de Santa Catarina em 1996 (Conceito CAPES 6). Tem experiência na área de Transmissão e Distribuição de Energia Elétrica. Trabalhou na Distribuidora de Energia Elétrica do Estado de Pernambuco (CELPE), nas áreas de meio-ambiente, Gestão de P&D e Planejamento da Expansão. Trabalha atualmente na CHESF (Companhia Hidroelétrica do São Francisco), desde 2002, na área de energias renováveis, tendo também realizado vários trabalhos nas áreas de planejamento da expansão da transmissão e expansão da geração. Atualmente leciona no Curso de Graduação de Eng. Elétrica e no Mestrado de Tecnologia da Energia da POLI-UPE.

Antonio Camelo da Costa Perrelli, nascido em Recife, Pernambuco, em 1982. Economista da Chesf desde 2009. Formado em Ciências Econômicas pela UFPE, em 2005, com MBA em Finanças Corporativas pelo IBMEC, em 2013.

Profissional Certificado em Gestão de Riscos Corporativos pela Global Institute for Risk Management Standards, em 2015. Possui extensão em Análise Probabilística de Risco pela Palisade, em 2015.

Alcides Codeceira Neto, possui graduação em Engenharia Elétrica pela Universidade Federal de Pernambuco (1983), mestrado em Thermal Power (Gas Turbine Technology) pela Cranfield University (1994) e doutorado em Thermal Power - (Advanced Gas Turbine Thermal Power Cycles) pela Cranfield University (1999). Atualmente é professor adjunto da Escola Politécnica de Pernambuco - Universidade de Pernambuco e leciona também no Mestrado Profissional de Tecnologia da Energia dessa mesma Universidade. Trabalha atualmente na Companhia Hidro Elétrica do São Francisco. Tem experiência na área de Engenharia Mecânica, com ênfase em Aproveitamento da Energia, atuando principalmente nos seguintes temas: Performance de Ciclos Térmicos com Turbinas a Gás, Exergia, Termodinâmica Aplicada, Transferência de Calor - CO2 Sequestration, Geração de Energia Elétrica, Gaseificação de Biomassa, Aplicação de Inteligência Artificial na Análise de Ciclos Térmicos para Geração de Energia, Células a Combustível e Tecnologia de Hidrogênio.