

Universidade Federal do Rio de Janeiro

**Estudo sobre a operação conjunta de usinas hidrelétricas:
estudo de caso com usinas pertencentes a diferentes agentes em
um ambiente competitivo**

Regina Reis da Costa Alves

2013



**Estudo sobre a operação conjunta de usinas hidrelétricas:
estudo de caso com usinas pertencentes a diferentes agentes em
um ambiente competitivo**

Regina Reis da Costa Alves

Projeto de Graduação apresentado
ao Curso de Engenharia de
Produção da Escola Politécnica,
Universidade Federal do Rio de
Janeiro.

Orientador: DSc Marcos Pereira Estellita Lins

Co-Orientador: PhD Sergio Granville

Rio de Janeiro

Abril de 2013

**Estudo sobre a operação conjunta de usinas hidrelétricas:
estudo de caso com usinas pertencentes a diferentes agentes em
um ambiente competitivo**

Regina Reis da Costa Alves

PROJETO DE GRADUAÇÃO DO CURSO DE ENGENHARIA DE PRODUÇÃO DA
ESCOLA POLITÉCNICA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO.

Examinada por:

Prof. Marcos Estellita Pereira Lins, DSc

Sergio Granville, Ph.D.

Prof. Samuel Jurkiewicz, DSc

Prof. Rosemarie Broker Bone, DSc

RIO DE JANEIRO, RJ - BRASIL

Abril de 2013

Alves, Regina Reis da Costa

Estudo sobre a operação conjunta de usinas hidrelétricas: estudo de caso com usinas pertencentes a diferentes agentes em um ambiente competitivo / Regina Reis da Costa Alves– Rio de Janeiro: UFRJ/ Escola Politécnica, 2013.

81 p

Orientador: Marcos Pereira Estellita Lins

Co-Orientador: Sérgio Granville

Projeto Graduação – UFRJ/ Escola Politécnica/ Curso de Engenharia de Produção, 2013.

Referencias Bibliográficas: p.81.

1. Introdução, 2. Contexto do problema, 3. Aspectos fundamentais da relação oferta-consumo de energia, 4. Medidas de risco, 5. Representação do rendimento, 6. Revisão dos métodos para abordagem do problema, 7. Modelo implementado: operação conjunta de usinas hidroelétricas pertencentes a diferentes agentes em ambientes competitivos, 8. Exemplos simulados, 9. Conclusão

I. Universidade Federal do Rio de Janeiro, Escola Politécnica, Curso de Engenharia de Produção. II. Estudo sobre a operação conjunta de usinas hidrelétricas: estudo de caso com usinas pertencentes a diferentes agentes em um ambiente competitivo

REIS DA COSTA ALVES, REGINA

ESTUDO SOBRE A OPERAÇÃO CONJUNTA DE USINAS HIDRELÉTRICAS:
ESTUDO DE CASO COM USINAS PERTENCENTES A DIFERENTES AGENTES EM
UM AMBIENTE COMPETITIVO

[Rio de Janeiro] 2013

(DEI-POLI/UFRJ, Engenharia de Produção, 2013)

p. 82, 29,7 cm

Projeto de Graduação – Universidade Federal do Rio
de Janeiro, Escola Politécnica, Departamento de Engenharia
Industrial, Curso de Engenharia de Produção

1 – Pesquisa Operacional, 2 – Sistema Hidrotérmico,

3 – Simulação

AGRADECIMENTOS

Terminar uma graduação em Engenharia não é uma tarefa fácil para ninguém, e por isso é preciso reconhecer, neste momento, o papel de inúmeras pessoas que foram fundamentais para me fazer chegar até aqui.

Agradeço primeiramente à minha turma, EP071. Tenho um carinho enorme por cada pessoa desta turma e sinto muitas saudades da convivência diária. Não sei se teria aguentado se não tivesse pessoas tão sensacionais do meu lado. Agradeço também a tantos outros grandes amigos da EP072 e EP081, que tive o prazer de conhecer pelos corredores e principalmente no último ano, e que para mim são também parte da minha turma e das pessoas que me fazem amar tanto essa universidade.

Agradeço aos amigos de escola, aos amigos de sempre, aos amigos por acaso, que, mesmo não estando na universidade comigo, vibraram com minhas vitórias, ouviram meus lamentos e sempre me provaram que nunca estarei sozinha.

Agradeço aos professores que tive o prazer de conhecer na UFRJ, em especial à professora Rosemarie Broker Bone, que tanto me ajudou nestes últimos momentos e que está sempre disponível para ajudar e ouvir os seus alunos, e ao professor Felipe Acker, que é um dos grandes responsáveis pelos rumos que a minha vida tem tomado, que sempre acreditou em mim e que me orientou desde minha entrada na UFRJ.

Agradeço a todas as pessoas que conheci na PSR, tenho um carinho enorme por todos. Em especial, agradeço ao quase doutor Luiz Carlos, que sempre teve uma paciência enorme para me orientar dentro da PSR, e que tem uma grande participação na minha evolução profissional, além de sempre ter me dado bons conselhos.

Agradeço ao Mario Veiga, presidente da PSR, por ter acreditado em mim, ter me dado ótimas oportunidades e aberto várias portas, além dos frequentes bons papos e conselhos.

Agradeço ao meu co-orientador Sergio Granville, por ter me acompanhado de perto neste trabalho, ter me explicado tudo com muita paciência e sempre ter estado disponível para me ajudar. Sem ele, com certeza não teria sido possível fazer a parte prática deste trabalho e eu aprendi muito com sua orientação.

Agradeço ao professor Marcos Pereira Estellita por ter aceitado meu convite e me orientado neste trabalho.

Por último agradeço à toda a minha família, por sempre ter estado por perto e ser uma grande inspiração na minha vida.

Resumo do Projeto de Graduação apresentado à Escola Politécnica/ UFRJ como parte dos requisitos necessários para a obtenção do grau de Engenheiro de Produção.

**Estudo sobre a operação conjunta de usinas hidrelétricas:
estudo de caso com usinas pertencentes a diferentes agentes em
um ambiente competitivo**

Regina Reis da Costa Alves

Abril/2013

Orientador: Marcos Pereira Estellita Lins

Co-Orientador: Sérgio Granville

Curso: Engenharia de Produção

Este trabalho apresenta uma compilação de trabalhos referentes ao estudo de diversos aspectos do problema de planejamento da operação de um sistema hidrotérmico em longo prazo. Este problema é geralmente apresentado através de um modelo de Pesquisa Operacional, mas possui aspectos complexos por conta da incerteza dos dados, não linearidades e dimensão do problema.

Através do desenvolvimento de um modelo simplificado em linguagem C++, este trabalho apresenta também um estudo sobre o problema específico da operação de usinas pertencentes a diferentes agentes em um ambiente competitivo através de simulações de casos teste e simulação de um caso com dados reais da usina de Salto Grande. Os resultados são apresentados e seus aspectos relevantes são comentados.

Palavras-chave: pesquisa operacional, sistema hidrotérmico, simulação.

Abstract of the Graduation Project presented to POLI/UFRJ as a partial fulfillment of the requirements for the degree of Industrial Engineer.

A study about the joint operation of hydroelectric plants: a case study with plants belonging to different agents in a competitive environment

Regina Reis da Costa Alves

April/2013

Advisor: Prof. DSc Marcos Pereira Estellita Lins

Co-Advisor: PhD Sergio Granville

Course: Industrial Engineering

This paper presents a compilation of works in the field of the study of planning the operation of a hydrothermal system in the long term. This problem is usually presented through a model of Operational Research, but it has complex aspects due to the uncertainty of the data, nonlinearities and the extent of the problem.

By developing a simplified model in C++, this paper presents a study on the specific problem of the operation of power plants belonging to different agents in a competitive environment through simulations of test cases and simulation of a case with real data belonging to Salto Grande. The results are presented and the relevant aspects are discussed.

Keywords: operational research, hydrothermal system, simulation

SUMÁRIO

1. Introdução	11
1.1. Contexto.....	11
1.2. Objetivo	11
1.3. Metodologia.....	11
2. Contexto do problema.....	11
2.1. Visão geral do problema.....	11
2.2. Aspectos não considerados nos modelos estudados.....	11
2.3. Explicação geral do modelo	12
2.3.1. Função Objetivo.....	12
2.3.2. Restrição de Balanço Energético.....	12
2.3.3. Restrição de Balanço Hídrico.....	13
2.3.4. Restrição de atendimento à demanda.....	13
Restrições de capacidade.....	13
3. Aspectos fundamentais da relação oferta-consumo de energia.....	14
3.1. Afluências.....	14
3.2. Demanda.....	16
3.3. Preços.....	17
4. Medidas de risco.....	18
5. Representação do rendimento.....	19
6. Revisão dos métodos para abordagem do problema.....	20
Programação Dinâmica	20
Programação Dinâmica Dual Estocástica (PDDE).....	21
Algoritmo Genético (AG).....	22
Otimização por Enxame de Partículas (OEP).....	23
7. Modelo implementado: operação conjunta de usinas hidroelétricas pertencentes a diferentes agentes em ambientes competitivos.....	24
7.1. Motivação pela questão de poder de mercado.....	24
7.2. Motivação pela otimização global de usinas em cascata.....	24
7.3. Explicação geral do problema.....	24
7.4. Modelo a ser implementado.....	24
7.5. Dados do Modelo.....	25
8. Exemplos simulados	27
8.1. Caso Teste.....	27
8.2. O caso de ganho do operador.....	30
8.3. Caso de uma cascata com ganho do operador.....	32
8.4. O caso de um ganho diferenciado entre o operador com e sem informação futura	35
8.5. Simulação de um caso real.....	39
9. Conclusão.....	45
Referências Bibliográficas.....	46

ÍNDICE DE FIGURAS

ÍNDICE DE TABELAS

1. Introdução

1.1. Contexto

O estudo do planejamento da operação de um sistema hidrotérmico em longo prazo é utilizado para diversos fins: previsão de preços no mercado de energia, utilização otimizada dos recursos, planejamento de novos investimentos, estratégia de produção de agentes privados, estratégia em leilões de energia, entre outros. Por isso, não é surpreendente que haja uma literatura muito ampla nesta área.

O problema de planejamento é bastante complexo, visto que depende da previsão de chuvas, de demanda de energia e de preços, exige a representação de aspectos físicos das fontes energéticas, linhas de transmissão e outros componentes do sistema, além de apresentar uma quantidade muito elevada de variáveis e restrições. Encontramos então muitos artigos na literatura que focam em apenas um ou poucos destes aspectos.

Com o desregulamento do mercado de energia em diversos países, muitos recursos que eram antes estatais foram vendidos para agentes privados, e questões sobre como evitar que alguns agentes possuam poder de mercado e como obter uma produção ótima global passaram a ser relevantes. Neste contexto, este trabalho apresenta um estudo sobre aspectos decorrentes da operação de usinas em cascata e usinas de grandes reservatórios pertencentes a diversos agentes, em um ambiente competitivo.

1.2. Objetivo

O presente trabalho possui como objetivo realizar uma compilação de trabalhos sobre o problema de planejamento do despacho energético, com maior foco na formulação para horizontes de longo prazo. Ainda, o presente trabalho possui o objetivo de mostrar uma aplicação da teoria em um problema específico, através de uma formulação simplificada implementada em linguagem C++.

O problema específico se trata da situação em que mais de um proprietário possui uma mesma usina ou usinas de uma mesma cascata, então cada um possui um cronograma de despacho específico e estes cronogramas são combinados por um “gerente da usina/cascata” responsável pelo despacho real da usina ou cascata. Maiores detalhes sobre este problema serão dados no capítulo 7 deste trabalho.

1.3. Metodologia

Em um primeiro momento, será apresentado o contexto do problema. Serão mencionados aspectos que não são considerados nos modelos apresentados, por uma questão de simplificação. Além disso, será apresentada a formulação básica do problema e seu conjunto clássico de restrições (por exemplo, em [1] e [17]), bem entendido que este conjunto pode ser alterado dependendo do contexto, tanto através de adições ou exclusões de restrições, como através de modificações em restrições do conjunto.

No capítulo 3, serão discutidas as formas de lidar com aspectos fundamentais do problema de oferta-demanda, em particular as incertezas em parâmetros do modelo, especificamente nos dados de afluência ([2] a [9]) e de demanda ([4]). Será ainda discutida a formação dos preços, que é afetada pelas previsões de afluência e demanda ([10]).

O próximo capítulo discute a restrição associada às características pessoais de aversão ao risco do tomador de decisão que utiliza o modelo ([3], [11], [12]). Esta discussão de risco decorre das incertezas associadas à determinação de parâmetros, que foi apresentada no capítulo anterior.

Posteriormente, serão mostradas discussões sobre a representação de uma das restrições, que se refere à produção de energia de uma hidrelétrica ([13], [14]). A energia produzida depende do volume turbinado e de um coeficiente que é dependente do volume de água no reservatório. Logo, a relação entre energia e volume não é linear.

Após uma visão geral das variáveis e restrições que serão consideradas na formulação, serão apresentados diversos métodos de resolução com o objetivo de lidar com a grande dimensão do

problema, como: Programação Dinâmica Estocástica ([1], [15], [17]), Programação Dinâmica Dual Estocástica ([1], [17]), Otimização por Enxame de Partículas ([21], [22]), Algoritmos Genéticos ([18], [19]), Sistemas de Inferência Fuzzy ([21]), entre outros.

Os capítulos 7 e 8 irão apresentar a aplicação específica e os resultados obtidos para casos simples ilustrativos e para um caso real. Inicialmente, será mostrada a relevância da questão de divisão da propriedade de uma hidrelétrica através das questões de poder de mercado. Será mostrada também a relevância de uma coordenação unificada no caso de uma cascata de usinas e um conjunto de agentes em que cada agente detém uma fração de cada usina da cascata. Será apresentado o modelo implementado, em linguagem C++, e os resultados obtidos.

2. Contexto do problema

2.1. Visão geral do problema

A revisão bibliográfica que é desenvolvida neste trabalho possui como objetivo apresentar diversos aspectos do problema de despacho energético em longo prazo, que são muito abordados na literatura.

Iniciamos então apresentando uma explicação geral do problema. O planejamento do despacho energético pode ser visto sob duas óticas diferentes. A primeira é o lado do planejador, por exemplo, o operador do sistema brasileiro, que possui como objetivo gerir os recursos energéticos do país de forma a minimizar os custos e, ao mesmo tempo, atender a demanda. A segunda é o lado do ofertante, por exemplo, o operador de uma usina hidrelétrica, que, a partir do preço da energia no mercado no estágio corrente (chamado preço “spot”), possui o objetivo de maximizar sua renda. Veremos no capítulo 2, item 3, que o valor destes preços “spot” decorre das soluções duais do problema de minimização de custo.

A minimização de custos ou maximização de renda é feita em um determinado período, tipicamente dividido em meses no caso do despacho em longo prazo, e dizemos que este período é formado por estágios [17].

Considera-se que o custo de geração das hidrelétricas é pequeno, portanto, no problema de minimização de custos, no caso de um sistema hidrotérmico, o custo de cada período é igual ao custo da energia produzida pelas termelétricas somado ao custo de déficit.

O operador possui a opção de, em uma determinada etapa, turbinar a água de seu reservatório ou armazená-la para um período futuro. Observa-se que, caso a decisão seja de utilizar a água no estágio corrente, se o estágio seguinte for um período de seca, será preciso uma geração muito grande pelas termelétricas e, com isso, um alto custo de operação. Se, ao contrário, for decidido guardar a água para o próximo estágio e a afluência do próximo estágio for alta, haverá um vertimento de água se a quantidade esbarrar nos limites do reservatório e de turbinamento [1].

Figura : Decisão de utilização da água. Fonte: a autora

2.2. Aspectos não considerados nos modelos estudados

O presente trabalho irá focar em apresentar a modelagem do problema de despacho em longo prazo desconsiderando alguns aspectos que, na realidade, influenciam no resultado final e não serão considerados por uma questão de simplificação (variáveis exógenas ao problema).

O estudo de um planejamento energético em longo prazo envolve diversas áreas de estudo e, por esse motivo, é fora do escopo deste trabalho tentar abranger todas essas áreas. Algumas destas áreas que não serão abordadas serão citadas a seguir.

Um destes aspectos relevantes que não será tratado aqui trata da expansão dos recursos energéticos. Um tratamento do uso dos recursos em longo prazo mais acurado deve prever que, neste espaço de tempo, novas usinas podem ser construídas ou ampliadas, ou seja, nem o número de usinas nem suas características dimensionais são, na realidade, certas durante todo o período de estudo. A própria necessidade de ampliar a matriz energética e como fazê-lo já é, por si só, assunto de estudos específicos.

demandar menos esforço computacional são amplamente estudados e alguns serão apresentados no capítulo 5.

Encontramos o conjunto básico de restrições associadas ao modelo em diversos trabalhos como em [1] e [20]. Neste capítulo, iremos apresentá-lo considerando a formulação de árvore de cenários, pois ela é mais simples para um bom entendimento do problema.

Existe no modelo completo um conjunto de restrições semelhante para cada estágio e cenário do período de estudo. Este conjunto básico será descrito a seguir.

2.3.1. Função Objetivo

Para o caso de minimização de custos, a função objetivo deve representar os custos associados a cada estágio e cenário do horizonte de estudo. A soma dos custos de cada etapa e cenário, multiplicados pela probabilidade do cenário ocorrer, deve ser minimizada. Para o caso de maximização de renda, a função é análoga, substituindo-se custos por preços. Considerando os cenários da árvore do exemplo anterior, e, por simplicidade, que existe uma única usina térmica com custo linear de despacho c , esta função objetivo fica como a seguir:

$$c \times g_{1,1} + p_{21} \times c \times g_{2,1} + p_{22} \times c \times g_{2,2} + p_{21} \times p_{31} \times c \times g_{3,1} \\ + p_{21} \times p_{32} \times c \times g_{3,2} + p_{22} \times p_{33} \times c \times g_{3,3} + p_{22} \times p_{34} \times c \times g_{3,4}$$

Em que:

$g_{i,j}$ é a quantidade de energia gerada no estágio i , cenário j

p_{ij} é a probabilidade de transição do estado correspondente no estágio $(i-1)$ para o estado

j

2.3.2. Restrição de Balanço Energético

A restrição de balanço energético obriga que a variável representando a quantidade de energia gerada em um período seja igual à soma das gerações das usinas hidrelétricas e termelétricas (considerando, por simplicidade, que não há outras fontes de energia). Ela é representada como:

$$e_{i,j} = \sum_{h=1}^H \rho_h u_{h,i,j} + g_{i,j}$$

Em que:

H é o número de hidrelétricas

$u_{h,i,j}$ é o volume turbinado pela hidrelétrica h no estágio i , cenário j

ρ_h é o rendimento da usina h

$g_{i,j}$ é a geração da termelétrica no estágio i , cenário j

2.3.3. Restrição de Balanço Hídrico

Esta restrição representa que o volume de um reservatório ao fim de um determinado período deve ser igual ao volume do reservatório ao início do período acrescido da água aportada ao reservatório e subtraindo-se a água que sai do reservatório neste mesmo período.

É esta restrição que explicita o acoplamento espacial e temporal do problema, visto que:

- O volume final de uma etapa é igual ao volume inicial da etapa seguinte associada a esse cenário;
- A água vertida e turbinada por um reservatório à montante é aportada ao reservatório à jusante.

Figura : Cascata de usinas. Fonte: a autora

Esta restrição é escrita como a seguir:

$$v_{h,i+1,k} = v_{h,i,j} + a_{h,i+1,k} - u_{h,i,j} - \sigma_{h,i,j} + \sum_{m \in M_h} (u_{m,i,j} + \sigma_{m,i,j})$$

Em que:

$v_{h,i,j}$ é o volume inicial da usina h , no estágio i , cenário j

$a_{h,i+1,k}$ é o volume lateral afluente à hidrelétrica h durante o estágio $i+1$, no cenário k

associado ao cenário j da etapa anterior

$\sigma_{h,i,j}$ é o volume vertido pela hidrelétrica h no estágio i , cenário j

M_h é o conjunto de usinas imediatamente a montante da hidrelétrica h

2.3.4. Restrição de atendimento à demanda

No caso de minimização de custo pelo comprador, deve-se obrigar que a energia gerada atenda a demanda de determinada etapa. Esta demanda também é incerta, assim como as afluições, e sua representação é discutida no capítulo 2, item 2. Por simplicidade, haverá, a título de exemplo, apenas um valor de demanda associado a cada cenário de afluição. Esta restrição é, então, representada como:

$$e_{i,j} \geq D_{i,j}$$

Em que:

$D_{i,j}$ é a demanda da etapa i , cenário j

Restrições de capacidade

As variáveis de decisão deste problema estão associadas a limites físicos de capacidade.

Temos então que:

- As variáveis de volume estão restritas pela capacidade máxima do reservatório:

$$v_{h,i,j} \leq v_{max_h}$$

- As variáveis de turbinamento estão restritas pela capacidade máxima das turbinas:

$$u_{h,i,j} \leq u_{max_h}$$

- As variáveis de geração das termelétricas estão restritas pela capacidade máxima de

geração:

$$g_{i,j} \leq g_{max}$$

As restrições acima formam o conjunto básico de fatores que serão considerados neste trabalho. Como foi dito, elas podem apresentar diferenças de representação dependendo do modelo. Além disso, será discutida, no capítulo 3, outra classe de restrições que dizem respeito à aversão ao

risco do tomador de decisão utilizando o modelo, mas ela não é apresentada por ora dado que o risco pode ser medido de diversas formas, algumas das quais serão mostradas.

3. Aspectos fundamentais da relação oferta-consumo de energia

Muitos dos aspectos que servem como parâmetros ou dados dos modelos que serão estudados apresentam incertezas, e por isso são amplamente estudados na literatura. Os estudos se referem a métodos para estimá-los, métodos para medir a sensibilidade do modelo a variações em seus valores e avaliação do risco que é introduzido por elas. As variáveis que serão discutidas neste presente trabalho são:

- Valores de afluência em cada usina. Este valor se refere basicamente a uma previsão da água que será aportada à usina através da chuva em uma determinada etapa, e claramente não é possível obter valores exatos desta para um período futuro.

- Valores de demanda. A demanda energética em um período futuro é uma variável incerta e que depende de diversos fatores, portanto, os valores que são utilizados fazem parte de um método de previsão de demanda.

- Valores dos preços spot. No caso do problema de maximização de renda, os preços spot são dados do problema, incertos porque dependem da solução dual do problema de minimização de custos.

3.1. Afluências

A série de afluências em um determinado período de estudo é uma série temporal estocástica, dado que as afluências podem ser consideradas uma família de variáveis aleatórias indexadas pelo tempo. As séries temporais geralmente não são estáveis, especialmente na área de hidrologia. As séries hidrológicas são influenciadas por inúmeros fatores, como a condição do tempo, evaporação, fator humano, etc, com variações aleatórias e sazonais [2].

CHENG-PING *et. alli* [2] citam como técnicas comuns para a previsão de séries temporais hidrológicas:

- Modelo auto-regressivo (AR),
- Modelo auto-regressivo de média móvel (ARMM),
- Redes neurais artificiais (RNA),
- *Grey Theory*,
- *Support vector machine*, etc.

Segundo os autores, os modelos AR e ARMM são adequados apenas para séries temporais estacionárias e possuem boa precisão apenas para previsões em curto prazo. Já as RNAs são boas para lidar com relações não lineares, mas possuem alguns inconvenientes como o encontro de pontos ótimos locais e a necessidade de uma amostra muito ampla para o estudo.

É apresentado [3] o modelo de séries temporais AR(1) para a variável Z_t , que representa a afluência em um estágio:

$$Z_t = \alpha + \phi_k Z_{t-1} + \epsilon_t$$

Em que:

α e ϕ_k são parâmetros do modelo a serem ajustados

ϵ_t é uma sequência iid de distribuição $N(0, \sigma^2)$

Em [4], encontramos uma explicação da modelagem do ARMM. De forma resumida, um processo estacionário $(X_t)_{t \geq 0}$ é chamado de processo ARMM(p,q) se for verificada a seguinte igualdade:

$$\phi_k X_{t-k} = Z_t + \sum_{m=1}^q \theta_m Z_{t-m} \\ X_t - \sum_{k=1}^p \psi_k X_{t-k}$$

O processo (Z_t) deve ser um ruído branco com média zero e desvio padrão σ constante. Os passos principais consistem então em determinar a ordem p da parte auto-regressiva e q da parte de média móvel e em estimar os coeficientes (BROCKWELL *et al*

(1991) apud [4]). Abordagens comuns para a estimação dos coeficientes utilizam a Probabilidade-Máxima e variantes do método dos mínimos quadrados.

Já o modelo de GT (MGT) se aplica apenas quando os dados originais são não-negativos e mudam através de uma lei exponencial, mas é mais adequada para resolver questões de falta de informação do processo de predição, diminui a aleatoriedade de fatores de distúrbio dos dados históricos e revela a regularidade da série temporal histórica [4]. O modelo SVR, por sua vez, é derivado da teoria de aprendizado estatístico e baseado na minimização do risco estrutural, possui boa habilidade de generalização, e ainda consegue alcançar boas características estatísticas mesmo na condição de muito menos amostras estatísticas [4].

Em [4], os autores combinam métodos do MGT com o SVR para criar um novo modelo de previsão de séries temporais hidrológicas.

O modelo de GT lida com sistemas com falta de informação, e utiliza um espectro de cor preto-cinza-branco para descrever sistemas complexos cujas características são apenas parcialmente conhecidas ou conhecidas com incerteza. No *Grey System*, o processo técnico de geração de dados é um conceito chave para obter uma série de dados mais regular a partir da série de dados original. Ele possui três métodos frequentemente utilizados: geração de média, operação de geração acumulada (OGA) e operação de geração acumulada invertida (OGAI).

O modelo desenvolvido pelo autor baseia-se nos seguintes pontos: a geração de sequências GT é melhor em lidar com amostras pequenas do que outros métodos, e ao mesmo tempo, diminui a influência de fatores de distúrbio aleatório entre as amostras, e ainda revela o padrão da série temporal histórica. Após o processamento, pode-se obter uma sequência “gray” com uma lei exponencial crescente que é mais benéfica para o estudo da SVR. Já a SVR possui como um dos pontos negativos um maior erro na fase de treinamento e um maior tempo de treinamento, de forma que a precisão da predição não é elevada, portanto é vantajoso o estudo de uma sequência já tratada anteriormente. De fato, os resultados do artigo mostraram uma melhor precisão do novo modelo se comparado com o SVR e RNA.

Em [5], é dito que uma abordagem comum para a geração de cenários de afluência é considerar a aleatoriedade das afluências segundo a sua função de distribuição e aplicar técnicas de otimização clássicas como o SDP, que será explicado posteriormente no presente trabalho.

Em [6], é utilizado um modelo para a geração de cenários hidrológicos chamado Modelo Periódico Auto-regressivo, PAR (p), em que os parâmetros apresentam um comportamento periódico baseado nas estações secas e chuvosas. Em geral, p é um vetor, em que cada elemento representa a ordem de cada período.

Técnicas baseadas neste modelo foram aplicadas de forma bem-sucedida para o planejamento energético de sistemas hidrotérmicos reais, como o Brasil, e são capazes de representar a sazonalidade e a dependência serial e espacial das afluências, produzindo cenários sintéticos de afluências [7].

O modelo PAR(p) é matematicamente descrito por:

$$\left(\frac{Z_t - \mu_m}{\sigma_m} \right) = \varphi_1^m \left(\frac{Z_{t-1} - \mu_{m-1}}{\sigma_{m-1}} \right) + \varphi_2^m \left(\frac{Z_{t-2} - \mu_{m-2}}{\sigma_{m-2}} \right) + \dots + \varphi_{p_m}^m \left(\frac{Z_{t-p_m} - \mu_{m-p_m}}{\sigma_{m-p_m}} \right) + a_t$$

Em que:

Z_t representa a séries de afluências

t indexa o tempo $t = 1, 2, \dots, sN$, em que N é o números de anos de estudo e s é o número de períodos sazonais no ano (tipicamente $s=12$)

m indexa os períodos sazonais, $m = 1, 2, \dots, s$

μ_m é a média sazonal do período m

σ_m é o desvio padrão do período m

φ_i^m é o i -ésimo coeficiente auto-regressivo do período m

p_m é a ordem do operador do período m

a_t série de ruídos independentes com média 0 e variância $\sigma_a^{2(m)}$

Em [7], encontramos o modelo PAR(p) aplicado para encontrar o modelo de geração de aflúências e utilizá-lo na simulação Monte Carlo, que possui como objetivo capturar a incerteza das aflúências durante o horizonte de planejamento. O cenário de aflúência é multivariado, com um componente para cada usina, e pode ser gerado através da simulação de Monte Carlo.

Os estimadores dos parâmetros do modelo PAR(p) estão sujeitos a variações aleatórias, já que são função de fenômenos aleatórios, o que significa que, além da incerteza nas aflúências, também há incertezas nos parâmetros estatísticos que não são capturadas no modelo PAR(p) padrão [7].

Os modelos PAR(p) para aflúência são comumente utilizados em hidrologia. A sazonalidade em médias mensais e desvios padrões são considerados através de meios para a padronização mensal das aflúências. Este modelo é atraente principalmente porque a variância e autocorrelação das aflúências anuais são também preservadas, o que é desejável para um sistema de regularização para diversos anos como o Brasil.

A ordem do modelo auto-regressivo univariado em relação à aflúência mensal da usina é escolhida de forma que o termo de erro do modelo seja um ruído branco, ou seja, não haja uma estrutura de correlação nos resíduos do modelo. Os parâmetros são estimados de forma a preservar as correlações seriais correspondentes das aflúências.

Devido ao comportamento positivo das aflúências, não pode ser assumida uma distribuição normal neste modelo. É considerada então uma distribuição marginal lognormal a 3 parâmetros, em que cada parâmetro (μ , δ e Ψ) é escolhido de forma a preservar os parâmetros históricos da usina (média da aflúência e desvio padrão) e garantir aflúências positivas, respectivamente. Os autores assumem um modelo univariado PAR(1), por simplicidade, mas afirmam que o desenvolvimento posterior pode ser estendido para maiores ordens.

Para a execução da simulação Monte Carlo, o parâmetro Ψ é calculado de forma a garantir uma aflúência positiva. As equações para seu cálculo estão em [7] mas serão omitidas neste trabalho.

Os autores apresentam os passos para a simulação Monte Carlo baseada no modelo PAR(1) univariado, que são:

1. Utilizar um gerador Gaussiano pseudo-aleatório para obter um erro;
2. Estimar o limite inferior Ψ ;
3. Calcular a média e o desvio padrão da variável aleatória w_m ;
4. Estimar o ruído branco que garante uma afluência positiva;
5. Obter o valor da afluência transformando-o de volta ao domínio lognormal e perfil

mensal.

Segundo os autores, o uso de modelos estocásticos representando as possíveis trajetórias das afluências está sujeito a dois principais tipos de erros: a incerteza na escolha de uma distribuição de probabilidades e a incerteza na estimação de parâmetros. Como os parâmetros, neste modelo, são determinados apenas considerando-se os dados históricos de afluência, pode haver um viés nas séries sintéticas de afluência quando se assume que os parâmetros da população são iguais aos parâmetros da amostra. Para avaliar o erro desta estimação, a técnica mais comum é computar o intervalo de confiança do estimador, que pode ser calculado através de fórmulas clássicas ou técnicas de reamostragem como *Jackknife* ou *Bootstrap*.

Quanto às redes neurais, elas são explicadas em [4]. Elas são modeladas com base em princípios básicos de funcionamento do cérebro humano, consistindo em diversos “neurônios”, que recebem informação de outros “neurônios” de input e agregam esta informação. Desta forma, é determinado se o “neurônio” deve ser ativado e assim propagar a informação para outros “neurônios”. As Redes Neurais Artificiais (RNA) foram largamente sugeridas para a análise de séries temporais devido à sua habilidade em lidar com relações não lineares entre input e output [5].

Encontramos em [5] e [8] a combinação das RNAs com Sistemas de Inferência Fuzzy, dando origem às Redes Neurais Fuzzy (RNF).

Em [8], encontramos um esquema geral de Sistema de Inferência Fuzzy (FIS):

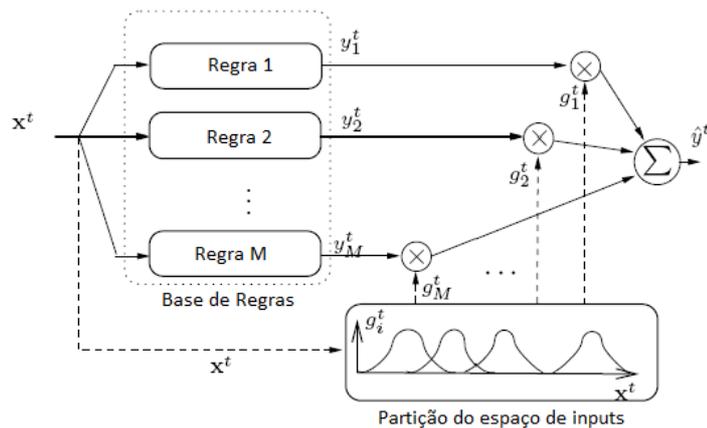


Figura : Sistema de Inferência Fuzzy. Fonte: adaptado de [8]

Em linhas gerais, podemos dizer que o espaço de inputs é particionado em M sub-regiões, e através de funções de pertencimento, cada input x^t terá um grau de pertencimento g_i^t a cada uma dessas sub-regiões. Através de uma regra para cada espaço, os outputs locais y_i^t são calculados e o output \hat{y}^t é calculado através da soma dos outputs locais multiplicados pelo grau de pertencimento g_i^t . O espaço de outputs é geralmente também particionado, e um output terá um determinado grau de pertencimento a cada um desses espaços. Posteriormente, há uma etapa de difuzzificação, geralmente através do método de cálculo do centroide.

Assim, as RNF representam um método que une a capacidade de aprendizado, associação e computação paralela com a habilidade de representação de conhecimento e racionalização da lógica fuzzy.

Em [5], utiliza-se o modelo de rede neural fuzzy adaptativa, em que os parâmetros essenciais para a modelagem de um sistema fuzzy, como as regras fuzzy e funções de pertencimento a um grupo, são aprendidos através de um método de aprendizado construtivo.

Em [8], avaliam-se duas abordagens distintas para a obtenção das sequências de previsão de afluência. Na primeira, chamada FIS-M, doze modelos FIS diferentes são ajustados, um para cada mês do ano. Na segunda, chamada FIS-A, reduz-se o erro da previsão em longo prazo através de uma estratégia de previsão “top-down” (TD).

A abordagem da FIS-A prevê a agregação de doze amostras de aflúências mensais futuras (a aflúência agregada para o próximo ano) através do ajuste de 12 modelos diferentes em uma base anual. Os resultados da previsão devem ser, então, posteriormente desagregados nas estimativas mensais, o que é feito utilizando-se os fatores de contribuição históricos de cada mês no ano, com base nos valores da média em longo prazo.

Em [9], a motivação para o estudo da previsão de aflúências não foi o estudo do despacho energético em longo prazo, mas os impactos de enchentes e secas na China para atividades econômicas e prevenção de desastres. O modelo de previsão neste trabalho considera que as séries temporais podem ser divididas em 3 subsequências: o termo periódico, o termo de tendência e o termo residual.

$$P(t) = P_s(t) + P_T(t) + P_R(t)$$

O termo periódico reflete mudanças cíclicas como o impacto de fatores climáticos, geologia, fenômenos de atividades humanas. Os parâmetros são baseados em estatísticas dos anos da última década ou mais anos, constituindo um “ano climático” com a representação das médias dos dados mensais. O termo de tendência reflete a mudança de elementos hidrológicos através do tempo t , causada por fatores humanos, e para seu cálculo, é feito um modelo de análise separado para o mesmo mês em anos diferentes.

Quanto ao termo residual, deve ser feita uma análise para determinar se a diferença da sequência residual não é caótica. Se, após retirados os termos de periodicidade e tendência, a sequência for caótica, os autores aplicam um sistema de inferência de rede neural fuzzy auto-adaptativa para ajustar e prever a sequência caótica remanescente.

3.2. Demanda

A demanda, assim como a aflúência, pode ser representada como uma série temporal estocástica. Previsões de demanda precisas são importantes tanto para a operação do sistema energético no dia-a-dia (previsões de curto prazo) quanto para decisões de investimentos (previsões

de longo prazo). Além disso, o fato de que o mercado é hoje desregulado faz com que estas previsões sejam ainda mais importantes, visto que, do lado do fornecedor, uma demanda subestimada pode levar a altos custos operacionais porque a demanda adicional deve ser suprida através da compra de energia no mercado, enquanto uma demanda superestimada leva ao desperdício de recursos escassos [4].

A previsão de demanda é fundamental para a previsão dos preços da energia, dado que ela é um dos principais fatores na decisão de preços. Visto que a previsão da demanda é importante para muitas tomadas de decisão no problema de planejamento energético, estudos sobre a análise e previsão de demanda remontam 1966 (Heinemann et al, 1966, apud [4]).

Em [4], os modelos e métodos para a previsão de demanda são agrupados em dois grupos: modelos e métodos que seguem uma abordagem mais clássica, ou seja, que aplicam conceitos vindos da análise de séries temporais e regressão, e métodos que pertencem ao campo de Inteligência Computacional e Artificial.

As previsões podem ainda ser divididas pelo seu horizonte de tempo: previsões em curto prazo geralmente são para a previsão da demanda de até uma semana à frente, que até agora têm sido o principal foco devido à sua importância na operação dos sistemas energéticos no dia a dia. No entanto, com o mercado desregulado, a previsão em maiores horizontes de tempo, como em médio prazo, passou a ganhar uma maior importância. Segundo González-Romera *et al apud* [4], as previsões a médio prazo (de uma semana a um ano) auxilia as negociações de contratos entre as companhias. Horizontes de tempo de mais de um ano são geralmente chamados de longo prazo, e segundo Kyriakides *et al* (2007) *apud* [4], estes horizontes são tipicamente de 20 anos, apesar de poderem ser encontrados horizontes de 25-30 anos.

As diferenças de horizontes são importantes na escolha do modelo e métodos a serem utilizados e nos dados disponíveis e selecionados. Como há diversos fatores que influenciam a demanda, como condições climáticas (por exemplo, em dias muito frios e muito quentes há um aumento na demanda por conta do uso de aquecedores e condicionadores de ar) e causas

socioeconômicas, além da escolha do modelo a ser utilizado, devem ser determinados os fatores externos que são importantes.

Em Kyriakides *et al* (2007) *apud* [4], existem três grupos principais de dados de input para a previsão a curto-prazo: variáveis de inputs sazonais, variáveis de previsão de tempo, e dados de demanda históricos. Para a previsão em médio prazo, geralmente são incorporados fatores econômicos e demográficos, e para a previsão em longo prazo, devem ser considerados ainda mais indicadores econômicos e demográficos, por exemplo, a taxa de crescimento da população e o PIB.

As séries temporais possuem geralmente três ciclos sazonais: um ciclo diário, um semanal (geralmente, devido à demanda industrial, a demanda energética é maior em dias úteis) e um anual.

Abordagens estatísticas requerem um modelo matemático explícito que forneça a relação entre a demanda e diversos fatores de input. Para o fim de previsão de demanda, são utilizados diversos modelos, como modelos de regressão, modelos de séries temporais, filtros de Kalman, etc. Em [4], foca-se nos modelos baseados em regressão e séries temporais.

Modelos baseados em regressão são usados para modelar a relação entre a demanda e fatores externos, como o clima, informação de calendário (por exemplo, férias, horário de verão), ou tipos de consumidores, como dito em Feinberg *et al* (2005) *apud* [4]. Geralmente é utilizada uma regressão linear, apesar de que a influência da temperatura é modelada de forma não linear, e geralmente possui uma curva em U, com picos tanto em dias muito frios quanto em dias muito quentes.

Segundo Kyriades *et al apud* [4], pode não ser simples identificar o modelo correto a ser ajustado devido à natureza não linear e complexa da relação entre a demanda e os fatores que a influenciam. Em [4] é citado ainda, como exemplo, o trabalho de Hor *et al.* (2005), onde foi desenvolvido um modelo de regressão múltipla e analisado o impacto de variáveis climáticas na demanda da Inglaterra e País de Gales. Eles usaram dados de 1989 a 1995 para o treinamento do modelo e os dados de 1996 a 2003 para testar a sua precisão.

O modelo de Hor *et al.* foi baseado em dois tipos de variáveis de input: fatores climáticos (temperatura, velocidade do vento, chuva, umidade relativa, horas de sol) e fatores socioeconômicos (em seu modelo, apenas o PIB). Eles analisaram inicialmente a relação entre a demanda e a temperatura e encontraram uma dependência não linear, e para lidar com ela, eles introduziram diversas variáveis derivadas, com o objetivo de adaptar modelos lineares. Como resultado, eles propuseram três modelos de regressão, e encontraram uma boa precisão em todos, em termos de erro percentual absoluto médio.

Quanto aos modelos utilizados em séries temporais, são citados em [4] os modelos auto-regressivos de média móvel (ARMM), cujos princípios já foram explicados no presente trabalho, no capítulo 2, item 1.

O modelo ARMM pode ser estendido para os modelos de auto-regressão de média móvel integrada (ARMMI), para lidar com o fato de que a situação modelada não é estacionária. Este modelo pode ser representado por

$$\phi(B)(1-B)^d X_t = \theta(B) Z_t$$

O parâmetro d deve ser um inteiro. Estes modelos são lineares univariados geralmente utilizados para previsões de curto prazo.

Por exemplo, Amjady *apud* [4] utilizou um modelo ARMMI modificado para prever a demanda horária e os momentos diários de pico no horizonte de curto prazo. Seu modelo considera as demandas passadas e também as estimativas das demandas passadas. Ele identificou quatro padrões diários diferentes nos dados de demanda do Irã, e ainda separou os modelos em dias quentes (acima de 23) e dias frios. No total, foram utilizados 16 modelos, e os parâmetros foram estimados utilizando dados de 1596 a 1597 e testados nos dados de 1598. Os modelos estimados se mostraram satisfatórios em termos de erro percentual absoluto médio.

Taylor *et al.* (2006) *apud* [4] apresentaram uma comparação entre diversos métodos univariados para a previsão de demanda em curto prazo. Os métodos escolhidos foram: o modelo

ARMMI duplo sazonal (ciclo diário e semanal), suavização exponencial para a dupla sazonalidade, rede neural artificial e um método de regressão com análise de componente principal (ACP). A comparação foi baseada em duas séries temporais: a demanda horária para o Rio de Janeiro em 1596 e a demanda de meia hora da Inglaterra e País de Gales em 2000. O método de suavização exponencial foi considerado o melhor método em termos de erro percentual absoluto médio.

Em relação aos modelos do campo de Inteligência Artificial, assim como no caso das afliências, as redes neurais podem ser aplicadas para a previsão de demanda. Existem diversos subtipos de redes neurais, e na previsão de demanda, as redes neurais mais frequentemente utilizadas são as de “feed-forward”, também chamadas de perceptron multicamada (Hippert *et al.*, 2001, 2005; Gonzalez-Romera *et al.*, 2006; Becalli *et al.*, 2004; Ringwood *et al.*, 2001). Uma rede deste tipo consiste em diversas camadas de “neurônios” sucessivas com uma camada de input, diversas camadas escondidas e uma camada de output. Os neurônios são conectados através de vetores com um peso atribuído e não existem conexões intracamada nem feedback.

Nesta rede, a função de ativação de um neurônio i é aplicada aos outputs dos neurônios de input, multiplicados pelos seus pesos e somados, subtraindo-se uma componente de viés, ou seja

$$y_i = a \left(\sum_{k=1}^n w_{ik} x_k - \theta_i \right)$$

O procedimento de aprendizado ou de ajuste dos pesos é uma propagação de trás para frente, ou seja, o erro é propagado de trás para frente os pesos são ajustados desta forma (Bishop, 1995 *apud* [4]).

Hippert *et al.* (2005) *apud* [4] fizeram uma comparação de grandes redes neurais com diversas abordagens clássicas, desde métodos bastante simples até a combinação de filtros com regressão linear, além de modelos híbridos de filtros com redes neurais. O resultado encontrado foi um melhor desempenho das grandes redes neurais em termos de erro percentual absoluto médio.

Além dos métodos mencionados neste trabalho, abordagens híbridas para a previsão de demandas também são muito comuns.

3.3. Preços

A questão da determinação dos preços no mercado está intimamente associada à determinação dos dados de afluência e demanda, e por isso está sendo discutida neste capítulo, a partir do trabalho desenvolvido em [10]. Os autores explicam que, no Brasil, os preços estabelecidos por contrato pagos aos operadores das usinas hidrelétricas são baseados nos preços duais da equação de oferta-demanda, resultado do modelo de programação dinâmica estocástica dual, que será explicado posteriormente neste trabalho. Ainda, é afirmado que, nos anos recentes, houve uma instabilidade não explicada dos preços duais, o que levou a flutuações semanais significativas do preço pago aos geradores.

Os autores possuem como objetivo mostrar que a separação dos cenários de afluências em clusters leva a uma maior estabilidade dos preços no planejamento hidrelétrico, mais especificamente, os preços duais relacionados ao primeiro estágio da simulação. A formação de clusters consiste na partição dos dados de forma que os dados em um subgrupo estejam mais próximos uns dos outros, de acordo com alguma medida de distância definida.

Por conta do grande esforço computacional para a resolução de programas estocásticos, há muitos trabalhos publicados sugerindo formas de diminuir as árvores de cenários que serão simuladas, como o uso de métricas de probabilidade (por exemplo, Dupacova *et al. apud* [10]), a formação de clusters de séries temporais univariadas através de funções de distância (Hochreiter *et al. apud* [10]), entre outros. Além disso, há outros métodos que tomam amostras de grandes árvores no tempo de solução (por exemplo, Alonso-Ayuso *et. al apud* [10]).

Neste trabalho, os autores utilizam o modelo de PAR(p) para simular os diferentes cenários. Com a formação de clusters com estes cenários, são obtidas árvores de cenários que

podem ser usadas como input para o modelo de otimização estocástica. Apesar de que há na literatura diversos métodos propostos para compactar as árvores de cenários sem perder os valores da função objetivo e da solução das variáveis, isso não é verdade para o resultado das variáveis duais associadas, o que torna o trabalho em [10] diferenciado visto que seu foco é nas variáveis duais, que estão relacionadas ao preço da energia.

Os autores levantam ainda diversas razões para a falta de estudos na literatura sobre as variáveis duais do primeiro estágio. Uma razão é a dificuldade de generalização dos resultados analíticos que relacionam os preços duais às suas árvores de cenário correspondentes. Outra é que, devido à discretização de distribuições multivariadas contínuas em árvores de cenário discretas, o problema estocástico é degenerado, o que dificulta a compreensão da relação entre os preços duais e suas árvores de cenários. Para estudar essa relação, os autores propõem um estudo computacional, a partir do pressuposto de que estudos do tipo podem levar a evidências experimentais úteis na compreensão desta relação.

Os autores utilizam um algoritmo recursivo para a geração de árvores de cenários através da formação de clusters. A conversão de séries temporais em árvores de cenários está associada a um trade-off entre a representação suficiente da diversidade de dados e a preocupação em não gerar uma árvore de cenário muito grande que torne o esforço computacional muito alto e até impossível de ser solucionado.

O objetivo da divisão de clusters era enfatizar as diferenças entre pontos que estão no início do período de estudo, e isso foi alcançado através da normalização das séries temporais seguida da atenuação de observações mais distantes do tempo, através da diminuição monotônica dos pesos associados. Após a formação dos clusters terminar em um determinado estágio t , os dados associados a este estágio são retirados de forma a não afetar a formação de clusters em estágios posteriores.

Após testes computacionais, os autores chegaram às seguintes conclusões:

- Para um número de estágios fixo, o aumento do número de nós finais da árvore de cenários no último estágio resulta em menores preços duais.

- Para um número fixo de estágios e nós finais, o aumento do número de nós em um estágio intermediário resulta em menores preços duais.

- Para um número fixo de nós finais, o aumento do número de estágios resulta em maiores preços duais.

Além disso, através dos resultados obtidos, eles puderam concluir que a geração de cenários em árvore baseada em cluster, em tamanho suficiente (segundo os autores, pelo menos com 32 clusters no estágio 2) é um método viável para a estabilização dos preços duais do primeiro estágio.

4. Medidas de risco

Os modelos de otimização utilizados para o problema de despacho energético otimizam o custo (minimização) ou a renda (maximização) na média, ou seja, podem haver cenários com resultados significativamente diferentes que se compensam na média. O objetivo de uma abordagem de aversão ao risco na formulação é limitar valores altos de custos a um determinado nível de probabilidades [3].

Existem diversas medidas de risco possíveis de serem aplicadas, mas elas devem atender as condições de coerência. De acordo com Artzner, P. apud 40, uma função $\rho: \mathbb{R}^n \rightarrow \mathbb{R}$ é uma medida de risco coerente se ρ satisfizer os seguintes axiomas para Z_1 e $Z_2 \in \mathbb{R}^n$:

- Convexidade:

$$\rho(\alpha Z_1 + (1-\alpha)Z_2) \leq \alpha \rho(Z_1) + (1-\alpha)\rho(Z_2), \text{ para } \alpha \in [0,1];$$

- Monotonicidade:

$$\text{Se } Z_1 \leq Z_2, \text{ então } \rho(Z_1) \leq \rho(Z_2)$$

- Homogeneidade Positiva:

$$\text{Se } c \in \mathbb{R} \text{ e } c > 0, \text{ então } \rho(c Z_1) = c \rho(Z_1)$$

- Equivariância de translação:

$$\text{Se } c \in \mathbb{R} \text{ e } c > 0, \text{ então } \rho(c + Z_1) = c + \rho(Z_1)$$

Em [11], encontramos um estudo com a aplicação de três abordagens diferentes para medir o risco, que são amplamente utilizados, e que são: Receita Mínima (RMin), “Value-at-risk” (VaR) e “Conditional Value-at-risk” (CVaR).

O primeiro indicador, RMin, consiste na imposição de um valor mínimo aceitável de receita para a distribuição estocástica de cenários de receitas. Como a exigência de que todos os cenários ou certa parcela grande deles tenham uma renda mínima pode ser impossível de ser atendida, esta restrição é implementada nos algoritmos através de uma variável de violação, que corresponde à diferença entre a receita de um cenário e a receita mínima imposta, caso a primeira seja menor do que a segunda, e vale zero caso contrário. Este termo é adicionado à função objetivo através de uma penalização.

Matematicamente, essa penalização é representada pela substituição, na função objetivo, dos custos $c^T X_t$ por funções:

$$f_t(x_t) = c_t^T x_t + \phi_t [c_t^T x_t - \theta_t]^+$$

Em que θ_t representa o limite mínimo e ϕ_t representa a penalidade por unidade excedida.

O segundo indicador, VaR, consiste na imposição de que, dado um α geralmente pequeno, todos os custos pertencentes ao $(1-\alpha)$ -ésimo percentil da distribuição decrescente de custos com variável aleatória Z sejam menores do que um determinado valor u , ou, analogamente, todas as receitas pertencentes ao $(1-\alpha)$ -ésimo percentil da distribuição crescente de receitas com variável aleatória Z sejam maiores do que um determinado valor u . No entanto, pode ser mostrado que esta medida não respeita a condição de sub-aditividade e não é convexa. Esta condição, para o caso de custos, é apresentada sob forma de equação, por exemplo em [12], como a seguir e representada graficamente como a figura em seguida.

$$VaR_{1-\alpha}[Z] = \inf_u \{u : Pr(Z \leq u)\} \geq 1 - \alpha$$

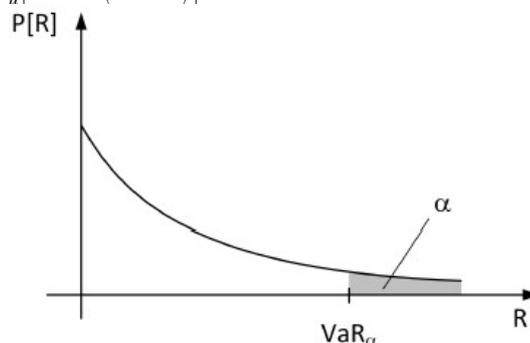


Figura : Representação Grafica do VaR para custos. Fonte: [12]

Como o VaR é uma restrição que considera apenas o $(1 - \alpha)$ -ésimo percentil de maiores receitas (ou seja, as menores receitas do α -ésimo percentil podem assumir qualquer valor pequeno), enquanto a RMin considera o α -ésimo percentil de menores receitas (nenhuma receita pode ficar abaixo de RMin), a otimização utilizando a restrição de controle de risco de RMin resulta em receitas menores do que utilizando o VaR equivalente como medida de risco, dado que a última restrição é mais relaxada.

O CVaR é uma extensão do indicador VaR que garante o atendimento das condições para ser considerado uma medida de risco coerente. Dado um α geralmente pequeno, a CVaR impõe uma condição mínima para o valor esperado das receitas pertencentes ao α -ésimo percentil da distribuição crescente de receitas.

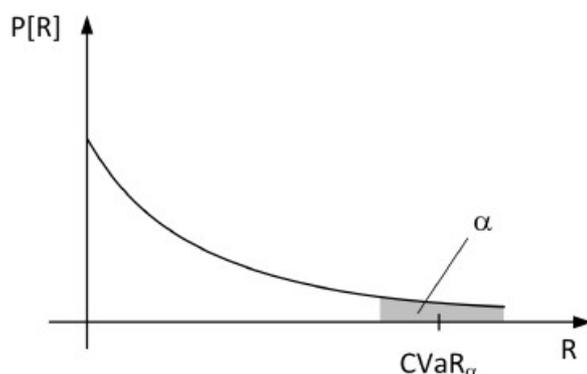


Figura : Representação gráfica do CVaR. Fonte: [1]

Estas três medidas apresentadas são as principais associadas ao estudo de risco no contexto do planejamento energético, mas outros indicadores podem ser usados e há trabalhos publicados desenvolvendo novos indicadores. Por exemplo, em [12] é feito um estudo sobre a combinação do custo total esperado com o CVAR, utilizando então a seguinte medida de risco:

$$p(Z) = \beta E[Z] + \gamma CVaR_{1-\alpha}[Z]$$

Pode-se observar que a medida acima atende aos três primeiros axiomas da medida de risco coerente e, para atender a quarta, deve-se ter que $\beta = 1 - \gamma$.

A conclusão dos autores é que essa medida de risco pode ser incorporada ao modelo de programação dinâmica dual estocástica com a redução da probabilidade de resultados insatisfatórios sem uma grande degradação no custo total.

5. Representação do rendimento

Na apresentação geral do modelo e das restrições, vimos que a restrição de balanço energético consiste em:

$$e_{i,j} = \sum_{h=1}^H \rho_h u_{h,i,j} + \sum_{tm=1}^{TM} g_{tm,i,j}$$

Fisicamente, o parâmetro ρ_h depende do volume do reservatório, visto que o fator de rendimento de cada unidade de volume turbinada é função da altura de queda (uma maior altura significa uma maior quantidade de energia produzida por volume). Encontramos, por exemplo, em [13], que a função que define ρ_h em função do tempo é:

$$\rho_{i,h} = \gamma \eta(v_{i,h}, v_{i+1,h}, r_{i,h}) h(v_{i,h}, v_{i+1,h})$$

Em que:

γ é o peso específico da água

η é a eficiência turbina/gerador como função da cabeça média e do turbinamento no período i

h é a altura de queda líquida

Vemos então que a restrição de balanço energético, quando a função rendimento é representada desta forma, não é linear, e portanto não pode ser diretamente incluída para a otimização em programação linear.

Uma das soluções adotadas para contornar a não linearidade da restrição é considerar que o rendimento é função da razão entre a capacidade instalada da hidrelétrica C_h e a capacidade máxima de turbinamento, multiplicada por uma constante B_h , como mostrado abaixo [13]. O

efeito do nível do reservatório no rendimento só pode ser negligenciado quando a diferença entre os níveis mínimo e máximo do reservatório é pequena comparada ao nível máximo do reservatório.

$$\rho_{i,h} = B_h \times \frac{C_h}{u_{max_h}}$$

Em [13], utiliza-se a aproximação da energia produzida por uma hidrelétrica por envoltória convexa. Neste método, a função da energia produzida por uma determinada hidrelétrica é aproximada por hiperplanos. A ideia do algoritmo de envoltória convexa é calcular, dado um número finito de pontos, a fronteira do conjunto convexo mínimo contendo estes pontos. No caso, a ideia é aproximar os pontos representando a geração de energia das hidrelétricas.

Por conta da não convexidade da restrição de balanço energético, a incorporação desta restrição de forma não linear torna impossível a aplicação de métodos de resolução do problema como a programação dinâmica dual estocástica (PDDE) que será apresentada no capítulo 6 deste trabalho [14].

Em [14] é encontrada uma proposta para tornar esta restrição convexa a partir da técnica de Relaxamento Lagrangeano (GEOFFRION (1974) apud [14]). A ideia do autor é utilizar o modelo bilinear para a função de produção e substituir esta relação bilinear pelo envelope de McCormick. A explicação desta proposta será apresentada em linhas gerais a seguir.

A aproximação de McCormick considera uma função bilinear $z = xy$ com $x \in [\underline{x}, \bar{x}]$ e $y \in [\underline{y}, \bar{y}]$ e a substitui pelo seu envelope convexo, definido pelas restrições a seguir:

$$z \geq x \bar{y} + \bar{x} y - \bar{x} \bar{y}$$

$$z \geq x \underline{y} + \underline{x} y - \underline{x} \underline{y}$$

$$z \leq x \bar{y} + \underline{x} y - \underline{x} \bar{y}$$

$$z \leq x \underline{y} + \bar{x} y - \bar{x} \underline{y}$$

Para aumentar a precisão da aproximação, divide-se o domínio da função em retângulos ainda menores e calcula-se a aproximação de McCormick para cada célula. Aplica-se então uma

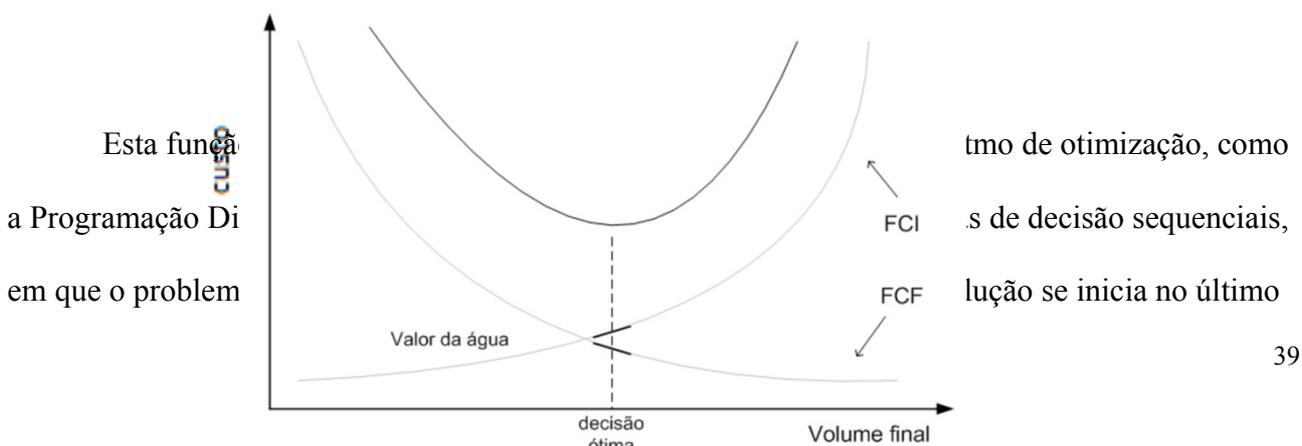
técnica de programação inteira para escolher apenas uma das células, onde z está contido. Logo, esta técnica pode ser aplicada à função de produção de energia, visto que ela é bilinear.

Os autores aplicaram esta técnica de aproximação em um caso real obtido do sistema espanhol. Eles compararam os resultados da evolução dos reservatórios do sistema quando o rendimento é constante e quando a não linearidade é considerada a partir do modelo proposto. Foi observado que a consideração da não linearidade leva a maiores volumes armazenados, com o objetivo de aumentar o rendimento e com isso diminuir o custo ou aumentar a renda.

6. Revisão dos métodos para abordagem do problema

O modelo mais simples para a representação do problema de despacho em longo prazo já foi apresentado e se refere à criação de uma árvore de cenários e criação de um conjunto de restrições para cada nó da árvore. É fácil ver que o número de restrições aumenta exponencialmente com o número de estágios simulados, e por isso este método só pode ser implementado em casos suficientemente pequenos. Com isso, foram desenvolvidos diversos modelos que oferecem um menor esforço computacional, alguns dos quais serão descritos a seguir.

Em [15], encontramos um resumo sobre alguns modelos que foram desenvolvidos para este fim. Uma das formas que foram encontradas para avaliar o impacto das decisões do presente no futuro é estimar uma função de custo/renda futuro(a), e assim o problema se resumiria a encontrar o ponto ótimo para minimizar/maximizar a soma entre o custo/renda do presente e o custo/renda da função de custo/renda futuro(a). Essa situação, para o caso do custo, pode ser representada pelo gráfico a seguir, em que FCF é a função de custo futuro e FCI é a função de custo imediato:



estágio de decisão, com uma recursão no tempo, e a solução ótima em cada estágio é um balanceamento da decisão neste estágio e nos estágios futuros.

Dentro deste grupo estão os métodos de Programação Dinâmica Estocástica (PDE), Programação Dinâmica Dual Estocástica (PDDE), reservatórios agregados, Método de Programação Dinâmica de Aproximações Sucessivas (PDAS), entre outros. A Programação Dinâmica Incremental e a Programação Dinâmica Diferencial também podem ser usadas para casos determinísticos, mas, como estamos tratando o caso estocástico, não serão abordadas neste trabalho.

Recentemente, a PD foi integrada a outros algoritmos, geralmente incluindo técnicas de heurística, como a programação neurodinâmica, algoritmos genéticos, e Otimização por Enxame de Partículas. Alguns destes modelos já foram abordados neste trabalho para a estimação dos cenários de demanda e afluência. Uma das desvantagens dessas metodologias é que, se não houver um bom conhecimento do sistema, a solução não converge a uma solução ótima [13].

Programação Dinâmica

Como o planejamento da operação em longo prazo é um problema estocástico, a PD aplicada ao problema deve ser estocástica. Este modelo é implementado da forma descrita a seguir ([1], [15], [17]).

Dado um estágio t , otimiza-se para cada um dos L cenários de afluências e M cenários de volumes iniciais das hidrelétricas, sujeito às restrições já descritas de balanço energético, balanço hídrico e restrições de capacidade, a seguinte função objetivo:

$$\alpha_t^l(v_t^m) = \text{Min } c_t e_t + \alpha_{t+1}(v_{t+1})$$

Em que:

l é o índice do cenário de afluência, $1 \leq l \leq L$

m é o índice do cenário de volume inicial, $1 \leq m \leq M$

$\alpha_{t+1}(v_{t+1})$ é o valor da função de custo futuro no ponto v_{t+1}

O processo é iniciado no último estágio, em que, claramente, a função de custo futuro vale zero. Após todos os cálculos, temos que o valor da função de custo futuro em determinado estágio t e para um determinado ponto de discretização de volumes m é calculado como:

$$\alpha_t(v_t^m) = \sum_{l=1}^L p_l \times \alpha_t^l(v_t^m)$$

Em que:

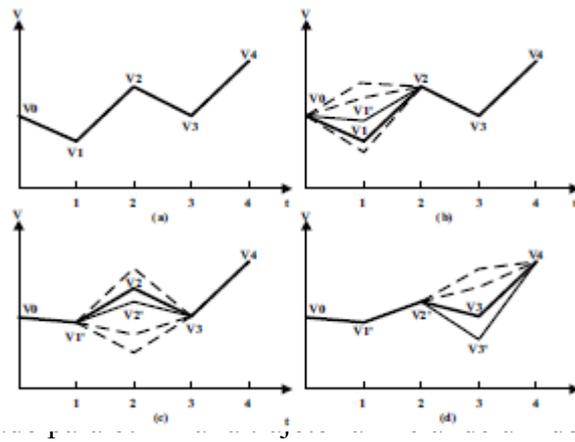
p_l é a probabilidade associada ao cenário de afluência l

A partir destes valores, a FCF em função dos volumes é encontrada por interpolação.

No entanto, é necessária, neste processo, a enumeração de um número muito grande de variáveis de estado (afluências e volumes iniciais) para uma representação adequada da FCF, e portanto o esforço computacional aumenta exponencialmente com o número de variáveis de estado [1]. Este crescimento é conhecido como a “maldição da dimensionalidade”.

Para lidar com a “maldição da dimensionalidade”, um dos métodos propostos foi o método de reservatórios agregados. Os reservatórios agregados são uma estimativa da geração de energia de um grupo de hidrelétricas com características de afluência similares, ou seja, um grupo de hidrelétricas é modelado como um único reservatório equivalente, reduzindo drasticamente a dimensão do problema [13].

Outro método proposto foi o de aproximações sucessivas. No método de Programação Dinâmica com Aproximações Sucessivas (PDAS), um reservatório é otimizado por vez, assumindo fixas as operações dos outros reservatórios [15]. Em [16], encontramos este método associado ao Algoritmo de Otimização Progressiva (AOP). Este algoritmo é um algoritmo de otimização gradual que utiliza o princípio de que cada decisão de dois estágios é a melhor em relação à sua decisão terminal e inicial. É apresentada uma figura ilustrativa deste método, para um reservatório, em que o período de estudo é dividido em quatro intervalos e os volumes inicial e final do período são conhecidos.



O algoritmo pr

s passos:

1. O PDAS é u
essas estratégias são tc

o para cada reservatório, e
os;

2. O AOP é us

reservatórios, enquanto os

outros mantém sua trajetória inicial;

3. O AOP é usado para otimizar a trajetória inicial de outro reservatório, enquanto os outros mantém a trajetória inicial exceto o reservatório otimizado na etapa anterior, cuja trajetória é como a otimizada;

4. A otimização prossegue até que o último reservatório tenha sua trajetória otimizada, considerando as trajetórias otimizadas de todos os outros;

5. Os passos 2, 3 e 4 são repetidos até que a condição de convergência seja atendida, que é:

$$\left| \frac{E(k+1) - E(k)}{E(k)} \right| \leq \varepsilon$$

Em que $E(k)$ é a capacidade de potência da cascata para a k -ésima rodada do cálculo iterativo, e ε é um número positivo pequeno. O estudo em um caso real em usinas do rio Hanjiang mostram que este método traz melhores resultados do que outros métodos, como a PDE.

Encontramos em [15] uma proposta de aproximação da FCF através do algoritmo de envoltória convexa, cuja ideia geral já foi apresentada no capítulo 4. Em cada estágio, o despacho ótimo é calculado para cada discretização do espaço de estados, e o conjunto de pontos encontrado é usado no algoritmo de envoltória convexa. O conjunto de hiperplanos assim obtido será usado como uma aproximação linear por partes das FCFs em cada estágio. A partir de simulações, os autores concluíram que é possível encontrar a operação ótima com a metodologia proposta, quando são considerados reservatórios agregados.

Programação Dinâmica Dual Estocástica (PDDE)

O modelo PDDE, proposto por Pereira, M.V.F. *et al* (1991) *apud* [1] é bastante utilizado na prática e apresenta uma importante evolução dos algoritmos anteriores de PD. Neste algoritmo, não é necessária a construção de uma aproximação linear por partes da FCF a partir de uma extensa discretização do espaço, o que, como foi visto, demanda um grande esforço computacional e está sujeito à “maldição da dimensionalidade”.

Em linhas gerais, o algoritmo funciona da seguinte forma: assim como no caso da PD, o problema é resolvido para cada estágio, iniciando no último estágio onde a FCF vale zero. Ele é resolvido para M discretizações de afluências e volumes iniciais. A diferença para o algoritmo da PD é que, ao encontrar os M valores de FCF correspondentes às discretizações, ao invés de uma interpolação ser realizada, as M soluções são aproximadas por M hiperplanos, os chamados cortes de Benders (Benders, J.F., 1962 *apud* [1]). Isso é possível visto que a FCF é convexa, e, portanto, estes cortes representam uma aproximação subestimada desta função e uma envoltória convexa.

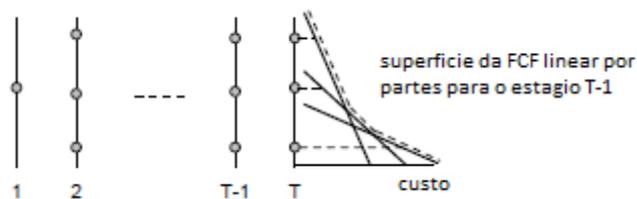


Figura : Construção da FCF linear por partes. Fonte: adaptado de [17]

Os coeficientes dos cortes de Benders são calculados através das variáveis duais do problema, visto que elas podem ser interpretadas como uma derivada da função objetivo no ponto de discretização M em relação a uma variação dos limites das restrições.

Explicitamente, a função de custo da última etapa T em função do volume inicial e afluência na mesma etapa, $\alpha_T(v_T, a_T)$, é aproximada pelos cortes de Benders da seguinte forma:

$$\alpha_T(v_T, a_t) = \max \beta$$

Sujeito a

$$\begin{aligned} \varphi_{Tim}^v v_{ii} + \dot{\iota} \sum_{i=1}^I \varphi_{Tim}^a a_{ii} \\ \beta \leq \delta_{Tm} + \sum_{i=1}^I \dot{\iota} \end{aligned} , \quad m=1,\dots,M$$

Em que I é o número de hidrelétricas, e os coeficientes dos planos são calculados da seguinte forma:

$$\begin{aligned} \varphi_{Tim}^v = \gamma_{im} \quad , \quad \varphi_{Tim}^a = \gamma_{im} \quad , \\ \delta_{Tm} = w_{Tm} - \sum_{i=1}^I \dot{\iota} \end{aligned}$$

Em que γ_{tim} é o multiplicador de Lagrange (ou variável dual) associado à restrição

de balanço hídrico para a usina i , no m -ésimo ponto de discretização e w_{im} é o valor da

função objetivo no estágio t , no m -ésimo ponto de discretização.

Desta forma, para a etapa anterior, a FCF será representada pelos M planos calculados. A partir de um procedimento análogo, em cada etapa haverá M planos representando a FCF. Esta é chamada a etapa “backwards” do algoritmo. Na simulação do primeiro estágio, em que os dados de volume inicial e afluência são determinísticos, o resultado obtido para a função objetivo é um limite inferior para a função de custo, visto que a FCF é subestimada pelas aproximações.

Para encontrar um limite superior, é executada a etapa “forward” do algoritmo, a partir de uma simulação Monte Carlo [17]. Definem-se N cenários de ruídos de afluências $\{\xi^n\}$

$(\xi^n)_{t=1, \dots, T-1}$, $n=1, \dots, N$ para cada estágio $t=1, \dots, T-1$. Cada cenário é definido através do

sorteio dos valores possíveis para cada estágio das variáveis ξ de acordo com suas probabilidades (os valores de ξ são equiprováveis).

Logo, serão resolvidas N seqüências de problemas forward para $t = 1, \dots, T$. Para cada uma dessas trajetórias o volume final do estágio t é igual ao volume inicial no estágio $t+1$ para $t = 1, \dots, T-1$ e faz-se o somatório do valor encontrado de $c_t e_t^n$ para $t=1, \dots, T$, que representa o custo gerado em cada etapa:

$$\sum_{t=1}^T c_t e_t^n = z^n$$

Uma média dos custos encontrados é feita, levando ao valor esperado do custo, representando um limite superior visto que é uma operação viável mas ainda não otimizada.

Calcula-se a diferença entre os limites superior e inferior e, caso supere uma tolerância previamente definida, é feito um refinamento para novas estimações de β . Valores naturais para esse refinamento são os volumes encontrados como resultado da simulação forward.

Algoritmo Genético (AG)

O algoritmo genético é um algoritmo de busca com base na seleção natural e genética. Uma população de soluções candidatas é gerada aleatoriamente, cobrindo todo o espaço de soluções viáveis. No caso em estudo em [18], um indivíduo possui a seguinte forma:

$$[N_{var}] = [R_{1,1}, R_{2,1}, \dots, R_{I,1}; \dots; R_{1,t}, R_{2,t}, \dots, R_{I,t}; \dots; R_{1,T}, R_{2,T}, \dots, R_{I,T}]$$

Em que:

$R_{i,t}$ é a quantidade de água turbinada do reservatório i na etapa t

I é o número de reservatórios no sistema considerado

T é o número de períodos no horizonte de estudo

$[N_{var}]$ é o conjunto de genes formando um indivíduo da população

N_{var} é o número total de genes em um cromossomo

Os valores de armazenamento de cada reservatório são em seguida calculados, através da equação de balanço hídrico.

Cada indivíduo, geralmente também chamado de cromossomo, da população individual possui um valor de adequação, que é um parâmetro através do qual avalia-se se o indivíduo deve ou não “sobreviver” na próxima “geração”. Os indivíduos selecionados para a próxima geração são utilizados para formar novos indivíduos, a partir das operações de *crossover* e mutação. Espera-se que os valores de adequação cresçam a cada geração.

No caso dos sistemas hidrotérmicos, no modelo apresentado em [18], o valor de adequação corresponde ao valor da função objetivo do membro em questão (considerando também os termos de penalidade quando houver violação de alguma restrição). Uma das técnicas para a seleção dos indivíduos para a próxima geração utilizadas é o operador “*Roulette Wheel Selection*”. Nesta técnica, calcula-se a razão entre o valor de adequação do indivíduo e a soma dos valores de adequação de toda a população, e esta razão é considerada a probabilidade de sobrevivência do indivíduo. O número de indivíduos em cada geração se mantém constante, logo, os indivíduos com maior valor de adequação irão eventualmente dominar a população.

O operador de *crossover* consiste em compartilhar informações entre indivíduos, o que é considerado o operador de busca principal nos algoritmos genéticos, dado que explora as informações disponíveis.

O operador de mutação, no algoritmo genético, é aplicado aleatoriamente com baixa probabilidade e modifica elementos nos indivíduos. O papel deste operador é geralmente visto como uma garantia de que a probabilidade de buscar qualquer indivíduo nunca será zero e para eventualmente recuperar indivíduos que tenham sido perdidos através da ação de seleção e *crossover*.

No estudo feito em [18], o algoritmo foi inicialmente aplicado a um caso multi-reservatório de referência com um ótimo global conhecido, e o resultado alcançado pelo modelo foi adequado para este ótimo global. Posteriormente, o código foi aplicado a um caso real de reservatórios nos Estados Unidos, também com resultados satisfatórios.

Em [19], os autores propõem um método que consiste em uma combinação do Algoritmo de Otimização Caótica (AOC) com o AG. Os autores afirmam que, ao aplicar o AG para a resolução de problemas de grande escala e complexos, é necessário um número muito grande de iterações para alcançar o ótimo global e a solução pode ficar presa a um ótimo local.

O caos é um fenômeno geral em sistemas não lineares caracterizado pelo fato de que possui uma sensibilidade tão grande que uma pequena mudança das condições iniciais pode levar a uma grande mudança no sistema, e apresenta um número infinito de diferentes respostas periódicas. Ele possui características como ergodicidade, regularidade, aleatoriedade e a aquisição de todos os tipos de estados em uma “auto regra” em um determinado intervalo.

A ideia do AOC é transformar as variáveis de problemas do espaço de soluções para o espaço caótico, e então executar a busca para encontrar a solução utilizando-se das características de aleatoriedade, regularidade e ergodicidade da variável caótica. Apesar de que este método possui vantagens como a facilidade de escapar do valor mínimo local e a aceleração da busca por conta da redução do espaço de busca por “onda transportadora”, ele não se utiliza da informação experimental adquirida anteriormente.

Os autores adotam duas medidas para melhorar o desempenho do AG. A primeira consistem em adotar o AOC para gerar a população inicial e a segunda é a utilização da operação de mutação caótica “*annealing*” substituindo o operador de mutação, de forma a evitar que a busca fique presa a um ótimo local.

A primeira medida é interessante pelo fato de que a convergência do problema é importante para a população inicial, visto que boa parte dos indivíduos está longe da solução ótima. A partir de uma população inicial aleatória, é feita uma busca no espaço caótico e após um tempo determinado de iteração, são escolhidos os n indivíduos de maior valor de adequação para se tornarem a população inicial.

Para um desempenho adequado do algoritmo, é necessária uma alta probabilidade de *crossover* (geralmente entre 0.5 e 0.8), uma baixa probabilidade de mutação (geralmente entre 0.001

e 0.1) e uma população de tamanho moderado. Os resultados obtidos por este algoritmo foram melhores do que a utilização do AG tradicional.

Em [20], os autores propõem uma combinação do chamado Algoritmo de Evolução Diferencial (AED) com o *shuffled frog leaping* (SFL). O AED é uma técnica de busca estocástica que utiliza operações similares a um algoritmo genético, sendo iniciado com uma população aleatória, e possuindo operações de mutação, crossover e seleção.

Ele nasce da ideia de se utilizar de um vetor de diferenças para perturbar cada indivíduo da população da seguinte forma: dois membros da população são selecionados aleatoriamente, sua diferença calculada e ponderada por um fator denominado peso de diferenciação, e este vetor de diferenças ponderado é somado a um terceiro indivíduo aleatoriamente escolhido. O crossover ocorre através da mistura de componentes entre o vetor obtido e um quarto vetor aleatório, e, caso o vetor assim gerado possua um valor de adequação maior, ele é selecionado.

Este algoritmo possui a desvantagem de que a solução pode ficar facilmente presa a um ótimo local, já que a informação de diferença entre os indivíduos se torna menor com o aumento do número de iterações.

O SFL é um algoritmo de inteligência por enxame de partículas que foca em estratégias de busca tanto global quanto local. A população é particionada em diferentes grupos chamados de memplex, buscas independentes locais são feitas simultaneamente em cada grupo, e os “frogs” são periodicamente misturados e reagrupados em novos memplex, até que um critério definido de convergência seja atingido.

O algoritmo proposto então é da seguinte forma: a população é dividida em memplex que são misturados de forma periódica. Em cada memplex, o indivíduo é atualizado com a evolução diferencial. Ele foi aplicado às usinas da cascata de Três Gargantas e concluiu-se que ele apresenta uma rápida convergência, evitando os ótimos locais e evitando a “maldição da dimensionalidade”.

Otimização por Enxame de Partículas (OEP)

Este algoritmo de otimização também é baseado no conceito de população como os anteriores. Ele simula as atividades de busca de alimento de um enxame de pássaros (partículas), e cada partícula possui sua própria posição e velocidade, e os indivíduos evoluem através da cooperação e competição entre si através das gerações [21].

A partir de parâmetros ω , c_1 e c_2 calculados previamente, e da escolha de dois números aleatórios r_1 e r_2 (de distribuição uniforme em $[0,1]$) a velocidade V_i^{k+1} do indivíduo e a posição X_i^{k+1} é atualizada para a próxima interação a partir das fórmulas abaixo:

$$V_i^{k+1} = \omega^{k+1} V_i^k + c_1 r_1 \times (P_{mi}^k - X_i^k) + c_2 r_2 \times (G_m^k - X_i^k)$$

$$X_i^{k+1} = X_i^k + V_i^{k+1}$$

Em que:

P_{mi}^k é a melhor posição do indivíduo i até a k -ésima iteração

G_m^k é a melhor posição entre todas as partículas até a k -ésima iteração

ω^{k+1} é o peso de inércia na $(k+1)$ -ésima iteração

O peso de inércia é utilizado para balancear entre a busca global (grande peso de inércia) e a busca local (pequeno peso de inércia). O valor de adequação é o valor da função objetivo adicionado a penalidades por violação de restrições (caso de minimizar os custos).

Em [21], encontramos uma combinação entre a OEP e o sistema fuzzy, cuja lógica já foi descrita no capítulo 2, item 1 do trabalho. O sistema fuzzy é utilizado para adaptar dinamicamente o peso de inércia.

Os inputs do sistema fuzzy são o fator de velocidade de evolução, que é calculado como

$$G_m^k / G_m^{k+1},$$
 e o desvio padrão do valor de adequação das partículas na etapa k . O output do

sistema fuzzy é a mudança do peso de inércia.

O modelo foi aplicado ao caso de usinas no rio Wuxi, na China, e os resultados foram comparados com a aplicação do modelo OEP e PD. Os resultados mostraram que o algoritmo pode melhorar a eficiência computacional e produzir outputs mais satisfatórios.

Em [22], os autores aplicam o modelo OEP na usina Três Gargantas, também se utilizando de uma adaptação dinâmica dos pesos de inércia, e concluíram que esta adaptação efetivamente melhorou o algoritmo e levou ao encontro de uma solução ótima global de forma rápida e estável.

7. Modelo implementado: operação conjunta de usinas hidroelétricas pertencentes a diferentes agentes em ambientes competitivos

7.1. Motivação pela questão de poder de mercado

Uma das dificuldades de aumentar a competição, a partir de privatizações, de um sistema com forte participação hidrelétrica é que uma única usina pode representar uma parcela substancial da produção total do país. Este é o caso, por exemplo, de El Cajón em Honduras e Itaipu no Brasil. Neste caso, a venda da usina para um agente privado pode trazer problemas, já que este agente passa a ter poder de mercado.

Em [23], os autores afirmam que a existência de uma hidrelétrica com um grande reservatório pode impor restrições à competição em um mercado aberto. Define-se poder de mercado, neste artigo, como a capacidade de uma empresa aumentar seu preço de forma significativa acima do preço competitivo e manter este preço de forma lucrativa durante um período de tempo considerável.

Em [23], são conduzidas duas simulações. A primeira obtém o equilíbrio de mercado sem que nenhum participante tenha poder de mercado. Já a segunda mostra o efeito da manipulação de um reservatório para aumentar os lucros em um período, através de uma mudança artificial da curva de custo futuro esperado para o grande reservatório, de forma a aumentar os valores.

O resultado obtido é que essa manipulação leva de fato a um aumento dos preços na rede, com um maior uso de outras fontes energéticas além das hidrelétricas. Isso acontece por conta da capacidade de armazenamento do reservatório.

7.2. Motivação pela otimização global de usinas em cascata

Outra dificuldade para o aumento da competição no mercado de energia é que, na maioria dos casos, as usinas estão em “cascata”. Isto significa que se a usina a montante é vendida para o agente A, e a de jusante para o agente B, a estratégia de oferta do agente A, a montante, afetará a operação da usina do agente B, a jusante. Por conta disso, o agente B, ao preparar sua oferta, não somente tem que representar a incerteza dos preços futuros e de sua vazão incremental, porém também deve modelar probabilisticamente a estratégia do agente a montante.

Isto complica bastante o problema e diminui o interesse dos agentes em comprar as usinas [24]. Em alguns casos, a falta de coordenação entre montante e jusante pode ter consequências ainda mais sérias, por exemplo, a violação de restrições operativas como defluência mínima ou máxima, ou volume de espera para controle de cheias.

7.3. Explicação geral do problema

Uma solução engenhosa para este problema é a criação de várias “cascatas” virtuais, uma para cada proprietário, cada qual com uma fração do volume, potência instalada, capacidade de turbinamento, etc. de todas as usinas da cascata real. A ideia é que o proprietário de cada fatia proponha uma operação para sua cascata virtual, e um operador central coordene todas estas propostas e as transforme em um cronograma de despacho para a operação real [24].

Um exemplo de usina com mais de um proprietário é a usina de Salto Grande, que pertence em proporções iguais à Argentina e Uruguai. Outro exemplo é a Bonneville Power Administration, que dividiu a cascata do rio Columbia em 26 fatias [24].

Apresenta-se a seguir um modelo para a operação de cascatas virtuais: se for exigido que cada um dos $n = 1, \dots, N$ participantes (por exemplo, $N = 26$ no caso da BPA) apresente uma

proposta de despacho detalhada para *toda a cascata*, incluindo todas as restrições operativas, porém só fique com uma fração f_n da produção de energia que corresponda à sua fatia ($\sum f_n=1$), teremos N despachos viáveis. Se o problema de despacho for convexo, também sabemos que a *combinação convexa* destes N despachos viáveis, onde f_n é o fator de ponderação, terá duas propriedades: (i) também será viável; e (ii) a energia produzida total poderá atender ao cronograma de produção de energia de cada agente.

No entanto, há uma alternativa mais interessante, que é o operador encontrar uma solução que, além de atender aos pedidos de cada agente, produza uma energia *suplementar*, que geraria uma renda adicional e/ou seria armazenada para uso futuro. No caso de um problema de despacho puramente linear (rendimentos constantes), uma maneira de obter este rendimento “extra” é armazenar a água que seria vertida em uma das cascatas virtuais. No caso em que os rendimentos são uma função côncava do armazenamento, uma estratégia seria manter os volumes finais físicos maiores ou iguais à combinação convexa dos volumes finais das fatias; a razão é a desigualdade de Jensen: a energia produzida pela combinação convexa dos volumes é maior ou igual do que a combinação convexa das energias produzidas pelos volumes de cada fatia.

7.4. Modelo a ser implementado

O modelo que será implementado é o mais simples entre os estudados, visto que a intenção desta implementação é apenas ilustrar questões interessantes a título de exemplo, de forma a compreender melhor o problema e pensar em situações interessantes para que haja este ganho suplementar do operador.

Desta forma, o modelo será baseado na otimização de uma árvore de cenários, com a definição da função objetivo como a apresentada no capítulo 1, item 2. Também não serão incorporados ao modelo os métodos de estimação das afluências, que serão consideradas como dados do problema para cada cenário, com uma probabilidade p associada que também é dada.

Além disso, o rendimento será considerado constante, ou seja, não nos preocuparemos com as questões de não linearidade da restrição de balanço energético, que ocorre quando consideramos o rendimento como função do volume armazenado.

As restrições que serão implementadas para o problema de despacho e que são comuns aos proprietários e ao operador são:

- Restrição de balanço energético
- Restrição de balanço hídrico
- Restrições de capacidade

A restrição de demanda não se aplica a este caso, de maximização do rendimento. Está implícito nesta modelagem que não há um problema de falta de demanda: enquanto for interessante vender energia, ela poderá ser vendida. Os preços spot de venda podem variar para cada cenário de uma mesma etapa, o que implicitamente significa, geralmente, que em cenários de baixas afluências, o preço da unidade de energia é mais caro. Além disso, os preços spots podem ser diferentes para cada proprietário, no caso em que a energia é vendida em mercados distintos. Os preços spots para cada etapa e período também são dados do problema.

Para os proprietários, é adicionada também uma restrição de aversão ao risco. A medida de risco que foi escolhida para ser implementada é o CVaR.

Para o operador, a primeira restrição que deve ser adicionada é que ele precisa atender a demanda dos proprietários, ou seja, deve entregar a eles a energia que eles decidiram produzir em determinado período. Essa restrição é expressa como:

$$e_{ots} \geq \sum_{i=1}^N e_{its}$$

Em que:

e_{ots} é a energia gerada pelo operador na etapa t , cenário s

e_{its} é a energia demandada pelo proprietário i na etapa t , cenário s

N é o número de proprietários

Deve-se notar que e_{its} já corresponde à parcela de energia real atribuída ao proprietário, ou seja, o resultado de seu planejamento multiplicado pela sua parcela de posse f_n .

Além disso, para garantir que o operador será capaz de atender aos pedidos dos proprietários nas etapas subsequentes, impõe-se que o volume das usinas reais seja maior ou igual do que a combinação convexa dos volumes das usinas virtuais. Temos então que, para cada usina h :

$$v_{ohs} \geq \sum_{i=1}^N f_i \times v_{ihts}$$

Outra questão que será simulada é a diferença entre um operador que “olha” para o futuro, ou seja, dada uma oportunidade de geração de energia extra, pode escolher entre gerar na etapa presente ou no futuro, e um operador que não “olha” para o futuro, ou seja, dada uma oportunidade de geração de energia extra, ele sempre irá fazê-lo na etapa presente. Chamaremos este operador de “operador míope”.

Na prática, a operação do operador míope é implementada através de uma otimização separada de cada cenário e estágio, com as mesmas restrições, e o volume inicial de cada etapa e cenário é dado pela solução do problema de otimização da etapa precedente, no cenário correspondente.

Para conduzir as simulações, é necessário fornecer diversos dados que serão utilizados para a formação das restrições e da função objetivo. Estes dados serão descritos em seguida.

Para validar o modelo, inicialmente foi proposto um caso bastante simples, que pode ser resolvido analiticamente de forma trivial. Neste caso, a árvore de cenários de afluência e de preço spot é como abaixo.

7.5. Dados do Modelo

Os dados que são necessários no modelo serão agrupados para sua descrição em categorias, que são: Informações Gerais, Hidrelétricas, Afluências, Preços Spot e CVaR.

Informações Gerais

- Número de etapas do horizonte de estudo
- Número de divisões de cada nó do cenário
- Número de etapas onde há divisões de cenário
- Número de proprietários
- f_n de cada proprietário

Note que a segunda informação é necessária para evitar que, no caso de muitas etapas serem simuladas, a quantidade de cenários parar de crescer a partir de uma determinada etapa.

Hidrelétrica

- Número de hidrelétricas

Para cada hidrelétrica :

- Índice da hidrelétrica
- Rendimento
- Volume máximo
- Volume mínimo
- Volume inicial
- Turbinamento máximo
- Índice da hidrelétrica à jusante

Deve-se observar que uma usina pode possuir diversas usinas à montante, mas há sempre apenas uma usina à jusante.

Afluência

- Valor da afluência para cada etapa, cada cenário e cada hidrelétrica
- Probabilidade de transição de um cenário da etapa t à um cenário da etapa $t+1$

Preço Spot

- Valor do preço spot para cada etapa, cada cenário e cada hidrelétrica

CvaR

- Os α para cada etapa e cada proprietário

- Os η para cada etapa e cada proprietário (se não houver uma restrição de CVaR em uma etapa, o valor de η é 0)

8. Exemplos simulados

8.1. Caso Teste

Para validar o modelo, inicialmente foi proposto um caso simples, que pode ser resolvido analiticamente de forma trivial.

Informações Gerais

- Número de etapas do horizonte de estudo: 3
- Número de divisões de cada nó do cenário: 4
- Número de etapas onde há divisões de cenário: 2
- Número de proprietários: 2
- f_n de cada proprietário: 0.5 cada um

Hidrelétrica

- Número de hidrelétricas: 1

Dados hidro	H1
Índice	1
Volume inicial	0
Rendimento	1
Turbinamento máximo	100
Volume máximo	100
Volume mínimo	0
Índice da hidro a jusante	0

Tabela : Dados da Hidrelétrica

Afluência

A árvore de cenários que representa as afluências e os preços spots associados a cada cenário é como mostrado na tabela a seguir. Considera-se que a probabilidade de transição é a mesma para cada cenário, o que significa que:

$$p(s_{ti}) = \frac{1}{SC_t}$$

Onde :

$p(s_{ti})$ é a probabilidade do cenário i na etapa t

SC_t é o número de cenários na etapa t

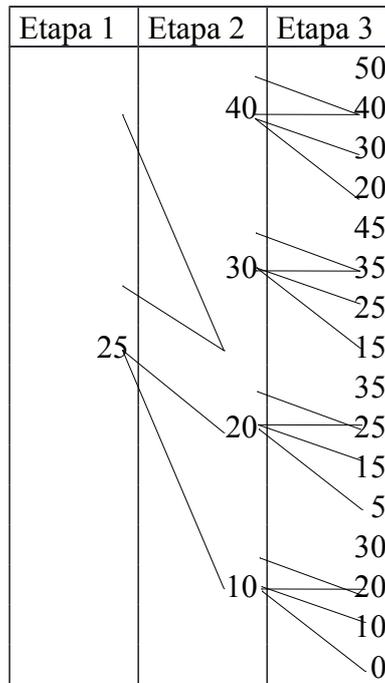


Tabela : Árvore de cenário do caso teste

Preços Spot

Os preços spot, neste caso, são constantes para cada etapa, e são:

Etapa 1	30
Etapa 2	20
Etapa 3	10

Tabela : Preço spot do caso teste

CVaR

- Não há restrições de CVaR ($\eta = 0$ para todas as etapas e proprietários)

Resultados

É fácil perceber que, como os preços spots diminuem a cada etapa, a decisão que vai maximizar a renda é turbinar todo o volume a cada etapa, ou seja, a quantidade de água turbinada em todas as etapas e cenários será igual à afluência desta etapa e deste cenário, e o volume final será sempre zero. Não haverá diferença entre o proprietário 1 e 2 porque não há restrições de CVaR.

Os resultados para um proprietário são apresentados na tabela a seguir.

Etapa	Cenário	Energia produzida	Renda	Renda Esperada
1	1	25	375	375
2	1	40	400	250
	2	30	300	
	3	20	200	
	4	10	100	
3	1	50	250	125
	2	40	200	
	4	20	100	
	5	45	225	
	6	35	175	
	7	25	125	
	8	15	75	
	9	35	175	
	10	25	125	
	11	15	75	
	12	5	25	
	13	30	150	
	14	20	100	
	15	10	50	
	16	0	0	

Tabela : Resultados do caso teste

A renda de uma etapa é dada pela energia produzida multiplicada pelo preço spot da etapa, multiplicada por f_n . O valor da função objetivo encontrada pelo solver Xpress é 750, o que pode ser também verificado analiticamente, uma vez que sabemos que a renda total esperada é:

$$\sum_{t=1}^T EV(r_t) = 375 + 250 + 125 = 750$$

Onde :

$EV(r_t)$ é o valor esperado da renda r na etapa t

8.2. O caso de ganho do operador

Quando o rendimento é modelado como constante, como no caso do modelo desenvolvido, o operador pode gerar uma energia suplementar ao estocar a água que seria vertida em uma entre as cascadas virtuais. No entanto, isso será possível somente no caso em que verifica-se pelo menos uma entre duas condições:

- 1) O volume final de pelo menos um dos proprietários não é igual ao máximo

2) A quantidade de água turbinada por pelo menos um dos proprietários não é máxima

Se nenhuma das duas condições ocorrerem, não haverá espaço para armazenar ou turbinar a água para gerar uma energia suplementar, e a água será vertida também pelo operador na cascata real.

Sabendo dessas condições, um exemplo foi elaborado para mostrar que essas condições podem ser atendidas e, dessa forma, provamos que é possível que haja um ganho para o operador mesmo quando o rendimento é constante.

Informações Gerais

- Número de etapas do horizonte de estudo: 2
- Número de divisões de cada nó do cenário: 4
- Número de etapas onde há divisões de cenário: 1
- Número de proprietários: 2
- f_n de cada proprietário: 0.5 cada um

Hidrelétrica

- Número de hidrelétricas: 1

Dados hidro	H1
Índice	1
Volume inicial	0
Rendimento	1
Turbinamento máximo	30
Volume máximo	100
Volume mínimo	0
Índice da hidro a jusante	0

Tabela : Dados da hidrelétrica

Afluência

A árvore de cenários que representa as afluências e os preços spots associados a cada cenário é como mostrado na tabela a seguir. Considera-se que a probabilidade de transição é a mesma para cada cenário.

Etapa 1	Etapa 2
	0

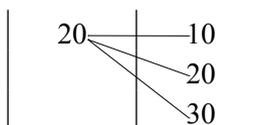


Tabela : Árvore de cenário

Preços Spot

Os preços spot, neste caso, são também constantes para cada etapa, e são:

Etapa 1	20
Etapa 2	10

Tabela : Preço spot para o caso de ganho do operador

CVaR

- Para o primeiro proprietário, não há restrições de CVaR ($\eta = 0$ para todas as etapas)
- Para o segundo proprietário, na etapa 2, $\alpha=0.25$ e $\eta=50$

Resultados obtidos

As colunas de VF (volume final) e Vertido (quantidade de água vertida) foram adicionadas à tabela de resultados para tornar mais clara a situação mostrada. Como o rendimento é igual a 1, a energia produzida é igual ao volume turbinado.

Os resultados do proprietário 1 são como a seguir:

Etapa	Cenário	Energia produzida	Renda	Renda Esperada	VF	Vertido
1	1	20	200	200	0	0
2	1	0	0	75	0	0
	2	10	50		0	0
	3	20	100		0	0
	4	30	150		0	0

Tabela : Resultados do proprietário 1

E os resultados do proprietário 2 são como a seguir:

Etapa	Cenário	Energia produzida	Renda	Renda Esperada	VF	Vertido
1	1	0	0	0	20	0
2	1	20	100	137.5	0	0
	2	30	150		0	0
	3	30	150		10	0
	4	30	150		20	0

Tabela : Resultados do proprietário 2

A partir da análise desses resultados, pode-se prever o ganho que o operador pode obter. Na etapa 2, no cenário 3, o proprietário 2 não utiliza 10 unidades de volume (VF neste estágio),

enquanto o proprietário 1 poderia usar 10 unidades de volume a mais (30-20) para gerar energia .

Como $f_n=0.5$ para os dois proprietários, isso significa, na hidrelétrica real, que o proprietário 1 não utiliza 5 unidades de volume e o proprietário 2 poderia utilizar 5 unidades de volume a mais.

Como resultado, o operador pode gerar uma energia adicional igual a 5 no cenário 3 do estágio 2. De fato, a simulação do modelo para o operador apresentou os seguintes resultados:

Etapa	Cenário	Energia produzida	Renda	Renda Esperada	VF	Verti do
1	1	10	0	0	10	0
2	1	10	0	12.5	0	0
	2	20	0		0	0
	3	30	50		0	0
	4	30	0		10	0

Tabela : Resultados do operador

8.3. Caso de uma cascata com ganho do operador

Neste caso, adiciona-se uma hidrelétrica para analisar o comportamento do sistema. As duas hidrelétricas serão dispostas de forma que uma esteja à montante e outra esteja à jusante de uma mesma cascata. A implicação desta disposição é que a operação da hidrelétrica à montante tem uma influência na operação da hidrelétrica à jusante.

Uma questão interessante que pode ser explorada em um trabalho futuro é o ganho global obtido quando a operação de duas hidrelétricas é calculada em conjunto, comparado com o ganho obtido quando as operações são calculadas separadamente.

O caso escolhido irá somente ilustrar a implementação do modelo para o caso de uma cascata, e mostrar ainda um ganho obtido pelo operador da mesma forma que no caso anterior.

Informações Gerais

- Número de etapas do horizonte de estudo: 2
- Número de divisões de cada nó do cenário: 4
- Número de etapas onde há divisões de cenário: 1
- Número de proprietários: 2
- f_n de cada proprietário: 0.5 cada um

Hidrelétrica

Número de hidrelétricas : 2

Dados hidro	H1	H2
Índice	1	2
Volume inicial	0	0
Rendimento	1	1
Turbinamento maximo	30	30
Volume maximo	100	100
Volume mínimo	0	0
Índice da hidro a jusante	2	0

Tabela : Dados das hidrelétricas

Afluência

As árvores de cenários, uma para cada hidrelétrica, que representam as afluências associadas a cada cenário são como as tabelas a seguir.

Considera-se ainda que a probabilidade de transição é a mesma para cada cenário.

Etapa 1	Etapa 2
20	0
	5
	7
	15

Tabela : Arvore de cenário para a hidrelétrica 1

Etapa 1	Etapa 2
10	0
	2
	4
	10

Tabela : Arvore de cenário para a hidrelétrica 2

Preços Spot

Os preços spot são também constantes para cada etapa, e são:

Etapa 1	20
Etapa 2	10

Tabela : Preços spot

CVaR

- Para o primeiro proprietário, não há restrições de CVaR ($\eta = 0$ para todas as etapas)
- Para o segundo proprietário, na etapa 2, $\alpha=0.25$ et $\eta=250$

Resultados obtidos

Na tabela abaixo, $E(r)$ é o valor esperado da renda, E.P. é a energia produzida e H abrevia hidrelétrica. Os resultados obtidos para o primeiro proprietário são:

Etapa	Cenário	E.P. H1	E.P. H2	Renda	EV(r)	VF(H1)	Vertido(H1)	VF(H2)	Vertido(H2)
1	1	20	30	0	0	20	0	10	0
2	1	0	0	250	277.5	0	0	0	0
	2	5	7	275		0	0	0	0
	3	7	11	285		0	0	0	0
	4	15	25	300		0	0	0	0

Tabela : Resultados do primeiro proprietário

Os resultados obtidos pelo segundo proprietário são :

Etapa	Cenário	E.P. H1	E.P. H2	Renda	EV(r)	VF(H1)	Vertido(H1)	VF(H2)	Vertido(H2)
1	1	0	0	0	0	20	0	10	0
2	1	20	30	250	277.5	0	0	0	0
	2	25	30	275		0	0	7	0
	3	27	30	285		0	0	11	0
	4	30	30	300		5	0	20	0

Tabela : Resultados do segundo proprietário

Nota-se que, neste caso, o operador poderá gerar energia suplementar no cenário 2, 3 e 4 da segunda etapa. De fato, encontra-se através da simulação os seguintes resultados do operador:

Etapa	Cenário	E.P. H1	E.P. H2	Renda	EV(r)	VF(H1)	Vertido(H1)	VF(H2)	Vertido(H2)
1	1	10	15	0	0	10	0	15	0
2	1	10	15	0	28.75	0	0	0	0
	2	15	22	35		0	0	0	0
	3	17	26	55		0	0	0	0
	4	22.5	30	25		2.5	0	17.5	

Tabela : Resultados do operador

8.4. O caso de um ganho diferenciado entre o operador com e sem informação futura

Foi dito anteriormente que o operador que considera as informações das etapas futuras pode escolher, no caso em que há uma oportunidade de gerar uma energia suplementar, se ele irá o fazer na mesma etapa ou se vale a pena estocar a água para gerar a energia em outra etapa.

O primeiro ponto que deve-se notar é que, para que o operador tenha a opção de escolher, é preciso que as condições apresentadas para que o operador possa gerar uma energia suplementar, que são:

- 1) O volume final de ao menos um dos proprietários não é máximo
- 2) O volume de água turbinada por ao menos um dos proprietários não é máximo

Devem se verificar ao mesmo tempo. Se a primeira condição não for atendida, o operador é obrigado a utilizar a água na mesma etapa, e se a condição 2 não for atendida, o operador é obrigado a armazenar a água.

A partir desta observação, encontramos um exemplo simples e ilustrativo onde se verifica um ganho diferenciado entre o operador que considera as etapas subsequentes e o operador que não o faz.

Informações Gerais

- Número de etapas do horizonte de estudo: 3
- Número de divisões de cada nó do cenário: 4
- Número de etapas onde há divisões de cenário: 1
- Número de proprietários: 2
- f_n de cada proprietário: 0.5 cada um

Hidrelétrica

Número de hidrelétricas: 1

Dados hidro	H1
Índice	1
Volume inicial	0
Rendimento	1
Turbinamento maximo	15
Volume maximo	15
Volume minimo	0
Índice da hidro a jusante	0

Tabela : Dados da hidrelétrica

Afluência

A árvore de cenários que representa as afluências associadas a cada cenário é como mostrado na tabela a seguir. Considera-se ainda que a probabilidade de transição é a mesma para cada cenário.

Etapa 1	Etapa 2	Etapa 3
	0	0
15	20	0
	25	0
	30	0

Tabela : Arvore de cenário

Preços Spot

Os preços spot, neste caso, são também constantes para cada etapa, e são:

Etapa 1	30
Etapa 2	20
Etapa 3	10

Tabela : Preços spot

CVaR

- Para o primeiro proprietário, na etapa 2, $\alpha=0.25$ et $\eta=75$, e não há restrições de CVaR para a etapa 3 ($\eta = 0$)
- Para o segundo proprietário, na etapa 2, $\alpha=0.5$ et $\eta=25$, e não há restrições de CVaR para a etapa 3 ($\eta = 0$)

Resultados obtidos

As tabelas com os resultados do primeiro proprietário e do segundo proprietário são mostradas a seguir :

Etapa	Cenário	E.P.	Renda	EV(r)	VF	Vertido
1	1	0	0	0	15	0
2	1	15	75	75	0	0
	2	15	75		15	5
	3	15	75		15	10
	4	15	75		15	15
3	1	0	0	84.375	0	0
	2	15	112.5		0	0

	3	15	112.5		0	0
	4	15	112.5		0	0

Tabela : Resultados do primeiro proprietário

Etapa	Cenário	E.P.	Renda	EV(r)	VF	Vertido
1	1	15	0	150	0	0
2	1	0	0	43.75	0	0
	2	10	50		10	0
	3	10	50		15	0
	4	15	75		15	0
3	1	0	0	75	0	0
	2	10	75		0	0
	3	15	112.5		0	0
	4	15	112.5		0	0

Tabela : Resultados do segundo proprietário

Analisando os resultados, é possível concluir que as duas condições necessárias para que o operador possa escolher em qual estágio gerar a energia suplementar estão presentes somente no cenário 2 do segundo estágio. Neste cenário, o proprietário 2 pode armazenar 5 unidades de volume a mais e pode turbinar 5 unidades a mais.

Como o preço spot do estágio 3 é maior do que o preço da etapa 2, o operador que considera as informações do futuro irá preferir armazenar a água. O operador sem informação irá utilizar a água extra para gerar a energia suplementar no mesmo estágio onde ocorre o vertimento, ou seja, no estágio 2.

De fato, podemos verificar esta situação nos resultados obtidos através da simulação:

Etapa	Cenário	E.P.	Renda	EV(r)	VF	Vertido
1	1	7.5	0	0	7.5	0
2	1	7.5	0	6.25	0	0
	2	12.5	0		15	0
	3	15	25		15	2.5
	4	15	0		15	7.5
3	1	0	0	9.375	0	0
	2	15	37.5		0	0
	3	15	0		0	0

	4	15	0		0	0
--	---	----	---	--	---	---

Tabela : Resultados do operador com informação

Etapa	Cenário	E.P.	Renda	EV(r)	VF	Vertido
1	1	7.5	0	0	7.5	0
2	1	7.5	0	12.5	0	0
	2	15	25		12.5	0
	3	15	25		15	2.5
	4	15	0		15	7.5
3	1	0	0	0	0	0
	2	12.5	0		0	0
	3	15	0		0	0
	4	15	0		0	0

Tabela : Resultados do operador sem informação

Verifica-se que, de fato, a renda do operador que considera o futuro é igual a $6.25 + 9.375 = 15.625$, superior à renda do operador sem informação, que é de 12.5.

8.5. Simulação de um caso real

Após as simulações apresentadas no capítulo 8 terem sido feitas, foi realizado um teste com dados reais. Os dados se referem à usina de Salto Grande que, como já mencionado, pertence à Argentina e ao Uruguai.

Os dados de 1200 cenários de afluência, para 24 estágios ou 2 anos, foram fornecidos, assim como o preço spot correspondente a cada etapa e cenário, para o mercado da Argentina e do Uruguai.

Para que os dados sejam apresentados sob a forma de uma árvore de cenário, o que é necessário para utilizar o modelo desenvolvido, os dados de afluência foram tratados para gerar esta árvore. Escolhemos uma árvore na qual cada cenário de uma etapa é ligado a três cenários da etapa seguinte até a etapa 7, onde existem $3^6 = 729$ cenários. Isso foi feito como a seguir:

- A afluência da primeira etapa é determinística, logo, ela foi calculada como a média de todos os cenários de afluência:

$$a_{11} = \frac{\sum_{i=1}^{1200} b_{1i}}{1200}$$

Em que:

a_{ij} é o dado de afluência referente ao estágio i cenário j da árvore de cenário

b_{ij} é o dado de afluência referente ao estágio i cenário j dos dados originais

- No segunda estágio, as 1200 séries são ordenadas em relação aos valores de afluência do segundo estágio e separadas em três grupos: afluências altas (G1), afluências médias (G2) e afluências baixas (G3). As afluências dos três cenários da etapa 2 são então calculados como a seguir:

$$a_{21} = \frac{\sum_{i \in G1} b_{2i}}{400}$$

$$a_{22} = \frac{\sum_{i \in G2} b_{2i}}{400}$$

$$a_{23} = \frac{\sum_{i \in G3} b_{2i}}{400}$$

- Nos estágios seguintes, o procedimento é análogo ao que será descrito para o estágio 3. As séries que pertencem ao grupo G1 são ordenadas em relação aos valores de afluência da terceira etapa e separadas em dois grupos como anteriormente, G11, G12 e G13. O mesmo é feito para os grupos G2 e G3 e obtém-se, desta forma, o valor dos 9 cenários do estágio 3 calculando-se a média das afluências em cada grupo.

Se o número de series em um grupo não for divisível por 3, os grupos gerados na etapa seguinte a partir deste grupo não terão a mesma quantidade de séries, mas isso não prejudica os resultados.

Os preços spot dos estágios e cenários foram calculados a partir da média dos preços das séries que pertencem aos grupos determinados pelas afluências.

Os dados originais de afluência e de preços spot, assim como os dados da árvore de cenário construída a partir deles, não serão fornecidos visto que é um volume de dados muito grande.

Informações Gerais

- Número de etapas do horizonte de estudo: 24
- Número de divisões de cada nó do cenário: 3
- Número de etapas onde há divisões de cenário: 6
- Número de proprietários: 2
- f_n de cada proprietário: 0.5 cada um

Hidrelétrica

- Número de hidrelétricas : 1

Dados hidro	H1
Índice	1
Volume inicial	0
Rendimento	66.67 MWh/hm ³
Turbinamento maximo	21360 hm ³ /móis
Volume maximo	4402 hm ³
Volume mínimo	0
Índice da hidro a jusante	0

Tabela : Dados da hidrelétrica

CVaR

Não há restrições de CVaR em nenhum estágio ($\eta = 0$)

Resultados obtidos

Os resultados obtidos são também muito numerosos para serem expostos neste trabalho. No entanto, podemos fazer análises que podem mostrar alguns aspectos destes resultados.

A primeira análise que será efetuada é uma comparação entre o cenário de seca (o cenário 1 em todas as etapas, que chamaremos de série 1) e o cenário de maiores afluências (o último cenário de todas as etapas, que chamaremos de série 729).

A tabela a seguir mostra os valores da energia produzida pelo Uruguai na série 1 e na série 729 em todos os estágios, assim como a diferença entre eles e a razão entre a diferença e o valor da série 729.

O gráfico mostra a energia produzida pelo Uruguai nas duas séries, para facilitar a visualização das diferenças.

Etapa	Energia sr1	Energia sr 729	Δ	Δ /Energia sr729
1	177377	177377	0	0
2	424956	1424070	999114	0.701591
3	169419	1248640	1079221	0.864317
4	18322.8	1424070	1405747	0.987133
5	0.00E+00	1424070	1424070	1
6	2.73E+05	1.42E+06	1151373	0.808509
7	205703	1424070	1218367	0.855553
8	768168	1424070	655902	0.460583
9	1129160	973650	-155510	-0.15972
10	1364270	1.42E+06	59800	0.041992
11	1059870	1424070	364200	0.255746
12	1241820	1288160	46340	0.035974
13	388646	398798	10152	0.025456
14	430379	485925	55546	0.11431
15	396334	528846	132512	0.250568
16	463535	561029	97494	0.173777
17	792266	1424070	631804	0.443661
18	843836	1424070	580234	0.407448
19	952079	1.41E+06	461891	0.326663
20	464190	1333450	869260	0.651888
21	556260	1424070	867810	0.609387
22	1424070	1160490	-263580	-0.22713
23	1424070	1424070	0	0
24	1424070	1424070	0	0

Tabela : Resultados do Uruguai

Figura : Gráfico de resultados do Uruguai

A partir da observação da tabela e do gráfico, pode-se concluir que, ao início do período de estudo, a produção de energia foi significativamente diferente entre as duas séries; as produções ao meio do período apresentaram um comportamento similar para as duas séries (um aumento seguido de uma diminuição, e novamente um aumento); as produções no fim do período apresentaram novamente uma grande diferença entre as duas séries.

Fazemos o mesmo para a produção da Argentina. A tabela e o gráfico dos resultados estão abaixo.

Etapa	Energia sr1	Energia sr 729	Δ	Δ /Energia sr729
1	470858	470858	0	0

2	7412.32	1147920	1140507.68	0.993543
3	0	1231310	1231310	1
4	72557.5	1424070	1351512.5	0.949049
5	76685.7	1424070	1347384.3	0.94615
6	435258	1424070	988812	0.694356
7	205703	1424070	1218367	0.855553
8	768168	1424070	655902	0.460583
9	1129160	973650	-155510	-0.15972
10	1293550	1424070	130520	0.091653
11	1424070	1424070	0	0
12	948340	1288160	339820	0.263803
13	388646	398798	10152	0.025456
14	430379	485925	55546	0.11431
15	102852	528846	425994	0.805516
16	757016	561029	-195987	-0.34933
17	792266	1424070	631804	0.443661
18	1137320	1424070	286750	0.201359
19	658598	1413970	755372	0.534221
20	464190	1333450	869260	0.651888
21	556260	1424070	867810	0.609387
22	1424070	1160490	-263580	-0.22713
23	1424070	1424070	0	0
24	1424070	1424070	0	0

Tabela : Resultados da Argentina

Figura : Gráfico dos resultados da Argentina

Observando os resultados da Argentina e comparando-os com os do Uruguai, vemos que o comportamento da produção nas duas séries são similares ao comportamento do Uruguai. Além disso, as quantidades produzidas foram similares, o que é claro observando-se o gráfico a seguir, onde as quatro séries são representadas. As séries 729 da Argentina e do Uruguai são, de fato, coincidentes a partir do estágio 4.

As diferenças entre a produção do Uruguai e da Argentina vêm do fato que os preços spot dos dois não são os mesmos.

Figura : Gráfico dos resultados da Argentina e do Uruguai

Outra observação interessante a fazer diz respeito ao resultado do operador. Foi considerado que um resultado de energia suplementar é significativo quando é maior do que 10000. A partir deste critério, encontram-se 7 cenários onde há uma produção significativa vendida no mercado da Argentina e 13 cenários onde há uma produção significativa vendida no mercado do Uruguai, que estão listados q seguir. O spot1 é o preço spot do mercado da Argentina e o spot 2 é o preço spot do mercado do Uruguai.

	Energia (spot1)	Energia (spot2)
stg7scen15	42152.3	0
stg7scen63	30494.3	0
stg7scen210	63140	0
stg7scen211	28019.7	0
stg7scen342	50632.4	0
stg7scen369	26787.1	0
stg7scen537	53043.2	0

Tabela : Energia suplementar vendida no mercado da Argentina

	Energia (spot1)	Energia (spot2)
stg5scen60	0	17097.9
stg7scen209	0	63139
stg7scen534	0	53044
stg9scen370	0	19674.6
stg9scen371	0	19673.7
stg9scen373	0	32113.6
stg9scen532	0	53045.1
stg9scen533	0	53045.1
stg9scen536	0	53045.2
stg10scen72	0	63067.1
stg10scen208	0	63146
stg10scen372	0	19676.6
stg10scen535	0	53046.2

Tabela : Energia suplementar vendida no mercado do Uruguai

O operador sempre prefere vender a energia suplementar no mercado onde o preço spot é mais elevado.

9. Conclusão

Neste trabalho, foram apresentados, através da compilação de artigos, diversos aspectos que envolvem o planejamento do despacho energético a longo prazo. Foram mostrados parâmetros que representam processos estocásticos e métodos para estimá-los, abordagens para lidar com restrições não lineares (através de sua linearização, representação simplificada ou utilização de métodos de otimização capazes de lidar com não linearidades), representação de aversão ao risco e métodos para lidar com a grande dimensão do problema.

Além disso, foi desenvolvido um modelo em C++ com o objetivo de simular a operação conjunta de hidrelétricas pertencentes a diferentes proprietários. Os resultados obtidos mostraram que, mesmo com um modelo bastante simplificado do problema, é possível uma geração extra de energia a partir da combinação das operações dos diferentes proprietários. Ainda, foi simulado um caso com dados reais da Usina Salto Grande que mostrou que, de fato, é possível que o operador da Usina gere energia extra.

Um desenvolvimento futuro deste trabalho pode incorporar representações mais fiéis dos aspectos relacionados ao problema, assim como adotar métodos de redução do esforço computacional para permitir que casos maiores sejam rodados. Isso poderia ser feito a partir da escolha de representações e métodos que foram apresentados na parte teórica deste trabalho.

Referências Bibliográficas

- [1] JUNIOR, L.C., *Planejamento ótimo da operação de sistemas hidrotérmicos com aversão ao risco*. Exame de Qualificação para o Doutorado – COPPE, 2011.
- [2] CHENG-PING, Z., CHUAN, L., HAI-WEI, G., *Research on Hydrology Time Series Prediction Based on Grey Theory and ε -Support Vector Regression*. Second International Conference on Digital Manufacturing & Automation, 2011.
- [3] SHAPIRO, A., TEKAYA, W., COSTA, J.P., SOARES, M.P., *Risk neutral and risk averse Stochastic Dual Dynamic Programming method*. European Journal of Operational Research 224, 375–391, 2013.
- [4] HAHN, H., MEYER-NIEBERG, S., PICKL, S., *Electric load forecasting methods: Tools for decision making*. European Journal of Operational Research 199, 902–907, 2009.
- [5] ZAMBELLI, M.S., SOARES, S., *A Predictive Control Approach for Long Term Hydrothermal Scheduling*. IEEE, 2009.
- [6] SOUZA, R.C., MARCATO, A.L.M., DIAS, B.H., OLIVEIRA, F.L.C., *Optimal operation of hydrothermal systems with Hydrological Scenário Generation through Bootstrap and Periodic Autoregressive Models*. European Journal of Operational Research 222, 606–615, 2012.
- [7] BEZERRA, B., VEIGA, A., BARROSO, L.A., PEREIRA, M., *Assessment of Parameter Uncertainty in Autoregressive Streamflow Models for Stochastic Long-term Hydrothermal Scheduling*. Power and Energy Society General Meeting, IEEE, 2012.
- [8] ZAMBELLI, M.S., LUNA, I., SOARES, S., *Long-Term Hydropower Scheduling Based on Deterministic Nonlinear Optimization and Annual Inflow Forecasting Models*. IEEE, 2009.
- [9] DING, G., DING, J., *An Improved Hydrological Forecast Method Based on Chaos and Trend Term*. IEEE, 2009.
- [10] LOPES, L., REICH, D., WANG, X., *Clustering to Stabilize Dual Prices in a Stochastic Program for Power Grids*.
- [11] ILIADIS, N.A., PEREIRA, M.V., GRANVILLE, S., CHABAR, R.M., BARROSO, L.A., *Benchmarking of financial indicators implemented in hydroelectric stochastic risk management models*. IEEE, 2006.
- [12] PHILPOTT, A.B., MATOS, V.L., *Dynamic sampling algorithms for multi-stage stochastic programs with risk aversion*. European Journal of Operational Research 218, 470–483, 2012.
- [13] GOOR, Q., KELMAN, R., TILMANT, A., *Optimal Multipurpose-Multireservoir Operation Model with Variable Productivity of Hydropower Plants*. Journal of Water Resources Planning and Management, 2011.

- [14] CERISOLA, S., LATORRE, J.M., RAMOS, A., *Stochastic dual dynamic programming applied to nonconvex hydrothermal models*. European Journal of Operational Research 218, 687–697, 2012.
- [15] DIAS, B.H., MARCATO, A.L.M., SOUZA, R.C., SOARES, M.P., JUNIOR, I.C.S., OLIVEIRA, E.J., BRANDI, R.B.S., RAMOS, T.P., *Stochastic Dynamic Programming Applied to Hydrothermal Power Systems Operation Planning Based on the Convex Hull Algorithm*. Mathematical Problems in Engineering ID 390940, 2010.
- [16] SUN, X., HUANG, Q., *Optimal Operation of the Cascade Hydropower Station Reservoirs in the Upper Hanjiang River*. IEEE, 2011
- [17] **SDDP – Manual da Metodologia, versão 10.2.4** – pertencente à empresa PSR (www.psr-inc.com)
- [18] HINÇAL, O. ALTAN-SAKARYA, A.B., GER, A.M., *Optimization of Multireservoir Systems by Genetic Algorithm*. Water Resources Management, 25:1465–1487, 2011.
- [19] CHENG, C.T. WANG, W.C., XU, D.M. CHAU, K.W., *Optimizing Hydropower Reservoir Operation using Hybrid Genetic Algorithm and Chaos*. Water Resources Management, 22:895–909, 2008.
- [20] LI, Y., Zuo, J., *Optimal Scheduling of Cascade Hydropower System Using Grouping Differential Evolution Algorithm*. International Conference on Computer Science and Electronics Engineering, 2012.
- [21] Wenping CHANG, W., LUO, X., YU, H., *A Fuzzy Adaptive Particle Swarm Optimization for Long-Term Optimal Scheduling of Cascaded Hydropower Station*. IEEE, 2009.
- [22] GUO, W., WANG, H., **Application of Improved PSO Algorithm to Hydropower Station Optimal Operation**. International Conference on Computer Application and System Modeling (ICCASM), 2010.
- [23] VARGAS, L.S. PALMA, R., MOYA, O., TORRES, R., *A Scenário Simulation Approach for Market Power Analysis in Hydrothermal Systems*. Ieee Transactions on Power Systems, vol. 18, no. 3, 2003.
- [24] BARROSO, L.A., GRANVILLE, S., JACKSON, P., PEREIRA, M.V., READ, E.G., *Overview of Virtual Models for Reservoir Management in Competitive Markets*.