



## SAZONALIZAÇÃO DA ENERGIA ASSEGURADA ATRAVÉS DO MÉTODO DE OTIMIZAÇÃO ACiD

**Vinicius A. Cabral, Waleska S. L. Ribeiro, Ana Carla O. W. Rocha,  
Ivo C. Silva Junior, André L.M. Marcato**

Universidade Federal de Juiz de Fora

waleska.lima@engenharia.ufjf.br, ana.olenka@engenharia.ufjf.br, ivo.junior@ufjf.edu.br,  
andre.marcato@ufjf.edu.br,

**Daniel Ito**

China Three Gorges Corporation

Rua Funchal 418, 3º andar

daniel.ito@ctgbr.com.br

### RESUMO

A energia assegurada de uma usina hidroelétrica é a quantidade máxima de energia que pode ser utilizada para comercialização e, portanto, o modo como essa energia é alocada tem impacto direto na receita das empresas de geração de energia relacionada ao ambiente livre de contratação. Diante disso, o presente trabalho tem como objetivo, através da simulação de diversos cenários relacionados às incertezas inerentes ao problema, a obtenção de uma estratégia ótima de sazonalização da energia assegurada visando a maximização da média das receitas. O método computacional ACiD (Adaptive Coordinate Descent) é proposto para resolução do problema, sendo os cenários de geração/demanda do sistema elétrico e os respectivos preços de energia obtidos via modelo de despacho hidrotérmico baseado em programação dinâmica dual estocástica. Os resultados, via ACiD, se mostraram satisfatórios e uma análise dos parâmetros foi realizada de modo a investigar a eficiência da metodologia proposta.

**PALAVRAS CHAVE.** Energia Assegurada, Sazonalização, Adaptive Coordinate Descent.

**Tópico:** EM - PO na área de energia

### ABSTRACT

The Assured Energy of a hydroelectric power plant is the maximum amount of energy that can be used for commercialization. Thus, the way this energy is allocated has direct impact on revenue of power generation companies related to free purchase environment. Therefore, the present work aims to obtain, through the simulation of several scenarios related to the uncertainties inherent in the problem, an optimal strategy of assured energy's seasonalization aiming at maximizing the average of revenues. The ACiD (Adaptive Coordinate Descent) computational method is proposed to solve the problem, whose generation/demand scenarios of the electric system and respective energy prices were obtained through hydrothermal dispatch model based on stochastic dual dynamic programming. The results, by means of ACiD, were satisfactory and an analysis of the parameters was performed to investigate the efficiency of the proposed methodology.

**KEYWORDS.** Assured Energy, Seasonalization, Adaptive Coordinate Descent

**Paper topics:** EN - OR in energy area



## 1. Introdução

A matriz energética brasileira é hidrotérmica, ou seja, com predominância das usinas hidráulicas e com as usinas térmicas em regime complementar. O sistema energético brasileiro é interligado entre as regiões Sul, Sudeste, Centro-Oeste, Nordeste e parte da região Norte, formando o Sistema Interligado Nacional (SIN), de responsabilidade do Operador Nacional do Sistema Elétrico (ONS) [BRASIL. Lei nº 10.848, art. 13, de 27 de maio de 1998].

Pelo fato do despacho do SIN ser centralizado pelo ONS, para as usinas que participam do MRE (Mecanismo de Realocação de Energia), a energia assegurada (EA) não é igual à energia efetivamente gerada por cada usina. A energia assegurada de uma usina hidroelétrica está relacionada ao limite de contratação por parte desta unidade geradora. Ou seja, é a quantidade máxima de energia que pode ser utilizada para comercialização.

Desta forma, quando os contratos são firmados, vários fatores são desconhecidos, como por exemplo: a real produção de energia de uma determinada usina ao longo dos anos, o custo da energia no mercado livre, o comportamento dos demais agentes de geração, entre outros. Tais fatores representam incertezas e trazem complexidade ao cálculo da sazonalização da energia assegurada. Fatores estes que evidenciam a necessidade de estudos e modelos matemáticos que possam direcionar da melhor maneira possível a estratégia dos agentes de geração de modo a maximizar suas receitas ou minimizar seus riscos. Pode-se citar, como parte do esforço no estudo da sazonalização da energia assegurada, o trabalho recente realizado através de uma abordagem via inteligência computacional [Hoffmann et al. 2015].

Diante do problema acima descrito, o presente trabalho tem como objetivo a utilização e validação do método ACiD (Adaptive Coordinate Descent) como técnica de resolução do problema referente à sazonalização da energia assegurada. Para tanto, através de um modelo de despacho hidrotérmico já existente, denominado de MDDH [Souza et al. 2014], foram utilizados diferentes cenários de geração/demanda de energia, preços de energia, entre outros fatores, de modo auxiliar na tomada de decisão por parte do agente gerador no que diz respeito à sazonalização da EA de seu parque gerador.

## 2. Energia assegurada e o Fator de Ajuste da Garantia Física

A energia assegurada é uma garantia física da contratação de energia que um agente/empresa de geração possui. É um valor anual calculado pela Empresa de Pesquisa Energética (EPE) [BRASIL. Lei nº 5.163, art. 4, § 1º, de 30 de julho de 2004] segundo critérios estabelecidos pelo Ministério de Minas e Energia (MME) e a Agência Nacional de Energia Elétrica (ANEEL) a partir de uma análise do histórico de geração dos últimos anos de uma determinada usina hidroelétrica. Tal valor representa o total de energia que poderá ser comercializada em um dado ano.

A sazonalização da EA consiste em distribuir mensalmente esse montante de energia ao longo de um ano, levando em consideração possíveis limites mensais de alocação. A partir do levantamento da EA são calculadas as receitas dos agentes levando em consideração o quanto ele comercializou em um dado mês e quanto realmente foi produzido, analisando-se desta forma se haverá uma necessidade de compra de energia ou se haverá excedente para a venda no mercado livre (curto prazo).

O GSF (Generation Scaling Factor), também conhecido como “Fator de Ajuste da Garantia Física”, é um indicativo da energia total gerada pelo SIN, diante do Mecanismo de Realocação de Energia (MRE), em relação ao total contratado pelo sistema, conforme apresentado pela Equação (1). O MRE serve para compartilhar riscos hidrológicos entre os membros participantes do sistema, pois, caso alguma usina membro do MRE não consiga atender o contrato firmado em um dado mês, as demais usinas do sistema poderão garantir a comercialização, diante de taxas de utilização de serviço (TEO). O MRE garante, pelo menos, o recebimento da garantia física de cada agente membro.



$$GSF = \frac{GH_{MRE}}{EA_{MRE}} \quad (1)$$

onde:

- $GH_{MRE}$  - Soma da energia gerada pelas usinas participantes do MRE;
- $EA_{MRE}$  - Soma das Energias Asseguradas (contratadas) das usinas participantes do MRE.

O fator do GSF poderá ser analisado da seguinte maneira:

- $GSF < 1$  - Produziu-se menos do que o que foi contratado;
- $GSF = 1$  - Produziu-se exatamente o que foi contratado;
- $GSF > 1$  - Produziu-se mais do que foi contratado, gerando excedente.

### 3. Metodologia Proposta

As estratégias de evolução introduzidas inicialmente, na década 60, por Ingo Rechenberg, na Alemanha, consistem em algoritmos que utilizam o conceito de evolução aplicado a problemas cujo objetivo é a otimização de parâmetros [Back 1991]. Cada algoritmo utilizado propõe uma alternativa diferente de obtenção de novos descendentes a partir de uma população anterior.

Uma estratégia proposta, dentre os algoritmos, é o método da Adaptação da Matriz de Covariância (CMA - *Covariance Matrix Adaptation*), que consiste em utilizar mudanças de sistemas de coordenadas ao longo do processo a fim de diminuir o número de iterações necessárias para se atingir a solução. Ou seja, utiliza-se uma matriz que sofre adaptações ao longo do processo e que é obtida a partir dos melhores candidatos à solução encontrados ao longo de um ciclo.

O método é utilizado devido à sua eficiência, uma vez que é independente do sistema de coordenadas e é um mecanismo que pode ser utilizado junto a qualquer outro algoritmo de otimização. Sua principal função é modificar o formato da região de busca de forma a não alterar a densidade da distribuição e que seu contorno se aproxime do formato da função objetivo, buscando assim, atingir o ponto ótimo de maneira mais rápida. Na Figura 1, é apresentado um exemplo geométrico do funcionamento do algoritmo para os métodos nos quais serão aplicados. [Loshchilov et al. 2011], [Hansen 2006b].




Figura 1 - Representação geométrica da CMA no problema.

Dentre os diversos métodos de otimização, o Coordinate Descent (CD) é um método de otimização baseado na dicotomia, onde um problema n-dimensional é transformado em n problemas unidimensionais e cada variável do problema é otimizada de forma independente,



através da análise do impacto de sua variação na função objetivo. O Algoritmo 1 apresenta o pseudocódigo do método onde todas as variáveis sofrem variações ao mesmo tempo, característica essa que torna o método mais robusto [Loshchilov et al. 2011].

---

**Algoritmo 1 - Coordinate Descent - CD**

---

- 1: Inicializar os parâmetros.
  - 2: Gerar uma solução inicial de acordo com o desejado pelo usuário.
  - 3: Calcular o valor da função objetivo para essa solução.
  - 4: **Enquanto** a melhor solução não entrar em estagnação
  - 5: Variar ciclicamente  $i$  de 1 até  $n$ .
  - 6: Gerar 2 soluções variando o  $i$ -ésimo parâmetro da melhor solução até o momento.
  - 7: Calcular o valor da função objetivo para cada solução.
  - 8: Verificar se houve melhora na solução e, se sim, atualiza-a.
  - 9: Atualizar o valor de  $\sigma$  a partir do sucesso, ou não, da busca pela melhor solução.
  - 10: **Se** acabou o ciclo
  - 11: Verificar se foi encontrada uma melhor solução durante o ciclo.
  - 12: Atualizar as variáveis que verificam se a solução estagnou.
  - 13: **Fim**
- 

Inicialmente (linha1) são inicializados os parâmetros utilizados na otimização ( $k_{succ}$ ,  $k_{unsucc}$  e  $\sigma$ ), os parâmetros de controle do algoritmo ( $lim$ ,  $tol$ ) e uma solução candidata inicial (Figura 2-a), que é utilizada para se obter o valor da função objetivo (linha 2). Em seguida, são geradas duas novas soluções candidatas, que serão avaliadas pela função objetivo (Figura 2-b). Uma solução é obtida a partir da variação de uma das variáveis de melhor solução (melhor valor de função objetivo) até o momento, por uma quantidade  $+\sigma$ , enquanto a outra solução, por uma variação de quantidade  $-\sigma$ , mantendo as demais variáveis constantes.

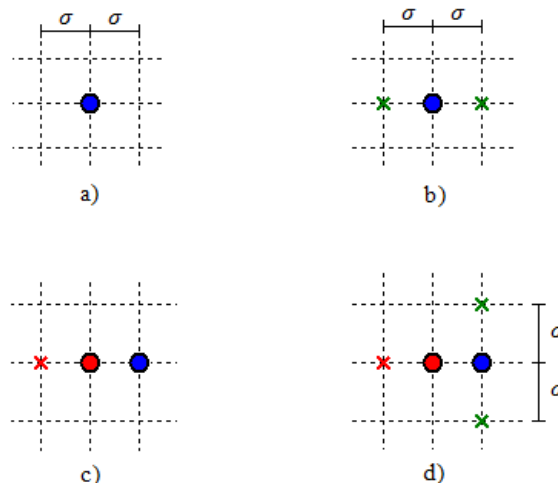


Figura 2: a) Primeiro, solução é gerada. b) São obtidas duas novas soluções ( $x$ ) variando apenas um parâmetro da melhor solução, enquanto os outros parâmetros são mantidos constantes. c) Cada solução candidata é avaliada e a melhor solução é atualizada (melhor solução - azul e melhor solução anterior - vermelho). d) Duas novas soluções candidatas são geradas a partir variação de outro parâmetro da melhor solução, enquanto os outros parâmetros são mantidos constantes.

Durante a execução, caso o algoritmo encontre uma melhor solução, o valor de  $\sigma$  é atualizado para  $\sigma \cdot k_{succ}$ , caso contrário, o valor de  $\sigma$  é atualizado para  $\sigma \cdot k_{unsucc}$ . Conforme será mostrado, os valores de  $k_{succ}$  e  $k_{unsucc}$  impactam diretamente no tempo de execução do



programa e no valor da solução ótima encontrada. A resposta obtida por cada solução candidata é comparada à melhor solução até o momento e, se uma melhor solução é encontrada, a melhor solução é então atualizada. (Figura 2-c).

Duas novas soluções candidatas, novamente, são geradas através da variação da variável seguinte (Figura 2-d), repetindo todo o processo até que todas as variáveis sofram uma variação, completando uma iteração do processo de otimização. O algoritmo será interrompido quando a melhor solução (valor da função objetivo) entrar em estagnação durante um determinado número pré-estabelecido (*lim*) de iterações. Uma mudança na solução é considerada significativa caso a variação seja superior a um valor pré-estabelecido (*tol*)

A inclusão em sua estrutura de uma mudança de sistema de coordenadas, através de uma matriz de covariância adaptativa (CMA) ao longo do processo, caracteriza o método Adaptive Coordinate Descent (ACiD) e seu pseudocódigo é representado a seguir, algoritmo 2.

---

**Algoritmo 2 - Adaptive Coordinate Descent (ACiD)**

---

- 1: Inicializar os parâmetros principais.
  - 2: Gerar uma solução inicial de forma aleatória, ou de acordo com o desejado.
  - 3: Calcular o valor da função objetivo para essa solução.
  - 4: **Enquanto** a melhor solução não entre em estagnação
  - 5:     Ajustar o tamanho do passo.
  - 6:     Variar ciclicamente *i* de 1 até *n*.
  - 7:     Gerar duas soluções variando todos os parâmetros da melhor solução até o momento.
  - 8:     Calcular o valor da função objetivo para cada solução.
  - 9:     Verificar se houve melhora na solução e, se sim, atualize-a.
  - 10:     Atualizar o valor do passo a partir do sucesso, ou não, da busca pela melhor solução.
  - 11:     **Se** acabou o ciclo (*i* = *n*)
  - 12:         Verificar se foi encontrada uma melhor solução durante o ciclo.
  - 13:         Atualizar as variáveis que verificam se a solução estagnou.
  - 14:         **Se** foi encontrada uma melhor solução ao longo do ciclo
  - 15:             Modificar a matriz de covariância a partir das melhores soluções.
  - 16:     **Fim**
- 

Assim como no CD, os mesmos parâmetros são inicializados, é gerada uma solução inicial e é obtido o valor da função objetivo referente a essa solução. A matriz de mudança de coordenadas é estabelecida inicialmente como sendo a matriz identidade ou pode-se optar por gerar uma matriz ortogonal aleatória, escolha essa que será analisada a seguir. Ao contrário do que ocorre no CD, cada solução candidata sofrerá uma variação em todas as variáveis ao mesmo tempo. Para isso,  $\sigma$  será um vetor coluna de *n* posições, onde *n* é a dimensão das soluções candidatas e é estabelecido inicialmente em 1/4 da diferença entre os limites superiores e inferiores de cada variável. Inicia-se então um ciclo de *n* iterações, controlado pelo parâmetro *i*, onde em cada iteração, o *i*-ésimo termo de  $\sigma$  será multiplicado pela coluna *i* da matriz, onde *i* varia entre [1,*n*]. O resultado obtido é um vetor *dx* que será utilizado para modificar os candidatos, conforme  $\sigma$  modificava no CD.

Ao longo do ciclo, o valor de  $\sigma$  sofre as modificações através dos parâmetros  $k_{succ}$  e  $k_{unsucc}$  da mesma forma como é feito no CD. Além disso, se for encontrada uma melhor solução ao longo de um ciclo, ao final desse, uma nova matriz de mudança de coordenadas será construída a partir das melhores soluções obtidas. O critério de parada do ACiD é o mesmo utilizado no CD, isto é, o processo se encerra quando a melhor solução não sofrer uma variação significativa (*tol*) ao longo de um número de iterações (*lim*) pré-estabelecidos.



#### 4. Modelagem do Problema

No ambiente livre de comercialização de energia elétrica, uma das parcelas da receita total do agente de geração pode ser modelada conforme a Equação (2). O cálculo leva em consideração a energia contratada, o valor de venda no mercado spot de curto prazo, valorado de acordo com o PLD (Preço de Liquidação das Diferenças) e a forma como a energia assegurada será alocada. A apuração do PLD é realizada semanalmente e é de responsabilidade da Câmara de Comercialização de Energia Elétrica (CCEE) [BRASIL. Lei nº 5.177, art. 2, inc. V, de 12 de agosto de 2004].

$$\text{Receita} = (\text{Energia Alocada} * X - \text{Energia Contratada}) * \text{PLD} \quad (2)$$

Onde:

- **Energia Alocada** - Valores conhecidos das unidades hidroelétricas que compõem o parque gerador da empresa;
- **PLD** - Preço da energia no mercado livre (obtido via simulação/histórico);
- **X** – Variáveis de otimização: Perfil mensal de sazonalização da EA.

A função objetivo (FOB) do problema aqui em análise consiste em maximizar a média das receitas para os diferentes cenários de geração/preço de energia (cenários hidrológicos) gerados pelo modelo computacional MDDH, que utiliza a técnica de programação dinâmica dual estocástica para resolução do problema de despacho hidrotérmico de geração. Com os cenários de geração/preço de energia levantados através da simulação computacional, fez-se uso do método ACiD para determinar os valores de sazonalização que irão maximizar a média das receitas para os diferentes cenários simulados.

Como parâmetros de entrada para o ACiD, define-se o vetor inicial (X) de sazonalização da EA com um comportamento denominado de *flat*, ou seja, com valores uniformemente distribuídos ao longo do ano em análise. O vetor X representa os valores percentuais mensais de sazonalização da EA e possuem restrições de canalização baseados nos limites mínimos e máximos de contrato firmados pela empresa geradora. Neste caso adotou-se o seguinte intervalo mensal de sazonalização baseado nos critérios do MRE : entre ( $7\% \leq X \leq 12\%$ ). O conjunto de valores ótimos (X) obtidos em cada mês é representado na Tabela 1.

Tabela 1 – Representação do vetor X.

Mês	1	2	...	12
EA(%)	X <sub>1</sub>	X <sub>2</sub>	....	X <sub>12</sub>

Outra restrição importante é que ao longo do ano a soma da sazonalização dever fechar em 100%. Ou seja, no valor total da EA. O fluxograma do algoritmo proposto é exibido através da Figura 3 e a modelagem matemática através da Equação (3).

$$\text{Max } FOB = \text{Receita Média}(X)$$

s. a.

$$\sum_{i=1}^{12} X_i = 1 \quad (3)$$

$$0,07 \leq X_i \leq 0,12$$

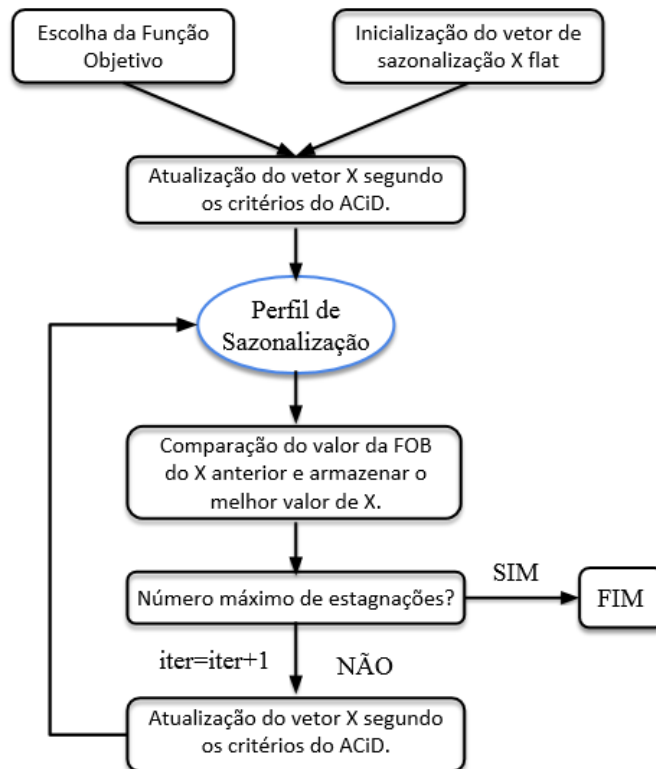


Figura 3 – Fluxograma do método ACiD para resolução do problema.

A partir do perfil inicial de sazonalização (X), o valor da FOB é calculado. Posteriormente, o perfil de sazonalização é atualizado através do método do ACiD, gerando duas novas soluções candidatas. Estas novas soluções são avaliadas através do valor numérico da FOB, as quais serão comparados com a solução inicial obtida e, caso uma delas represente uma solução melhor, o perfil de sazonalização, que representa a melhor a solução, é atualizado. A partir da nova solução encontrada, duas novas soluções candidatas são geradas. Este processo segue sucessivamente durante um ciclo de doze iterações e, ao final, uma nova mudança no sistema de coordenadas é feita, caso uma melhor solução tenha sido encontrada ao final deste ciclo.

O detalhamento do algoritmo referente ao “Perfil de Sazonalização” pode ser visualizado através da Figura 4. As entradas desse algoritmo são: (i) o perfil de sazonalização gerado pelo método de otimização (ACiD); (ii) os diferentes cenários de geração/demanda/preço, os quais são determinados através de simulação computacional do modelo MDDH; (iii) o perfil de EA dos agentes de geração concorrentes, sendo estes levantados através de dados históricos. Esses dados são sorteados através da simulação de Monte Carlo para gerar significativa variabilidade desses parâmetros, os quais são incertezas inerentes ao problema e que influenciam diretamente no valor de receita a ser obtida. A partir dos cenários sorteados, é possível obter uma curva de distribuição com os respectivos valores de receitas e assim, uma receita média pode ser calculada.



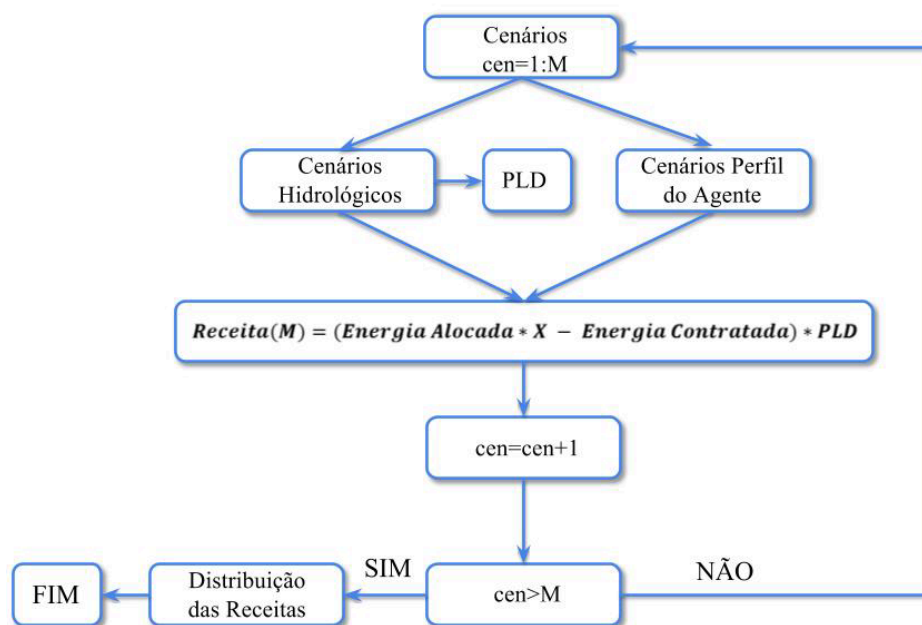


Figura 4 – Fluxograma do cálculo da receita para um determinado perfil de sazonalização X.

### 3. Resultados

Os resultados aqui apresentados baseiam-se em cenários de geração/demanda do ano de 2013. O objetivo é encontrar um perfil de sazonalidade que maximize os rendimentos médios considerando as incertezas relacionadas ao problema.

Para as simulações realizadas visando o cálculo das receitas, foram considerados 10.000 cenários de geração/demanda/preço obtidos via modelo MDDH e 12 cenários médios de sazonalização dos agentes geradores concorrentes obtidos via dados históricos. Diante das possíveis combinações entre os cenários, buscou-se a melhor estratégia de sazonalização de forma a maximizar a receita média, isto é, buscar a alternativa que apresenta maior lucro em cenários favoráveis e menor prejuízo em cenários desfavoráveis.

Em relação à técnica proposta de resolução, foram feitas algumas simulações do ACiD buscando uma melhor combinação entre os valores de  $k_{succ}$  e  $k_{unsucc}$  de forma a encontrar uma solução ótima no menor tempo possível. Além disso, foi investigada a possibilidade da consideração ou não de uma matriz de mudança de coordenadas aleatória, no início do processo. Para cada análise investigada, foram executadas 6 simulações e serão apresentadas a média dos resultados e o tempo gasto na obtenção da solução final. Como critério de convergência do ACiD, foi considerada a estagnação da solução em uma determinada solução. Para todas as simulações foi estipulado um total de 15 estagnações, isto é, o processo encerra após 15 iterações seguidas sem mudanças significativas na solução.

Na variação do parâmetro  $k_{succ}$  foram adotados valores dentro do intervalo [0.8:0.05:2], que contém alguns valores utilizados por [Loshchilov et al. 2011], e, para os valores de  $k_{unsucc}$ , foram escolhidas apenas duas opções: 0,5 ou o inverso de  $k_{succ}$  conforme [Hansen 2006b].

O comportamento de  $k_{unsucc}$  ao longo do processo e a possibilidade de inicialização de uma matriz de mudança de coordenadas inicial dá origem a quatro possíveis simulações (A B C e D). A forma como cada simulação foi estabelecida está indicada na Tabela 2. Na simulação A, antes do início do processo, é gerada uma matriz de mudança de coordenadas aleatória e o valor de  $k_{unsucc}$  terá um valor fixo e igual a 0,5. Na simulação B, também é gerada a matriz aleatória,





mas o valor de  $k_{unsucc}$  será igual ao inverso de  $k_{succ}$ . Na simulação C, a matriz de mudança de coordenadas é estabelecida como a matriz identidade, isto é, o primeiro ciclo acontecerá no sistema de coordenadas original e  $k_{unsucc}$  terá um valor fixo e igual a 0,5. E por fim, na simulação D, a matriz será inicializada também como a matriz identidade, porém  $k_{unsucc}$  será igual ao inverso de  $k_{succ}$ .

Tabela 2 – Simulações Consideradas- ACiD.

Simulações	Mudança de coordenadas inicial	Valor de $k_{unsucc}$
A	Sim	0,5
B	Sim	$1/k_{succ}$
C	Não	0,5
D	Não	$1/k_{succ}$

Para cada simulação foram obtidos os valores de receita média e os resultados são apresentados na Figura 5.




Figura 5 - Resultados obtidos em cada simulação analisada- ACiD.

Diante dos resultados, pode-se observar que adequar o parâmetro  $k_{unsucc}$  ao  $k_{succ}$  acarreta uma menor dispersão dos resultados. Pode-se verificar, através da simulação D, que manter  $k_{unsucc} = 1/k_{succ}$  garantiu respostas melhores com dispersões menores, principalmente, se for mantido o sistema de coordenadas original. Comparando o método D com o método B, pode ser verificado que a presença da matriz de mudança de coordenadas no início do processo interfere no processo de busca, levando a algumas soluções piores e com uma dispersão um pouco maior.

Um segundo critério que deve ser analisado entre as simulações é referente ao tempo computacional. A Figura 6 apresenta um gráfico com os tempos médios obtidos em cada simulação.




Figura 6 - Tempo gasto médio em cada simulação-ACiD.

É possível verificar que a simulação A que apresenta uma mudança no sistema de coordenadas inicial, exibe uma menor dispersão em relação ao tempo de processamento. Entretanto, manter o sistema de coordenadas original no início do processo, além de levar a uma solução melhor, simulação D, apresenta muitos casos onde o tempo gasto é menor. Com relação ao valor de  $k_{unsucc}$ , no quesito tempo, ambos os casos, A e D, apresentaram medianas muito próximas.

Os dados utilizados para a construção do gráfico da Figura 5 é apresentado na Figura 7, onde é possível verificar que, para os valores de  $k_{succ}$  simulados, os melhores resultados ocorreram em 60% dos casos, no método D.

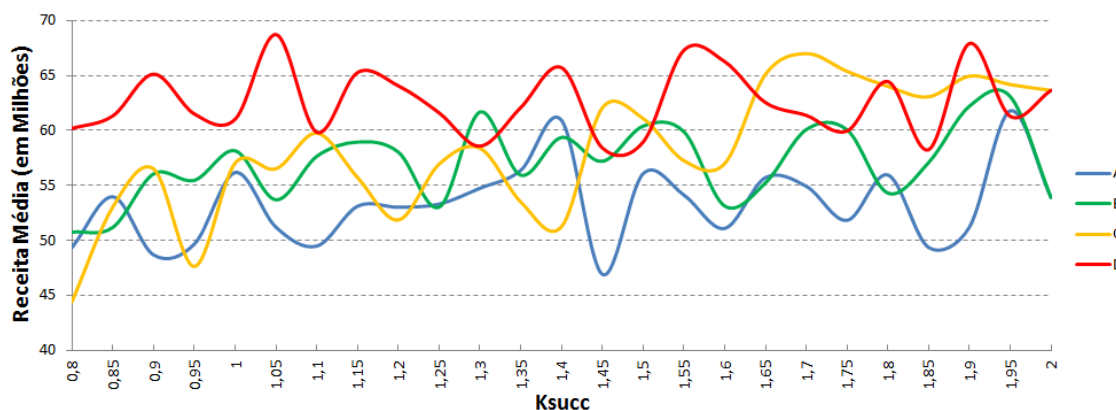


Figura 7 - Média das Receitas para cada valor de  $k_{succ}$  e para cada simulação.

Todos os resultados apresentados foram obtidos através da média aritmética de um total de 6 execuções em cada situação. Dentre todos os resultados obtidos, o melhor foi obtido através do caso D e o tempo necessário para atingi-lo, bem como os parâmetros de otimização utilizados são mostrados na Tabela 3. É importante ressaltar que, conforme apresentado na Tabela 4, todos os resultados obtidos pela simulação D foram superiores ao resultado obtido pelo vetor *flat*.

Tabela 3 - Dados da melhor solução obtida

Receita Média (R\$)	Tempo (min)	$k_{succ}$	$k_{unsucc}$
69.253.023,32	8,72	1,95	0,512

A estratégia de sazonalização da EA que deu origem ao resultado apresentado na Tabela 3 é apresentada na Figura 8 e consiste em alocar a maior parte da EA nos meses de Janeiro, Março e Abril.




Figura 8 - Estratégia da Sazonalização obtida na Maximização da Receita Média.-ACiD.

A Tabela 4 apresenta uma comparação do valor médio das receitas obtidas pelo ACiD e o valor obtido por uma sazonalização *flat*, sendo esta uma alternativa muito comum entre as empresas geradoras.

Tabela 4 – Resultado ACiD x Flat.

Sazonalização	Média das Receitas (R\$)
Flat	52.000.000,00
ACiD	69.253.023,32

#### 4. Conclusões

O método computacional ACiD (Adaptive Coordinate Descent) foi proposto no presente trabalho para resolução do problema referente a sazonalização da EA, sendo os cenários de geração/demanda do sistema elétrico e os respectivos preços de energia obtidos via modelo de despacho hidrotérmico baseado em programação dinâmica dual estocástica. Diante dos resultados, as seguintes conclusões podem ser apresentadas:

- O algoritmo ACiD, proposto para resolução do problema aqui abordado, apresentou resultado satisfatório, sendo capaz de encontrar uma estratégia de sazonalização da EA mais eficiente do que a estratégia *flat* normalmente usada pelas empresas de geração.

- Pode-se verificar que a simulação D, onde a matriz de mudança de coordenadas foi inicializada como sendo uma matriz identidade e com  $k_{unsucc}$  igual ao inverso de  $k_{succ}$ , originou os melhores resultados médios de receita. Nesta simulação, os valores médios das receitas foram mais altos, com menor dispersão e com mediana mais alta quando comparada com as demais simulações.

- Alguns fatores são de importância significativa quando se analisa o tempo computacional: (i) o número de cenários considerados no processo de Monte Carlo; (ii) o critério de convergência adotado para o ACiD, baseado no número de estagnação da melhor solução encontrada; (iii) a combinação entre os valores de  $k_{succ}$  e  $k_{unsucc}$  e a possibilidade da consideração ou não de uma matriz de mudança de coordenadas aleatória, no início do processo.

- Apesar do satisfatório desempenho do ACiD, deve-se ter em mente que este algoritmo não garante a otimalidade das soluções encontradas, podendo vir a encontrar soluções de menor



qualidade. Porém, percebe-se o grande potencial do mesmo como geradores de soluções iniciais para a utilização de algoritmos combinatoriais/metaheurísticas, pois se sabe que a eficiência do processo de busca no espaço de soluções é função das soluções iniciais factíveis.

## Referências

Back, T., Hoffmeister, F., & Schwefel, H. P. (1991, July). A survey of evolution strategies. In *Proceedings of the fourth international conference on genetic algorithms* (Vol. 2, No. 9). Morgan Kaufmann Publishers, San Mateo.

BRASIL (1998). Lei nº 10.848, de 27 de maio de 1998. Dispõe sobre a comercialização de energia elétrica, altera as Leis nºs 5.655, de 20 de maio de 1971, 8.631, de 4 de março de 1993, 9.074, de 7 de julho de 1995, 9.427, de 26 de dezembro de 1996, 9.478, de 6 de agosto de 1997, 9.648, de 27 de maio de 1998, 9.991, de 24 de julho de 2000, 10.438, de 26 de abril de 2002, e dá outras providências. Web page. [http://www.planalto.gov.br/ccivil\\_03/\\_ato2004-2006/2004/lei/l10.848.htm](http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/lei/l10.848.htm). Acessado: 2017-04-05.

BRASIL (2004b). Decreto nº 5.163, de 30 de julho de 2004. Regulamenta a comercialização de energia elétrica, o processo de outorga de concessões e de autorizações de geração de energia elétrica, e dá outras providências. Web page. [http://www.planalto.gov.br/ccivil\\_03/\\_Ato2004-2006/2004/Decreto/D5163.htm](http://www.planalto.gov.br/ccivil_03/_Ato2004-2006/2004/Decreto/D5163.htm). Acessado: 2017-04-05.

BRASIL (2004). Decreto nº5.177, de 12 de agosto de 2004. Regulamenta os arts. 4º e 5º da Lei nº 10.848, de 15 de março de 2004, e dispõe sobre a organização, as atribuições e o funcionamento da Câmara de Comercialização de Energia Elétrica - CCEE. Web page. [http://www.planalto.gov.br/ccivil\\_03/\\_ato2004-2006/2004/decreto/d5177.htm](http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/decreto/d5177.htm). Acessado: 2017-04-05.

Hansen, N. (2006). The CMA evolution strategy: A comparing review. In I. I. J. A. Lozano, P. Larrañaga and E. Bengoetxea (Eds.), *Towards a new evolutionary computation. Advances on estimation of distribution algorithms.*, Volume 192 of *Studies in Fuzziness and Soft Computing*. Springer-Verlag.

Hoffmann, L., Pereira, I.F., Chaves, I.S., Dias, B.H., Marcato, A.L.M., Lorey, L.F. e Iha, F.H. (2015). Stochastic Optimization applied to Brazilian Hydroelectric Seasonalization of Assured Energy. In *Anais do 2015 IEEE Eindhoven PowerTech*, Eindhoven. IEEE.

Loshchilov, I., Schoenauer, M., and Sebag, M. (2011). Adaptive Coordinate Descent. In *Genetic and Evolutionary Computation Conference*, pages 885–892. ACM.

Souza, R. C., Oliveira, F. L. O., Ferreira, P. G. C., Marcato, A. L. M., Dias, B. H., Brandi, R. B. S., Ramos, T. P. Planejamento da operação de sistemas hidrotérmicos no Brasil - Geração de cenários e otimização (2014). Ed. PUC-Rio, Rio de Janeiro.