

Investigação de Meta-heurísticas para Otimização de Portfólio de Energia Elétrica

Ruan D. J. Anselmo* Andre A. Augusto** Julio C. S. Souza**
Milton B. Do Coutto Filho***

* *Programa de Pós-Graduação em Engenharia Elétrica e Telecomunicações, Universidade Federal Fluminense, RJ.*

** *Departamento de Engenharia Elétrica, Universidade Federal Fluminense, RJ (e-mail: aaugusto@id.uff.br)*

*** *Instituto de Computação, Universidade Federal Fluminense, RJ*

Abstract: The growth of the national electricity market has attracted many trading and generators agents to the sector. However, the players in the market face the challenges of high price volatility. From the generators point of view, in addition to the market price risk, there are uncertainties associated with own generation that depends on the generation technology. In this way, the portfolio optimization technique is an approach that aims to improve the management of a business and achieve strategic objectives in an environment of uncertainty. Among the various technologies and mathematical models in the literature, the ones that stand out the most are those of computational intelligence, which are widely explored in portfolio optimization applied in other segments of the industry. In this work, we investigate the application of meta-heuristics applied to electricity portfolio optimization problems in the Brazilian market. The results obtained indicate that such techniques are adequate, contributing to improve the management and the results of the trader's companies.

Resumo: O crescimento do mercado de energia elétrica nacional tem atraído diversos agentes comercializadores e geradores para o setor. Entretanto, os agentes que atuam no mercado enfrentam os desafios da alta volatilidade dos preços. Do ponto de vista dos geradores, além do risco de preços de mercado existem ainda incertezas associadas à geração própria que depende da tecnologia de geração. Desta forma, a otimização de portfólio é uma abordagem que tem o objetivo de melhorar a gestão de um negócio e alcançar os objetivos estratégicos em um ambiente de incertezas. Dentre as diversas tecnologias e modelagens matemáticas utilizadas, destacam-se aquelas baseadas em inteligência computacional, que são amplamente exploradas em otimização de portfólio de outros segmentos da indústria. Neste trabalho, investiga-se a aplicação de meta-heurísticas aos problemas de otimização de portfólio de energia elétrica no mercado brasileiro. Os resultados obtidos indicam que tais técnicas se mostram adequadas, contribuindo para melhorar a gestão e os resultados das comercializadoras.

Keywords: Renewable energy resources, Portfolio, Risk management, Optimization, Computational Intelligence

Palavras-chaves: Fontes renováveis de energia, Portfólio, Gestão de risco, Otimização, Inteligência computacional.

1. INTRODUÇÃO

A crescente demanda por energia elétrica, somada à necessidade de redução de uso de fontes fósseis e da poluição ambiental, tem impulsionado a busca por maior eficiência energética e adoção de fontes renováveis de energia (Chowdhury et al., 2011). Neste contexto, os setores elétricos em todo mundo estão passando por um profundo processo de transformação, caracterizado pela alta penetração de geração renovável e distribuída nas redes elétricas, com incorporação de novas tecnologias de comunicação e controle, desregulamentação e formas inovadoras de comercialização, como os mercados livres de energia elétrica (Momoh, 2012).

O mercado livre de energia elétrica brasileiro tem atraído nos últimos anos agentes do setor elétrico (geradores, consumidores livres, concessionárias, e comercializadoras de energia) em razão das possibilidades de negociação de que dispõem (CCEE, 2021a). Além disso, ações governamentais, na forma de leis (Brasil, 2018) e portarias (Brasil, 2016), visam facilitar a adesão a essa modalidade de comercialização. Estudos recentes também indicam tendência de aumento da participação dos agentes neste ambiente de contratação (EPE et al., 2021).

Empresas comercializadoras buscam nesses mercados obter lucros através do gerenciamento de uma carteira de contratos bilaterais de compra e venda de energia elétrica. A alta volatilidade dos preços — fruto das expectativas dos agentes em relação à demanda por energia, a oferta

existente, as condições operacionais da rede elétrica, e fatores socioeconômicos e ambientais — introduz risco na gestão dos contratos. Embora a geração renovável contribua para o aumento da oferta de energia elétrica, sua inerente intermitência, por outro lado, introduz mais incertezas na geração, com reflexo direto nos riscos a serem administrados pelas comercializadoras. Dessa forma, torna-se necessário que as comercializadoras adotem estratégias de gerenciamento das suas carteiras de contratos que visem o melhor resultado financeiro e considerem o risco ao qual esses agentes estão expostos.

A otimização de portfólio é uma abordagem utilizada em diversas áreas, que consiste em compor um conjunto de projetos ou ativos de maneira a facilitar a gestão de um negócio e alcançar os objetivos estratégicos estabelecidos (Mohagheghi et al., 2019). As referências Kalayci et al. (2019), Mohagheghi et al. (2019), e Doering et al. (2019) apresentam revisões sistemáticas da literatura sobre o tema. No trabalho (Kalayci et al., 2019) são abordadas apenas técnicas determinísticas para seleção ótima de Portfólio enquanto Doering et al. (2019) focaliza em meta-heurísticas. Mohagheghi et al. (2019) traz um amplo e detalhado levantamento da literatura sobre problemas de Portfólio. Nele são discutidos diferentes critérios de seleção, formas de modelagem do problema e suas incertezas, estratégias de solução e estudos de caso. Segundo os autores, são poucos os trabalhos voltados ao setor elétrico.

Nas últimas duas décadas, a seleção de Portfólio de contratos no ambiente contratado livre (ACL) tem recebido cada vez mais atenção de investigadores. Marzano et al. (2004) propõe um modelo de otimização de portfólio de contratos de energia de um agente de geração que detém um único ativo. A metodologia busca maximizar o retorno esperado, dado um limite aceitável de risco, quantificado por meio do *Conditional Value at Risk* (CVaR). Em Street et al. (2009) o problema de otimização de um Portfólio de geração renovável é abordado. Os autores propõem um modelo de programação estocástica no qual buscase maximizar o valor presente líquido (VPL). O nível de risco, expresso pelo CVaR, constitui uma das restrições do problema, o qual é solucionado por programação linear (PL). Uma abordagem híbrida de programação robusta e estocástica é proposta por Fanzeres et al. (2015) para o mesmo problema. Em Camargo et al. (2017), um modelo de programação estocástica para seleção de portfólio é proposto. Nele são considerados operações de swap e contratos de flexibilidade. Maia and Marzano (2018) estendem o modelo apresentado em Marzano et al. (2004) para agentes de geração que detenham mais de um ativo. O modelo é solucionado utilizando-se a Decomposição de Benders.

Os trabalhos mencionados até este ponto recorrem a técnicas de otimização clássica para a seleção de portfólio. Métodos de alocação de portfólios baseados em meta-heurísticas têm recebido cada vez mais atenção recentemente (Mohagheghi et al., 2019), (Doering et al., 2019) e (Ferreira et al., 2021). As técnicas mais utilizadas têm sido os Algoritmos Genéticos (AGs), Enxame de Partículas (*Particle Swarm Optimization* - PSO) e a Colônia Artificial de Abelhas (*Artificial Bee Colony* - ABC), segundo (Mohagheghi et al., 2019) e (Doering et al., 2019). Os trabalhos relacionados à otimização de portfólio de contratos de energia são escassos. Um dos poucos nessa linha, Guder

(2009) emprega um AG para otimização multiobjetivo de Portfólios. Portanto, trata-se de um campo da literatura que ainda não foi significativamente explorado.

Este trabalho tem por objetivo investigar a utilização de meta-heurísticas no problema de otimização de portfólio de contratos de energia elétrica. A alocação da carteira é realizada de modo que o risco da exposição ao PLD seja minimizado e a receita esperada maximizada. A modelagem proposta considera a contratação de diversas fontes renováveis, e a complementariedade do perfil sazonal delas e perfis sazonais de contratos com os consumidores.

2. COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA

Nesta seção apresenta-se um panorama do mercado livre de energia elétrico brasileiro, dos agentes participantes, contratos celebrados e os riscos associados.

Os agentes do mercado de energia brasileiro negociam contratos bilaterais de energia que são instrumentos financeiros, não precisando, portanto, deterem a energia elétrica fisicamente para realizar negociações. Entretanto, os contratos de venda devem ser lastreados pela garantia física das usinas, no caso dos geradores, ou por contratos de compra de energia. As diferenças entre a energia negociada e a física devem ser conciliadas na CCEE, no mercado de curto prazo (MCP). A valoração da energia nesse mercado se dá com o Preço de Liquidação de Diferenças (PLD). O PLD é determinado pela CCEE fazendo uso de uma cadeia de modelos computacionais, desenvolvidos pelo Centro de Pesquisas em Energia Elétrica (CEPEL), cujo objetivo é de otimizar o despacho hidrotérmico do Sistema Interligado Nacional (SIN) de forma que o custo da operação do sistema em todo horizonte de estudo seja minimizado. As incertezas do PLD têm como causa as incertezas das variáveis que influenciam a programação e operação do sistema interligado nacional brasileiro, como fatores ambientais (especialmente o volume de chuvas nos reservatórios das usinas hidráulicas), a demanda de energia, custo e disponibilidade dos combustíveis, entre outras.

Os contratos bilaterais normalmente negociados são os denominados contratos de quantidade, onde as partes negociam um volume de energia fixo a um preço contratual que deve ser pago após o período de suprimento de cada mês contratual. Outra modalidade contratual são os contratos por capacidade (Street et al., 2009), em que se comercializa um percentual da geração também a um preço fixo.

A diferença entre o requisito e o recurso de energético de um agente, isto é, sua exposição de energia, é valorada ao PLD. Como o gerador e o consumidor não sabe com exatidão o volume de energia que irão produzir e consumir, todos os agentes no mercado estão sujeitos a esse risco de quantidade, ou seja, o risco dos contratos bilaterais devido às incertezas na liquidação de energia no MCP. Este risco introduz uma parcela variável de receita, e conseqüentemente, um risco de receita a ser considerado na otimização do portfólio.

O risco de receita pode ser quantificado de diferentes maneiras, como o desvio padrão, o *Value at Risk* (VaR), e o CVaR. Neste trabalho se utilizará como medida risco o CVaR, que pode ser escrito como:

$$CVaR_\alpha(x) = \min_{\eta} \left\{ \eta + \frac{1}{1-\alpha} E_y [(\ell(x, y) - \eta)^+] \right\} \quad (1)$$

onde $(\ell(x, y) - \eta)^+ = \max(\ell(x, y) - \eta, 0)$, x é a variável de decisão, y é a variável aleatória que representa as incertezas, η é a variável auxiliar para o cálculo do CVaR que ao atingir valor ótimo pode ser interpretada como o $VaR_\alpha(x)$, ℓ a função de perda e α o nível de probabilidade, onde $(1 - \alpha)$ é o nível de confiança.

O $CVaR_\alpha(x)$ pode ser compreendido como a receita esperada de um portfólio considerando os mais desfavoráveis $(1 - \alpha)\%$ cenários estabelecidos por y . Matematicamente também pode ser calculado como a média de todos os valores de $VaR_\alpha(x)$ calculados para todos os valores acima de α . O CVaR tem propriedades numéricas e estatísticas superiores à do VaR, sendo a medida adotada neste trabalho. Tal superioridade também se dá devido ao CVaR considerar os eventos “catastróficos” de uma variável aleatória que, apesar de terem baixa probabilidade de ocorrência, são indispensáveis nas análises do gestor do portfólio. No mercado de energia brasileiro, o conhecimento do efeito desses cenários é importantíssimo devido à alta incerteza associada à comercialização de energia. Embora o CVaR normalmente seja utilizado para mensurar perda, neste trabalho ele é visto como a pior receita do portfólio, dado um nível α de confiança, ou seja, refere-se a média dos piores $(1 - \alpha)\%$ cenários de receita do portfólio. Neste trabalho, o risco foi expresso como a diferença entre o valor esperado e o CVaR de uma distribuição de receitas, indicando qual é o valor financeiro que o portfólio pode perder em relação ao valor esperado com um nível de confiança de $\alpha\%$.

3. OTIMIZAÇÃO POR META-HEURÍSTICAS

Nesta seção apresenta-se um panorama geral das meta-heurísticas utilizadas neste trabalho. Ressalta-se que não se pretende comparar as diferentes técnicas apresentadas, mas sim verificar a eficácia do emprego de meta-heurísticas para a solução de problemas de otimização de portfólio aplicados ao mercado de energia elétrica brasileiro.

3.1 Algoritmos Genéticos

Os Algoritmos Genéticos (AG) são algoritmos bio-inspirados no neodarwinismo — a teoria evolutiva moderna em que os processos evolutivos se dão pelos mecanismos de seleção natural propostos por Darwin e mecanismos de variabilidade genética existentes na natureza (Glover and Kochenberger, 2003). Os AG pertencem a uma classe de meta-heurísticas denominada estratégias evolutivas (*Evolution Strategies* — ES) que simulam o processo adaptativo por meio de operações de seleção natural e variabilidade genética através de mutação (Glover and Kochenberger, 2003), (Schwefel, 1977). Por outro lado, os AG se destacam entre essas estratégias por empregarem uma população de indivíduos e utilizarem a operação de recombinação, na qual o material genético de dois indivíduos é combinado de forma a produzir outros (Holland, 2019). Inicialmente concebido para sistemas adaptativos, os AG tornaram-se populares quando se constatou sua aplicabilidade em problemas de otimização (Holland, 2019) e (Goldberg, 1989).

Neste contexto, cada indivíduo da população corresponde a uma solução candidata, codificada através de uma coletânea de símbolos (usualmente dígitos binários) denominada cromossomo. Essa população passa por diversos ciclos geracionais (denominadas gerações) até que um conjunto de critérios de parada sejam satisfeitos. Em uma geração, os indivíduos da população são avaliados através da função de aptidão (*fitness*), que avalia o quanto estão adaptados ao ambiente (isto é, o quão bem resolvem o problema de otimização). Uma parcela dos indivíduos é então selecionada, sendo que os indivíduos mais aptos têm mais chance de serem selecionados. Os selecionados são submetidos a diferentes operações genéticas, sendo as mais importantes a mutação, em que um ou mais genes de um indivíduo são modificados aleatoriamente, e a recombinação (cruzamento ou *cross-over*) em que os cromossomos de dois ou mais indivíduos são combinados entre si de modo a gerar um ou mais indivíduos, cujos cromossomos são distintos dos indivíduos-pais caso esses sejam geneticamente diferentes. Ao final do ciclo geracional é realizada a reposição, onde os indivíduos-pais e os filhos gerados são selecionados para compor a nova população. Maiores detalhes podem ser encontrados em (Glover and Kochenberger, 2003), (Holland, 2019) e (Goldberg, 1989).

3.2 Enxame de Partículas

A otimização por enxame de partículas (*Particle Swarm Optimization* - PSO) (Kennedy and Eberhart, 1995) corresponde a um algoritmo baseado no comportamento social coletivo de seres vivos, especificamente os descolamentos coordenados exibidos por cardumes e passaradas, por exemplo. O PSO se enquadra na classe de algoritmos de inteligência coletiva (*Swarm Intelligence*), caracterizados por serem sistemas auto-organizáveis, capazes de solucionar problemas utilizando somente as iterações individuais de cada membro do sistema (Dreo et al., 2010). O que posiciona o PSO à parte da maioria das meta-heurísticas é sua inata aptidão para solucionar problemas de natureza contínua.

O método estabelece um conjunto de partículas que se movem em torno de um espaço de busca. Cada partícula representa uma solução, caracterizada por sua posição (ponto no espaço de busca) e um deslocamento, também chamado velocidade, enquanto a qualidade da localização é aferida por uma função objetivo. A cada iteração ou instante, a posição futura da partícula é função da posição e deslocamentos atuais, da atual melhor localização da partícula e do melhor posicionamento indicado por partículas vizinhas (isto é, aquelas que compartilham informação). Em geral, a posição final é a soma das atuais localização e velocidade. Já o deslocamento futuro é a combinação linear do posicionamento atual da melhor partícula e do mais favorável segundo os vizinhos. A definição dos pesos é feita de forma aleatória, tornando o PSO um método de otimização estocástico. O processo de busca é relativamente simples, iniciando-se com a definição da população inicial, de forma aleatória. A cada iteração avalia-se, para cada partícula, a qualidade do seu posicionamento atual, atualiza-se sua melhor localização e aquela segundo seus vizinhos, e por fim calcula-se sua nova velocidade e posicionamento. O processo se encerra quando os critérios de parada forem atendidos. Maiores detalhes podem ser

encontrados em (Kennedy and Eberhart, 1995), (Clerc, 2006), e (Dreo et al., 2010).

3.3 Algoritmo de Colônia Artificial de Abelhas

O algoritmo de ABC, proposto pela primeira vez por Karaboga (2005), é um método meta-heurístico utilizado em problemas de otimização que foi inspirado no comportamento observado nas colônias de abelhas durante o forrageamento. O processo de forrageamento em colônias de abelhas inicia-se com as abelhas procurando por novas fontes de alimentos (ou néctar). Após encontrar o néctar, a abelha viaja para a colônia para compartilhar informações sobre a quantidade de néctar, distância e direção da localização da fonte de alimento. O compartilhamento das informações é feito na área de dança através da chamada *waggle dance*. Na área de dança existem outras abelhas observando as informações sobre as fontes de alimentos encontradas pelas demais abelhas. Após observar as danças, as abelhas são capazes de escolher e buscar as melhores fontes de alimentos em função da distância e quantidade de néctar no local.

No algoritmo, a fonte de alimento é representada por um vetor de solução do problema que, inicialmente, é aleatoriamente definido. A quantidade de néctar é representada pelo valor da função objetivo obtido utilizando os dados do vetor de solução atual. Após a inicialização dos vetores, o algoritmo passa por um processo iterativo onde cada abelha busca uma nova fonte de alimento vizinha e verifica se a qualidade desta fonte é melhor, verificando o resultado da função de aptidão. No processo da *waggle dance*, os vetores de solução das abelhas também são modificados baseados nos resultados da solução das demais abelhas. Nesta fase, também se verifica se o novo vetor de solução é melhor do que o vetor de solução da iteração anterior. Após algumas tentativas sem sucesso na busca por fontes melhores a abelha morre ou a fonte de alimento se esgota, ou seja, o vetor de solução desta abelha é esquecido e uma nova abelha nasce para substituí-la no processo de busca.

4. METODOLOGIA PROPOSTA

A otimização de um portfólio de energia elétrica consiste em definir uma composição de contratos capaz de simultaneamente minimizar o risco de mercado associado aos contratos e maximizar o resultado financeiro esperado com a celebração destes. Trata-se, portanto, de um problema de decisão em um ambiente de incertezas. Diferentes abordagens podem ser adotadas para solucioná-lo. Nesta seção apresentará a estratégia de construção de portfólio proposta.

4.1 Premissas de Modelagem

Este trabalho tratará apenas de Portfólios de Energia Elétrica para agentes comercializadores. Portanto, o Portfólio será composto tanto por contratos de venda para consumidores com perfil sazonal de consumo definido, quanto de compra de energia. Em relação a esse último, assume-se a existência de duas modalidades contratuais: uma por quantidade, usualmente feita para produtos de maior liquidez, e a outra por capacidade, envolvendo contratos onde o gerador entrega toda sua energia para o comprador em

troca de uma receita fixa, similarmente a (Street et al., 2009). Esta será considerada na modelagem a complementaridade dos perfis sazonais das diversas formas de geração de energia elétrica.

4.2 Formulação do Problema

Considere um cenário de geração de energia elétrica e PLD i no ano de apuração a . Tendo por base as premissas estabelecidas na subseção anterior, a receita anual de um portfólio de energia para este cenário e ano de apuração calcula-se através de:

$$R_a(i) = \sum_{t \in T_a} \sum_{s \in S} \left[\sum_{v \in V} QV_{v,t,s} \cdot (PV_{v,t,s} - PLD_{t,s,i}) + \sum_{c1 \in C} QC_{c,t,t} \cdot (PLD_{t,s,i} - PC_{c,t,s}) + \sum_{u \in U} X_u \cdot G_{u,t,s,i} \cdot PLD_{t,s,i} - \sum_{u \in U} X_u \cdot P_{u,t} \cdot GF_{u,t,s} \cdot H_t \right] \quad (2)$$

onde,

- t : tempo mensal dentro do intervalo $[1, T_a]$ do ano a ;
- s : índice do submercado $[1, S]$;
- v : índice do contrato de venda $[1, V]$;
- c : índice do contrato de compra $[1, C]$;
- u : índice da usina $[1, U]$;
- i : índice da série $[1, I]$;
- a : índice do ano $[1, A]$;
- QV : Quantidade de energia do contrato de venda (MWh);
- PV : Preço de contrato de venda (R\$/MWh);
- QC : Quantidade de energia do contrato de compra (MWh);
- PC : Preço de contrato de compra (R\$/MWh);
- PLD : Preço de liquidação das diferenças (R\$/MWh);
- G : Geração de energia elétrica (MWh);
- X : Percentual de contratação por capacidade da usina;
- GF : Garantia Física da usina (MWm);
- H_t : Número de horas do do mês t no ano P ;
- P : Preço de contrato de compra por capacidade (R\$/MWh).

A estratégia de otimização de portfólio adotada neste trabalho foi inspirada em Street et al. (2009) e consiste em obter uma combinação de contratos de compra, de venda por quantidade e de compra por capacidade de modo a maximizar a receita esperada com o portfólio e minimizar o risco a ele associado, que de acordo com a seção 2 é a diferença entre o valor esperado e o CVaR da receita.

$$\max_{a \in A} \sum [E[R_a] - \lambda(E[R_a] - CVaR[R_a])] (1 + r)^{1-a} \quad (3)$$

s.a

$$X_u \geq 0, \quad \forall u \in U \quad (4)$$

$$\sum_{t \in T_a} X_u \cdot GF_u \cdot H_t \leq GF_u \cdot \sum_{t \in T_a} H_t, \quad \forall u \in U \quad (5)$$

$$\sum_{t \in T_a} QV \leq \sum_{t \in T_a} QC + X_u \cdot GF_u \cdot H_t, \quad \forall u \in U \quad (6)$$

onde $E[R_a]$ representa o valor esperado da receita do portfólio considerando todos os cenários de preço e geração no ano a . $CVaR[R_a]$ representa o CVaR da receita do portfólio no ano a . Já o parâmetro λ pondera a aversão ao risco na função objetivo e deve estar no intervalo $[0, 1]$. Designa-se por r a taxa de desconto anual e a é o ano do horizonte de estudo que varia de 1 até A .

A Equação (3) maximiza o valor presente líquido anual do equivalente certo da empresa que é composto por uma combinação convexa do valor esperado da receita da empresa e do CVaR, para maiores detalhes veja Street (2008). Vale ressaltar que a parcela livre de risco da função objetivo consiste no valor esperado anual da receita da comercializadora enquanto a parcela aversa ao risco consiste no CVAR anual da receita da comercializadora. A restrição (4) garante que as operações de compra sejam maiores ou iguais a zero, este quando é igual a zero indica que não deve ser feito nenhuma compra desta usina. A restrição (5) impede que as usinas disponíveis para contratos por capacidade tenham problemas de lastro, garantindo que o saldo anual de venda de energia das usinas será menor ou igual à garantia física. De forma semelhante, a restrição (6) previne que a comercializadora tenha problemas de lastro evitando que o volume anual de venda de energia seja maior que os recursos comprados para atendimento dos seus contratos. Nos modelos de otimização adotados, as restrições foram modeladas como penalizações incluídas na função objetivo.

O risco do portfólio também pode ser entendido como a perda máxima que o portfólio pode ter em relação ao seu valor esperado, ou seja, equivale à diferença entre o valor esperado e o CVaR do portfólio. Fazendo um rearranjo na Equação (3) obtém-se a Equação (7), frequentemente utilizada na literatura (Street et al., 2009) (Fanzeres et al., 2015) (Passos et al., 2017).

$$\max_{a \in A} \sum [(1 - \lambda)E[R_a] + \lambda CVaR[R_a]] (1 + r)^{1-a} \quad (7)$$

5. TESTES E RESULTADOS

Esta seção ilustra a aplicação da metodologia proposta na obtenção de um portfólio ótimo de energia no mercado brasileiro de energia elétrica.

5.1 Descrições das simulações

Os modelos de otimização utilizados neste trabalho foram desenvolvidos em linguagem Python. A máquina utilizada nas simulações possui 8GB de memória RAM e processador Intel Core I5-8250U CPU @ 1.6GHz. Neste trabalho consideraram-se cenários de PLDs obtidos com o *deck* de janeiro de 2021 do programa NEWAVE disponibilizado pela CCEE (CCEE, 2021b). Foram utilizadas distribuições correlacionadas de cenários de PLD e geração das usinas disponíveis para contratação por capacidade. Após a coleta dos cenários realizou-se um filtro de séries para remover cenários considerados *outliers*. Além dos cenários de PLD, foi extraído do *deck* do NEWAVE os cenários de Energia Natural Afluente (ENA) correspondentes a cada cenário de PLD. Desta forma foi possível projetar cenários de geração

de energia de usinas correlacionadas com os cenários de ENA do NEWAVE e, conseqüentemente, também correlacionados com os de PLD utilizados nas simulações.

Adotou-se um horizonte de estudo de 24 meses. A comercializadora analisada possui um contrato de venda de 10MWm no submercado Sudeste/Centro-Oeste ao preço de R\$205/MWh no primeiro ano e R\$200/MWh no segundo ano. Este contrato possui uma opção de sazonalização limitada a $\pm 15\%$ e foi adotada uma sazonalização típica de uma rede de shopping centers localizada na cidade do Rio de Janeiro (Volty, 2021). A Figura 1 apresenta os montantes de energia contratados em cada mês.

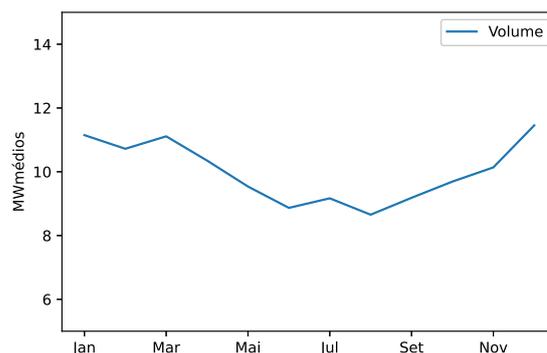


Figura 1. Volume mensal de energia contratado.

Os contratos por capacidade das usinas adotadas neste trabalho possuem preços fixos em todo horizonte de estudo. O submercado, garantia física (GF) e preço dos contratos por capacidade destas usinas podem ser vistos na Tabela 1.

Tabela 1. Dados das usinas disponíveis para contratos por capacidade

Usina	Submercado	GF	Preço
PCH 1	SE	4.2MWm	R\$170/MWh
PCH 2	S	4.5MWm	R\$155/MWh
Biomassa	SE	12MWm	R\$155/MWh
Eólica	NE	12.1MWm	R\$135/MWh
Solar	NE	12.4MWm	R\$165/MWh

Os perfis médios mensais de geração das usinas em relação as gerações anuais de cada uma delas são apresentados na Figura 2. Pode-se perceber que as usinas disponíveis para compra de energia possuem perfis de geração complementares, ou seja, os perfis de geração anual das usinas se complementam entre os meses do ano. Quando as usinas hidráulicas estão gerando menos energia, as usinas eólicas e termelétricas à biomassa estão gerando mais energia.

Os produtos disponíveis para compra de energia utilizados neste trabalho são os que possuem maiores liquidez nos finais de ano. Todos os produtos deste estudo são do submercado Sudeste/Centro-Oeste, devido ao fato de que os produtos de outros submercados possuem baixa liquidez. No final do ano, normalmente são negociados os produtos do primeiro e segundo trimestre do ano seguinte (Q1 e Q2), primeiro e segundo semestre do ano seguinte (H1 e H2), e os produtos anuais do ano seguinte (A1) e do segundo

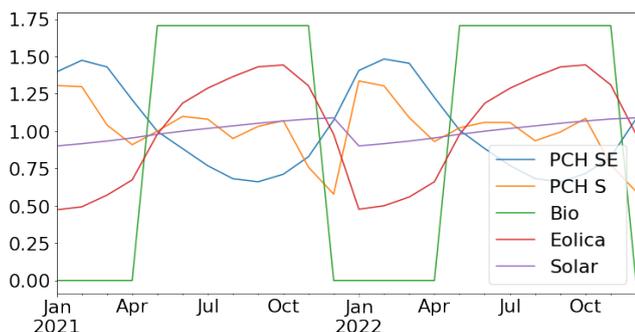


Figura 2. Perfil de geração médio das usinas.

ano seguinte (A2). A Tabela 2 contém produtos e preços adotados nos testes.

Tabela 2. Produtos disponíveis para compra - contratos por quantidade

Produto	Preço
Q1	R\$255/MWh
Q2	R\$169/MWh
H1	R\$211/MWh
H2	R\$208/MWh
A1	R\$212/MWh
A2	R\$281/MWh

Na modelagem foram fixados o valor que pondera a aversão ao risco λ igual a 0,75 e o valor da taxa utilizada para o cálculo do valor presente líquido r em 12%.

Foram realizadas 100 simulações para cada um dos 3 modelos mencionados. A Tabela 3 apresenta os principais parâmetros escolhidos para as meta-heurísticas utilizadas nos testes. Foram realizadas diversas simulações, variando-se os parâmetros das meta-heurísticas entre elas. Os parâmetros adotados neste trabalho são aqueles para os quais as meta-heurísticas apresentaram os melhores resultados.

Tabela 3. Parâmetros dos modelos

Meta-heurística	Parâmetros
AG	Tam. população: 100, No. Iterações: 150 Taxa mutação: 10%, Taxa cruzamento: 50%
PSO	Tam. população: 100, No. Iterações: 150 $c1=0,5$, $c2=0,3$ e $w=0,9$
ABC	Tam. população: 60, No. Iterações: 100

5.2 Resultados Obtidos

Os resultados apresentados nesta seção foram obtidos após 100 execuções de cada um dos modelos apresentados.

A Figura 3 apresenta os resultados das otimizações de cada simulação executada, enquanto a Figura 4 apresenta o gráfico de caixa dos resultados das otimizações, que permite verificar a dispersão dos resultados. Já a Figura 5 apresenta o tempo médio de execução de cada modelo. Pode-se perceber que, com os parâmetros adotados, os modelos gastaram, em média, tempos aproximadamente iguais. Os resultados obtidos com a aplicação de ABC e AG foram similares, enquanto o modelo PSO levou a

um resultado inferior. Vale destacar que o modelo ABC teve um resultado ligeiramente melhor com um tempo de execução médio 13% menor.

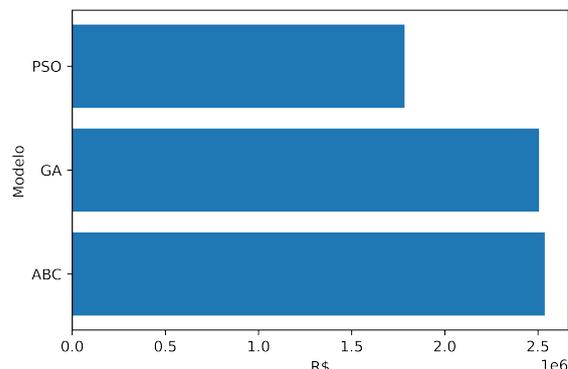


Figura 3. Resultados médios das simulações.

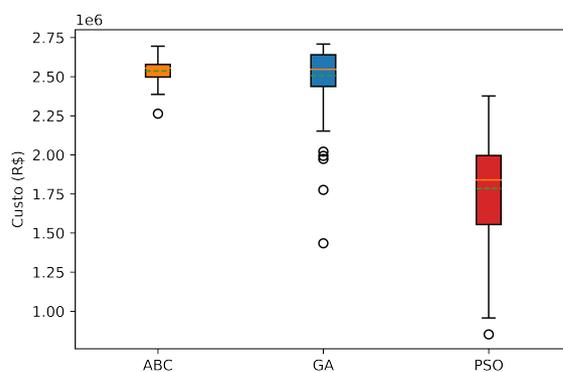


Figura 4. Resultados das simulações.

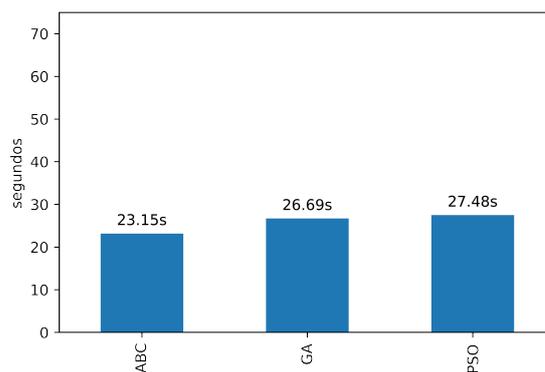


Figura 5. Tempo médio das simulações.

Silberholz and Golden (2010) recomenda que ao comparar resultados de diferentes modelos é importante verificar o desvio dos resultados de cada modelo em relação ao valor ótimo, para verificar a acurácia dos modelos. Além disso, verificar o desvio em relação ao valor médio do próprio modelo, para verificar a precisão do modelo aplicado a determinado problema. Tais informações podem ser extraídas da Figura 6, que apresenta o desvio médio

quadrático absoluto das soluções de cada modelo em relação ao valor ótimo. A Figura 7, por sua vez, contém o desvio médio quadrático absoluto das soluções de cada modelo em relação a seu próprio resultado médio. Com base nos resultados obtidos, os modelos com aplicação de ABC e AG foram os mais precisos, tendo os menores desvios em relação ao valor médio dentre os modelos comparados. Porém ao observar o desvio em relação ao valor médio do próprio modelo foi verificado que o modelo ABC se revelou superior.

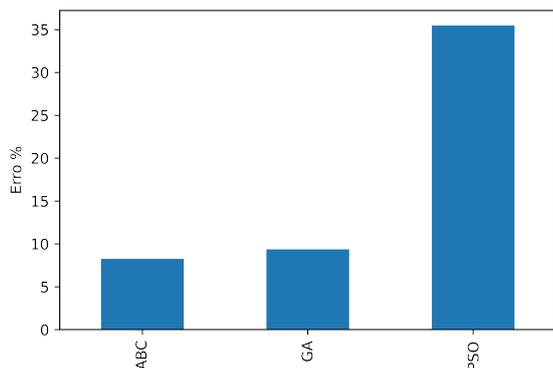


Figura 6. Erro percentual médio absoluto das simulações em relação ao valor ótimo.

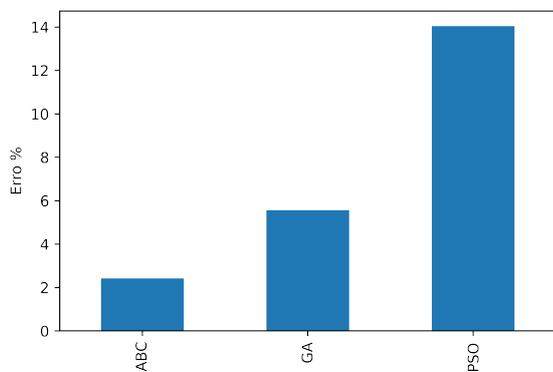


Figura 7. Erro percentual médio absoluto das simulações em relação ao resultado médio de cada modelo.

A Figura 8 apresenta os resultados ótimos dos montantes de compra de energia do portfólio obtidos com o modelo ABC. O único contrato de quantidade recomendado foi a compra do primeiro trimestre do ano. Isto ocorre devido a um conjunto de fatores, como a ausência de geração termelétrica à biomassa neste período, a baixa produtividade das usinas eólicas no início do ano e a incerteza dos cenários de geração hidráulica. Entretanto, o volume contratado pelo contrato de quantidade é significativamente menor que nos contratos de capacidade das usinas, indicando que com o nível de risco aceitável pela comercializadora a compra de energia das usinas ainda são mais atrativas mesmo com as suas incertezas de geração.

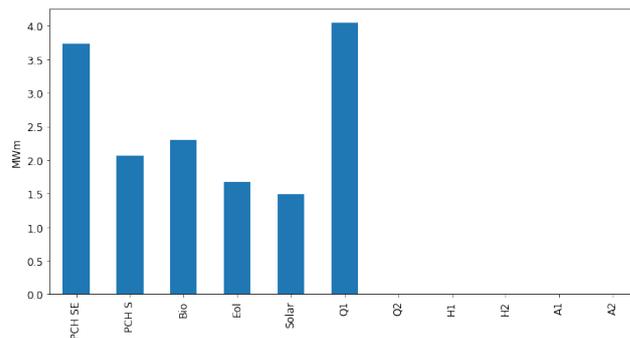


Figura 8. Produtos ótimos.

6. CONCLUSÃO

O presente trabalho apresentou um estudo de otimização de portfólio definindo os montantes de energia que devem ser comprados de usinas via contratos por capacidade e de outras comercializadoras via contratos de quantidade, para atender um contrato de venda para um determinado cliente com um perfil sazonal de consumo. Para a otimização do portfólio foram utilizadas técnicas de otimização meta-heurísticas e verificou-se que tais técnicas podem ser facilmente implementadas em problemas desta natureza. O emprego de tais técnicas leva aos mesmos resultados (ou muito próximos) que são obtidos por um modelo clássico de programação linear, como por exemplo o modelo proposto por Street et al. (2009). Além disso, tais técnicas permitem resolver problemas não lineares causados por alguma restrição na modelagem devido, por exemplo, a uma premissa específica da comercializadora que está implementando o algoritmo. Das técnicas analisadas, verificou-se que o ABC apresentou melhor desempenho dentre os modelos simulados quando se compara a precisão e a acurácia dos resultados obtidos nas simulações. Porém, vale ressaltar que todos os modelos podem alcançar resultados melhores ao se aumentar o número de iterações e/ou ajustar outros parâmetros que foram fixados neste trabalho.

O modelo de alocação de portfólio apresentado conseguiu aproveitar a complementariedade dos perfis sazonais das diferentes fontes de geração considerando suas incertezas. Além disso, o modelo também consegue aproveitar a incerteza associada a diferença de preços entre os PLDs dos submercados para conseguir resultados melhores do portfólio. Os resultados indicam que apesar dos contratos por quantidade negociados em balcão estarem associados a preços mais altos, eles são importantes na composição do portfólio, uma vez que eles garantem o suprimento de energia para a comercializadora em períodos de maiores incertezas.

AGRADECIMENTOS

Os autores agradecem à CAPES, FAPERJ e CNPQ pelo suporte financeiro.

REFERÊNCIAS

Brasil (2016). Lei nº 13.360, de 17 de novembro de 2016. *Diário Oficial [da] República Federativa do Brasil*.

- Brasil (2018). Portaria nº 514, de 27 de dezembro de 2018. *Diário Oficial [da] República Federativa do Brasil*.
- Camargo, L.A.S., Ramos, D.S., Guarnier, E., and Balan, M.H. (2017). Definições de parâmetros de negociação para operações de swap e precificação de contratos contendo cláusula de flexibilidade com suporte de modelo de otimização estocástica e análise de risco versus retorno. CCEE (2021a). Acervo ccee. URL <https://www.ccee.org.br/acervo-ccee>. Accessed: 10.07.2021.
- CCEE (2021b). Informações ao mercado. URL <https://www.ccee.org.br/acervo-ccee>. Accessed: 10.07.2021.
- Chowdhury, S., Chowdhury, S.P., and Crossley, P. (2011). *Microgrids and Active Distribution Networks*. Institution of Engineering and Technology, Stevenage, England.
- Clerc, M. (2006). *Particle swarm optimization*. ISTE, London, England.
- Doering, J., Kizys, R., Juan, A.A., Àngels Fitó, and Polat, O. (2019). Metaheuristics for rich portfolio optimisation and risk management: Current state and future trends. *Operations Research Perspectives*, 6, 100121. doi:<https://doi.org/10.1016/j.orp.2019.100121>.
- Dreo, J., Petrowski, A., Siarry, P., and Taillard, E. (2010). *Metaheuristics for hard optimization: Methods and case studies*. Springer, Berlin, Germany.
- EPE, CCEE, and ONS (2021). PDE, plano decenal de expansão de energia 2030.
- Fanzeres, B., Street, A., and Barroso, L.A. (2015). Contracting Strategies for Renewable Generators: A Hybrid Stochastic and Robust Optimization Approach. *IEEE Transactions on Power Systems*, 30(4), 1825–1837. doi:10.1109/TPWRS.2014.2346988.
- Ferreira, F.G., Gandomi, A.H., and Cardoso, R.T. (2021). Artificial Intelligence Applied to Stock Market Trading: A Review. *IEEE Access*, 9, 30898–30917. doi:10.1109/ACCESS.2021.3058133.
- Glover, F.W. and Kochenberger, G.A. (eds.) (2003). *Handbook of metaheuristics*. Springer, New York, NY.
- Goldberg, D.E. (1989). *Genetic algorithms in search, optimization, and machine learning*. Addison Wesley, Boston, MA.
- Guder, R. (2009). Otimização De Portfólios De Contratos De Energia Elétrica Utilizando Algoritmos Genéticos Multiobjetivo. 122.
- Holland, J.H. (2019). *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*. Bradford Books, Cambridge, MA.
- Kalayci, C.B., Ertenlice, O., and Akbay, M.A. (2019). A comprehensive review of deterministic models and applications for mean-variance portfolio optimization. *Expert Systems with Applications*, 125, 345–368. doi:10.1016/j.eswa.2019.02.011. URL <https://doi.org/10.1016/j.eswa.2019.02.011>.
- Karaboga, D. (2005). An idea based on honey bee swarm for numerical optimization, technical report - tr06. *Technical Report, Erciyes University*.
- Kennedy, J. and Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95 - International Conference on Neural Networks*, volume 4, 1942–1948 vol.4. doi:10.1109/ICNN.1995.488968.
- Maia, D.N. and Marzano, L.G.B. (2018). Otimização De Portfólio De Contratos De Energia Sob a Ótica De Uma Empresa Com Vários Ativos De Geração. *SBPO*.
- Marzano, L.G.B., Melo, A.C.G., and Souza, R.C. (2004). An approach for portfolio optimization of energy contracts in the brazilian electric sector. In *2003 IEEE Bologna Power Tech Conference Proceedings*. IEEE.
- Mohagheghi, V., Mousavi, S.M., Antuchevičienė, J., and Mojtaheidi, M. (2019). Project portfolio selection problems: A review of models, uncertainty approaches, solution techniques, and case studies. *Technological and Economic Development of Economy*, 25(6), 1380–1412. doi:10.3846/tede.2019.11410.
- Momoh, J.A. (2012). *Smart grid: Fundamentals of design and analysis*. Wiley-IEEE Press, New York, NY, 1 edition.
- Passos, A.C., Street, A., and Barroso, L.A. (2017). A Dynamic Real Option-Based Investment Model for Renewable Energy Portfolios. *IEEE Transactions on Power Systems*, 32(2), 883–895. doi:10.1109/TPWRS.2016.2564983.
- Schwefel, H.P. (1977). *Numerische Optimierung von Computer-Modellen mittels der Evolutionsstrategie*. Birkhäuser Basel, Basel, Switzerland.
- Silberholz, J. and Golden, B. (2010). *Comparison of Metaheuristics*, 625–640. doi:10.1007/978-1-4419-1665-5_21.
- Street, A. (2008). Equivalente certo e medidas de risco em decisões de comercialização de energia elétrica. doi:10.17771/PUCRio.acad.11477.
- Street, A., Barroso, L.A., Flach, B., Pereira, M.V., and Granville, S. (2009). Risk constrained portfolio selection of renewable sources in hydrothermal electricity markets. *IEEE Transactions on Power Systems*, 24(3), 1136–1144. doi:10.1109/TPWRS.2009.2022981.
- Volty (2021). Volty. URL <https://volty.com.br/>. Accessed: 10.07.2021.