



Ingeniare. Revista Chilena de Ingeniería

ISSN: 0718-3291

facing@uta.cl

Universidad de Tarapacá
Chile

S. Pinto, Mauro S.; Martins, Claudio R.; Cerqueira, Sidney N.; Trovão, Sergio A.; Saavedra, Osvaldo R.

Tomada de decisões em leilões de energia elétrica de longo prazo

Ingeniare. Revista Chilena de Ingeniería, vol. 22, núm. 4, octubre, 2014, pp. 539-546

Universidad de Tarapacá
Arica, Chile

Disponível em: <http://www.redalyc.org/articulo.oa?id=77231865009>

- ▶ Como citar este artigo
- ▶ Número completo
- ▶ Mais artigos
- ▶ Home da revista no Redalyc

redalyc.org

Sistema de Informação Científica

Rede de Revistas Científicas da América Latina, Caribe, Espanha e Portugal
Projeto acadêmico sem fins lucrativos desenvolvido no âmbito da iniciativa Acesso Aberto

Tomada de decisões em leilões de energia elétrica de longo prazo

Decision making in long-term electricity auctions

Mauro S. S. Pinto¹ Claudio R. Martins¹ Sidney N. Cerqueira¹ Sergio A. Trovão²
Osvaldo R. Saavedra¹

Recibido 2 de octubre de 2013, aceptado 12 de mayo de 2014

Received: October 2, 2013 Accepted: May 12, 2014

RESUMO

Neste artigo, apresenta-se uma ferramenta inteligente para a tomada de decisão nos leilões de energia elétrica. A abordagem proposta otimiza simultaneamente a maximização da receita esperada e a minimização do risco de contrato, a métrica utilizada para o cálculo do risco foi o valor em risco, VaR. Para validar o algoritmo proposto, dois casos são apresentados. O primeiro é feito com agentes hidrotérmicos de médio porte e o segundo é parte do portfólio de uma empresa do nordeste brasileiro. Os resultados mostram a percepção de risco da perspectiva do gerador e a eficiência do algoritmo proposto como suporte à tomada de decisão.

Palavras-chaves: Estratégia de oferta, leilões de energia elétrica, enxame de partículas, auxílio à decisão, sistemas de potência.

ABSTRACT

An intelligent tool for decision aid in electric energy auctions is proposed. The proposed approach optimizes simultaneously the expected revenue maximization and the contract risks minimization. As risk metric, value at risk (Var) is considered. To validate the proposed algorithm, two cases are presented. The first one considers midsize hydrothermal agents and the second one takes into account part of the portfolio of a Brazilian company. The results show the risk perception from the point of view of GENCO's in competitive environment and demonstrate the effectiveness of the proposed algorithm in the decision support process.

Keywords: Bidding strategy, electricity auctions, PSO, decision support, power systems.

LISTA DE SÍMBOLOS E ABREVIACÕES

Genco: Companhia Geradora de eletricidade participante do mercado.

Disco: Companhia de Distribuição de Energia.

MRE: Mecanismo de Relocação de Energia.

PSO: *Particle Swarm Optimization*, Otimização por Exame de Partículas.

VaR: *Value at Risk*, Valor em Risco.

ACL: Ambiente de Contratação Livre.

ACR: Ambiente de Contração Regulada.

π_{ACR} : Preço da energia no Ambiente Regulado.

π_{ACL} : Preço da energia no Ambiente Livre.

π_{spot} : Preço da energia no Mercado de Curto Prazo ou Mercado Spot.

y : Fator de penalidade entre o risco e a receita esperada.

$E(R)$: Receita Esperada.

$Penalty_i$: Fator de Penalidade.

¹ Instituto de Energia Elétrica. Universidade Federal do Maranhão São Luís, MA, Brasil. E-mail: maurosergiospinto@gmail.com; claudio.bragamartins@gmail.com; cerqueirasidney@gmail.com; o.saavedra@ieee.org

² CEMAR S. A. São Luís, Maranhão, Brasil. E-mail: sergio.trovao@cemar-ma.com.br

INTRODUÇÃO

O advento da competição trouxe uma série de novos problemas associados à negociação da energia elétrica, assim como mudanças nas perspectivas e nas interações entre os agentes do sistema.

No Brasil, assim como em outros países sul-americanos como Chile, Peru e Colômbia, os modelos de mercados são baseados em leilões de mercados futuros ou de opções [1]. Em função de suas especificidades, os leilões são utilizados para a negociação de médio e longo prazo.

Do ponto de vista dos geradores, a negociação para a venda de energia elétrica dentro de ambientes competitivos e incertos, como são os leilões de eletricidade, envolve uma série de aspectos a serem considerados com o objetivo de maximizar os lucros e de gerenciar os riscos associados à contratação da energia. Assim, é essencial o desenvolvimento de ferramentas que permitam realizar simulações e análises de cenários, de forma a auxiliar na tomada de decisão.

Para definir a estratégia de oferta mais rentável, é importante para o agente modelar as incertezas relacionadas ao preço *spot* e ao despacho futuro da geração, em horizontes muita vezes distantes, resultando em problemas de otimização de grande porte e com alto grau de não-linearidade e incertezas.

Desta forma, a utilização de ferramentas computacionais tornou-se imprescindível no processo de tomada de decisões e no desenvolvimento de modelos que auxiliem na elaboração de estratégias de ação, constituindo um importante requisito para as empresas do setor elétrico.

Do ponto de vista dos geradores, as ferramentas de suporte e auxílio para agentes em ambiente competitivos têm sido amplamente pesquisadas. Em [2-6] são utilizadas Estratégias Evolutivas para ofertar lances no mercado do dia seguinte (*day-ahead market*). Em [7] é sugerida uma abordagem de sistemas multi-agentes baseada em Algoritmos Genéticos e Lógica Nebulosa para o ambiente de mercados competitivos de energia. Em [8] é proposta uma ferramenta para definição do portfólio ótimo de contratação e gerenciamento dos riscos através da formulação de uma função de utilidade baseada

em média-variância, utilizando a meta-heurística PSO (*Particle Swarm Optimization*). Em [9] são apresentados análise de risco através de VaR. Em [10-12] é construído um modelo de jogos competitivos utilizando conceitos de portfólio para leilões de contratos de longo prazo em mercados de energia e preços de energia. Em [13] é definida uma estratégia de formação de preços para geradores em leilões de energia no Brasil, onde o perfil de risco do agente é incorporado ao problema por meio de uma função utilidade linear por partes.

Este trabalho propõe uma ferramenta de auxílio e suporte à decisão na formação de estratégias de oferta do ponto de vista de agentes geradores participantes de leilões de quantidade de energia utilizando técnicas inteligentes baseada em PSO para resolver o problema de otimização formulado para encontrar uma curva de oferta de forma a maximizar os ganhos do agente, respeitando as restrições de mercado, assim como observar a influência da aversão ao risco na estratégia de oferta.

O método proposto tem os seguintes atributos:

- Garante um nível de segurança à oferta, procurando mitigar os riscos de sub ou sobrecontratação da GENCO;
- Possibilita análises e realização de testes de cenários e estratégias de negócios;
- Maximiza os ganhos da GENCO;
- Realiza análises das informações possíveis dentro do ambiente do mercado e auxilia na tomada de decisões dos agentes (formação da curva de oferta da GENCO).
- Formular um problema de otimização e resolvê-lo através de uma nova meta-heurística que é uma extensão do PSO clássico;

O método proposto é validado com estudo de casos reais do sistema brasileiro.

MERCADO ELÉTRICO BRASILEIRO

O sistema brasileiro é de natureza hidrotérmica, composto basicamente por fontes hidráulicas de grande porte, complementadas por plantas térmicas. Além disso, em função de sua grande extensão territorial, o sistema é constituído também por grandes redes de transmissão, construídas com o objetivo de transportar a energia proveniente destas fontes aos centros de carga.

Assim, há a necessidade de um despacho centralizado, realizado por uma instituição independente, o qual busca manter o equilíbrio entre o benefício do uso presente da água e seu armazenamento para uso futuro, de forma a aproveitar ao máximo os recursos hídricos disponíveis.

Estas características tornam o sistema vulnerável às condições sazonais entre os períodos úmidos e os períodos secos, sendo o regime das chuvas a principal variável de incerteza.

A comercialização de energia elétrica no Brasil é realizada através de contratos entre os agentes vendedores e compradores, celebrados por meios de leilões de energia ou pela livre comercialização entre os agentes. A premissa principal destas transações é que toda a demanda do sistema deva ser contratada, garantindo maior segurança do sistema e incentivando sua expansão. Ademais, cada contrato firmado deve ser assegurado por um “lastro” físico de energia, o que garante que o sistema sempre atenda a sua demanda mesmo em momentos de baixa afluência, além de desacoplar a operação financeira da operação física.

O mercado *spot* brasileiro é definido pela negociação do resultado da diferença entre a energia consumida e a energia contratada, ou seja, o agente que gerar/consumir menos ou mais que o contratado deve comprar/vender no mercado *spot*. Cabe à Câmara de Comercialização de Energia Elétrica (CCEE) a liquidação mensal de todos os agentes do sistema.

No Brasil, são instituídos dois ambientes para celebração de contratos de compra e venda de energia: o Ambiente de Contratação Regulada (ACR), do qual participam agentes de geração (GENCO's) e de distribuição de energia (DISCO's); e o Ambiente de Contratação Livre (ACL), do qual participam agentes de geração, comercializadores, importadores e exportadores de energia e consumidores livres [6].

ESTRATÉGIA PROPOSTA

O lucro dos agentes geradores leva em consideração os contratos firmados (P) nos dois ambientes de contratação, juntamente com a liquidação do mercado *spot*, menos os custos associados com a operação (C_v) e com as tarifas de transmissão. O lucro (\tilde{L}) do agente gerador, para um período fixo de tempo, pode ser descrito através de (1).

$$\tilde{L} = \pi_{ACR} P_{ACR} + \sum_{i=1}^{NC} \left(\pi_{ACL,i} P_{ACL,i} \right) + \pi_{spot} \left(\tilde{G} - P_{ACL,i} \right) - C_v \left(\tilde{G} \right) \quad (1)$$

A presença de variáveis estocásticas na formulação do lucro dos agentes é reflexo da natureza futura dos contratos, pois a potência efetivamente gerada (\tilde{G}) no leilão será entregue após um determinado prazo. Assim, o preço *spot* e a geração física são desconhecidos, por motivos de simplificação, os custos relacionados com a operação e com a transmissão não são levados em consideração. Desta forma, a equação pode ser reescrita na forma da receita (\tilde{R}) obtida através do leilão de energia e o mercado *spot*:

$$\tilde{R} = \pi_{ACR} P_{ACR} + \pi_{spot} \left(\tilde{G} - P_{ACR} \right) \quad (2)$$

A exposição ao mercado *spot* de subcontratação ou sobre contratação são os principais riscos. A parte que se refere ao ambiente livre da equação (2) não foi considerada por que no Brasil os leilões são feitos apenas para o ambiente regulado.

Os riscos de contratação estão relacionados principalmente com a volatilidade do preço *spot* (π_{spot}). No caso brasileiro, por ser um sistema predominantemente hidráulico, a volatilidade está diretamente relacionada às afluências nas hidroelétricas. Além disso, no caso de leilões de energia, o agente também está exposto ao risco de não-contratação, derivado do ambiente de competição.

Várias metodologias de análise de riscos podem ser encontradas na literatura. Uma das mais conhecidas e utilizadas é o *valor em risco* (VaR), onde o risco é calculado considerando a máxima perda para um dado nível de confiança.

Para mitigação dos riscos associados à negociação, assim como maximização dos seus ganhos, cada agente necessita conhecer ou estimar o preço futuro da energia, assim como sua programação horária para a época da venda (quantidade de energia efetivamente despachada). Além disso, torna-se necessária a simulação das regras utilizadas na liquidação do mercado de energia que possam vir a influenciar o balanço financeiro do agente. Desta forma, o modelo de estratégia proposto neste artigo é dividido em três etapas: *Previsão do Mercado Futuro*, *Ajuste do MRE* e *Formação de Curva de Oferta*.

A geração de energia por uma hidrelétrica depende da disponibilidade de água que chega à usina e, caso possua reservatório, do montante de água nela armazenado. Como estes valores dependem do regime das chuvas, a capacidade de produção de energia por parte destas usinas pode tornar-se bastante volátil. No entanto, em sistemas distribuídos por grandes extensões territoriais, como é o caso do Brasil, as diversas usinas hidrelétricas encontram-se em zonas climáticas distintas e, portanto, estão submetidas a regimes de chuvas também diferenciados. Desta forma, o risco agregado de todas as usinas atuando conjuntamente é menor do que quando consideradas isoladamente.

O Mecanismo de Realocação da Energia (MRE) é um mecanismo financeiro para mitigação dos riscos hidrológicos, funcionando como um “*hedging*” compulsório entre as usinas hidrelétricas que compõem o sistema, repartindo os riscos da venda em longo prazo entre seus participantes.

Em termos gerais, o MRE realoca entre cada participante uma parcela da energia assegurada total proporcional à participação do respectivo gerador diante da soma das potências de todos os outros geradores despachados. Este montante pode ser individualmente calculado através de (3).

$$F_{MRE}^i = \frac{EA_i}{\sum_{k=1}^N EA_k} \quad (3)$$

A Energia Assegurada (EA) define a quantidade de energia que pode ser gerada por determinado parque gerador, de acordo com critérios técnicos e econômicos [15].

Formação da curva de oferta

os cenários de geração de energia foram concebidos através de simulações de Monte Carlos e a partir destes cenários gerados nas duas primeiras etapas, o modelo propõe a formulação de uma curva de oferta para cada agente. A curva de oferta para uma GENCO indica a quantidade de energia P que deve ser ofertada no leilão de forma a maximizar a receita \tilde{R} da GENCO para um dado preço de oferta π . A receita da GENCO para cada preço de oferta é definido por .

Assumindo que cada agente tem seu risco modelado conforme a função de utilidade $U(\tilde{L})$, a maximização da receita pode ser formulada conforme equação (4).

$$\text{Maximizar } U(\tilde{R}) = (1-y)E(\tilde{R}) - y \cdot \text{Risk}(\tilde{R}) \quad (4)$$

Este modelo considera uma função de utilidade semelhante à utilizada em [8] e [10], onde é realizada simultaneamente a maximização da receita e a minimização do risco, sendo P a solução do problema para um dado preço de oferta π .

Os leilões no Brasil são feito em duas fases, na Fase 1, os agentes disputam entre si o direito de participar da Fase 2. Na fase 1, os agentes concorrem pelo empreendimento, na Fase 2 a disputa dos agentes é feita para vender energia do respectivo empreendimento, mas sobre leilões pode ser encontrada em [6]. De fato, levando em conta a Fase 1 para um leilão de quantidade, os preços da energia são decrementados a cada rodada, em que cada agente oferta apenas um lance de quantidade de energia.

Sendo assim, é possível definir uma curva de oferta para cada agente a partir de um vetor de preços $\pi = [\pi_1, \pi_2, \dots, \pi_n]$, variando entre os preços mínimo e máximo de contratação, para os quais há uma oferta de energia associada, definida pelo vetor $P = [P_1, P_2, \dots, P_n]$, em que cada valor é encontrado a partir do processo de maximização da utilidade esperada dada por (4).

Entretanto, este modelo exige a realização de um processo de otimização para cada cenário simulado. Alternativamente, para realização de apenas um único processo e levando em consideração a característica homogênea da receita esperada, o problema pode ser formulado como a maximização do somatório das utilidades para um determinado vetor de preços de oferta, como segue:

$$\text{Maximizar } \sum_{i=1}^n \tilde{U}(\tilde{R}_i) \quad (5)$$

s.a.:

$$P_{j-1} \leq P_j, \text{ sendo } j = \{2 \dots n\} \quad (6)$$

Esta formulação, além de permitir que seja realizado apenas um processo de otimização, tem explicitada a restrição imposta pelo ambiente de negociação, no qual o lance ofertado deve ser menor ou igual ao da rodada anterior. Para o cálculo dos riscos é considerada como métrica o VaR. Para o cálculo do VaR são consideradas as distribuições de probabilidade geradas a partir dos cenários de mercados criados na etapa de previsão do mercado futuro, onde a função de perda de investimento é modelada como a diferença entre o lucro e o seu valor esperado $E(\tilde{R}) - \tilde{R}$, ou seja, o VaR é calculado sobre a perda de oportunidade da GENCO em relação à sua receita média, mais sobre a metodologia de análise de risco VaR pode ser encontrada em [4]. As restrições físicas de geração não precisam ser consideradas na equação (5), pois tais limitações já foram consideradas em processos anteriores.

ALGORITMO EVOLUTIVO INSPIRADO EM ENXAME DE PARTÍCULAS (SEA)

Nos últimos anos, uma nova área de pesquisa conhecida como inteligência coletiva (*Swarm Intelligence – SI*) tem ganhado atenção, inspirada no comportamento coletivo de algumas espécies da natureza. Atualmente, o SI inclui dois tipos básicos de algoritmos: a Colônia de Formigas (*Ant Colony Optimization - ACO* [16]), inspirada no comportamento das formigas e o Enxame de Partículas (*Particle Swarm Optimization – PSO* [17]), criado a partir do comportamento de grupos de aves ou peixes.

Para resolver o problema deste trabalho, foi desenvolvido um Algoritmo Evolutivo Inspirado em Enxames (*Swarm-Inspired Evolutionary Algorithm – SEA*). O SEA é, fundamentalmente, um algoritmo evolutivo (AE) cujas características de interação entre os indivíduos são inspiradas na SI. A vantagem do SEA em relação a outros AE's é sua memória coletiva, sendo a geração de novos indivíduos governada por esta memória. Além disso, diferentemente do PSO clássico, o SEA mantém em sua estrutura o conceito darwiniano da seleção natural, aproveitando, desta forma, as melhores características de cada campo de pesquisa.

Estrutura do SEA

No SEA, assim como no PSO, a população de soluções é chamada de *enxame* e cada indivíduo da

população é denominado *partícula*. Uma partícula i em um espaço de busca n-dimensional possui, como parâmetros, suas coordenadas hiper-espaciais $x_i \in R^n$ e velocidade $\lambda_i = \{\lambda_{i1}, \lambda_{i2}, \dots, \lambda_{in}\} \in R^n$. Além disso, cada partícula possui um campo de visão que representa uma região dentro do espaço de busca, que auxilia na geração de novos descendentes. A largura desse campo de visão é igual para cada partícula, sendo representada pelo vetor σ , onde $\sigma = \{\sigma_1, \sigma_2, \dots, \sigma_n\} \in R^n$.

APLICAÇÃO DO SEA AO PROBLEMA

Esta seção apresenta a aplicação da meta-heurística proposta, ou seja, a maximização da utilidade esperada conforme a formulação do problema dado por (6). Deste modo, tem-se o vetor de oferta P como solução do problema.

Para aplicação do SEA, define-se o vetor de ofertas P como as coordenadas de uma partícula. Deste modo, uma determinada partícula x_i é formada por n coordenadas, de modo que $x_i = [P_{i1}, P_{i2}, \dots, P_{in}]$. A população $Pop(t)$, formada por k partículas, é uma estrutura matricial $n \times k$ referente à posição das partículas no espaço de busca, conforme (7).

$$Pop(t) = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1k} \\ P_{21} & P_{22} & \dots & P_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ P_{n1} & P_{n2} & \dots & P_{nk} \end{bmatrix} \quad (7)$$

Cada partícula tem associado um valor de aptidão (*fitness*), calculado pela equação (8).

$$F_i = \sum_{j=1}^n U(\tilde{R}_{ij}) - Penalty_i \quad (8)$$

O termo $Penalty_i$ representa a função de penalidade relacionada à restrição de oferta dada por (9) e (10).

$$Penalty_i = R_{\max} \cdot \sum_{j=1}^{n-1} z_j \cdot (P_{ij} - P_{i(j+1)}) \quad (9)$$

Em que

$$z_j = \begin{cases} 1, & \text{se } P_{i(j+1)} < P_{ij} \\ 0, & \text{se } P_{i(j+1)} \geq P_{ij} \end{cases} \quad (10)$$

Na equação (9), R_{\max} representa o valor da receita obtida considerando todos os valores de P iguais ao máximo e z_j é uma variável auxiliar para o cálculo da penalidade.

RESULTADOS

Para a validação do modelo de formação de estratégias de oferta em leilões de energia proposto neste artigo, nesta seção são apresentados os resultados obtidos a partir de um estudo de caso feito com o agente formador de oferta, a Usina de Três Marias. Seus dados físicos estão abaixo relacionados na Tabela 1. Para validação e análise da metodologia, é considerada a existência de incerteza nos níveis de geração e preços do mercado *spot*.

Tabela 1. Dados da GENCO – Três Marias.

Capacidade máxima	Energia firme	Energia contratada
396 MW	239 MWmed.	109MWmed.

Neste estudo de caso, considera-se a variação nos cenários de geração física de energia e preço do mercado *spot* no período futuro de negociação. Para formação dos cenários, foram utilizadas distribuições normais sobre perfis típicos considerados para a GENCO ao longo de um período de 12 meses. Para este teste foram simulados 1000 cenários de preço e de geração de energia, com valores de variância 0.1 e 1, respectivamente. Os perfis típicos considerados são apresentados na Figura 1 e na Figura 2.

A Figura 3 apresenta o histograma dos cenários de preço *spot* gerados. Observa-se que o preço *spot* médio é aproximadamente 55 \$/MWh, enquanto que o máximo é aproximadamente 116 \$/MWh. A partir da criação dos cenários para o mercado futuro, são levantadas as curvas de oferta com o

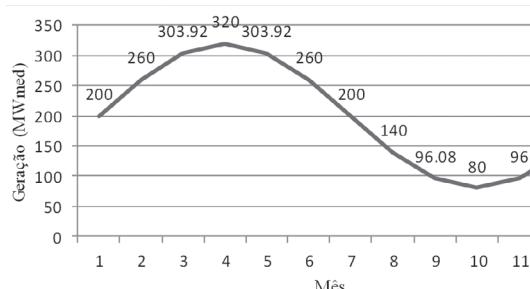


Figura 1. Perfil típico de geração considerado para criação dos cenários.

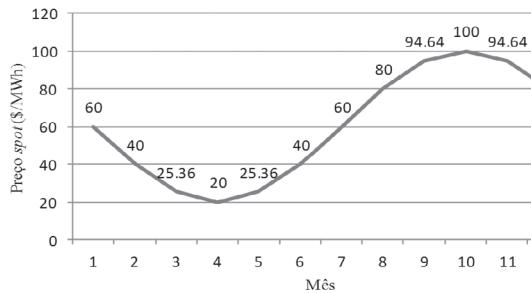


Figura 2. Perfil típico do preço *spot* considerado para criação dos cenários.

objetivo de maximizar o lucro da GENCO, levando em consideração duas estratégias de oferta distintas:

- Estratégia propensa ao risco*: oferta sem considerar os riscos de contratação ($y=0$);
- Estratégia VaR*: oferta considerando o risco mensurado pelo *VaR* ($y=1$).

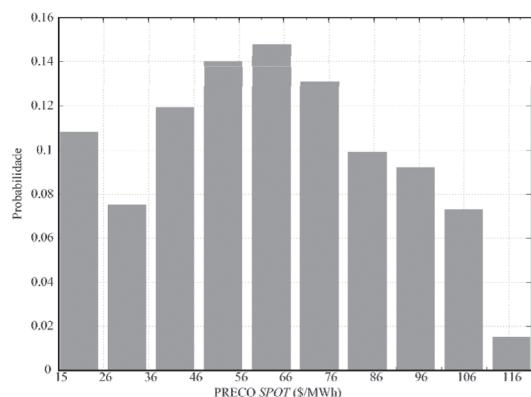


Figura 3. Histograma dos cenários de preços *spot* gerados para o Caso 1.

As curvas são referentes à quantidade de energia disponível para contratação pela GENCO (energia firme menos energia já contratada), conforme apresentado na Figura 4.

Analizando a estratégia propensa ao risco, nota-se que a quantidade de energia ofertada é praticamente nula para preços até aproximadamente 50 \$/MWh. Acima deste valor, a quantidade de energia ofertada pela GENCO é máxima. Esta característica indica que a solução baseada apenas na maximização do lucro esperado sofre forte influência da média de preços prevista para o mercado *spot*. Logo, quando o preço de oferta é maior que o preço previsto para o mercado *spot* ($\pi > 55$/MWh$), a oferta de energia

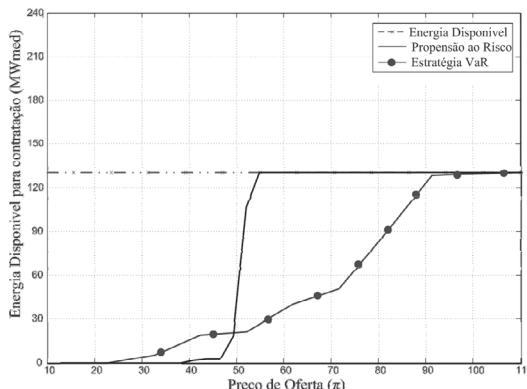


Figura 4. Curva de oferta resultante para o Caso 1.

é máxima. Do mesmo modo, quando o preço de oferta é menor que o preço *spot* esperado ($\pi < 55\$/MWh$), a oferta de energia é mínima.

De fato, as duas situações, de máxima e mínima oferta, demonstram os dois extremos do problema: na primeira, a GENCO fica exposta positivamente ao mercado *spot* (risco de sobrecontratação); na segunda, a exposição é negativa (risco de subcontratação).

Observando a curva de oferta gerada considerando os riscos de contratação modelados pela métrica *VaR*, nota-se uma clara diferença em relação à oferta propensa ao risco ($y = 0$). Enquanto que na primeira curva observa-se apenas os dois extremos (máxima e mínima contratação), a curva gerada pela estratégia *VaR* demonstra um caminho intermediário, onde uma parcela da energia está sempre disponível à negociação no curto prazo. Esta parcela funciona como *hedge* contra os riscos de contratação, ou seja, previne a GENCO da exposição de cenários futuros que sejam “ruins” ao lucro.

Observa-se ainda que, para excelentes preços de oferta ($\pi > 90\$/MWh$), não há mais necessidade de *hedge*, pois, para a maioria dos cenários, a oferta supera o melhor preço estimado para o *spot*. Por outro lado, para baixos preços de oferta ($\pi < 25\$/MWh$), a quantidade ofertada é nula, pois o preço ofertado está próximo do mínimo estimado para o mercado *spot* ($20\$/MWh$).

Considere agora a Figura 5, onde são comparadas as receitas anuais obtidas por diferentes estratégias de oferta para um preço de leilão de $70\$/MWh$. Para este preço são levantados os valores das receitas brutas

anuais para cada cenário de preço *spot* e geração de energia levando em conta três estratégias distintas: *i) oferta VaR*, com quantidade ofertada igual a 48.9739 MWmed ; *ii) oferta Máx*, com oferta igual à máxima energia disponível e; *iii) oferta Min*, com oferta igual a zero, ou seja, a GENCO opta apenas pela negociação no mercado *spot*.

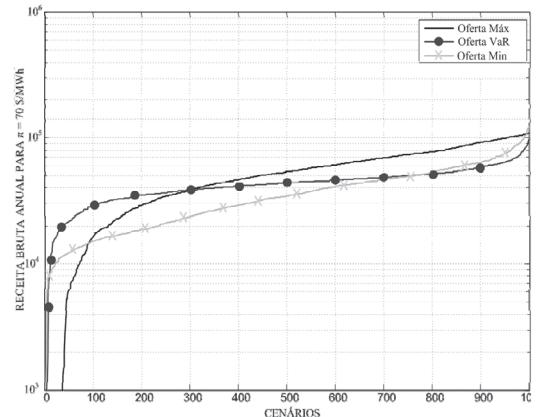


Figura 5. Cenários de receita anual para diferentes estratégias de oferta ($\pi = 70\$/MWh$).

Analizando a Figura 5, nota-se que, ofertando a máxima energia para o preço igual a $70\$/MWh$, obtém-se os cenários com as maiores receitas. No entanto, em quase 10% dos cenários a receita fica muito abaixo da esperada. Utilizando a oferta definida pela estratégia *VaR*, percebe-se que houve apenas uma pequena redução na média dos cenários de receita. No entanto, a perda de oportunidade nos piores cenários também é menor. Isso significa que o modelo reagiu ao risco dos piores cenários. Na Tabela 2 é apresentada uma comparação entre as diferentes estratégias de oferta.

Tabela 2. Receita esperada, risco e utilidade para $\pi = 70\$/MWh$.

Estratégia	Máx.	VaR	Min
Qntd (Mw med)	130	489.739	0
($10^2 \times \$$) Receita Esperada	53.05	43.52	37.76
VaR ($10^2 \times \$$)	47.42	22.28	25.82
Utilidade ($10^2 \times \$$)	5.63	21.24	11.93

CONCLUSÃO

Os resultados da simulação das estratégias de ofertas sobre a primeira fase do leilão de energia mostram a necessidade de cada agente apresentar

a sua melhor oferta para que a solução do leilão convirja à solução ótima, maximizando o retorno de cada agente. Na segunda fase, apresentou-se uma estratégia alternativa utilizando ponderação do risco através do fator de aversão ao risco (y).

A utilização de meta-heurística se mostrou eficiente na otimização do problema, adequando-se à complexidade e não-linearidades dos modelos de riscos utilizados, contribuindo para a otimização e gestão do risco em mercados de eletricidade.

AGRADECIMENTOS

Os autores agradecem ao CNPq do Brasil e à Eletrobrás através do Convênio ECV 065/2005, pelo apoio financeiro no desenvolvimento desta pesquisa. Brasil.

REFERÊNCIAS

- [1] R. Moreno, L.A. Barroso, H. Rudnick, B. Bezerra, M. Pereira, S. Mocarquer, B. Flach and J. Moreno. “Lessons from Five Years of Experience in Energy Contract Auctions in South America”. IAEE Rio International Conference. Rio de Janeiro, Brasil. 2010.
- [2] I. Walter e F. Gomide. “Estratégias inteligentes de oferta no mercado brasileiro de energia”. Simpósio Brasileiro de Automação Inteligente. Brasília, Brasil. 2009.
- [3] F. Azevedo and Z.A. Vale. “Long-Term Swarm Intelligence Hedging Tool Applied to Electricity Markets”. 2nd Swarm Intelligence Algorithms and Applications Symposium. Edinburgh, Escocia. 2009.
- [4] D. Das and B.F. Wollenberg. “Risk assessment of generators bidding in day-ahead market”. Power Systems. IEEE Transactions on. Vol. 20, Issue 1, p. 8. 2005.
- [5] A. Street, L.A. Barroso, S. Granville and M.V. Pereira. “Bidding strategy under uncertainty for risk-averse generator companies in a long-term forward contract auction”. Power & Energy Society General Meeting. 2009. Calgary, Canadá. 2009.
- [6] CCEE. Câmara de Comércio de Energia Elétrica. 2 de marzo de 2011. URL: www.ccee.org.br
- [7] EPE. “Metodología de Cálculo da Garantía Física das Usinas - Nota Técnica N° EPE-DEE-RE-099/2008”. Empresa de Pesquisa Energética. Brasília, Brasil. 2008.
- [8] E. Roubik and H. Rudnick. “Assessment of generators strategic behavior in long term supply contract auctions using portfolio concepts”. IEEE Power Tech Conference. Bucharest, Rumania. 2009.
- [9] M. Dorigo, V. Maniezzo and A. Colorni. “Ant System - Optimization by a Colony of Cooperating Agents”. IEEE Transactions on Systems, Man and Cybernetics. Vol. 26, pp. 29-41. February, 1996.
- [10] J. Kennedy and R. Eberhart. “Particle Swarm Optimization”. IEEE International Conference on Neural Network, pp. 1942-1948. Perth, Australia. 1995.
- [11] G. Xiong, T. Hashiyama and S. Okuma. “An Evolutionary Computation for Supplier Bidding Strategy in Electricity Auction Market”. IEEE Transactions on Evolutionary Computation, pp. 83-88. 2002.
- [12] J.F. Rivera, S.M. Shahidehpour and R.W. Ferrero. “Application of games with incomplete information for pricing electricity in deregualted power pools”. IEEE Trans. on Power Systems. Vol. 13, p. 5. February, 1998.
- [13] D.M.R. Martins. “Análise do Investimento de Capital em Usinas Termelétricas”. PUC-RIO. Dissertação de Mestrado. Rio de Janeiro, Brasil. 2008.
- [14] J. Zhang, J.D. Fuller and S. Elhedhli. “A Stochastic Programming Model for a Day-Ahead Electricity Market With Real-Time Reserve Shortage Pricing”. Power Systems, IEEE Transactions on. Vol. 10, Issue 1, p. 5. 2010.
- [15] P. Yang, G. Tang and A. Nehorai. “A Game-Theoretic Approach for Optimal Time-of-Use Electricity Pricing”. Power Systems, IEEE Transactions on. Vol. 28, Issue 1, p. 8. 2013.
- [16] L. Shuyong, C. Yan, Z. Liwei and H. Jiaxing. “Analysis of Synergy Marketing in Supply Chain Based on Game Theory”. Advanced Computer Control, 2009. ICACC ‘09. International Conference on. Vol. 9, Issue 1, p. 3. 2009.
- [17] F. Careri, C. Genesi, P. Marannino, M. Montagna, S. Rossi and I. Siviero. “Bidding strategies in day-ahead energy markets: System marginal price vs. pay as bid”. 7th International Conference on the European. Vol. 1, Issue 1, pp. 7. 2010.