



UNIVERSIDADE FEDERAL FLUMINENSE
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
TELECOMUNICAÇÕES

RUAN DUARTE JALES ANSELMO

**Otimização Dinâmica de Portfólio de Energia
Elétrica Utilizando Processos de Decisão de
Markov**

NITERÓI

2023

UNIVERSIDADE FEDERAL FLUMINENSE
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
TELECOMUNICAÇÕES

RUAN DUARTE JALES ANSELMO

Otimização Dinâmica de Portfólio de Energia Elétrica Utilizando Processos de Decisão de Markov

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica e de Telecomunicações. Área de concentração: Sistemas de Energia Elétrica.

Orientador:

Andre Abel Augusto

Coorientador:

Julio Cesar Stacchini de Souza

NITERÓI

2023

Ficha catalográfica automática - SDC/BEE
Gerada com informações fornecidas pelo autor

A618o Anselmo, Ruan Duarte Jales
Otimização Dinâmica de Portfólio de Energia Elétrica
Utilizando Processos de Decisão de Markov / Ruan Duarte Jales
Anselmo. - 2023.
88 f.: il.

Orientador: Andre Abel Augusto.
Coorientador: Julio Cesar Stacchini de Souza.
Dissertação (mestrado)-Universidade Federal Fluminense,
Escola de Engenharia, Niterói, 2023.

1. Comercialização de Energia Elétrica. 2. Otimização
de Portfólio. 3. Processo de Decisão de Markov. 4.
Otimização Dinâmica. 5. Produção intelectual. I. Augusto,
Andre Abel, orientador. II. Souza, Julio Cesar Stacchini de,
coorientador. III. Universidade Federal Fluminense. Escola de
Engenharia.IV. Título.

CDD - XXX

Ruan Duarte Jales Anselmo

Otimização Dinâmica de Portfólio de Energia Elétrica Utilizando Processos de Decisão de Markov

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica e de Telecomunicações. Área de concentração: Sistemas de Energia Elétrica.

Aprovada em 19 de setembro de 2023.

BANCA EXAMINADORA

Andre Abel Augusto

Assinado de forma digital por Andre Abel Augusto aaugusto@id.uff.br:12055365746
DN: cn=Andre Abel Augusto aaugusto@id.uff.br:12055365746, ou=UFF -
Universidade Federal Fluminense, o=ICPEdu, c=BR
Dados: 2023.10.16 17:10:06 -03'00'
Versão do Adobe Acrobat Reader: 2023.006.20320

Prof. Andre Abel Augusto, D.Sc. – Orientador, UFF



Documento assinado digitalmente
JULIO CESAR STACCHINI DE SOUZA
Data: 23/10/2023 08:06:35-0300
Verifique em <https://validar.iti.gov.br>

Prof. Julio Cesar Stacchini de Souza, D.Sc. – Coorientador, UFF



Documento assinado digitalmente
BRUNO SOARES MOREIRA CESAR BORBA
Data: 18/10/2023 21:03:26-0300
Verifique em <https://validar.iti.gov.br>

Prof. Bruno Soares Moreira Cesar Borba, D.Sc. UFF

Andre Luis Marques Marcato

Prof. André Luis Marques Marcato, D.Sc. UFJF

Niterói

2023

Com profundo reconhecimento, dedico esta dissertação a Deus, o autor da minha existência e o sustentador de todas as coisas. Em meio às dificuldades e incertezas, foi a Sua graça que me sustentou, fortaleceu e iluminou o caminho até a conclusão deste mestrado. A Ti, Senhor, expresso minha gratidão eterna. Que este trabalho seja uma maneira humilde de honrar e glorificar o Seu nome.

Agradecimentos

Expresso minha profunda gratidão a Deus, que me guiou e me deu força durante todo o período do mestrado e da escrita desta dissertação. Foi por Sua graça e orientação que pude perseverar e alcançar a conclusão deste mestrado.

Agradeço imensamente à minha esposa, Camilla Anselmo Luna Jales, pela compreensão, paciência e apoio incansável ao longo dessa jornada. Sua presença e encorajamento foram fundamentais para meu sucesso acadêmico.

Meus sinceros agradecimentos à minha mãe, Luciane Duarte Jales, por ter me incentivado desde minha infância a valorizar a educação. Sua dedicação e apoio constante durante meus estudos foram essenciais para minha motivação e perseverança.

Estendo meus sinceros agradecimentos aos demais membros da minha família. Aos meus pais, irmãos e demais familiares pelo amor, encorajamento constante e apoio emocional durante toda a minha jornada acadêmica. Seus gestos e palavras de incentivo me ajudaram a superar os desafios.

Também gostaria agradecer aos meus colegas da Enel e da Elera. Durante os períodos em que precisei me dedicar mais ao mestrado, vocês compreenderam e ofereceram seu apoio e compaixão. Agradeço por compreenderem a importância deste trabalho para mim e por serem uma fonte de encorajamento durante esse período desafiador.

Agradeço aos meus orientadores, Andre Abel Augusto e Julio Cesar Stacchini de Souza, pela paciência, disponibilidade e conhecimentos compartilhados durante a pós-graduação.

Também expresso minha gratidão aos professores do Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da UFF, pela contribuição na minha formação acadêmica e profissional.

Por fim, agradeço a todos os amigos que direta ou indiretamente contribuíram para o desenvolvimento desta Dissertação.

Resumo

Os agentes que atuam no mercado de energia elétrica brasileiro encaram os desafios da alta volatilidade dos preços da energia elétrica. Adicionalmente, os geradores enfrentam os riscos associados à incerteza da geração. Diante deste cenário, as empresas desse setor buscam ferramentas que auxiliem à tomada de decisão, visando aumentar seus resultados financeiros e minimizar os riscos aos quais estão expostas. Nesse contexto, a abordagem de otimização de portfólio tem sido estudada como uma forma de aprimorar a gestão e alcançar os objetivos estratégicos em um ambiente de incertezas. Neste trabalho, um modelo de otimização dinâmica é implementado para definir o volume ótimo de contratação de um portfólio, bem como decidir o melhor momento para construí-lo. Esse processo pode ser dividido em duas etapas. Na primeira, utiliza-se uma abordagem de otimização estática com a técnica de Programação Linear para definir os volumes do portfólio, visando maximizar a receita do portfólio e minimizar o risco ao qual o portfólio está exposto. Enquanto a segunda etapa, emprega-se um Processo de Decisão de Markov para decidir o momento de contratação que maximize os resultados do portfólio e minimize os riscos, levando em consideração a incerteza da variação de preços de mercado. Um estudo de caso foi realizado com dados reais, e os resultados obtidos indicam que a metodologia se mostra adequada, contribuindo para apoiar a tomada de decisão e melhorar os resultados de agentes que atuam no setor de comercialização de energia elétrica brasileiro.

Palavras-chave: Comercialização de Energia Elétrica, Otimização de Portfólio, Otimização Dinâmica, Processo de Decisão de Markov.

Abstract

Agents operating in the Brazilian electricity market face the challenges of high volatility in electricity prices. Additionally, generators face risks associated with generation uncertainty. In this scenario, companies in this sector seek tools that assist in decision-making, aiming to increase their financial results and minimize the risks they are exposed to. In this context, portfolio optimization has been studied in order to improve management and achieve strategic objectives in an environment of uncertainties. In this work, a dynamic optimization model is implemented to determine the optimal volume of portfolio contracts and decide the best timing for their construction. This process can be divided into two stages. In the first stage, a static optimization approach is employed using Linear Programming techniques to determine the portfolio volumes, aiming to maximize portfolio revenue and minimize the associated risk. In the second stage, a Markov Decision Process is used to decide the timing of contracts that maximize portfolio results and minimize risks, considering the uncertainty of market price variations. A case study was conducted with real data, and the obtained results indicate that the methodology is appropriate, contributing to decision-making support and improving the outcomes for agents operating in the Brazilian electricity trading sector.

Keywords: Electricity Trading, Portfolio Optimization, Dynamic Optimization, Markov Decision Process.

Lista de Figuras

2.1	Número de unidades consumidoras no ACL por ano. Fonte: CCEE, 2023. .	10
2.2	Percentual de participação do consumo nos ambientes ACL e ACR por ano. Fonte: CCEE, 2023.	10
2.3	Matriz energética brasileira em 2023. Fonte: ONS, 2023.	10
2.4	Matriz energética brasileira em 2027. Fonte: ONS, 2023.	11
2.5	Balanco Energético valorado ao PLD.	12
2.6	Histórico da média mensal do PLD. Fonte: CCEE, 2023.	15
2.7	Preço médio das operações fechadas na plataforma da BBCE. Fonte: BBCE, 2023.	16
3.1	Modelo de um neurônio. Fonte: Haykin, 2001.	28
3.2	Exemplo de um processo de decisão de Markov.	29
4.1	Ilustração da modelagem do problema estático.	37
4.2	Representação das probabilidades na matriz de transição para o agente que está no estado s e escolhe a ação $a = 1$	47
4.3	Fluxograma da metodologia proposta.	49
5.1	Cenários de PLD utilizados na simulação.	51
5.2	Volume mensal de energia contratado.	51
5.3	Perfil de geração médio das usinas.	52
5.4	Matriz de preços de mercado de energia representados pela média dos preços em cada estado.	53
5.5	Matriz de variações de preços para construção da matriz de estados.	54
5.6	Volumes de energia para cada produto que compõe o portfólio ótimo em cada estado.	55

5.7	Volumes de energia para cada produto que compõe o portfólio ótimo no estado do extremo superior direito.	55
5.8	Volumes de energia para cada produto que compõe o portfólio ótimo no estado do extremo inferior esquerdo.	56
5.9	Equivalentes Certos (ECs) resultantes de cada portfólio ótimo.	56
5.10	VPL do valor em risco do portfólio ótimo em cada cenário de preço.	57
5.11	VPL do valor esperado do portfólio ótimo em cada cenário de preço.	57
5.12	Resultado das iterações do MDP utilizando $\gamma = 0,99$	58
5.13	Resultado das utilidades e recomendação do MDP utilizando $\gamma = 0,99$	60
5.14	ECs esperados para 10 mil simulações considerando $\gamma = 0,99$	60
5.15	Resultado das utilidades e recomendação do MDP utilizando $\gamma = 0,985$	61
5.16	Resultado das utilidades e recomendação do MDP utilizando $\gamma = 0,98$	61
5.17	Resultado das utilidades e recomendação do MDP utilizando $\gamma = 1$	62
5.18	Volumes de energia para cada produto que compõe o portfólio ótimo em cada estado.	63
5.19	Equivalentes Certos (ECs) resultantes de cada portfólio ótimo.	63
5.20	Resultado das iterações do MDP utilizando $\gamma = 0,99$	64
5.21	Resultado das utilidades e recomendação do MDP utilizando $\gamma = 0,99$	65
5.22	Resultados esperados para 10 mil simulações considerando $\gamma = 0,99$	65

Lista de Tabelas

2.1	Limites máximos e mínimos do PLD.	14
5.1	Dados das usinas disponíveis para contratos por capacidade	52
5.2	Produtos disponíveis para compra - contratos por quantidade	53
5.3	Volatilidade dos produtos disponíveis para compra	54

Lista de Abreviaturas e Siglas

ABC	: Colônia Artificial de Abelhas;
ACL	: Ambiente de Contratação Livre;
ACR	: Ambiente de Contratação Regulado;
AG	: Algoritmos Genéticos;
ANEEL	: Agência Nacional de Energia Elétrica;
BBCE	: Balcão Brasileiro de Comercialização de Energia;
CCEE	: Câmara de Comercialização de Energia Elétrica;
CEPEL	: Centro de Pesquisas de Energia Elétrica;
CMSE	: Comitê de Monitoramento do Setor Elétrico;
CVaR	: <i>Conditional Value at Risk</i> ;
EC	: Equivalente Certo;
ENA	: Energia Natural Afluente;
EPE	: Empresa de Pesquisa Energética;
MAE	: Mercado Atacadista de Energia Elétrica;
MCP	: Mercado de Curto Prazo;
MDP	: <i>Markov Decision Processes</i> ;
MME	: Ministério de Minas e Energia;
MRE	: Mecanismo de Realocação de Energia;
ONS	: Operador Nacional do Sistema Elétrico;
PL	: Programação Linear;
PLD	: Preço de Liquidação das Diferenças;
PSO	: Enxame de Partículas;
REE	: Reservatório Equivalente de Energia;
RNA	: Rede Neural Artificial;
SIN	: Sistema Interligado Nacional;
SUIISHI	: Modelo de Simulação a Usinas Individualizadas de Subsistemas Hidrotérmicos Interli
VaR	: <i>Value at Risk</i> ;
VPL	: Valor Presente Líquido.

Sumário

1	Introdução	1
1.1	Revisão da literatura	1
1.2	Objetivo	5
1.3	Contribuições e publicações	6
1.4	Estrutura do trabalho	6
2	Mercado de energia elétrica brasileiro	8
2.1	Matriz energética brasileira	10
2.2	Contratação de energia	11
2.3	Mercado de curto prazo	12
2.4	Preço de liquidação das diferenças	13
2.5	Preços de contratos futuros no mercado de energia elétrica	15
2.6	Riscos no mercado de energia elétrica	17
2.7	Quantificação de riscos	19
3	Fundamentação teórica	22
3.1	Otimização estocástica	22
3.1.1	Soluções para problemas de otimização estocástica	23
3.1.1.1	Programação linear	24
3.2	Redes neurais artificiais	27
3.3	Processos de decisão de Markov	28
3.3.1	Recompensas e probabilidade de transição	30

3.3.2	Política	31
3.3.3	Utilidade	31
3.3.4	Política ótima	33
3.3.5	Iteração de valor	33
4	Metodologia proposta	36
4.1	Otimização estática	36
4.1.1	Premissas	37
4.1.1.1	Posição inicial de contratação do portfólio	38
4.1.1.2	Preços e disponibilidade dos produtos	38
4.1.1.3	Cenários de PLD	38
4.1.1.4	Cenários de geração	38
4.1.2	Formulação do problema	39
4.2	Otimização dinâmica	44
4.2.1	Premissas	45
4.2.1.1	Matriz de estados S	45
4.2.1.2	Conjunto de ações A	46
4.2.1.3	Matriz de transição T	47
4.2.1.4	Matriz de recompensas R	48
4.2.2	Algoritmo proposto	48
5	Testes e resultados	50
5.1	Descrição das simulações	50
5.2	Caso 1: Considerando contratos por capacidade e quantidade	54
5.2.1	Variações do parâmetro de risco γ	59
5.3	Caso 2: Considerando apenas contratos de quantidade	62
6	Conclusão	66

6.1	Trabalhos futuros	68
	Referências	70

Capítulo 1

Introdução

1.1 Revisão da literatura

O setor elétrico brasileiro passou por uma reestruturação que iniciou no final da década de 1990 [1, 2]. Nas mudanças impostas neste período, a comercialização de energia foi estruturada em dois ambientes de contratação: Ambiente de Contratação Regulado (ACR) e Ambiente de Contratação Livre (ACL). As operações no ACR ocorrem entre distribuidoras e geradores, enquanto as no ACL são feitas entre geradores, comercializadoras e consumidores livres.

Logo após a reestruturação do setor, grande parte dos consumidores eram atendidos pela distribuidora local, sendo, portanto, classificados como consumidores cativos, gerando uma demanda de contratos muito maior no ACR em comparação com aquela no ACL. Como consequência, as novas usinas que eram construídas no Brasil destinavam sua energia, principalmente, para os leilões de energia no ACR. No entanto, nos últimos anos o mercado livre de energia ganhou mais visibilidade e tem se tornado mais atraente e competitivo. Diante deste cenário, muitos consumidores migraram para o ACL, tornando-se consumidores livres, causando um crescimento na demanda de energia nesse ambiente [3]. Com o objetivo de atender a alta demanda no ACL, as empresas começaram a investir na construção de usinas parcialmente ou completamente descontratadas no ACR, deixando sua energia livre para comercializar no ACL.

Embora atualmente ainda haja requisitos mínimos para se tornar um consumidor livre, a tendência é de que o Brasil siga os passos de outros países, permitindo o acesso ao mercado de energia elétrica a todos os consumidores. Para tanto, com o objetivo de incentivar essa evolução, o Governo está estimulando a redução dos limites exigidos para

se tornar um consumidor livre [4, 5]. Nesta perspectiva, é possível assumir que o mercado livre ainda está em “fase de crescimento” e há expectativa de aumento na demanda por energia no ACL [6].

Devido ao aumento da demanda de energia, houve crescimento relevante das novas fontes de geração, principalmente de natureza eólica e solar [3]. Apesar da inserção de novas usinas geradoras ser benéfica, a penetração crescente da geração de energia elétrica por meio de fontes intermitentes, como usinas eólicas e solares, introduz mais incertezas na operação do sistema e na comercialização de energia. Tais incertezas, por sua vez, contribuem para o aumento dos riscos associados à receita das empresas de energia, trazendo maiores desafios para este segmento.

As empresas comercializadoras de energia buscam obter lucros através do gerenciamento de uma carteira de contratos bilaterais de compra e venda de energia elétrica. A alta volatilidade dos preços de mercado, devido às expectativas dos agentes em relação ao Preço de Liquidação das Diferenças (PLD), introduz mais risco ao setor. Dessa forma, é fundamental que as comercializadoras adotem estratégias de gerenciamento das suas carteiras de contratos almejando o melhor resultado financeiro e que considerem o risco ao qual esses agentes estão expostos. A estratégia de comercialização adotada por uma empresa tem impactos na sua remuneração, podendo potencializar seus ganhos ou ocasionar prejuízos [7]. Isso ocorre porque a comercializadora pode ter prejuízos consideráveis caso venda energia elétrica quando o preço estiver baixo e compre energia em momentos de alta, ou lucro se vender energia elétrica quando o preço estiver alto e comprar quando esse estiver baixo. Desta forma, a gestão otimizada da carteira de ativos de geração é importantíssima, para que o retorno financeiro seja maximizado e o risco seja minimizado. Tais objetivos são naturalmente conflitantes e sujeitos a incertezas, o que torna o problema extremamente complexo.

A otimização de portfólio é uma abordagem utilizada em diversas áreas, que consiste em compor um conjunto de ativos de maneira a facilitar a gestão de um negócio e alcançar os objetivos estratégicos estabelecidos [8]. As referências [8, 9, 10] apresentam revisões sistemáticas da literatura sobre o tema. No trabalho [8], um amplo e detalhado levantamento da literatura sobre problemas de portfólio é levantado, apresentando diferentes critérios de seleção, formas de modelagem do problema, suas incertezas e as estratégias de solução utilizadas. Em [9], diversas técnicas exatas são utilizadas em problemas de seleção ótima de portfólio, enquanto [10] focaliza em técnicas meta-heurísticas aplicadas na solução dos problemas de otimização de portfólio.

Diversos estudos foram adaptados e desenvolvidos com o objetivo de criar estratégias e mecanismos para comercializar energia no mercado livre de energia brasileiro. Os trabalhos [11, 12, 13, 14] se baseiam na teoria de portfólio de Markowitz, que se originou no trabalho pioneiro ao abordar a otimização de portfólio buscando simultaneamente maximizar o resultado e minimizar o risco [15], com uma abordagem de otimização estocástica para otimizar a carteira de comercialização de energia. O trabalho [13] aumenta o tamanho do problema implementando uma solução para otimizar o portfólio sob a ótica de uma empresa com vários ativos de geração. Em [16, 17, 18], um modelo de otimização estocástica é proposto para definir os montantes de contratação ótima de uma comercializadora de energia elétrica visando maximizar a receita esperada e minimizar o valor em risco da carteira. Nesses trabalhos, o problema é modelado de forma que a comercializadora compre energia via contratos por capacidade para atender seu portfólio. Em [16, 17] são modeladas uma pequena central hidrelétrica e uma usina térmica a biomassa para atender um contrato de venda existente, onde a metodologia proposta consegue explorar e aproveitar a complementariedade sazonal da geração das usinas. Já em [18], representa-se a contratação de uma usina eólica para atender o portfólio existente. Uma abordagem semelhante é implementada em [19], considerando que uma comercializadora otimize seu portfólio comprando energia de uma pequena central hidrelétrica, de uma usina eólica e de uma empresa comercializadora de energia para atender seu contrato com um consumidor. No entanto, uma abordagem híbrida de otimização robusta e estocástica é empregada, considerando que a modelagem da geração é resolvida com a abordagem de otimização estocástica e a modelagem do PLD é resolvida com uma abordagem de otimização robusta. Este último, se deve ao fato de que a otimização robusta é uma boa ferramenta para resolver problemas em que a distribuição de probabilidades das variáveis de incerteza do problema é difícil de modelar, como é o caso do PLD [19, 20]. Em [21] um modelo de otimização estocástica é desenvolvido para definir simultaneamente o portfólio ótimo de energia e a sazonalização da garantia física das usinas participantes do Mecanismo de Realocação de Energia (MRE) que, combinada aos contratos bilaterais, compõe o portfólio ótimo total.

Em relação as técnicas utilizadas nos problemas de seleção de portfólio, diferentes técnicas de gestão de portfólio foram desenvolvidas pela área econômico-financeira. Os trabalhos [8, 9] apresentam pesquisas que mostram que abordagens Fuzzy, Programação Inteira, Programação Não-Linear e Programação Quadrática são amplamente utilizados em problemas de seleção de portfólio, porém grande parte destes estudos são aplicados ao mercado financeiro. Além dos métodos clássicos, métodos de alocação de portfólios

baseados em meta-heurísticas têm recebido cada vez mais atenção [8, 10, 22, 23]. Segundo [8, 10], as técnicas meta-heurísticas mais utilizadas tem sido os Algoritmos Genéticos (AG), Enxame de Partículas (*Particle Swarm Optimization* - PSO) e a Colônia Artificial de Abelhas (*Artificial Bee Colony* - ABC).

Algumas dessas técnicas foram implementadas nos estudos de otimização de portfólio de energia elétrica aplicadas ao mercado brasileiro, tais como simulações de Monte Carlo para explorar diferentes cenários e definir o portfólio ótimo com base nas curvas de risco-retorno, como observado nos trabalhos [11, 12, 24]. Além disso, são encontradas abordagens de otimização com métodos exatos, aplicando a técnica de Programação Linear para solucionar o problema, como visto em [16, 17, 18, 19, 20, 21]. No trabalho [13] implementou-se a técnica de Decomposição de Benders em uma Programação Dinâmica Dual Estocástica para a solução da otimização considerando vários ativos de geração. Em [25] é utilizada Programação Linear Inteira Mista combinada com Decomposição de Benders para resolver um problema de compartilhamento de cotas de um *Pool* de geradores em comercialização de energia. Em [14] é utilizada Otimização Estocástica para a análise de risco. Já em [26], um modelo de AG para otimização multiobjetivo de portfólios de energia é implementado de forma que os objetivos de maximizar o resultado e minimizar o risco sejam atingidos. Em [23] uma investigação sobre a implementação de técnicas meta-heurísticas neste tipo de problema é realizada. Neste último, o problema é modelado utilizando AG, PSO e ABC e seus resultados demonstram que o portfólio solucionado por meta-heurísticas alcança resultados similares quando comparados aos outros métodos.

Os trabalhos mencionados até este ponto recorrem à abordagem estática para o problema de otimização de portfólio de energia elétrica no mercado brasileiro, ou seja, a otimização é realizada baseando-se nas características de um determinado instante. No entanto, [27, 28, 29] adotam uma abordagem de otimização dinâmica. Nesta abordagem, além de definir o portfólio ótimo, o modelo busca decidir qual é o melhor momento para investir nesse portfólio, levando em conta as flutuações de preços ao longo do tempo. Em [27], uma abordagem de otimização dinâmica é implementada para um problema de otimização de portfólio de forma que a decisão de contratação de longo prazo é realizada através de um modelo baseado em opções reais, onde os preços sofrem variações ao longo do tempo e a abordagem de opções reais permite valorar as decisões de contratação em cada instante para definir o melhor momento de investimento. Em [28, 29], em que uma abordagem de programação estocástica multi-estágios é utilizada, a decisão do melhor momento para realizar as operações é feita com a implementação de uma árvore de de-

ção multi-escalas. Nestes trabalhos, cada nó da árvore de decisão representa os preços de mercado em um determinado instante, que sofrem variações positivas e negativas de forma simétrica a medida em que a árvore se expande.

1.2 Objetivo

A abordagem que emprega otimização dinâmica é importante porque os resultados financeiros do agente podem melhorar ao postergar a contratação de energia para um momento em que os preços de mercado estiverem mais favoráveis. Os trabalhos [27, 28, 29] são os que mais se aproximam da proposta do presente trabalho. Entretanto, neste presente trabalho, o processo de decisão é realizado utilizando Processos de Decisão de Markov (*Markov Decision Processes* - MDP), que é um modelo utilizado para resolver problemas de decisão sequencial sob incerteza [30]. O MDP é interessante porque, ao considerar incertezas com diferentes probabilidades em cada estado, permite que cada estado de decisão possa apresentar diferentes configurações de preços, podendo ser facilmente implementado considerando que cada estado representa um instante no tempo com um determinado preço de mercado. Para o MDP auxiliar a tomada de decisão é possível incorporar recompensas e penalidades associadas a diferentes ações. Além disso, a flexibilidade do MDP permite que o problema seja modelado de forma mais compatível com a realidade.

Nesta perspectiva, este trabalho tem como objetivo propor uma metodologia para obter o portfólio ótimo de energia elétrica baseando-se em uma abordagem de otimização dinâmica, que busca determinar o momento ótimo para a execução das contratações. Essa abordagem é composta por duas etapas distintas. Na primeira etapa, onde o problema de otimização estática é resolvido, um modelo estocástico é utilizado para definir os montantes ótimos de contratação de energia, considerando os preços de mercado de um determinado momento. O objetivo desta etapa é definir os montantes ótimos de contratação de forma que o valor esperado da receita do portfólio seja maximizado e o risco seja minimizado. Enquanto na segunda etapa, uma abordagem de otimização dinâmica é empregada, utilizando o MDP. Essa etapa determina o melhor momento para investir no portfólio ótimo recomendado pelo modelo estático, considerando um conjunto de cenários de preços de mercado, buscando maximizar o resultado financeiro considerando o risco da variação de preços.

1.3 Contribuições e publicações

As contribuições deste trabalho são resumidas a seguir:

- Este trabalho contribui para o tema de otimização de portfólio no mercado brasileiro ao desenvolver uma ferramenta de suporte à decisão para contratação de energia em um contexto de incertezas, considerando um sistema estocástico com restrição de risco.
- A abordagem adotada neste trabalho utiliza cenários realistas, que permitem um melhor entendimento da metodologia proposta e também vislumbrar a eficácia na solução de problemas reais.
- O modelo apresentado é simples e flexível, podendo ser adaptado para atender às necessidades específicas de um agente e/ou melhorado para ser utilizado em trabalhos futuros.
- O MDP é uma técnica amplamente reconhecida e utilizada em diversos campos, porém, até o momento, foram poucos os estudos que aplicaram de maneira sistemática e aprofundada no contexto da otimização de portfólio no mercado brasileiro de energia elétrica. Portanto este trabalho contribui no uso do MDP na otimização dinâmica de portfólio com a aplicação ao mercado de energia elétrico brasileiro. Ao incorporar o MDP ao modelo proposto, este trabalho proporciona uma nova perspectiva para a análise e aprimoramento da otimização de portfólio em um ambiente de incertezas e riscos.

Até o presente momento, o seguinte artigo associado a esta dissertação foi publicado:

ANSELMO, R. D. J., AGUSTO, A. A.; SOUZA, J. C. S. de; FILHO, M. B. do C.; “Investigação de meta-heurísticas para otimização de portfólio de energia elétrica”. XXIV Congresso Brasileiro de Automática - CBA, n. 1534, p. 1–8, Fortaleza, CE, 2022.

1.4 Estrutura do trabalho

Esta Dissertação está estruturada da seguinte forma:

O Capítulo 2 introduz o mercado de energia elétrica brasileiro, descrevendo as características da comercialização de energia elétrica e apresentando os riscos associados.

O Capítulo 3 apresenta o embasamento teórico utilizado no modelo proposto neste trabalho, que inclui redes neurais, otimização estocástica e MDP. Já o Capítulo 4 descreve a metodologia proposta, desde a sua formulação até as etapas utilizadas para a solução do problema. O Capítulo 5 apresenta algumas aplicações, onde o modelo proposto é implementado e os resultados são apresentados e analisados. Por fim, no Capítulo 6 são apresentadas as conclusões do trabalho e sugestões para futuras pesquisas.

Capítulo 2

Mercado de energia elétrica brasileiro

Até o final do século XX o modelo do setor elétrico brasileiro era totalmente verticalizado, onde os segmentos de geração, transmissão e distribuição de energia elétrica eram todos estatais, e a construção de novas usinas, linhas de transmissão e de novos sistemas de distribuição eram financiadas por recursos públicos.

A modernização do setor iniciou em 1996 com a criação de um Projeto de Reestruturação do Setor Elétrico Brasileiro, conhecido popularmente por Projeto RE-SEB, coordenado pelo Ministério de Minas e Energia (MME) e com a participação de diversos técnicos brasileiros e a consultoria inglesa Coopers e Lybrand. Como resultado, diversas mudanças foram impostas no mercado de energia elétrica brasileiro, dentre elas a desverticalização do setor elétrico, onde os setores de geração, transmissão e distribuição foram separados e privatizados, desconstruindo o monopólio estatal, de forma que a energia elétrica passou a ser um produto comercializado. Os segmentos de transmissão e distribuição foram mantidos sob regulação, e ainda são considerados monopólios naturais, porque eles operam em seus territórios de concessão e não existe competição de empresas no mesmo território de concessão. Outras mudanças resultantes do projeto de reestruturação do setor foram a criação de um órgão regulador, a Agência Nacional de Energia Elétrica (ANEEL), um operador para o sistema elétrico brasileiro, o Operador Nacional do Sistema Elétrico (ONS), e de um ambiente de realização de transações de compra e venda de energia elétrica, o Mercado Atacadista de Energia Elétrica (MAE). [1, 2]

Após uma crise que ocorreu em 2001, onde a escassez de recursos hídricos ocasionou um racionamento de energia no Brasil, foi instituído, em 2002, o Comitê de Revitalização do Setor Elétrico, com o objetivo de fornecer propostas de aperfeiçoamento do modelo

vigente. Nesta perspectiva, nos anos de 2003 e 2004 o Governo Federal lançou as bases para um novo modelo para o setor elétrico brasileiro, que foi sustentado pelas leis nº 10.847/04, 10.848/04 e pelo Decreto nº 5.163/04. As principais mudanças institucionais foram a criação da Empresa de Pesquisa Energética (EPE), o Comitê de Monitoramento do Setor Elétrico (CMSE) e uma instituição para substituir e dar continuidade às atividades do MAE, relativas à comercialização de energia elétrica no Sistema Interligado, a Câmara de Comercialização de Energia Elétrica (CCEE). [1]

No atual modelo de mercado de energia elétrica brasileiro existem dois tipos de ambiente de negociação, os já anteriormente mencionados ACL e ACR. O ACL é onde os agentes comercializadores, importadores e exportadores de energia, geradores e consumidores livres podem negociar contratos bilaterais de energia livremente. No ACR a contratação ocorre através de contratos regulados entre agentes geradores e distribuidores participantes dos leilões de compra e venda de energia elétrica organizados pela ANEEL de acordo com as regras pré-definidas de cada leilão.

As usinas que eram construídas no Brasil, normalmente, destinavam sua energia para os leilões de energia no ACR porque este ambiente era o que apresentava maior demanda. No entanto, devido a maior visibilidade e atratividade do ACL nos últimos anos, este tem se tornado mais competitivo. Como consequência, a demanda por energia no ACL aumentou nos últimos anos devido a migração de consumidores cativos para se tornarem consumidores livres comprando energia no ACL [3]. Atualmente, existem pré-requisitos para se tornar um consumidor livre. Porém, o governo o Governo está incentivando a redução dos limites para se tornar consumidor livre através de leis, decretos e portarias [4, 5]. Nesta perspectiva, a tendência é de que o Brasil siga os passos de outros países e torne o mercado de energia elétrica totalmente livre, o que cria expectativas de crescimento significativo no ACL [6].

O crescimento no ACL pode ser observado nas Figuras 2.1 e 2.2. A Figura 2.1 mostra que o número de agentes no mercado livre cresceu nos últimos 10 anos, saindo de aproximadamente 3,4 mil unidades consumidoras em 2013 para aproximadamente 29,5 mil em 2022 [3]. Adicionalmente, a Figura 2.2 apresenta a proporção de consumo de energia entre ACL e ACR nos últimos 10 anos, onde a proporção do consumo no ACL saiu de 27% em 2013 aumentando para 36% em 2022. Vale destacar que o consumo total de energia em 2022 foi de aproximadamente 67 GWmédios [3].



Figura 2.1: Número de unidades consumidoras no ACL por ano. Fonte: CCEE, 2023.

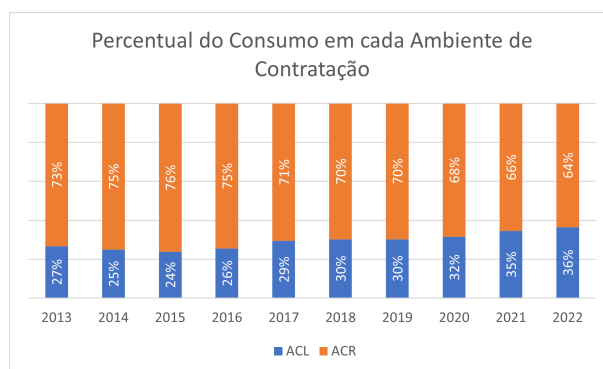


Figura 2.2: Percentual de participação do consumo nos ambientes ACL e ACR por ano. Fonte: CCEE, 2023.

2.1 Matriz energética brasileira

O número de usinas solares e eólica aumentou significativamente nos últimos 15 anos, entretanto o sistema elétrico brasileiro ainda permanece predominantemente hidráulico, possuindo uma relevante dependência de recursos hídricos. A Figura 2.3 apresenta a matriz energética brasileira atual (em 2023) e a Figura 2.4 apresenta a matriz energética brasileira estimada em 2027 considerando os projetos que estão em fase de construção.




Figura 2.3: Matriz energética brasileira em 2023. Fonte: ONS, 2023.

As usinas hidráulicas, eólicas e solares juntas representam 77% da capacidade insta-




Figura 2.4: Matriz energética brasileira em 2027. Fonte: ONS, 2023.

lada do Sistema Interligado Nacional (SIN), portanto é possível concluir que o sistema elétrico brasileiro é bastante dependente de recursos naturais, como água das chuvas, ventos e radiação solar. Tal configuração, onde a oferta é composta por muita incerteza, resulta em um mercado amplamente volátil e arriscado.

2.2 Contratação de energia

No ACR, as contratações são regidas pelas regras de cada leilão de energia organizado pela ANEEL. Já no ACL, os agentes podem comercializar energia em qualquer momento, sendo os acordos contratuais negociados entre as partes envolvidas. Este trabalho irá abordar a otimização de portfólio considerando apenas os contratos que podem ser negociados no ACL, uma vez que a modelagem dos contratos no ACR depende de regras pré-definidas em cada leilão e, além disso, não é possível firmar contratos no ACR em qualquer instante, porque o momento de contratação do ACR depende do cronograma de leilões estabelecido pela ANEEL.

Os agentes que negociam contratos no ACL não precisam necessariamente deter a energia elétrica fisicamente para realizar as negociações, por isso esses contratos podem ser interpretados como instrumentos financeiros. Entretanto, vale destacar que apesar de não existir a necessidade de o agente possuir energia fisicamente, os contratos de venda devem ser lastreados por contratos de compra ou por recurso energético próprio (como por exemplo a garantia física dos geradores), caso contrário os agentes são submetidos a penalidades definidas nas regras de comercialização. [1]

Existem algumas modalidades distintas de contratos bilaterais, sendo os contratos de quantidade a mais comum dentre elas. Nesta modalidade, as partes negociam um volume de energia fixo a um preço contratual que deve ser pago mensalmente durante o período

de suprimento do contrato. Apesar do volume de energia destes contratos ser considerado “fixo”, estes contratos costumam apresentar uma faixa de tolerância (denominada de “flexibilidade”), principalmente quando o contrato ocorre com um consumidor livre, permitindo que o consumidor contrate apenas o seu consumo desde que a variação do consumo verificado em relação ao estimado não ultrapasse a faixa de tolerância definida no contrato.

Outro exemplo de modalidade contratual é conhecido como contratos por capacidade [16, 17, 18, 24]. Nesta modalidade, negocia-se um percentual da geração a um valor financeiro fixo, permitindo assim que o agente gerador consiga reduzir seu risco, uma vez que se ele estiver 100% contratado ele venderá exatamente a energia que ele gerar, não tendo déficit de energia para liquidar no Mercado de Curto Prazo (MCP) e não ficando exposto ao PLD.

2.3 Mercado de curto prazo

No mercado de energia elétrica brasileiro, as diferenças entre a energia negociada e a energia física devem ser conciliadas no MCP, que é calculado pela CCEE. O MCP é contabilizado mensalmente, e uma das atividades da CCEE é calcular o balanço energético de cada agente para cada submercado e hora do mês, bem como valorar o déficit ou sobra de energia ao PLD. A Figura 2.5 ilustra o cálculo realizado no MCP.

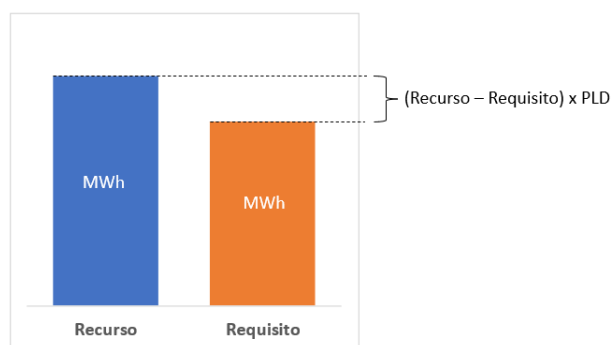


Figura 2.5: Balanço Energético valorado ao PLD.

A Equação 2.1 representa o cálculo genérico do balanço energético de um agente para o mês m , na hora h e no submercado s .

$$BE(m, h, s) = RE(m, h, s) + \sum VolC(m, h, s) - \sum VolV(m, h, s) - CE(m, h, s) \quad (2.1)$$

Onde RE representa o recurso energético do agente, que pode ser, por exemplo, a geração de energia de um gerador ou um valor igual a zero no caso de um consumidor ou comercializador. De forma semelhante, CE representa o consumo energético, que equivale ao consumo verificado de um agente consumidor e, sendo igual a zero para os demais agentes. $VolC$ e $VolV$ representam, respectivamente, os montantes (volumes) de energia dos contratos de compra e de venda.

A Equação 2.2 apresenta a exposição financeira do MCP de um determinado agente, que é calculada valorando o seu balanço energético para o mês m , na hora h e no submercado s ao PLD para o mesmo período e submercado.

$$ExposiçãoMCP(m, h, s) = BE(m, h, s) \times PLD(m, h, s) \quad (2.2)$$

Durante a contabilização do MCP, a CCEE também calcula o balanço de lastro dos agentes, isso é, a CCEE verifica se o agente possui lastro para cobrir seu requisito energético (vendas + consumo). Diferente do balanço energético, no cálculo do balanço de lastro o recurso equivale ao somatório do lastro de energia disponível dos 12 meses anteriores ao período de contabilização. Caso o agente possua déficit de lastro, este agente irá ser penalizado de acordo com as regras de comercialização.

2.4 Preço de liquidação das diferenças

O PLD é determinado pela CCEE para cada um dos 4 submercados (Sudeste/Centro-Oeste, Sul, Nordeste e Norte) do SIN e para cada hora do dia seguinte. Ele é baseado no custo marginal da operação obtido a partir da execução de uma cadeia de modelos computacionais, desenvolvidos pelo Centro de Pesquisas de Energia Elétrica (CEPEL), cujo objetivo é otimizar o despacho hidrotérmico do SIN de forma que o custo da operação do sistema em todo horizonte de estudo seja minimizado e a demanda de energia seja atendida.

Até 2020, o PLD era definido utilizando os modelos NEWAVE e DECOMP e tinha uma granularidade semanal por patamares de carga (leve, média e pesada). Desta forma, em cada semana era determinado o PLD dos 3 patamares de carga da semana operativa seguinte. Em 2017, com o objetivo principal de melhorar as decisões do despacho hidrotérmico, foi estabelecido um plano para integrar, a partir de 2021, o modelo DESSEM na cadeia de modelos utilizados na programação da operação. Para tanto, em 2019 iniciou-

se um processo denominado “operação sombra”, em que a CCEE executava a cadeia de modelos para calcular o PLD em intervalos horários, passando em 2021 o PLD a ser oficialmente determinado para cada hora do dia seguinte.

O PLD possui seus valores máximos e mínimos estabelecidos anualmente pela ANEEL. A Tabela 2.1 apresenta os valores máximos e mínimos definidos nos últimos anos. O valor do PLD máximo horário só passou a ser definido em 2020, devido ao início da divulgação do PLD horário na operação sombra da CCEE.

Tabela 2.1: Limites máximos e mínimos do PLD.

Ano	PLD mínimo (R\$MWh)	PLD máximo estrutural (R\$MWh)	PLD máximo horário (R\$MWh)
2013	30,26	388,04	-
2014	15,62	822,83	-
2015	30,26	388,48	-
2016	30,25	422,56	-
2017	33,68	533,82	-
2018	40,16	505,18	-
2019	42,35	513,89	-
2020	39,68	559,75	1.148,36
2021	49,77	583,88	1.197,87
2022	55,70	646,58	1.326,50
2023	69,04	684,73	1.404,77

A Figura 2.6 apresenta a média mensal do PLD dos últimos 10 anos para cada submercado. É possível perceber que historicamente o PLD do submercado Sudeste/Centro-Oeste foi diversas vezes igual ou muito próximo ao PLD do submercado Sul.

Devido a origem do PLD, é possível perceber que a incerteza associada ao PLD contém, indiretamente, um pacote de incertezas de diversas variáveis que influenciam a programação e operação do SIN. Como exemplos pode-se citar: fatores meteorológicos, especialmente o volume de chuvas nos reservatórios das usinas hidráulicas, velocidade e direção do vento (que podem afetar a performance das usinas eólicas), radiação solar (que afeta a performance das usinas solares), a demanda de energia, custo e a disponibilidade dos combustíveis, o contexto econômico, entre outros.




Figura 2.6: Histórico da média mensal do PLD. Fonte: CCEE, 2023.

2.5 Preços de contratos futuros no mercado de energia elétrica

O PLD é o preço de referência para as operações no mercado de energia brasileiro porque toda exposição energética é valorada ao PLD no MCP. Desta forma, as negociações futuras de energia normalmente são realizadas com base nas expectativas de cada agente em relação ao valor do PLD para o período negociado. Devido às incertezas do PLD, negociar energia torna-se uma tarefa bastante arriscada, uma vez que se um agente vender energia a um determinado preço e o PLD for, posteriormente, verificado superior, este agente terá uma receita líquida negativa nesta operação.

Nesta perspectiva, devido às necessidades do setor, diversas tecnologias e ferramentas foram construídas para auxiliar as negociações de energia, como por exemplo a plataforma eHUB desenvolvida pelo Balcão Brasileiro de Comercialização de Energia (BBCE), que atualmente é amplamente utilizada para contratação de energia. o eHUB funciona como um balcão de energia, onde os agentes podem ofertar energia a um determinado preço e os demais agentes podem contratar a energia ofertada. Esse tipo de ferramenta, implicitamente, facilita que o mercado esboce uma curva de “preço de mercado” de referência, porque torna factível consultar os volumes e os preços em que outros agentes estão negociando a energia elétrica em cada período.

A análise do preço de mercado permite que os agentes tentem criar estratégias para decidir o melhor momento para realizar as contratações visando aumentar seus resultados.

Neste contexto, se um agente decide vender energia em um determinado período futuro a um determinado preço, porém o “mercado” está negociando essa energia a um preço inferior, o agente pode decidir aguardar, ou seja, não vender a energia no momento, com a expectativa de que o “preço de mercado” aumente, para então vender a energia em um momento que o preço de mercado esteja com um valor que lhe favoreça.

A Figura 2.7 apresenta o preço médio das transações realizadas na plataforma eHUB da BBCE em cada dia durante os meses de novembro e dezembro de 2020 [31]. Essas transações envolvem os contratos que forneceriam energia no primeiro trimestre de 2021, segundo semestre de 2021 e para o todo o ano de 2022. Para simplificar a visualização, nos dias em que não ocorreram negociações para suprimento de energia nos períodos apresentados no gráfico, considerou-se que os preços foram iguais aos preços do dia imediatamente anterior.

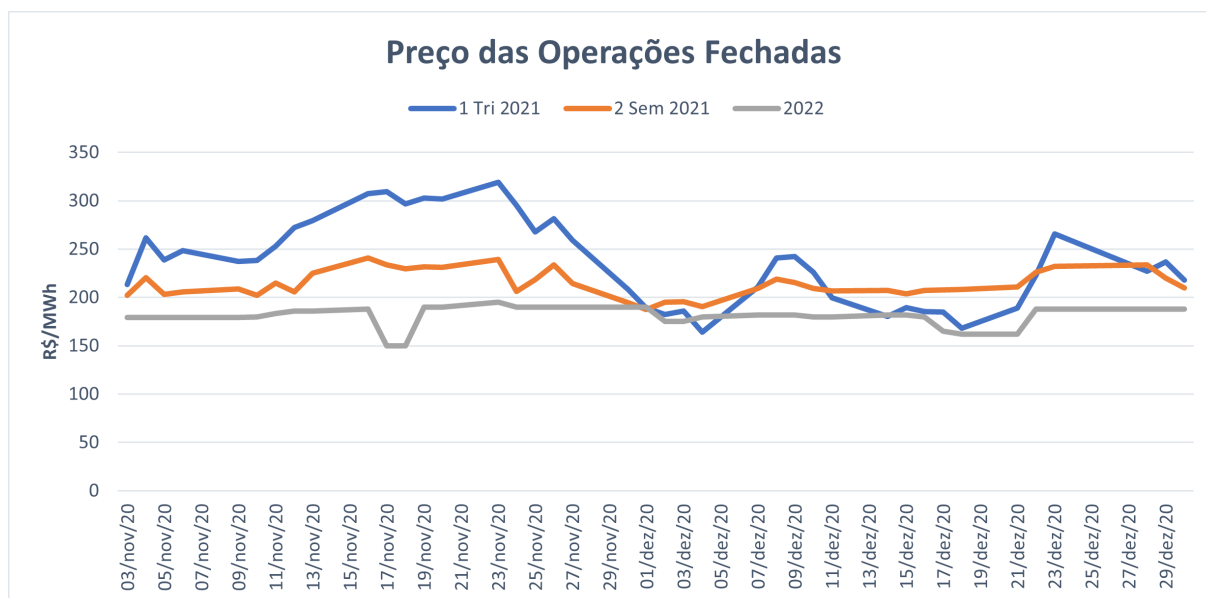


Figura 2.7: Preço médio das operações fechadas na plataforma da BBCE. Fonte: BBCE, 2023.

Os preços das negociações realizadas no eHUB variam de acordo com a necessidade de energia, estratégia de contratação e expectativa de PLD de cada agente. Um comportamento comum dos preços da energia elétrica e que, apesar do pouco histórico, podem ser visualizados na Figura 2.7, é que os preços das negociações para períodos de suprimento muito distantes, como o ano de 2022 sendo negociado no final de 2020, apresentam menos variações de preços. Enquanto, para as operações para períodos de suprimento próximos, como a primeiro trimestre à frente, apresenta maior volatilidade e neste período apresentou variações de até R\$ 150/MWh.

Pode-se também observar da Figura 2.7, que os preços médios dos contratos negociados ao final de 2020 foram de R\$ 218/MWh, R\$ 210/MWh e R\$ 188/MWh, para os produtos com suprimento de energia no primeiro trimestre de 2021, segundo semestre de 2021 e ano de 2022, respectivamente. Em contrapartida, após a divulgação dos valores do PLD, pode-se calcular e verificar que os valores médios do PLD adequado aos mesmos produtos foram de R\$ 173/MWh, R\$ 358/MWh e R\$ 58/MWh, respectivamente. Desta forma, considerando que um agente vendeu energia no final de 2020 para os 3 produtos representados no gráfico ao preço de médio de mercado no final de 2020, pode-se constatar que no primeiro trimestre de 2021 este agente obteve um lucro financeiro médio de aproximadamente R\$ 45/MWh. No entanto, para o segundo semestre de 2021, este agente registrou um prejuízo financeiro médio de aproximadamente R\$ -148/MWh. Por fim, obteve um lucro médio de aproximadamente R\$ 130/MWh para o ano de 2022. Portanto, é notório que a gestão eficiente de portfólio é fundamental para garantir a maximização dos lucros e a minimização dos prejuízos em operações de venda de energia. Tais variações de preços corroboram a necessidade de aperfeiçoamento e utilização das técnicas de otimização de portfólio.

2.6 Riscos no mercado de energia elétrica

O risco de volume (ou de quantidade) é o risco de o agente ficar exposto ao PLD. Do ponto de vista do consumidor livre, isso implica que se ele consumir mais energia do que a quantidade contratada, ocasionará em um déficit de energia que será valorado ao PLD no MCP. O raciocínio do ponto de vista do gerador é semelhante, que pode gerar um déficit ou excedente de energia devido a diferença entre o recurso energético verificado (por exemplo, geração) e a energia vendida, sendo essa diferença valorada ao PLD no MCP. No caso do comercializador, que não possui consumo ou geração própria, o volume de energia exposto ao PLD corresponderá à diferença entre os contratos de compra e venda do comercializador. Vale destacar que isso não significa que o comercializador esteja livre de incertezas em relação ao volume de energia que ficará exposto ao PLD. Porque o comercializador pode ter contratos por capacidade, nos quais a incerteza associada à geração da usina contratada é transferida para o comercializador, ou contratos com flexibilidade, onde a incerteza associada ao consumo é transferida ao comercializador.

O risco de submercado é o risco de o agente ficar exposto ao PLD em diferentes submercados, podendo gerar um prejuízo financeiro que dependerá da diferença dos valores dos PLDs em cada submercado. Por exemplo, se uma usina que está localizada no

submercado Nordeste vender energia no submercado Sudeste/Centro-Oeste, e o PLD do Sudeste/Centro-Oeste for maior que o PLD do Nordeste, este agente terá um prejuízo financeiro que vai depender dos volumes negociados e das diferenças entre os PLDs de cada submercado.

O risco de lastro refere-se à possibilidade de um agente enfrentar um déficit de lastro de energia. No mercado de energia elétrico brasileiro, todo requisito energético, seja ele o consumo de energia ou contratos de venda, devem ser lastreados por recursos energéticos do mesmo tipo de fonte, que podem ser a garantia física ou os contratos de compra. No mercado brasileiro, alguns consumidores podem consumir energia incentivada, e essa energia deve ser lastreada por recursos energéticos incentivados. Caso o agente possua déficit de lastro, aplica-se uma penalidade financeira relacionada a quantidade de energia que não foi lastreada. Neste contexto, quando o portfólio precisa atender um contrato de energia incentivada, há necessidade de considerar o risco de lastro que pode se tornar bastante complexo principalmente devido as flexibilidades de volumes que normalmente são negociadas nos contratos. Tais incertezas, principalmente as associadas ao requisito energético mensal, fazem com que seja necessário verificar a contratação dos últimos meses e gerenciar as contratações futuras para evitar que seja vendido mais energia do que a quantidade de lastro existente.

O risco de liquidez está associado à dificuldade de operacionalizar as negociações em tempo suficiente para o sucesso da estratégia do agente. No mercado de energia, como há muita incerteza nos preços da energia de anos futuros, a comercialização de energia para horizontes mais distantes, como a negociação de anos futuros, apresenta baixa liquidez. Além disso, no curto prazo a baixa liquidez pode ser ocasionada por incertezas regulatórias que podem ter consequências imediatas.

Os riscos apresentados introduzem uma parcela variável na receita dos agentes deste mercado, e conseqüentemente, um risco de receita a ser considerado na otimização do portfólio. Os comercializadores, que por sua vez, compram energia dos geradores e vendem para os consumidores potencializam seus riscos dado que possuem incerteza do PLD, da geração e do consumo de seus clientes. Portanto, é fundamental que sejam utilizadas estratégias que mitiguem tais riscos, uma vez que todas as incertezas envolvidas na formação do PLD fazem com que esta seja uma variável muito difícil de se prever com boa acurácia.

É importante destacar que, apesar de existirem outros riscos associados ao setor, os riscos supracitados são aqueles que afetam consideravelmente, direta ou indiretamente, o

modelo proposto neste trabalho. Portanto, outros riscos não serão contemplados neste trabalho, tais como risco de crédito, legal, tributário, operacional, entre outros.

2.7 Quantificação de riscos

Existem diversas maneiras de quantificar os riscos financeiros. Uma das abordagens mais conhecidas é a da teoria de portfólio proposta por Markowitz [15], que introduziu o conceito de risco-retorno, onde o risco era avaliado através da média-variância.

Outra medida de risco muito utilizada em finanças é o *Value at Risk* (VaR). Esta medida quantifica a perda máxima esperada de um investimento em um período definido, com um determinado nível de confiança α . Em outras palavras, o VaR mede a perda potencial em um intervalo de tempo, levando em conta um determinado grau de confiança α . A Equação (2.3) apresenta como o VaR pode ser calculado.

$$VaR_\alpha(X) = \min \eta \quad (2.3)$$

$$\text{Sujeito a: } P(X \leq \eta) \geq \alpha \quad (2.4)$$

onde η é a variável auxiliar para o cálculo do VaR e α o nível de probabilidade, onde $(1 - \alpha)$ é o nível de confiança.

Existe uma crítica ao utilizar o VaR como medida de risco porque ele não possui a propriedade de subaditividade, ou seja, o $VaR(a + b)$ pode ser maior que $VaR(a) + VaR(b)$. A propriedade de subaditividade faz parte do conjunto de axiomas que definem as medidas de risco coerentes [32]. Desta forma, outra medida de risco que ganhou destaque na literatura é o *Conditional Value at Risk* (CVaR), também conhecido como *Expected Shortfall* [24, 32, 33]. O CVaR é uma medida de risco que se baseia na média das perdas que excedem o nível de confiança determinado pelo VaR. Dessa forma, o CVaR oferece uma visão mais completa do risco associado a um investimento, pois leva em conta cenários que não são considerados no VaR com o mesmo nível de confiança.

As medidas de risco VaR e CVaR são amplamente utilizadas em finanças para avaliar o risco associado a um investimento e podem ser aplicadas a uma ampla variedade de ativos financeiros e classes de ativos. A escolha da medida de risco mais adequada depende do objetivo do investidor, do horizonte de tempo do investimento e do perfil de risco do investidor.

O CVaR tem propriedades numéricas e estatísticas superiores à do VaR [34]. Além disso, o CVaR considera os eventos “catastróficos” que, apesar da baixa probabilidade de ocorrência, são fundamentais nas análises de risco. No mercado de energia elétrica brasileiro, o conhecimento do efeito desses cenários é fundamental devido à alta incerteza associada à comercialização de energia. Portanto, o CVaR é a medida de risco utilizada para o problema de otimização de portfólio estático deste trabalho. Em [34] é apresentada uma forma de representar o CVaR como a solução do problema de otimização descrito em (2.5) que pode ser facilmente solucionado com um modelo de programação linear.

$$CVaR_\alpha(x) = \min_{\eta} \left\{ \eta + \frac{1}{1-\alpha} E_y [(\ell(x, y) - \eta)^+] \right\} \quad (2.5)$$

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

O CVaR pode ser escrito na forma de programação linear [32]:

$$CVaR_\alpha(x) = \min_{\eta} \left\{ \eta + \frac{1}{1-\alpha} E_y[\delta] \right\} \quad (2.6)$$

s.a

$$\delta \geq 0, \quad (2.7)$$

$$\delta \geq \eta - \ell(x, y) \quad (2.8)$$

onde η é a variável auxiliar que armazena o VaR_α na solução ótima. δ é uma variável que auxilia o cálculo do CVaR.

O $CVaR_\alpha(x)$ pode ser compreendido como a receita esperada de um portfólio, considerando os $(1 - \alpha)\%$ cenários mais desfavoráveis estabelecidos por y . Matematicamente também pode ser calculado como a média de todos os valores de $VaR_\alpha(x)$ obtidos para todos os valores acima de α . Embora as medidas de risco normalmente sejam utilizadas para mensurar prejuízos (ou perdas), neste trabalho ele é visto como a pior receita do portfólio, dado um nível α de confiança, ou seja, refere-se a média dos piores $(1 - \alpha)\%$ cenários de receita do portfólio.

Vale destacar que, neste trabalho, foi adotado a abordagem em que o risco é expresso como a diferença entre o valor esperado e o CVaR de uma distribuição de receitas. Desta

forma, o risco quantificado neste trabalho representa o valor financeiro que o portfólio pode perder, considerando um determinado grau de confiança $\alpha\%$, em relação ao valor esperado.

Capítulo 3

Fundamentação teórica

Este capítulo apresenta o embasamento teórico do modelo proposto para otimização dinâmica de portfólio de energia elétrica, com o objetivo de decidir o melhor momento de investimento em um portfólio ótimo de energia. Para tal, busca-se maximizar a receita esperada e minimizar o valor em risco, levando-se em conta as flutuações de preços de mercado ao longo do tempo. A otimização estática é responsável por definir os montantes de contratação do portfólio ótimo, sempre com o objetivo de maximizar a receita esperada e minimizar a exposição ao risco. Para atingir tal objetivo, o modelo utiliza uma abordagem de otimização estocástica que considera um conjunto de cenários de dados de entrada que são construídos, em parte, com o auxílio de uma Rede Neural Artificial (RNA). A otimização dinâmica é responsável por apontar o melhor momento para investir no portfólio ótimo. Para o processo de decisão, o MDP é implementado.

3.1 Otimização estocástica

Existem diversos problemas da vida real que contém incertezas em pelo menos uma de suas variáveis, principalmente quando tais incertezas se referem ao comportamento futuro de tais variáveis. Isso ocorre devido à dificuldade de se realizar previsões precisas sobre variáveis envolvidas em problemas como, por exemplo, a otimização de portfólio, entre outros.

Na literatura existem diversas abordagens para resolver problemas que envolvem informações incertas. Uma dessas estratégias consiste em representar as informações desconhecidas pelo seu valor esperado, transformando o problema em questão em um problema determinístico. Entretanto, ela pode levar a um resultado subótimo, uma vez que não considera os diferentes cenários que podem acontecer no futuro. [32]

Alternativamente, pode-se utilizar a abordagem de otimização estocástica, que se concentra em resolver problemas de otimização que possuem parâmetros não determinísticos. A otimização estocástica considera um conjunto de cenários possíveis para as incertezas, encontrando uma solução ótima considerando todo conjunto de cenários para as variáveis envolvidas no problema. Ela permite que sejam feitas análises e tomadas decisões sob condições de incerteza, o que é muito útil em situações da vida real. Além disso, a otimização estocástica permite avaliar os riscos e incertezas associados às decisões tomadas, o que é importante para gerenciar os riscos envolvidos e para embasar à tomada decisões mais informadas. [32]

A incerteza está presente em diversas variáveis nos problemas de otimização de portfólio de energia elétrica e isso se deve ao fato de que a receita de um portfólio depende de variáveis futuras que podem variar amplamente ao longo do tempo. Como exemplo destas, pode-se citar o PLD, a produção e consumo de energia, entre outras. Portanto, a otimização estocástica se apresenta como uma ferramenta valiosa para solucionar problemas de otimização de portfólio.

3.1.1 Soluções para problemas de otimização estocástica

Os problemas de otimização estocástica podem ser solucionados utilizando diferentes algoritmos de solução, como por exemplo as técnicas de otimização clássicas e as meta-heurísticas.

Os métodos exatos (ou métodos clássicos) buscam a solução ótima de forma exata, utilizando, por exemplo, programação linear. Os métodos exatos possuem a vantagem de garantir ou que a solução encontrada seja ótima ou indicar o quão próximo da ótima a solução obtida está. No entanto, requerem uma formulação rigorosa do problema que satisfaça propriedades matemáticas necessárias ao uso das técnicas (como convexidade, continuidade, diferenciabilidade, etc.), ensejando modificações, simplificações e relaxações do problema, para que possam ser resolvidas.

Por outro lado, as meta-heurísticas são métodos de solução de problemas de otimização que combinam procedimentos de aprimoramento local de soluções e estratégias de alto nível para criar um processo de busca capaz de escapar de ótimos locais e caminhar de forma inteligente pelo espaço de soluções [35]. Em contraste com os métodos exatos, elas não requerem uma formulação do problema que garanta determinadas propriedades matemáticas, sendo de propósito geral. Entretanto, não conseguem garantir que a solução ótima seja alcançada, ou seja, não é possível afirmar que a solução final obtida pelo método

corresponde a um ótimo global. Algumas das técnicas meta-heurísticas mais utilizadas incluem o AG e o PSO. A vantagem das meta-heurísticas é que elas são mais flexíveis do que as técnicas exatas. Além disso, são menos propensas a ficarem presas em mínimos locais, como os métodos clássicos.

Em [23], um modelo de otimização de portfólio com uma abordagem de otimização estática é proposto utilizando técnicas de modelos meta-heurísticos, sendo possível verificar que, no problema abordado, as técnicas meta-heurísticas conseguem alcançar resultados similares aos resultados obtidos com técnicas exatas. Portanto, desde que bem aplicado, o método de otimização utilizado para solucionar o problema de otimização de portfólio não alterará de forma significativa o resultado do portfólio ótimo, ou seja, o problema é flexível o suficiente para ser solucionado pelo modelo de preferência do agente tomador de decisão.

3.1.1.1 Programação linear

Neste trabalho, utilizou-se a técnica de Programação Linear (PL) para solucionar o problema de otimização estática. A PL é uma técnica utilizada para maximizar ou minimizar uma função linear sujeita a um conjunto de restrições lineares, que podem ser de igualdade ou desigualdade. A PL consiste na representação das características de um problema na forma de um conjunto de equações lineares, sendo útil em situações em que é necessário encontrar a melhor alocação de recursos, maximizando lucros ou minimizando custos, e ao mesmo tempo, atender a restrições e limitações. É amplamente utilizada em problemas de otimização em engenharia, economia, administração e outras áreas.

A PL vem sendo utilizada há muitas décadas e continua a ser aprimorada por pesquisadores e profissionais em todo o mundo. Com o avanço da capacidade computacional, a PL tem se tornado capaz de solucionar problemas cada vez mais complexos, o que a torna uma ferramenta muito útil para a tomada de decisões estratégicas em diversos setores [16, 17, 18, 19, 20, 21, 36].

De um modo geral, a PL consiste em encontrar a solução para o problema de otimização representado na forma padrão indicada nas Equações (3.1) a (3.3). [32]

$$\min \quad z = c^T x \quad (3.1)$$

$$\text{Sujeito a: } Ax = b \quad (3.2)$$

$$x \geq 0 \quad (3.3)$$

onde z a função objetivo a ser otimizada, x é o vetor de variáveis de decisão ($n \times 1$), c o vetor de coeficientes da função objetivo, A a matriz de coeficientes das restrições e b o vetor de restrições. As matrizes c , A e b possuem as dimensões ($n \times 1$), ($m \times n$) e ($m \times 1$), respectivamente.

Uma solução viável para a Equação (3.1) consiste em um vetor x que satisfaz $Ax = b$ e $x \geq 0$.

A Programação Linear Estocástica é uma extensão da PL e pode ser empregada quando algum parâmetro do problema possui incerteza. Ela considera cenários possíveis baseados em distribuições de probabilidade, possibilitando a análise de riscos e a busca por soluções mais robustas em ambientes incertos. A programação linear estocástica combina a estrutura da programação linear com a análise probabilística, permitindo a tomada de decisões informadas mesmo em ambientes incertos.

Em casos em que decisões podem ser tomadas após a divulgação de incertezas, o problema pode ser resolvido com programas com recurso. Neste caso, a solução do problema é dividida em dois estágios. No primeiro, decisões são tomadas antes de qualquer experimento, geralmente representadas pelo vetor x . No segundo estágio, as decisões são tomadas após a ocorrência do experimento, sendo normalmente representadas pelo vetor y , $y(\omega)$ ou $y(\omega, x)$, onde ω é uma realização específica da incerteza. A Programação Linear com Recurso permite que as decisões do segundo estágio sejam adaptadas aos resultados incertos do primeiro estágio.

A formulação geral da programação linear com recurso é expressa pelo conjunto de Equações (3.4) a (3.9). Nessa formulação, quando comparada com a estrutura básica da PL clássica, incorpora-se um elemento estocástico à equação, a fim de lidar com a incerteza nos dados do problema.

$$\min \quad z = c^T x + \mathbb{E}_\xi[Q(x, \xi)] \quad (3.4)$$

$$\text{Sujeito a:} \quad Ax = b \quad (3.5)$$

$$x \geq 0 \quad (3.6)$$

onde $\mathbb{E}_\xi[\cdot]$ é o valor esperado em relação à variável aleatória ξ , que representa a incerteza no problema. $Q(x, \xi)$ é o termo estocástico que captura a relação entre as variáveis de decisão x e uma realização específica da variável aleatória ξ , sendo expresso pela Equação (3.7).

$$Q(x, \xi) = \min \quad q(\xi)^T y(\xi) \quad (3.7)$$

$$\text{Sujeito a:} \quad W(\xi)y(\xi) = h(\xi) - T(\xi)x \quad (3.8)$$

$$y \geq 0 \quad (3.9)$$

onde, $q(\xi)$ é um vetor de coeficientes associados à função objetivo estocástica, $y(\xi)$ é um vetor de variáveis de decisão do segundo estágio relacionadas a uma realização da variável aleatória ξ . $W(\xi)$ é uma matriz que representa as restrições lineares no segundo estágio relacionadas a uma realização da variável aleatória ξ . $h(\xi)$ é um vetor das restrições no segundo estágio relacionadas a uma realização da variável aleatória ξ . $T(\xi)$ é uma matriz que relaciona as variáveis de decisão do primeiro estágio x às variáveis de decisão do segundo estágio $y(\xi)$. A Equação (3.8) representa as restrições lineares de segundo estágio, levando em consideração as decisões do primeiro estágio x .

Na programação probabilística, algumas das restrições ou o objetivo são expressos usando declarações que envolvem probabilidades sobre as decisões tomadas no primeiro estágio. Isso significa que não é necessário especificar exatamente quais serão as ações tomadas em etapas posteriores. Desta forma, a programação probabilística permite lidar com incertezas ao tomar decisões, sem precisar definir todos os detalhes das ações futuras.

A solução para um problema de PL é geralmente encontrada usando algoritmos especializados para esse tipo de problema, como o Método Simplex e método dos Pontos Interiores [37]. No entanto, devido à complexidade da implementação de algoritmos para solução de PLs, muitos trabalhos utilizam os diversos *softwares* distribuídos que possuem tais algoritmos embutidos, concentrando esforços na correta modelagem do problema para depois obter a solução apropriada através de um *software* existente [37]. O desenvolvi-

mento de algoritmos para solução do problema de PL não é o foco deste trabalho, sendo também utilizado um programa que possui o algoritmo para solução da PL já embutido.

3.2 Redes neurais artificiais

As RNAs, comumente chamadas apenas de redes neurais, são sistemas computacionais inspirados na estrutura e forma como o cérebro humano trabalha, onde a rede adquire conhecimento a partir dos dados a ela apresentados, através de um processo de aprendizagem. Os pesos sinápticos, que são as intensidades de conexões entre neurônios, são utilizados para armazenar o conhecimento adquirido. Após a rede ter passado pelo processo de aprendizagem ela deve ser capaz de generalizar o conhecimento adquirido, oferecendo respostas para novos dados de entrada relacionados ao problema aprendido. [38]

Existem diversas estruturas de redes neurais e algoritmos de aprendizagem, sendo que cada modelo de rede neural possui características específicas que justificam seu uso em diferentes áreas, como problemas de previsão e classificação. Segundo [38], algumas características importantes das RNAs são:

- Mapeamento de Entrada-Saída: A rede é capaz de relacionar as entradas com as saídas e encontrar um padrão de associação em um processo de treinamento supervisionado, tornando-a capaz de realizar previsões ou classificações quando apresentada a informações inéditas, não vistas durante o processo de treinamento.
- Adaptabilidade: Uma rede treinada em condições específicas é capaz de ser facilmente retreinada para se adaptar a ambientes dinâmicos, onde ocorrem modificações significativas nas condições do problema abordado.
- Tolerância a Falhas: As redes neurais são capazes de tolerar falhas e dados ruidosos como por exemplo dados atípicos ocorridos no passado.
- Não linearidade: elas suprem uma alternativa analítica que vence limitações encontradas nas técnicas convencionais, muitas vezes devidas a suposições estritas de normalidade, linearidade, independência de variável, etc.

As redes neurais são compostas por unidades de processamento conhecidas como neurônios e um modelo de neurônio pode ser visto na Figura 3.1.

Os sinais de entrada (x_i) podem ser os dados de entradas do problema ou saídas de outros neurônios de uma camada anterior.




Figura 3.1: Modelo de um neurônio. Fonte: Haykin, 2001.

O somatório de todas as entradas (x_i) multiplicadas por seus respectivos pesos (w_i) é somado ao *bias* (w_0) e depois passa pela função de ativação ($f(\cdot)$) para gerar uma saída (y_t). Em termos matemáticos temos:

$$y_k = f\left(\left[\sum_{i=1}^N (x_i \times w_i)\right] + w_0\right) \quad (3.10)$$

A função de ativação define a saída de um neurônio. Neste trabalho a função de ativação utilizada foi a função Logística Sigmoidal.

$$y = \frac{1}{1 + e^{-\lambda s}} \quad (3.11)$$

A rede neural que possui uma ou mais camadas ocultas (ou intermediárias) e uma camada de saída é denominada rede Perceptrons de Múltiplas Camadas. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. A camada intermediária funciona como extratora de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação interna, mais rica e complexa do problema. [38]

3.3 Processos de decisão de Markov

Um MDP é um modelo matemático utilizado para resolver problemas de decisão sequencial sob incertezas. O MDP também é conhecido como Otimização Sequencial Estocástica, Controle Estocástico com Tempo Discreto e Programação Dinâmica Estocástica [39]. Como o nome do modelo já indica, o MDP é utilizado para resolver problemas onde as variáveis obedecem a propriedade de Markov, ou seja, problemas onde o efeito de uma ação em um determinado estado depende apenas da ação e do estado atual do sistema sem depender de ações tomadas anteriormente [40]. Um MDP soluciona um problema de

otimização considerando tanto os resultados das decisões atuais quanto as oportunidades futuras de tomada de decisão. O MDP e suas variações têm sido objeto de estudo em diversos campos, como por exemplo a inteligência artificial, pesquisa operacional, economia e teoria de controle [41].

Formalmente, um MDP consiste em uma tupla (S, A, T, R) [41], onde:

- S representa o conjunto de estados do problema;
- $A(s)$ representa o conjunto de ações que podem ser tomadas no estado s ;
- $T = P(s'|s, a)$ representa a probabilidade de transição para o estado s' dado que o agente está no estado s e tomou a ação a ;
- $R(s, a, s')$ representa a recompensa de estar no estado s , tomar a ação a e chegar ao estado s' .

Diz-se que um sistema ocupa o estado s quando os atributos do sistema assumem valores característicos do estado s . Adicionalmente, compreende-se a transição para o estado s' como a modificação dos valores correntes dos atributos do sistema para aqueles próprios do estágio s' . [42]

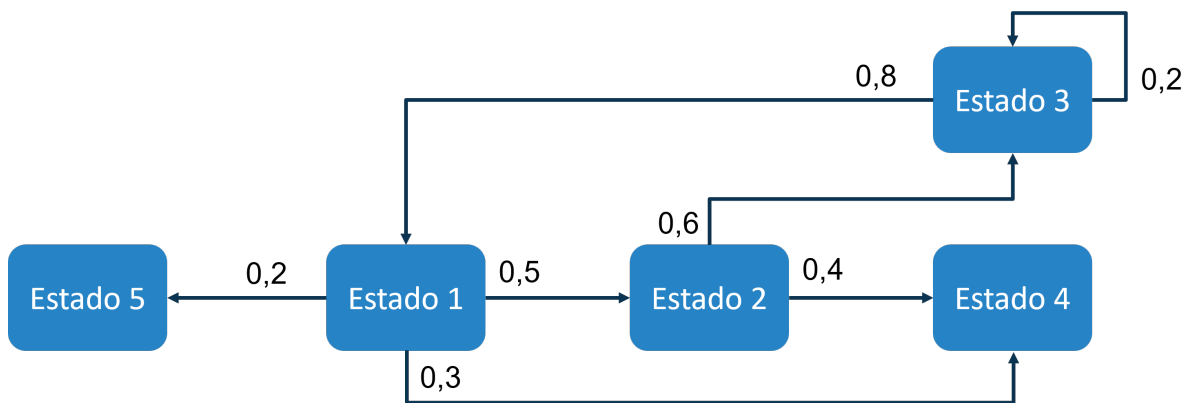


Figura 3.2: Exemplo de um processo de decisão de Markov.

A Figura 3.2 apresenta um exemplo de um processo de decisão de Markov composto por 5 estados representados pelos retângulos azuis. Em cada estado existe um conjunto de ações que podem ser tomadas, representados, neste exemplo, pelas setas azuis. Neste exemplo, o agente que estiver no “Estado 1”, pode decidir ir para os Estados 2, 4 e 5. Para cada ação tomada em cada estado, deve existir uma probabilidade de transição para que o agente se mova para cada um dos estados posteriores. Por exemplo, se o agente que está no “Estado 1” decide ir para o “Estado 2”, a probabilidade deste agente transitar

para “Estado 2” é de 50%, porém existe 20% de probabilidade deste agente transitar para o “Estado 4” e 30% para o “Estado 4”. Essa probabilidade de transição representa, por exemplo, a incerteza associada ao sucesso de uma determinada ação. Por fim, ao transitar para um determinado estado, o agente receberá uma recompensa ou penalidade relacionada a este movimento.

Um modelo de decisão sequencial é aquele em que o agente (ou tomador de decisão) observa o estado do sistema, escolhe uma ação baseado no seu estado atual e a partir desta ação recebe uma recompensa imediata e o sistema evolui para um novo estado subsequente de acordo com a distribuição de probabilidade determinada pela ação escolhida. Conforme o processo evolui, o agente recebe uma sequência de recompensas. Por esta razão, o MDP tem características similares a de um aprendizado por reforço. [30]

As decisões em um MDP são tomadas em determinados momentos denominados de “épocas de decisão”, sendo que em cada época de decisão o sistema ocupa um estado. As épocas de decisão podem ser classificadas como discretas ou contínuas e como finitas ou infinitas. Quando forem discretas, as decisões são feitas para todas as épocas de decisão. Quando for contínua, as decisões podem ser feitas para todas as épocas de decisão, em épocas aleatórias quando certos eventos ocorrerem, e em épocas específicas escolhidas pelo agente. Em certos problemas o tempo pode ser representado de forma discreta, sendo dividido em períodos ou estados. [30]

Um MDP pode ser considerado finito se existe um determinado instante no futuro em que as decisões se tornam irrelevantes para a decisão atual, ou seja, se a decisão atual (instante t) independe estatisticamente de decisões futuras a partir de um determinado instante (instante $t + \Delta t$). Desta forma, com um horizonte finito, uma ação ótima de um dado estado pode depender de quanto tempo falta, ou seja, de quantos estados futuros ainda restam até o fim do período. Neste contexto, um horizonte infinito não necessariamente significa que o conjunto de estados são infinitos. [30]

3.3.1 Recompensas e probabilidade de transição

A cada estado $s \in S$ o agente pode escolher uma ação $a \in A$ e como consequência o agente recebe uma recompensa $R(s, a)$ que depende do estado atual e da ação escolhida. Em seguida, o próximo estado s' é definido de acordo com a distribuição de probabilidades $P(s'|s, a)$. É importante ressaltar que o agente possui flexibilidade para calcular a recompensa da maneira que considerar mais apropriada para o seu problema, desde que a recompensa seja conhecida antes da escolha da ação e não seja influenciada pelas decisões

futuras. Além disso, a recompensa pode representar um ganho ou um custo, podendo assumir valores positivos ou negativos. Em alguns problemas, a recompensa também pode depender do próximo estado, sendo representada por $R(s, a, s')$. [30]

3.3.2 Política

Denomina-se política $\pi(s)$ a sequência de ações (decisões) recomendadas para um agente que está inicialmente no estado s . Uma política é uma possível solução para o MDP.

Uma política pode ser classificada como estacionária, se as ações recomendadas independem do número de épocas de decisão, ou não-estacionária, se as decisões tomadas dependem da época de decisão. [41]

A política também pode ser classificada como determinística, se cada estado contém uma única ação a ser tomada, ou estocástica, se cada estado contém um conjunto de ações que podem ser tomadas com base em uma distribuição de probabilidades. Quando a política é estocástica, normalmente assume-se que o somatório das probabilidades das ações de um estado é igual a 1, conforme representado na Equação (3.12). [41]

$$\sum_{j \in S} p(j|s, a) = 1 \quad (3.12)$$

onde:

- s representa o índice do estado atual, a representa o índice da ação escolhida;
- j representa o índice do estado subsequente ao estado se o agente tomar a ação a ;
- $P(j|s, a)$ representa a probabilidade do sistema chegar no estado j dado que o agente está no estado s e escolheu a ação a .

3.3.3 Utilidade

A utilidade quantifica numericamente o valor de uma decisão ou de uma série de decisões. Em outras palavras, em um modelo de MDP, a utilidade representa o valor de uma política. Portanto, uma função utilidade $U(s)$ representa a qualidade das decisões tomadas pelo agente que está no estado s . Normalmente, a utilidade esperada é medida pela soma de recompensas das transições experimentadas, sendo calculada conforme a Equação (3.13). [41]

$$U([s_0, s_1, s_2, \dots]) = R(s_0) + R(s_1) + R(s_2) + \dots \quad (3.13)$$

Um fator de desconto γ variando entre 0 e 1 pode ser utilizado para representar a preferência de um agente pelas recompensas atuais em relação às futuras recompensas. Desta forma, as recompensas em um futuro distante podem ser vistas como menos atrativas à medida que γ for próximo de 0. Incluindo o fator de desconto γ na Equação (3.13), a utilidade pode ser calculada conforme a Equação (3.14). [41]

$$U([s_0, s_1, s_2, \dots]) = R(s_0) + \gamma R(s_1) + \gamma^2 R(s_2) + \dots \quad (3.14)$$

O fator de desconto γ aplicado nas recompensas pode ser justificado por diversos motivos [41]:

- Ele pode ser utilizado para representar o efeito de valorizar mais recompensas a curto prazo do que recompensas no longo prazo.
- Ele pode ser equivalente a uma taxa de juros, representando o benefício de se obter uma recompensa financeira com antecedência, de forma que estas recompensas antecipadas possam ser investidas e produzir um benefício para o agente.
- Ele também pode ser representado como uma variável de aversão ao risco, uma vez que, em problemas envolvendo incertezas, as recompensas podem não ser alcançadas. Neste caso, é como se, independente da ação tomada, o fator de desconto seja equivalente a adicionar a probabilidade $(1 - \gamma)$ de rescisão acidental a cada passo de tempo.
- Ele também pode fazer com que a solução para problemas com muitas ou infinitas épocas de decisão seja encontrada mais rápido, uma vez que as recompensas por decisões em horizontes de tempo distantes do estado atual se tornem insignificantes.

Alguns estudos [33, 43, 44, 45] apresentam modificações no MDP para considerar uma abordagem de aversão ao risco. No entanto, como este trabalho não tem como objetivo investigar a melhor forma de representação do risco associado as decisões, optou-se por considerar, de forma simplificada, o fator γ como um fator de aversão ao risco.

3.3.4 Política ótima

Uma política é avaliada pela sua utilidade esperada, desta forma é possível comparar duas políticas com base nos seus respectivos valores de utilidade esperada. Portanto, conforme representado na Equação (3.15), é possível definir a política ótima de cada estado como a política que resulta na maior utilidade esperada.

$$\pi^*(s) = \underset{\pi}{\operatorname{argmax}} U^\pi(s) \quad (3.15)$$

onde $\pi^*(s)$ representa a política ótima para um agente que está inicialmente no estado s , $U^\pi(s)$ representa a utilidade esperada para a política π dado que o agente está inicialmente no estado s .

Por fim, assumindo que o agente escolhe uma ação ótima, a utilidade de um estado é igual a recompensa esperada do estado atual somado à utilidade descontada do próximo estado. Essa utilidade é dada pela Equação (3.16), que é conhecida por Equação de Bellman. [30]

$$U(s) = \max_{a \in A(s)} \left[R(s, a) + \gamma \sum_{j \in S} P(j|s, a) U(j) \right] \quad (3.16)$$

onde a representa a ação $a \in A$, s representa o estado $s \in S$ e $j \in S$ representa o estado subsequente ao estado s dado que o agente escolheu a ação a . $U(s)$ representa a utilidade esperada para o agente que inicialmente está no estado s . $R(s, a)$ representa a recompensa que o agente irá receber dado que está no estado s e tomou a ação a . γ é o fator de desconto dentro do intervalo $[0, 1]$. Já $P(j|s, a)$ é a probabilidade de o agente estar no estado s , tomar a ação a e ir para o estado j . $U(j)$ é a utilidade esperada para o agente que está inicialmente no estado j .

3.3.5 Iteração de valor

A solução para o MDP pode ser obtida empregando-se diferentes algoritmos. Como o objetivo deste trabalho não é investigar qual é o melhor algoritmo para solucionar um MDP, será aqui adotado o algoritmo conhecido como Iteração de Valor, que é um dos mais utilizados na literatura. As referências [30, 39, 41] abordam outros algoritmos para solucionar o MDP e podem ser consultados para maiores informações sobre tais algoritmos.

A equação de Bellman é a base do algoritmo de Iteração de Valor para resolver MDPs.

Este algoritmo utiliza uma abordagem em que a Equação de Bellman é usada em cada estado do problema. É possível observar que a Equação de Bellman (Equação (3.16)) possui o operador “max”, isso implica que a Equação de Bellman não seja linear, tornando a solução da equação mais difícil. Portanto, o algoritmo de Iteração de Valor resolve o problema utilizando um método iterativo. [41]

O processo de iteração de valor se inicia com valores arbitrários para as utilidades de cada estado, em seguida, a equação de Bellman é calculada para cada estado e as utilidades dos estados são atualizadas. Este processo se repete até que o critério de parada seja satisfeito. O processo de atualização das utilidades pode ser realizado com a Equação (3.17).

$$U_{i+1}(s) \leftarrow \max_{a \in A(s)} \left[R(s, a) + \gamma \sum_{j \in S} P(j|s, a) U_i(j) \right] \quad (3.17)$$

onde, $U_i(s)$ é a utilidade esperada do estado s na i -ésima iteração.

O algoritmo de Iteração de Valor normalmente converge para um único conjunto de soluções das equações de Bellman [30]. Isso ocorre porque a atualização de Bellman é uma “contração”, isso significa que, quando a atualização de Bellman é aplicada a dois vetores de utilidade diferentes, os novos vetores resultantes estarão mais próximos um do outro do que os vetores originais, multiplicados por um fator de desconto $\gamma \in (0, 1)$. Essa propriedade de contração garante a convergência do algoritmo de Iteração de Valor [30].

O Algoritmo 1 apresenta a utilização do processo de Iteração de Valor para calcular as utilidades de cada estado.

Algoritmo 1 Algoritmo de Iteração de Valor para calcular a utilidade dos estados

Function *IteraçãoValor*($S, A, P, R, \gamma, \epsilon$):

Inputs:

S , conjunto de estados

$A(s)$, conjunto de ações para cada estado

$P(s'|s, a)$, modelo de transição para cada estado e ação

$R(s, a)$, modelo de recompensas para cada estado e ação

γ , fator de desconto

ϵ , Erro máximo permitido na utilidade para cada estado

Output: Função utilidade U

```

1  for  $s$  in  $S$  do
2     $U(s) \leftarrow 0$ 
3  Do
4     $delta \leftarrow 0$ 
5    for  $s$  in  $S$  do
6       $U'(s) \leftarrow \max_{a \in A(s)} [R(s, a) + \gamma \sum_{j \in S} P(j|s, a)U(j)]$ 
7      if  $|U'(s) - U(s)| > delta$  then
8         $delta \leftarrow |U'(s) - U(s)|$ 
9     $U \leftarrow U'$ 
10 Until  $delta < \epsilon(1 - \gamma)/\gamma$ 
11 return  $U$ 

```

Capítulo 4

Metodologia proposta

Este capítulo apresenta a metodologia proposta, com destaque para as suas duas principais abordagens, as quais podem ser resumidamente descritas da seguinte forma:

1. **Otimização Estática:** Um modelo de otimização estocástica é utilizado para determinar os montantes da contratação ótima de um portfólio de energia elétrica. O modelo simultaneamente maximiza o valor esperado do portfólio e minimiza o valor em risco. Esta etapa leva em conta a posição contratual inicial, os preços de mercado do momento e um conjunto de cenários futuros correlacionados de PLD e geração das usinas disponíveis para contratação via contratos de compra por capacidade.
2. **Otimização Dinâmica:** O modelo de MDP é utilizado para definir o momento ótimo para otimizar o portfólio. O modelo considera que o preço de mercado apresenta variações ao longo do tempo, de acordo com um conjunto de cenários, e busca maximizar o resultado financeiro do portfólio, levando em consideração o risco associado à espera por preços de mercado mais favoráveis.

As duas etapas descritas são detalhadas a seguir.

4.1 Otimização estática

A otimização estática tem como objetivo encontrar a combinação ótima de contratos de compra e/ou venda de quantidade e/ou compra por capacidade de energia, considerando uma posição contratual inicial e uma distribuição correlacionada de PLD e geração de energia. Essa abordagem busca simultaneamente maximizar o resultado financeiro esperado e minimizar o valor em risco do portfólio. A estratégia de otimização estática de portfólio

adotada neste trabalho é baseada em referências anteriores [16, 17, 18, 19, 21, 23, 24, 27], nas quais a tomada de decisão é feita a partir de um portfólio inicial e a contratação de energia pode ser realizada por duas formas: contratos por quantidade aos preços de mercado no momento da otimização; ou contratos por capacidade, contratando as usinas que estão disponíveis para contratação aos preços definidos entre as partes. Neste presente estudo, as usinas consideradas para contratação por capacidade foram pequenas centrais hidrelétricas e usinas eólicas.

A Figura 4.1 apresenta graficamente o problema estático. Onde uma Comercializadora, pode comprar contratos por capacidade ou por quantidade para atender seu portfólio existente.

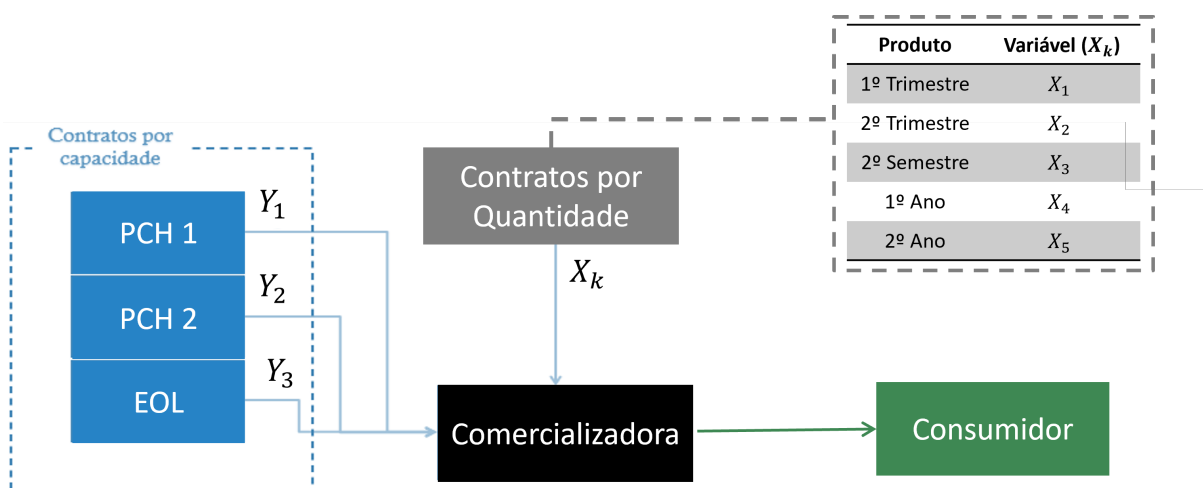


Figura 4.1: Ilustração da modelagem do problema estático.

4.1.1 Premissas

Os dados de entrada utilizados pelo modelo proposto são apresentados abaixo, e são descritos de forma mais detalhada nas subseções seguintes:

- Posição energética inicial de contratação do portfólio;
- Preços dos produtos disponíveis no mercado para firmar contratos de quantidade;
- Conjunto de cenários de PLD;
- Conjunto de cenários de geração das usinas disponíveis para contratação por capacidade correlacionados com os cenários de PLD.

4.1.1.1 Posição inicial de contratação do portfólio

A posição inicial de contratação do portfólio consiste no volume energético mensal por submercado que representa a posição líquida de energia do portfólio, isto é, a diferença entre o recurso e o requisito energético atual do mesmo.

É importante destacar que o modelo proposto neste trabalho é flexível o suficiente para permitir que a posição inicial seja igual a zero, caso o agente não tenha nenhum contrato atual.

4.1.1.2 Preços e disponibilidade dos produtos

Os produtos e preços disponíveis para realizar contratos de quantidade são dados de entrada do modelo estático. Portanto, são definidos pelo agente tomador de decisão.

4.1.1.3 Cenários de PLD

Conforme mencionado no Capítulo 2, o PLD é formado empregando-se uma cadeia de modelos computacionais desenvolvidos pelo CEPEL. Como o desenvolvimento de uma distribuição de previsões de PLD não é o objeto de estudo deste trabalho, adotou-se a representação da distribuição para cada mês e submercado por meio de um amplo conjunto de cenários originados dos modelos computacionais mencionados.

4.1.1.4 Cenários de geração

A metodologia proposta considera que os cenários de geração das usinas que estão disponíveis para contratação por capacidade estão correlacionados com os cenários de PLD. No entanto, a complexa tarefa de construção de uma distribuição conjunta de variáveis aleatórias multivariadas não faz parte do escopo deste trabalho. Para a construção de cenários realistas, neste trabalho foi utilizada uma abordagem que leva em conta que a geração das usinas hidráulicas está correlacionada com os valores de Energia Natural Afluente (ENA) dos Reservatórios Equivalentes de Energia (REEs) em que estão localizadas e a geração eólica está inversamente proporcional às ENAs do REEs mais próximos em que tais usinas estão presentes. Para isso, foi desenvolvido em Python um modelo de RNA para construir o conjunto de cenários de previsão de geração das usinas correlacionado com o conjunto de cenários de PLD utilizado. A RNA utilizada possui 8 neurônios na camada de entrada, 1 na camada de saída e a função sigmóide como função de ativação.

Os parâmetros de entrada da rede neural foram: o ano e mês da previsão; a ENA do reservatório mais próximo da usina; e a geração de energia verificada da usina no mês anterior. O modelo foi treinado com os dados históricos de geração das usinas e de ENA do REEs mais próximo de cada usina. Desta forma, para cada uma das usinas disponíveis para contratação foi construído uma rede neural artificial com as mesmas premissas. Elas foram treinadas considerando os respectivos dados de cada usina.

Finalmente, utilizando os dados resultantes da execução do *deck* do NEWAVE em que o conjunto de séries sintéticas de PLD foi extraído, coletou-se o conjunto de séries sintéticas de ENA correlacionadas com os respectivos PLDs. Em seguida, esses dados foram utilizados para construir o conjunto de cenários de previsões de geração das usinas através do resultado da previsão de cada rede neural treinada anteriormente. Onde, para cada cenário de PLD, capturou-se o cenário correlacionado de ENA do REE mais próximo da usina e este foi utilizado como parâmetro de entrada da RNA treinada para prever a geração da usina.

Em resumo, foram construídas redes neurais artificiais para cada uma das usinas disponíveis para contratação por capacidade, e tais redes foram utilizadas para gerar os cenários de previsões de geração correlacionados com o PLD. Para isso, os cenários de ENA correlacionados com os cenários de PLD foram utilizados como parâmetro de entrada das redes neurais.

Vale destacar que existem diversas alternativas de metodologias que podem ser utilizadas para construir os cenários de geração que podem ser usadas na modelagem de otimização de portfólio. Por exemplo, pode-se utilizar o NEWAVE e alterar seus parâmetros para que ele simule individualmente as usinas disponíveis para contratação por capacidade. Outra alternativa é utilizar o Modelo de Simulação a Usinas Individualizadas de Subsistemas Hidrotérmicos Interligados (SUISHI) para gerar os cenários de geração das usinas correlacionados com os cenários de PLD. Além disso, modelos de previsão utilizando modelos estatísticos ou outros modelos de inteligência artificial podem ser utilizados.

4.1.2 Formulação do problema

A receita anual de portfólio de energia composto por contratos de quantidade e de capacidade, considerando um cenário i de geração de energia elétrica e PLD no ano de apuração a , é calculada por (4.1).

$$R_a(i) = RCE_a(i) + RCQ_a(i) + RCC_a(i) \quad (4.1)$$

onde i representa o índice do cenário, a representa o ano de apuração, $RCE_a(i)$ é a receita do ano a dos contratos existentes no portfólio considerando o cenário de PLD i , $RCQ_a(i)$ é a receita do ano a dos contratos de quantidade considerando o cenário de PLD i e $RCC_a(i)$ é a receita do ano a dos contratos de capacidade considerando o cenário de PLD e de geração i .

A receita líquida anual dos contratos do portfólio existente é expressa pela soma entre a receita anual dos contratos de venda e de compra, sendo calculada por (4.2). Onde a receita dos contratos de venda é igual ao produto entre o volume contratado e a diferença entre o preço do contrato de venda e o PLD. Já a receita dos contratos de compra é igual ao produto entre o volume contratado e a diferença entre o PLD e o preço do contrato de compra.

$$RCE_a(i) = \sum_{t \in T_a} \sum_{s \in S} \left[\sum_{v \in V} QV_{v,t,s} \cdot (PV_{v,t,s} - PLD_{t,s,i}) + \sum_{c \in C} QC_{c,t,s} \cdot (PLD_{t,s,i} - PC_{c,t,s}) \right] \quad (4.2)$$

onde:

a : índice do ano $[1, A]$;

i : índice do cenário $[1, I]$;

t : tempo mensal dentro do intervalo $[1, T_a]$ do ano a ;

s : índice do submercado $[1, S]$;

v : índice do contrato de venda $[1, V]$;

c : índice do contrato de compra $[1, C]$;

QV : Quantidade de energia do contrato de venda (MWh);

PV : Preço de contrato de venda (R\$/MWh);

QC : Quantidade de energia do contrato de compra (MWh);

PC : Preço de contrato de compra (R\$/MWh);

PLD : Preço de liquidação das diferenças (R\$/MWh).

De forma semelhante, a receita líquida anual dos contratos de venda por quantidade

definidas pelo modelo de otimização é calculada por (4.3).

$$RCQ_a(i) = \sum_{t \in T_a} \sum_{s \in S} \sum_{k \in K} X_k \cdot (PLD_{t,s,i} - PQ_k) \quad (4.3)$$

onde:

k : índice da produto disponível para contratação por quantidade $[1, K]$;

X_k : Volume de energia da contratação por quantidade do produto k ;

PQ_k : Preço do contrato por quantidade do produto k (R\$/MWh).

A receita líquida anual dos contratos de capacidade é calculada por (4.4). O cálculo é expresso como a diferença entre a receita da fração comprada da geração de energia da usina valorada ao PLD e o custo da compra da fração comprada da capacidade da usina.

$$RCC_a(i) = \sum_{t \in T_a} \sum_{s \in S} \sum_{u \in U} Y_u (G_{u,t,s,i} \cdot PLD_{t,s,i} - P_{u,t} \cdot GF_{u,t,s} \cdot H_t) \quad (4.4)$$

onde:

u : índice da usina disponível para contratação por capacidade $[1, U]$;

Y_u : Percentual de contratação por capacidade da usina u ;

G : Geração de energia elétrica (MWh);

P : Preço do contrato de compra por capacidade (R\$/MWh);

GF : Garantia Física (MWm);

H_t : Número de horas do mês t no ano P .

Desta forma, unindo (4.1) com (4.2), (4.3) e (4.4) pode-se obter a Equação (4.5) que apresenta a expressão completa da receita anual do portfólio composto por contratos de quantidade e de capacidade, considerando um cenário correlacionado de geração de energia elétrica e PLD i no ano de apuração a .

$$\begin{aligned}
R_a(i) = \sum_{t \in T_a} \sum_{s \in S} \left[\sum_{v \in V} QV_{v,t,s} \cdot (PV_{v,t,s} - PLD_{t,s,i}) \right. \\
+ \sum_{c \in C} QC_{c,t,s} \cdot (PLD_{t,s,i} - PC_{c,t,s}) \\
+ \sum_{k \in K} X_k \cdot (PLD_{t,s,i} - PQ_k) \\
+ \sum_{u \in U} Y_u \cdot G_{u,t,s,i} \cdot PLD_{t,s,i} \\
\left. - \sum_{u \in U} Y_u \cdot P_{u,t} \cdot GF_{u,t,s} \cdot H_t \right] \quad (4.5)
\end{aligned}$$

Assim como em estudos anteriores [16, 17, 19, 23, 24, 27], a otimização de portfólio tem o objetivo de encontrar uma combinação de contratos de compra e/ou venda por quantidade e de compra por capacidade, de modo a maximizar a receita esperada do portfólio e minimizar o risco a ele associado. Conforme mencionado na Seção 2.7, o valor em risco é expresso pela diferença entre o valor esperado e o CVaR da distribuição de receitas do portfólio. Para atingir tal objetivo, a função objetivo do problema estático pode ser expressa pelas Equações (4.6) a (4.10).

$$\max_{a \in A} \sum [E[R_a] - \lambda(E[R_a] - CVaR[R_a])] (1+r)^{1-a} \quad (4.6)$$

s.a

$$X_k \geq 0, \quad \forall k \in K \quad (4.7)$$

$$Y_u \geq 0, \quad \forall u \in U \quad (4.8)$$

$$Y_u \leq 1, \quad \forall u \in U \quad (4.9)$$

$$\sum_{t \in T_a} QV_t \leq \sum_{t \in T_a} \left[QC_t + \sum_{u \in U} Y_u G_{u,t} + \sum_{k \in K} X_{k,t} \right], \quad \forall u \in U \quad (4.10)$$

onde, $E[R_a]$ representa o valor esperado da receita do portfólio, considerando todos os cenários de preço e geração no ano a . $CVaR[R_a]$ representa o CVaR da distribuição de receitas do portfólio no ano a . O parâmetro λ pondera a aversão ao risco na função objetivo e deve estar dentro do intervalo $[0, 1]$. Designa-se por r a taxa de desconto anual e a é o ano do horizonte de estudo que varia de 1 até A . $u \in U$ representa os índices das usinas disponíveis para contratação por capacidade. $k \in K$ representa os índices

dos produtos disponíveis para contratação por quantidade. X_k e Y_u são as variáveis de decisão do problema, sendo X_k o volume a ser contratado via contrato de quantidade do produto k e Y_u o percentual a ser contratado da usina u via contrato por capacidade. É importante destacar que, além das variáveis de decisão se apresentarem nas inequações que representam as restrições do problema, elas também compõem a função objetivo dentro do cálculo da receita do portfólio R_a conforme a equação (4.5).

Cabe destacar que a parcela livre de risco da função objetivo consiste no valor esperado anual da receita do portfólio, enquanto a parcela aversa ao risco consiste na diferença entre o valor esperado e o CVaR anual da receita do portfólio. As restrições (4.7) e (4.8) garantem que as operações de compra sejam maiores ou iguais a zero. A restrição (4.9) evita que as usinas disponíveis para contratos por capacidade sofram penalidades de lastro, garantindo que o percentual de contratação seja limitado a 100% da garantia física. De forma semelhante, a restrição (4.10) previne que a comercializadora tenha problemas de lastro, impedindo que o volume anual de venda de energia seja maior que os recursos comprados para atendimento dos seus contratos.

Neste trabalho, o risco do portfólio é entendido como a perda máxima que pode ocorrer em relação ao seu valor esperado, sendo representado pela diferença entre o valor esperado e o CVaR do portfólio. A partir de uma reorganização da função objetivo apresentada em (4.6), é possível obter a expressão (4.11), que apresenta a mesma função objetivo com a forma mais comumente encontrada em outros trabalhos na literatura [16, 17, 18, 19, 20, 27, 36]. Esta expressão representa uma combinação convexa do valor esperado e do valor em risco de uma distribuição de receitas, podendo ser entendida como um Equivalente Certo (EC) [36]. O EC é uma medida que captura tanto a expectativa de retorno quanto a aversão ao risco em uma única métrica. Ao utilizar essa combinação convexa, é possível ponderar o equilíbrio entre o valor esperado e o valor em risco, permitindo comparar diferentes distribuições de receitas levando em conta tanto o potencial de retorno quanto a incerteza envolvida. Desta forma, pode-se interpretar a Equação (4.11) como sendo uma que maximiza o Valor Presente Líquido (VPL) do EC do portfólio.

$$\max_{a \in A} \sum [(1 - \lambda)E[R_a] + \lambda CVaR[R_a]] (1 + r)^{1-a} \quad (4.11)$$

A equação (4.11) pode ser implementada em um PL baseando-se em [32, 34], onde o CVaR pode ser calculado com a Equação (2.6). Desta forma, a função objetivo pode ser expressa da seguinte forma:

$$\max \sum_{a \in A} \left[(1 - \lambda) E[R_a] + \lambda \left(\eta_a - \frac{E[\delta_a]}{1 - \alpha} \right) \right] (1 + r)^{1-a} \quad (4.12)$$

s.a

$$\delta \geq 0, \quad (4.13)$$

$$\delta_a \geq \eta_a - R_a, \quad (4.14)$$

$$X_k \geq 0, \quad (4.15)$$

$$Y_u \geq 0, \quad (4.16)$$

$$Y_u \leq 1, \quad (4.17)$$

$$\sum_{t \in T_a} QV_t \leq \sum_{t \in T_a} \left[QC_t + \sum_{u \in U} Y_u G_{u,t} + \sum_{k \in K} X_{k,t} \right] \quad (4.18)$$

onde η é a variável auxiliar que armazena o VaR_α de cada ano a na solução ótima. δ é um vetor que auxilia o cálculo do $CVaR$ em cada ano, ele possui a mesma dimensão que o vetor de receitas R_a . Vale destacar que as variáveis auxiliares de decisão η e δ são adicionadas na equação com o objetivo de permitir o cálculo do $CVaR$ em um PL.

4.2 Otimização dinâmica

A otimização dinâmica tem como objetivo determinar o melhor momento para otimizar o portfólio, considerando a possibilidade de aumentar o resultado financeiro ao aguardar movimentações favoráveis de preços de mercado e também o risco associado à espera por preços vantajosos.

Para isso, são utilizados como dados de entrada do modelo dinâmico o valor do parâmetro γ (que representa o fator de desconto utilizado na expressão (3.17)), os cenários de preços de mercado correspondentes aos diferentes estados e os respectivos ECs resultantes do modelo de otimização estático. Dessa forma, o modelo dinâmico leva em consideração tanto a maximização do lucro quanto a minimização do risco associado à incerteza do mercado, permitindo uma gestão mais eficiente e adequada do portfólio ao longo do tempo.

4.2.1 Premissas

O MDP proposto possui duas principais premissas: a matriz de estados S , onde cada estado s representa um cenário de preço de mercado; e a matriz de recompensas R , onde cada elemento da matriz representa o resultado da função objetivo otimizada com o modelo estático descrito na Seção 4.1 utilizando os preços de mercado do estado s .

Além disso, no MDP também é necessário definir um valor de tolerância ϵ , conforme apresentado no Algoritmo 1. Este valor é utilizado para definir a convergência do modelo, verificando se a variação do valor das políticas entre as iterações atende ao critério de parada.

4.2.1.1 Matriz de estados S

No modelo proposto, os estados são representados na forma matricial por meio de uma matriz de estados, onde cada elemento da matriz corresponde a um estado. Sendo assim, cada estado representa um momento em que o agente deve escolher uma ação diante de um conjunto de informações que estão disponíveis naquele estado. Também pode-se entender que a matriz de estados representa o conjunto de cenários possíveis para os preços de mercado ao longo do tempo. Desta forma, a cada estado está associado um vetor que contém os valores dos preços de mercado para aquele momento. Na matriz de estados, cada estado possui 8 possíveis estados sucessores, com exceção daqueles que estão nas extremidades da matriz.

Para construir a matriz de estados, o vetor de preços de mercado de referência foi associado ao estado (elemento) que está no centro da matriz, e os demais elementos representam as variações dos preços em relação a esse referencial. Tais variações foram calculadas a partir do percentual de variação Δ do estado s , multiplicado pela volatilidade σ de cada produto de energia k . Dessa forma, cada elemento da matriz contém a variação percentual em relação aos preços de mercado de referência, permitindo assim uma representação mais flexível do modelo. Isto se deve ao fato do intervalo de tempo entre um estado e outro não ser importante, podendo o modelo ser utilizado para matrizes construídas com intervalos diários, semanais ou mensais.

A Equação (4.19) representa o cálculo realizado para cada elemento da matriz S .

$$P_{ij}^k = P_{ref}^k \times \Delta_{ij} \times \sigma^k \quad (4.19)$$

onde i e j representam, respectivamente, os índices de linha e coluna da matriz S . k representa o produto ao qual o preço se refere. P_{ref}^k representa o preço de referência do produto k , ou seja, o preço do produto k no momento atual. Δ_{ij} representa a variação percentual na célula i, j da matriz em relação ao preço de referência. σ^k representa a volatilidade do produto k .

Para simplificar a visualização, quando a matriz de estados for apresentada visualmente neste trabalho, cada um de seus elementos será representado pela média simples dos produtos k de cada estado. Desta forma, a representação em cada elemento da matriz será dada por (4.20).

$$P_{ij} = \frac{1}{K} \sum_{k=1}^K P_{ij}^k \quad (4.20)$$

onde K representa a quantidade de produtos de energia sendo comercializados.

A matriz de estados S é representada em (4.21).

$$S = \begin{bmatrix} P_{11} & P_{12} & \cdots & P_{1j} & \cdots \\ P_{21} & P_{22} & \cdots & P_{2j} & \cdots \\ \vdots & \vdots & \ddots & \vdots & \ddots \\ P_{i1} & P_{i2} & \cdots & P_{ij} & \cdots \\ \vdots & \vdots & \ddots & \vdots & \ddots \end{bmatrix} \quad (4.21)$$

4.2.1.2 Conjunto de ações A

O conjunto A representa duas possíveis ações que o agente tomador de decisão pode executar:

- Ação 0: O agente tomador de decisão decide fechar os contratos recomendados pelo modelo estático.
- Ação 1: O agente tomador de decisão decide não fechar os contratos recomendados pelo modelo estático, em outras palavras, o agente decide aguardar a movimentação de preços.

4.2.1.3 Matriz de transição T

A matriz de transição $T = P(s'|s, a)$ é utilizada para modelar a probabilidade de transição do agente de um estado s para um estado s' dado que ele tomou a ação a . Vale ressaltar que essa matriz deve ser construída de forma que, se o agente tomou a Ação 0 ($a = 0$) no estado s , ele não terá mais necessidade de atuar no mercado considerando o mesmo ambiente de contratação, portanto a probabilidade de transição para qualquer estado subsequente é zero. Já se o agente tomou a Ação 1 ($a = 1$), a probabilidade de transição para os estados subsequentes é neste trabalho considerada equiprovável, ou seja, caso existam n estados imediatamente subsequentes a s , a probabilidade de transição para cada um deles é de $1/n$. A Equação (4.22) apresenta a expressão que define a probabilidade de transição para o estado s' a partir do estado s e da ação a tomada pelo agente.

$$P(s'|s, a) = \frac{1}{NF} \times a \quad (4.22)$$

onde NF representa o número de elementos da matriz (número de estados) que fazem fronteira com o elemento do estado s , ou seja, para os quais se pode transitar.

A Figura 4.2 apresenta as probabilidades de o agente transitar do estado s para cada estado subsequente s' considerando que o agente decidiu aguardar a movimentação de preços, ou seja, tomou a ação $a = 1$. Neste exemplo, como existem 8 estados subsequentes, a probabilidade de o agente ir para qualquer estado é $\frac{1}{8}$. Cada estado subsequente ao estado atual representa um possível instante no tempo futuro em que o agente pode estar posteriormente. Sendo que, em cada um desses instantes um possível preço de mercado é conhecido. Vale destacar que o intervalo de tempo entre cada estado não é relevante para o problema modela, o que importa nesta modelagem é qual será a expectativa de preços de mercado em cada um destes estados.


0	0	0	0	0
0	$\frac{1}{8}$	$\frac{1}{8}$	$\frac{1}{8}$	0
0	$\frac{1}{8}$		$\frac{1}{8}$	0
0	$\frac{1}{8}$	$\frac{1}{8}$	$\frac{1}{8}$	0
0	0	0	0	0

Figura 4.2: Representação das probabilidades na matriz de transição para o agente que está no estado s e escolhe a ação $a = 1$.

4.2.1.4 Matriz de recompensas R

A recompensa $R(s', a, s)$ representa o valor esperado do VPL do EC obtido ao estar no estado s , escolher uma ação a e ir para o estado s' . Se a ação a for igual a 1, que representa a decisão de aguardar por melhores preços, a recompensa $R(s', a, s)$ é igual a zero, pois não há ganho financeiro imediato nesta ação. No entanto, considerando que ação a é igual zero, que representa a decisão de executar o portfólio ótimo, cada elemento da matriz de recompensas $R(s', a, s)$ corresponde ao resultado da função objetivo otimizada com o modelo estático descrito na Seção 4.1 utilizando os preços de mercado do estado s .

4.2.2 Algoritmo proposto

A princípio, o modelo estático deve ser utilizado para calcular o portfólio ótimo e o seu respectivo EC para cada cenário de preços de mercado. Em seguida, o MDP é utilizado considerando que:

- Os estados S representam os possíveis instantes do tempo, e em cada instante são conhecidos os preços de mercado daquele momento;
- As ações $A(s)$ representam decisões binárias (“sim” ou “não”) de otimizar o portfólio no estado s ;
- A matriz de transição T representa as probabilidades de transição para o estado s' dado que o agente tomador de decisão está no estado s e tomou a decisão a ;
- A recompensa $R(s, a, s')$ representa o EC do portfólio otimizado para os preços de mercado do estado s' se o tomador de decisão decidir tomar a ação $a = 1$ de não otimizar o portfólio no momento do estado s , ou o EC do portfólio s se o tomador de decisão decidir tomar a ação $a = 0$ de otimizar o portfólio no momento do estado s .

O algoritmo de iteração de valor foi escolhido para resolver o MDP devido à sua ampla utilização em diversos tipos de problemas [30, 39, 41]. É importante destacar que existem outros algoritmos que poderiam ser utilizados para resolver o MDP, mas este trabalho não tem o objetivo de avaliar qual seria o melhor algoritmo para o problema em questão. Portanto, a escolha pelo algoritmo de iteração de valor foi baseada em sua simplicidade e efetividade em diversos tipos de problemas.

Quando o agente toma a decisão de esperar por preços mais favoráveis, ele corre o risco de que o preço de mercado se torne desfavorável em relação ao preço no momento da decisão. Visando reduzir esse risco, aplica-se exponencialmente um fator de desconto γ à medida que o agente tomador de decisão escolhe esperar para otimizar o portfólio, diminuindo a atratividade das recompensas futuras. O fator de desconto γ representa o risco associado à variação do preço de mercado. Portanto, quanto mais tempo o agente espera, menor será a importância dada às recompensas futuras, o que pode tornar mais atrativo definir o portfólio o mais rápido possível para reduzir o risco de variação dos preços de mercado.

A Figura 4.3 ilustra os passos empregados no algoritmo da solução.

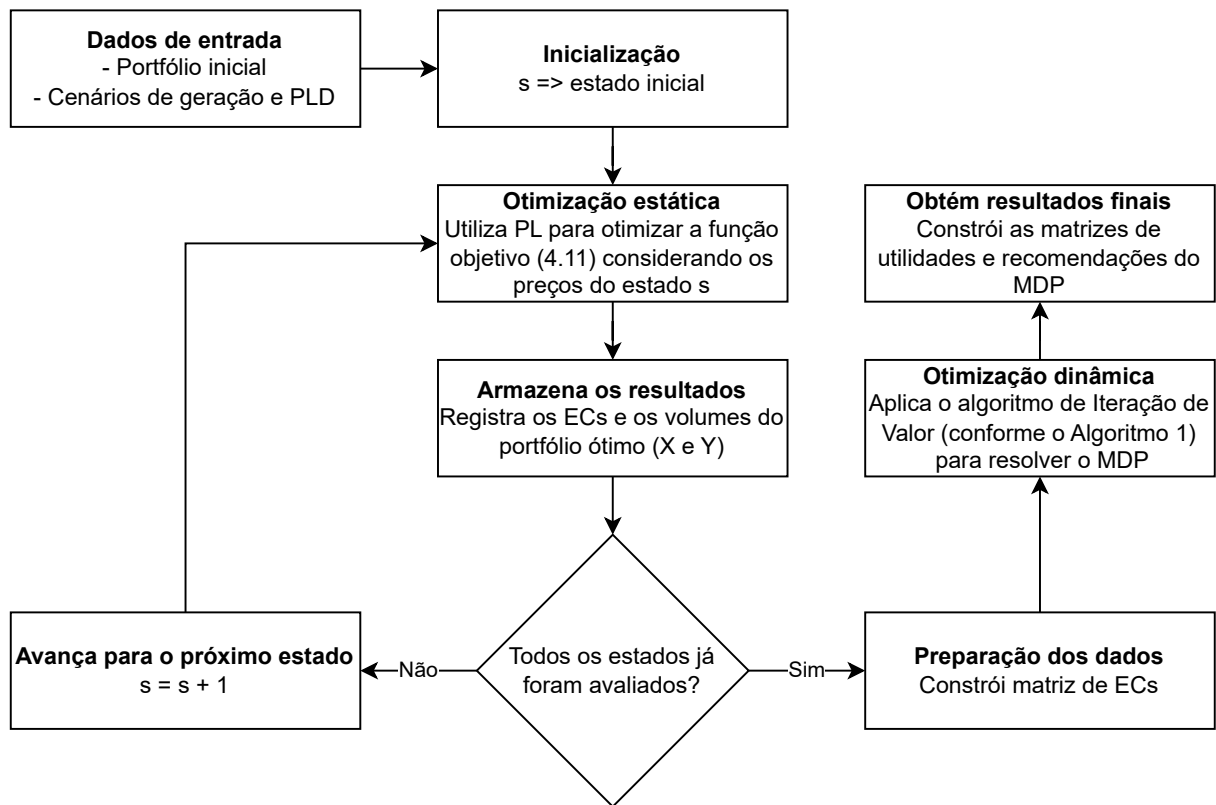


Figura 4.3: Fluxograma da metodologia proposta.

Capítulo 5

Testes e resultados

Este capítulo apresenta simulações realizadas com o intuito de ilustrar a aplicação da metodologia proposta, bem como os resultados obtidos. A Seção 5.1 contém a descrição geral das simulações realizadas. A Seção 5.2 apresenta um caso teste que considera tanto contratos por capacidade quanto contratos por quantidade. Já na Seção 5.3, uma simulação considerando apenas contratos por quantidade é realizada, dado que os contratos por capacidade ainda não são amplamente utilizados no Brasil e por esta razão o modelo proposto é empregado em um experimento que abrange um cenário mais comum para os agentes do setor.

5.1 Descrição das simulações

O modelo utilizado neste trabalho foi desenvolvido em linguagem Python. A máquina utilizada nas simulações possui 8 GB de memória RAM e processador Intel Core I5-8250U CPU @ 1.8GHz. Para a solução da PL foi utilizado o *solver* gratuito ECOS [46], que pode ser facilmente utilizado com Python.

Neste trabalho foi considerado um conjunto de séries sintéticas de PLD, obtidas com o *deck* do NEWAVE de janeiro de 2021 disponibilizado pela CCEE [3], as quais foram submetidas a um filtro de cenários para remover possíveis *outliers*. Tais cenários de PLD são apresentados na Figura 5.1. Além dos cenários de PLD, foram extraídos do mesmo *deck* os cenários de ENA correspondentes a cada cenário de PLD para que fosse possível utilizá-las para projetar cenários de geração de energia das usinas disponíveis para contratação por capacidade que fossem correlacionados com os cenários de ENA do NEWAVE e, conseqüentemente, também correlacionados com os de PLD utilizados nas simulações.




Figura 5.1: Cenários de PLD utilizados na simulação.

Adotou-se um horizonte de estudo de 24 meses e a comercializadora analisada possui um portfólio inicial de 10 MW médios vendidos em cada ano no submercado Sudeste/Centro-Oeste ao preço real de R\$ 225/MWh no primeiro ano e R\$ 231/MWh no segundo ano. O portfólio inicial de 10 MW médios vendidos em cada ano possui um volume mensal sazonal conforme ilustrado na Figura 5.2 e considerado igual para os dois anos de estudo.




Figura 5.2: Volume mensal de energia contratado.

Os contratos por capacidade das usinas adotadas neste trabalho possuem preços fixos em todo horizonte de estudo sofrendo apenas uma atualização pela inflação considerada de 5% para o segundo ano de estudo. O submercado, a garantia física (GF) e os preços nominais dos contratos por capacidade destas usinas são apresentados na Tabela 5.1.

Tabela 5.1: Dados das usinas disponíveis para contratos por capacidade

Usina	Submercado	GF	Preço
PCH 1	SE	10 MWm	R\$ 170/MWh
PCH 2	S	12 MWm	R\$ 160/MWh
Eólica	NE	12.1 MWm	R\$ 160/MWh

Os perfis médios mensais de geração das usinas em relação ao volume anual de energia gerada de cada uma delas são apresentados na Figura 5.3. Pode-se perceber que as usinas disponíveis para compra de energia possuem perfis de geração complementares, ou seja, quando as usinas hidráulicas estão gerando menos energia, as usinas eólicas estão gerando mais energia. Desta forma, os perfis de geração das usinas podem se complementar entre os meses do ano.




Figura 5.3: Perfil de geração médio das usinas.

Os produtos disponíveis para compra de energia utilizados neste trabalho são os que possuem mais liquidez nos finais de ano. Todos os produtos deste estudo são do submercado Sudeste/Centro-Oeste, devido ao fato de que os produtos de outros submercados possuem baixa liquidez. No final do ano, normalmente são negociados os produtos do primeiro e segundo trimestre do ano seguinte (T1 e T2), segundo semestre do ano seguinte (S2), e os produtos anuais do ano seguinte (A1) e do segundo ano seguinte (A2). A Tabela 5.2 apresenta os produtos e os respectivos preços de referência adotados nos testes. Os preços utilizados neste trabalho são equivalentes aos preços médios dos negócios fechados no eHUB no dia 30 de dezembro de 2020.

Tabela 5.2: Produtos disponíveis para compra - contratos por quantidade

Produto	Preço
T1	R\$ 218/MWh
T2	R\$ 162/MWh
S2	R\$ 210/MWh
A1	R\$ 219/MWh
A2	R\$ 197/MWh

O fator λ que pondera a aversão ao risco no modelo estático foi definido como 0,75 nas simulações. Já o valor da taxa de retorno r utilizada no cálculo do VPL foi de 10%.

Os preços de referência indicados na Tabela 5.2 foram utilizados para construir a matriz de estados do MDP. A matriz de estados, obtida através do processo descrito na subseção 4.2.1.1, é apresentada na Figura 5.4. A matriz foi construída baseando-se nos valores de referência de preços indicados na Tabela 5.2, levando em consideração as variações de preços entre os estados indicados na Figura 5.5 e as volatilidades apresentadas na Tabela 5.3. As variações indicadas na matriz da Figura 5.5 foram definidas considerando que o elemento central possui uma variação de 0%. As demais variações foram estimadas para que a matriz fosse preenchida com diferentes cenários de preços. Ao deslocar-se para a direita é incrementada uma variação de +10% e para a esquerda o incremento é de -10%. Já para o deslocamento para a parte superior da matriz considera-se um incremento de +15% e para a parte inferior um incremento de -15%. Vale ressaltar que esta matriz pode ser construída de acordo com as necessidades de cada agente.

212	215	218	221	224	227	230	233	236
207	210	213	216	219	222	225	228	231
202	205	209	212	215	218	221	224	227
198	201	204	207	210	213	216	219	222
193	196	199	202	205	209	212	215	218
189	192	195	198	201	204	207	210	213
184	187	190	193	196	199	202	205	209
180	183	186	189	192	195	198	201	204
175	178	181	184	187	190	193	196	199

Figura 5.4: Matriz de preços de mercado de energia representados pela média dos preços em cada estado.

As volatilidades apresentadas na Tabela 5.3 foram calculadas com base no histórico

20%	30%	40%	50%	60%	70%	80%	90%	100%
5%	15%	25%	35%	45%	55%	65%	75%	85%
-10%	0%	10%	20%	30%	40%	50%	60%	70%
-25%	-15%	-5%	5%	15%	25%	35%	45%	55%
-40%	-30%	-20%	-10%	0%	10%	20%	30%	40%
-55%	-45%	-35%	-25%	-15%	-5%	5%	15%	25%
-70%	-60%	-50%	-40%	-30%	-20%	-10%	0%	10%
-85%	-75%	-65%	-55%	-45%	-35%	-25%	-15%	-5%
-100%	-90%	-80%	-70%	-60%	-50%	-40%	-30%	-20%

Figura 5.5: Matriz de variações de preços para construção da matriz de estados.

Tabela 5.3: Volatilidade dos produtos disponíveis para compra

Produto	Volatilidade
T1	21%
T2	20%
S2	18%
A1	20%
A2	5%

de cotações no mercado consultados na plataforma eHUB (mencionada na seção 2.5). Vale frisar que o método de estimação destes valores pode ser definido de acordo com a percepção de cada agente.

5.2 Caso 1: Considerando contratos por capacidade e quantidade

Esta subseção apresenta os resultados do problema considerando que a comercializadora irá contratar energia através de contratos por capacidade e por quantidade.

A Figura 5.6 contém o resultado do modelo de otimização estático em cada elemento da matriz de estados, apresentando o volume de energia, em MW médios, que compõe o portfólio ótimo de cada estado considerando os respectivos preços de mercado indicadas na Figura 5.4.

A Figura 5.7 destaca o resultado do modelo estático do estado da extremidade superior direita da matriz da Figura 5.6. Como pode ser observado na parte superior-direita,




Figura 5.6: Volumes de energia para cada produto que compõe o portfólio ótimo em cada estado.

apresentado na Figura 5.7, quando os preços de mercado são muito elevados o modelo estático propõe a contratação de energia exclusiva das usinas através de contratos de compra por capacidade. As colunas do gráfico representam o montante de energia que devem ser contratados para os produtos indicados no eixo x.




Figura 5.7: Volumes de energia para cada produto que compõe o portfólio ótimo no estado do extremo superior direito.

Por outro lado, na parte inferior-esquerda, onde os preços de mercado são mais baixos, percebe-se que o modelo estático compõe quase todo portfólio com contratos de quantidade, que mitigam o risco de quantidade. Este resultado pode ser facilmente visualizado na Figura 5.8, que destaca o estado da extremidade inferior esquerda da Figura 5.6. Vale destacar que, mesmo nas condições de preços baixos, o modelo ainda identifica vantagens em comprar uma pequena parcela da energia das usinas via contratos por capacidade. Isso demonstra que, considerando as premissas adotadas neste estudo, a modalidade de contratação de energia por meio de contratos de compra por capacidade pode ser bem valiosa.

Essa constatação é evidenciada pelo fato de que o modelo de otimização recomendou sua utilização independentemente do cenário de preços.




Figura 5.8: Volumes de energia para cada produto que compõe o portfólio ótimo no estado do extremo inferior esquerdo.

A Figura 5.9 apresenta o resultado do EC, em milhões de reais, do portfólio ótimo para cada cenário de preços de mercado. Em outras palavras, a Figura 5.9 apresenta o resultado da função objetivo (Equação (4.11)) do modelo de otimização estático baseado nas premissas de cada elemento da matriz de estados.

4,165	4,054	3,973	3,908	3,847	3,791	3,738	3,687	3,638
4,482	4,234	4,107	4,007	3,940	3,877	3,818	3,764	3,712
4,982	4,642	4,337	4,165	4,054	3,973	3,908	3,847	3,791
5,529	5,162	4,808	4,482	4,234	4,107	4,007	3,940	3,877
6,101	5,718	5,344	4,982	4,642	4,337	4,165	4,054	3,973
6,686	6,295	5,908	5,529	5,162	4,808	4,482	4,234	4,107
7,282	6,883	6,490	6,101	5,718	5,344	4,982	4,642	4,337
7,888	7,482	7,081	6,686	6,295	5,908	5,529	5,162	4,808
8,508	8,093	7,685	7,282	6,883	6,490	6,101	5,718	5,344

Figura 5.9: Equivalentes Certos (ECs) resultantes de cada portfólio ótimo.

Pode-se perceber que os ECs são maiores quando os portfólios são construídos em estados com preços de mercado menores, como na parte inferior-esquerda da matriz. Este resultado ocorre devido ao portfólio ótimo ser majoritariamente composto por contratos de quantidade em cenários de preços baixos, conforme ilustra a Figura 5.6, fazendo com que o valor em risco nestas composições seja menor que o valor em risco de um portfólio composto majoritariamente por contratos por capacidade, que aumentam o risco devido à incerteza da geração das usinas. Este comportamento pode ser verificado na Figura 5.10, que apresenta o valor em risco, em milhões de reais, para cada cenário de preço de mercado da matriz de estados. Para complementar esta observação, na Figura 5.11 pode-se verificar

que o valor esperado se mantém em níveis próximos nas extremidades de preços, ou seja, na parte inferior-esquerda e superior-direita da matriz. Portanto, percebe-se que a principal variável que faz com que o EC do portfólio ótimo seja maior na parte inferior-esquerda da matriz da Figura 5.9 é o valor em risco.

9,462	9,719	9,995	10,005	9,989	9,989	9,989	9,989	9,998
3,997	9,418	9,665	9,996	9,995	9,988	9,989	9,988	9,989
2,727	3,473	5,592	9,462	9,719	9,995	10,005	9,989	9,989
2,206	2,480	3,061	3,997	9,418	9,665	9,996	9,995	9,988
1,909	2,135	2,454	2,727	3,473	5,592	9,462	9,719	9,995
1,757	1,798	1,915	2,206	2,480	3,061	3,997	9,418	9,665
1,706	1,690	1,776	1,909	2,135	2,454	2,727	3,473	5,592
1,935	1,764	1,705	1,757	1,798	1,915	2,206	2,480	3,061
3,041	1,948	1,883	1,706	1,690	1,776	1,909	2,135	2,454

Figura 5.10: VPL do valor em risco do portfólio ótimo em cada cenário de preço.

11,262	11,344	11,470	11,412	11,339	11,283	11,230	11,179	11,137
7,479	11,297	11,356	11,504	11,436	11,368	11,310	11,255	11,204
7,027	7,247	8,531	11,262	11,344	11,470	11,412	11,339	11,283
7,184	7,022	7,103	7,479	11,297	11,356	11,504	11,436	11,368
7,533	7,319	7,184	7,027	7,247	8,531	11,262	11,344	11,470
8,003	7,644	7,345	7,184	7,022	7,103	7,479	11,297	11,356
8,561	8,150	7,822	7,533	7,319	7,184	7,027	7,247	8,531
9,339	8,805	8,360	8,003	7,644	7,345	7,184	7,022	7,103
10,789	9,553	9,097	8,561	8,150	7,822	7,533	7,319	7,184

Figura 5.11: VPL do valor esperado do portfólio ótimo em cada cenário de preço.

A matriz de ECs apresentada na Figura 5.9, resultante da abordagem de otimização estática, é utilizada como dado de entrada para o MDP. Desta forma, o próximo passo consiste em determinar o melhor momento para investir no portfólio ótimo, empregando a abordagem de otimização de dinâmica com o MDP. Nesta análise, o fator γ foi definido como 99%, e o MDP foi executado.

A Figura 5.12 apresenta a quantidade de iterações do algoritmo de iteração de valor que foram necessárias para alcançar a convergência do modelo de decisão considerando o valor ϵ igual a 10^{-6} , que é utilizado na avaliação do critério de parada do algoritmo de iteração de valor. Apesar do modelo ter utilizado 122 iterações para alcançar a convergência, na segunda iteração foi possível identificar uma queda imediata do valor de δ , implicando que houve uma melhoria significativa nas primeiras iterações. Vale destacar

que o modelo precisou de 38 iterações para atingir o critério de parada considerando o valor de ϵ igual a 10^{-3} . No entanto, os resultados obtidos divergiram apenas a partir da segunda casa decimal. Nesta perspectiva, é possível considerar que, embora a escolha de um valor menor de ϵ apresentar resultados melhores, a alteração de ϵ não afeta significativamente o resultado do modelo, uma vez que os resultados obtidos com outros valores, na prática, podem ser considerados equivalentes.




Figura 5.12: Resultado das iterações do MDP utilizando $\gamma = 0,99$.

A Figura 5.13 apresenta a utilidade de cada estado, bem como as decisões recomendadas pelo modelo MDP. O valor numérico representa a utilidade esperada de cada estado e os ícones representam as recomendações do MDP, onde o círculo vermelho indica que o modelo recomenda a execução do portfólio no momento do estado atual, enquanto os ícones de setas azuis indicam que o modelo recomenda aguardar a movimentação de preços para cenários mais favoráveis de preços de mercado. A direção das setas indica qual seria a transição de estado que resultaria no melhor resultado. É importante ressaltar que, uma vez que o preço de mercado é uma variável sujeita a incertezas, a direção das setas tem apenas caráter indicativo, fornecendo ao agente informações sobre as possíveis movimentações favoráveis de preços para o seu portfólio.

Desta forma, a Figura 5.13 indica que quando o preço de mercado atual está localizado no centro da matriz, o MDP sugere que a melhor decisão é aguardar uma possível flutuação de preços que possa favorecer um resultado mais vantajoso para o agente. A direção do ícone de seta do estado da célula central indica que o melhor cenário seria se o preço de mercado atual sofresse uma variação negativa, saindo de uma média de R\$ 205/MWh e chegando ao preço médio de R\$ 198/MWh. Vale ressaltar que o resultado do modelo

apresenta uma recomendação para cada estado da matriz de estados, o que significa que, em casos de variações de preço, basta verificar qual é a recomendação do estado correspondente ao novo preço de mercado. Desta forma, não é necessário construir uma nova matriz de estados e nem executar todo o processo novamente. No teste realizado, o modelo indicou que se ocorrer variações positivas de preço (células na direção superior-direita da matriz), seria melhor esperar por uma possível queda de preços do que executar o portfólio nesses estados.

Por fim, a Figura 5.14 apresenta o resultado dos ECs obtidos em 10 mil simulações em que o agente tomador de decisão segue as recomendações do modelo proposto. É possível verificar que, na maioria dos casos, o agente tomador de decisão deve alcançar um EC de aproximadamente R\$ 5,72 milhões.

Analisando em conjunto as Figuras 5.10, 5.11, 5.13 e 5.14, pode-se verificar que o valor esperado do portfólio seria de aproximadamente R\$ 7,25 milhões se o agente executasse o portfólio no momento atual sem utilizar a recomendação do MDP, ou seja, se o problema fosse modelado apenas com uma abordagem estática. No entanto, utilizando o MDP para decidir o melhor momento para realizar as contratações, o valor esperado alcançaria, na maioria das vezes, aproximadamente R\$ 7,32 milhões. Além disso, na maioria dos casos o agente conseguiria reduzir o seu valor em risco, que no estado central (atual) é de aproximadamente R\$ 3,47 milhões, para um valor de aproximadamente R\$ 2,14 milhões. Esta análise indica que, em comparação com a abordagem estática, a abordagem dinâmica utilizando o MDP foi capaz de aumentar o resultado esperado e, ao mesmo tempo, reduzir a exposição ao risco. Esses resultados destacam a eficiência da utilização do MDP e sua importância nas estratégias de otimização de portfólio.

5.2.1 Variações do parâmetro de risco γ

O parâmetro γ pode ser utilizado para ponderar a aversão ao risco associado à incerteza dos preços ao decidir esperar por flutuações de preços visando obter resultados mais aderentes ao apetite ao risco de cada agente.

As Figuras 5.15 e 5.16 apresentam as utilidades em cada estado para o mesmo estudo supracitado utilizando o fator γ igual a 98,5% e 98,0%, respectivamente. É possível notar que à medida que a aversão ao risco aumenta, ou seja, γ diminui, o problema fica mais restritivo e tende a recomendar otimizar o portfólio mais rapidamente, fazendo com que mais ícones de círculos vermelhos apareçam nas matrizes dos resultados do MDP, indicando que é melhor executar o portfólio no momento atual do que aguardar a movimentação de

4,4621 ↓	4,4104 ↗	4,3083 ↗	4,1822 ↗	4,0566 ↗	3,9464 ↗	3,8611 ↗	3,8071 ↗	3,7885 ↗
4,5884 ↓	4,5227 ↗	4,3934 ↗	4,2504 ↗	4,1135 ↗	3,9954 ↗	3,9046 ↗	3,8472 ↗	3,8262 ↗
4,9818 ✓	4,7965 ↗	4,6066 ↗	4,4249 ↗	4,2611 ↗	4,1235 ↗	4,0191 ↗	3,9529 ↗	3,9285 ↗
5,5291 ✓	5,2017 ↗	4,9356 ↗	4,6998 ↗	4,4965 ↗	4,3289 ↗	4,2025 ↗	4,1224 ↗	4,0923 ↗
6,1013 ✓	5,7175 ✓	5,3658 ↗	5,0708 ↗	4,8167 ↗	4,6094 ↗	4,4522 ↗	4,3515 ↗	4,3131 ↗
6,6855 ✓	6,2952 ✓	5,9085 ✓	5,5308 ↗	5,2227 ↗	4,9639 ↗	4,7644 ↗	4,6341 ↗	4,5828 ↗
7,2815 ✓	6,8826 ✓	6,4899 ✓	6,1013 ✓	5,7175 ✓	5,3930 ↗	5,1364 ↗	4,9599 ↗	4,8869 ↗
7,8883 ✓	7,4824 ✓	7,0814 ✓	6,6855 ✓	6,2952 ✓	5,9085 ✓	5,5710 ↗	5,3113 ↗	5,1933 ↗
8,5084 ✓	8,0927 ✓	7,6848 ✓	7,2815 ✓	6,8826 ✓	6,4899 ✓	6,1013 ✓	5,7175 ✓	5,3533 ↗

Figura 5.13: Resultado das utilidades e recomendação do MDP utilizando $\gamma = 0,99$.

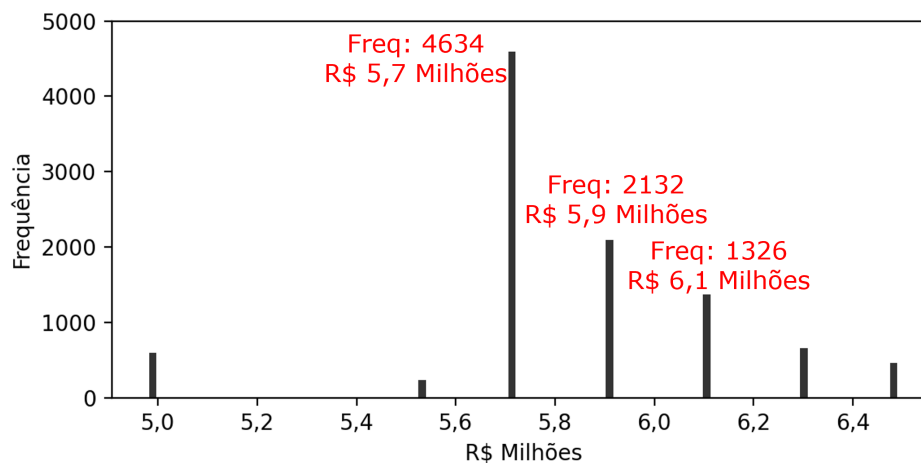


Figura 5.14: ECs esperados para 10 mil simulações considerando $\gamma = 0,99$.

preços.

A Figura 5.17 ilustra o caso em que o agente tomador de decisão não possui aversão ao risco da incerteza da movimentação de preços, ou seja, considerando o fator $\gamma = 1$. Desta forma, se a recompensa de uma decisão futura não possui nenhum tipo de “desconto” ou risco, então o modelo sempre irá indicar que o melhor momento para construir o portfólio é no momento em que este apresentar o maior EC.

4,2820 ↓	4,2112 ↙	4,0839 ↙	3,9590 ↙	3,8609 ↙	3,7910 ✓	3,7379 ✓	3,6867 ✓	3,6651 ↙
4,4820 ✓	4,3485 ↙	4,1804 ↙	4,0312 ↙	3,9401 ✓	3,8773 ✓	3,8184 ✓	3,7641 ✓	3,7120 ✓
4,9818 ✓	4,6689 ↙	4,4272 ↙	4,2230 ↙	4,0662 ↙	3,9730 ✓	3,9083 ✓	3,8468 ✓	3,7910 ✓
5,5291 ✓	5,1616 ✓	4,8090 ↙	4,5342 ↙	4,3097 ↙	4,1368 ↙	4,0131 ↙	3,9401 ✓	3,8983 ↙
6,1013 ✓	5,7175 ✓	5,3439 ✓	4,9818 ✓	4,6654 ↙	4,4221 ↙	4,2404 ↙	4,1264 ↙	4,0838 ↙
6,6855 ✓	6,2952 ✓	5,9085 ✓	5,5291 ✓	5,1616 ✓	4,8163 ↙	4,5724 ↙	4,4129 ↙	4,3525 ↙
7,2815 ✓	6,8826 ✓	6,4899 ✓	6,1013 ✓	5,7175 ✓	5,3439 ✓	4,9942 ↙	4,7798 ↙	4,6912 ↙
7,8883 ✓	7,4824 ✓	7,0814 ✓	6,6855 ✓	6,2952 ✓	5,9085 ✓	5,5291 ✓	5,1991 ↙	5,0691 ↙
8,5084 ✓	8,0927 ✓	7,6848 ✓	7,2815 ✓	6,8826 ✓	6,4899 ✓	6,1013 ✓	5,7175 ✓	5,3439 ✓

Figura 5.15: Resultado das utilidades e recomendação do MDP utilizando $\gamma = 0,985$.

4,2119 ↓	4,1326 ↙	4,0050 ↙	3,9083 ✓	3,8468 ✓	3,7910 ✓	3,7379 ✓	3,6867 ✓	3,6465 ↙
4,4820 ✓	4,2790 ↙	4,1067 ✓	4,0071 ✓	3,9401 ✓	3,8773 ✓	3,8184 ✓	3,7641 ✓	3,7120 ✓
4,9818 ✓	4,6424 ✓	4,3684 ↙	4,1689 ↙	4,0541 ✓	3,9730 ✓	3,9083 ✓	3,8468 ✓	3,7910 ✓
5,5291 ✓	5,1616 ✓	4,8078 ✓	4,4870 ↙	4,2609 ↙	4,1067 ✓	4,0071 ✓	3,9401 ✓	3,8773 ✓
6,1013 ✓	5,7175 ✓	5,3439 ✓	4,9818 ✓	4,6424 ✓	4,3691 ↙	4,1779 ↙	4,0541 ✓	4,0055 ↙
6,6855 ✓	6,2952 ✓	5,9085 ✓	5,5291 ✓	5,1616 ✓	4,8078 ✓	4,5017 ↙	4,3185 ↙	4,2461 ↙
7,2815 ✓	6,8826 ✓	6,4899 ✓	6,1013 ✓	5,7175 ✓	5,3439 ✓	4,9818 ✓	4,6953 ↙	4,5906 ↙
7,8883 ✓	7,4824 ✓	7,0814 ✓	6,6855 ✓	6,2952 ✓	5,9085 ✓	5,5291 ✓	5,1616 ✓	4,9997 ↙
8,5084 ✓	8,0927 ✓	7,6848 ✓	7,2815 ✓	6,8826 ✓	6,4899 ✓	6,1013 ✓	5,7175 ✓	5,3439 ✓

Figura 5.16: Resultado das utilidades e recomendação do MDP utilizando $\gamma = 0,98$.

8,5083 ↓	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙
8,5083 ↓	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙
8,5083 ↓	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙
8,5083 ↓	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙
8,5083 ↓	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙
8,5083 ↓	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙
8,5083 ↓	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙
8,5084 ↓	8,5084 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙	8,5083 ↙
8,5084 ✓	8,5084 ←	8,5083 ←	8,5083 ←	8,5083 ←	8,5083 ←	8,5083 ←	8,5083 ←	8,5083 ←

Figura 5.17: Resultado das utilidades e recomendação do MDP utilizando $\gamma = 1$.

5.3 Caso 2: Considerando apenas contratos de quantidade

Esta subseção apresenta os resultados do problema considerando que a comercializadora irá contratar energia apenas por meio de contratos por quantidade. Desta forma, a diferença em relação ao caso 1 é que os contratos por capacidade não serão considerados neste estudo de caso. Apesar da vantagem de se obter resultados melhores com a abordagem utilizada no caso 1, este caso 2 representa a grande maioria das situações praticadas no mercado de energia elétrica brasileiro. Vale destacar que, apesar das diferenças entre os casos, as explicações e análise dos resultados para ambos os casos são similares.

A Figura 5.18 apresenta o resultado do modelo de otimização estático para cada elemento da matriz de estados, exibindo o volume de energia que compõe o portfólio ótimo em cada estado considerando as variações de preços de mercado indicadas na Figura 5.4. Nota-se que a composição do portfólio apresentou poucas variações de volume entre os estados.

A Figura 5.19 expõe o resultado do modelo de otimização estático em cada elemento da matriz de estados, apresentando o EC do portfólio ótimo para cada estado considerando as variações de preços de mercado indicadas na Figura 5.4. Percebe-se que, conforme




Figura 5.18: Volumes de energia para cada produto que compõe o portfólio ótimo em cada estado.

exibido na Figura 5.18, apesar dos volumes dos produtos apresentar pequenas variações entre cada estado, os valores dos ECs apresentaram grandes variações. Isso ocorreu porque o valor esperado em momentos de preços baixos ficou elevado devido ao modelo tentar aproveitar os momentos de preços baixos para obter ganhos ao comprar energia mais barata e liquidá-la ao PLD mais alto.

3,297	2,875	2,453	2,031	1,610	1,188	0,767	0,346	-0,075
3,931	3,508	3,086	2,664	2,242	1,820	1,399	0,977	0,556
4,565	4,142	3,719	3,297	2,875	2,453	2,031	1,610	1,188
5,200	4,777	4,353	3,931	3,508	3,086	2,664	2,242	1,820
5,836	5,412	4,988	4,565	4,142	3,719	3,297	2,875	2,453
6,474	6,049	5,624	5,200	4,777	4,353	3,931	3,508	3,086
7,115	6,687	6,261	5,836	5,412	4,988	4,565	4,142	3,719
7,761	7,330	6,901	6,474	6,049	5,624	5,200	4,777	4,353
8,412	7,977	7,545	7,115	6,687	6,261	5,836	5,412	4,988

Figura 5.19: Equivalentes Certos (ECs) resultantes de cada portfólio ótimo.

A Figura 5.20 apresenta a quantidade de iterações do algoritmo de iteração de valor que foram necessárias para alcançar a convergência. Neste caso, foi necessário um total de 163 iterações para alcançar a convergência. Esse número é superior ao caso 1, principalmente devido às maiores variações nos valores dos ECs desta simulação. Essas

flutuações acentuadas tornaram o processo de convergência mais complexo e exigiram um maior número de iterações para se obter a solução ótima.

A Figura 5.21 apresenta a utilidade de cada estado. Conforme informado no caso 1, esta matriz apresenta as possíveis decisões recomendadas pelo modelo MDP, onde o ícone de um círculo vermelho indica que o modelo recomenda a execução do portfólio no momento do estado atual, enquanto os ícones de seta azuis indicam que o modelo recomenda aguardar a movimentação de preços para cenários mais favoráveis de preços de mercado. Por fim, a Figura 5.22 apresenta o resultado dos ECs obtidos em 10 mil simulações em que o agente tomador de decisão segue as recomendações do modelo proposto.




Figura 5.20: Resultado das iterações do MDP utilizando $\gamma = 0,99$.

Os resultados indicam que em ambos os casos foi possível aumentar o valor do EC do portfólio ótimo ao utilizar a abordagem de otimização dinâmica com MDP. Demonstrando a eficácia e importância da abordagem nas aplicações de otimização de portfólio.

Como os contratos por capacidade nem sempre estão disponíveis no mercado e nem todos os agentes possuem usinas na composição de seus portfólios, este estudo de caso demonstra que o modelo é suficientemente flexível para ser modelado para as necessidades de cada agente. Assim, o modelo proposto se apresenta como uma ferramenta capaz de melhorar os resultados até mesmo no caso de empresas que só transacionam energia via contratos por quantidade.

4,1685 ↓	4,1283 ↙	4,0473 ↙	3,9435 ↙	3,8356 ↙	3,7386 ↙	3,6624 ↙	3,6138 ↙	3,5971 ↙
4,2758 ↓	4,2277 ↙	4,1306 ↙	4,0110 ↙	3,8919 ↙	3,7868 ↙	3,7050 ↙	3,6528 ↙	3,6338 ↙
4,5750 ↓	4,4956 ↙	4,3416 ↙	4,1840 ↙	4,0376 ↙	3,9127 ↙	3,8168 ↙	3,7557 ↙	3,7332 ↙
5,2002 ✓	4,9069 ↙	4,6705 ↙	4,4571 ↙	4,2697 ↙	4,1140 ↙	3,9957 ↙	3,9202 ↙	3,8919 ↙
5,8361 ✓	5,4287 ↙	5,1041 ↙	4,8237 ↙	4,5853 ↙	4,3884 ↙	4,2384 ↙	4,1419 ↙	4,1049 ↙
6,4743 ✓	6,0486 ✓	5,6272 ↙	5,2825 ↙	4,9833 ↙	4,7342 ↙	4,5412 ↙	4,4140 ↙	4,3637 ↙
7,1155 ✓	6,6874 ✓	6,2613 ✓	5,8361 ✓	5,4654 ↙	5,1538 ↙	4,9004 ↙	4,7256 ↙	4,6524 ↙
7,7609 ✓	7,3298 ✓	6,9014 ✓	6,4743 ✓	6,0486 ✓	5,6522 ↙	5,3211 ↙	5,0574 ↙	4,9364 ↙
8,4116 ✓	7,9771 ✓	7,5450 ✓	7,1155 ✓	6,6874 ✓	6,2613 ✓	5,8361 ✓	5,4120 ✓	5,0839 ↙

Figura 5.21: Resultado das utilidades e recomendação do MDP utilizando $\gamma = 0,99$.

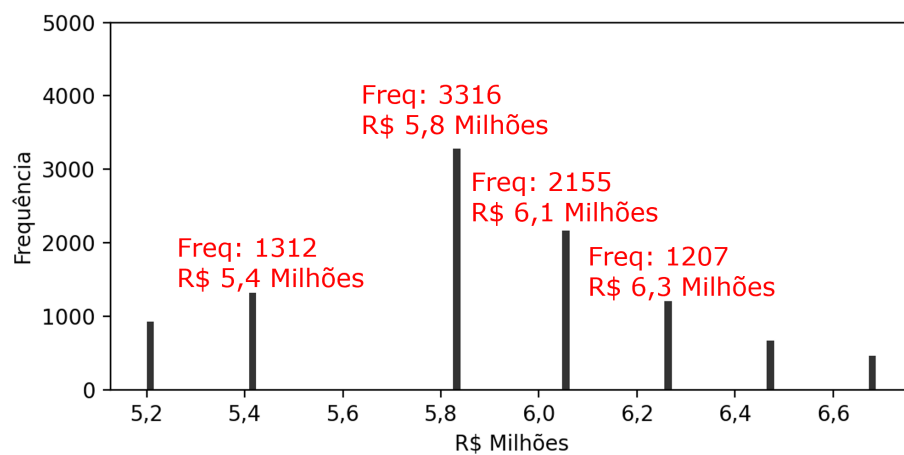


Figura 5.22: Resultados esperados para 10 mil simulações considerando $\gamma = 0,99$.

Capítulo 6

Conclusão

Os agentes que atuam na comercialização de energia elétrica no Brasil enfrentam diversos riscos associados às incertezas do setor, como as incertezas de geração, consumo e PLD. Essas, mesmo que implicitamente, incluem aleatoriedades de natureza climática, regulatórias, entre outras. Com tantas variáveis envolvidas na comercialização de energia, torna-se fundamental o emprego de modelos probabilísticos de forma a obter resultados que possam embasar a tomada de decisões em um ambiente sob incertezas.

O presente trabalho apresentou um modelo de otimização dinâmica de portfólio de energia elétrica que visa auxiliar na gestão dos portfólios dos agentes que atuam no setor. O modelo possui duas principais etapas. O primeiro deles resolve um problema estático, constituindo em obter os montantes ótimos de energia que devem ser contratados através de contratos de quantidade e contratos de capacidade, com o objetivo de maximizar o valor esperado do portfólio e minimizar o valor em risco do mesmo. O segundo estágio consiste em um modelo de decisão sequencial, por meio da implementação do MDP, que tem como objetivo definir qual é o momento mais adequado para otimizar o portfólio, ou seja, o momento em que os preços de mercado podem maximizar os resultados do portfólio, levando-se em conta o risco da frustração de receita devido a flutuações desfavoráveis de preços.

Para atingir tais objetivos, o modelo estático foi desenvolvido utilizando programação linear. O modelo se baseou na maximização do valor esperado e minimização do valor em risco, sendo este expresso como a diferença entre o valor esperado e o CVaR da distribuição de receitas. A versatilidade do modelo permite que outros modelos de otimização estocástica sejam utilizados, como outras técnicas clássicas ou até meta-heurísticas [23].

O modelo estático conseguiu explorar a complementaridade dos perfis de diferentes

fontes de geração, compondo o portfólio com uma parcela de cada usina. Vale destacar que outras fontes de geração podem ser facilmente incluídas no modelo, o qual será capaz de definir a alocação ótima que maximiza os resultados e minimiza os riscos considerando as premissas adotadas. Além disso, foram modeladas usinas em diferentes submercados a fim de explorar a possibilidade da diferença de preços entre os submercados. E as contratações ótimas indicadas nas simulações demonstram que o modelo foi capaz de identificar e aproveitar as possibilidades de ganhos ao explorar fontes localizadas em diferentes submercados.

Os resultados obtidos indicaram que, apesar dos contratos por quantidade negociados em balcão estarem associados, normalmente, a preços mais altos quando comparados aos contratos por capacidade, eles são importantes na composição do portfólio, uma vez que garantem o suprimento de energia para a comercializadora em períodos de maiores incertezas, reduzindo a exposição ao risco do portfólio.

O modelo de otimização dinâmica se mostrou uma importante ferramenta, visto que é possível obter um ganho financeiro considerável ao contratar energia para o compor o portfólio em determinados momentos. O MDP se apresenta como um modelo flexível e funcional que pode ser utilizado para atender as necessidades de cada agente considerando suas particularidades. Quando comparado a abordagem estática, o modelo proposto conseguiu explorar as possíveis variações de preços de mercado e conseguiu definir o melhor momento para o investimento no portfólio aumentando o resultado do portfólio levando em conta o risco associado à incerteza de esperar por preços mais atrativos.

Apesar de estudos indicarem outras técnicas que consideram a aversão ao risco no MDP [33, 43, 44, 45], a utilização clássica do fator γ permitiu considerar adequadamente o risco associado à incerteza dos preços de mercado e decidir com eficácia o melhor momento para a otimização do portfólio. É importante destacar que, além do modelo permitir melhorar o valor esperado do portfólio, o modelo proposto é também conseguiu reduzir o valor em risco do mesmo. Esse resultado é muito importante porque reduzir o risco representa um valor significativo para os portfólios, principalmente em cenários com tanta incerteza.

Outra característica importante que o MDP apresentou foi a capacidade de aceitar diferentes configurações de preços de mercado, sendo neste trabalho representados pela matriz de estados. É possível atribuir pesos distintos a cada variação de preços, o que pode fazer com que o modelo seja representado de forma mais fiel a realidade. Esta característica representa uma vantagem em relação a técnicas como árvore binomial [27, 28, 29],

porque torna possível que a representação dos preços considere variações de preços além da variação bidirecional (aumento ou decaimento). Além disso, torna possível considerar diferentes probabilidades para estados específicos, sendo altamente adaptável para atender às necessidades de cada agente tomador de decisão. É importante destacar que, apesar deste trabalho ter representado os estados na forma matricial, os estados do MDP podem ser representados de outras formas como por meio de diagramas, por exemplo.

Por fim, além da simulação que propõe a contratação de contratos por capacidade para complementar o portfólio de um agente, foi realizada uma simulação que buscou se adequar a realidade de parte dos agentes do setor que não possuem usinas ou que não tem disponibilidade de contratos por capacidade. Desta forma, foi realizado uma simulação de otimização de forma que o portfólio fosse composto apenas por contratos por quantidade. Verificou-se que o modelo dinâmico pode melhorar de forma significativa o resultado de um agente, inclusive se ele operar no mercado apenas através de contratos por quantidade.

6.1 Trabalhos futuros

- Investigar o emprego de uma abordagem robusta ou de técnicas que possam melhorar os dados de entrada do modelo para reduzir a dependência do modelo em relação a qualidade dos dados de entrada, como por exemplo os cenários de PLD e geração das usinas.
- Explorar outras formas de representar os preços de mercado, como por exemplo implementando a abordagem de *Markov Influence Diagram* [47].
- Aprimorar a aversão ao risco do MDP, fazendo com que o risco de cada decisão seja considerado utilizando outras métricas além da simplificação do uso do parâmetro γ [33, 43, 44, 45].
- Utilizar uma abordagem de inteligência artificial, utilizando técnicas de aprendizado por reforço, para que não seja necessário executar o modelo estático em cada variação de preços.
- A implementação de técnicas meta-heurísticas para resolver o problema de otimização de portfólio considerando uma abordagem dinâmica.
- Uma análise comparativa para verificar quais modelos apresentam os melhores resultados nos problemas de otimização de portfólio.

-
- Aprimorar a modelagem do problema considerando os diferentes tipos de energia, abrangendo tanto a convencional quanto a incentivada, e incorporar a inclusão dos descontos relacionados à energia incentivada na precificação dos contratos.

Referências

- [1] CCEE. Visão geral das operações na ccee. *CCEE*, CCEE, 2010. Disponível em: <http://www.ccee.org.br/ccee/documentos/CCEE_125688>.
- [2] SILVA, L. G. e S. Análise do processo de reestruturação do setor elétrico brasileiro. *EmpíricaBR - Revista Brasileira de Gestão, Negócio e Tecnologia da Informação*, v. 1, n. 1, p. 39–55, 2017. ISSN 2447-178X. Disponível em: <<http://www2.ifrn.edu.br/ojs/index.php/EmpiricaBR/article/view/5270>>.
- [3] CCEE. *CCEE - Informações ao mercado*. 2023. Disponível em: <https://www.ccee.org.br/o/ccee/documentos/CCEE_1068101>.
- [4] BRASIL. Lei nº 13.360, de 17 de novembro de 2016. *Diário Oficial da República Federativa do Brasil*, Brasília, DF, 2016. Disponível em: <<https://legislacao.presidencia.gov.br/atos/?tipo=LEI&numero=13360&ano=2016&ato=998k3a650dZpWTb2b>>.
- [5] BRASIL. Portaria nº 514, de 27 de dezembro de 2018. *Diário Oficial da República Federativa do Brasil*, Brasília, DF, 2018. Disponível em: <https://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/57219064/doi-2018-12-28-portaria-n-514-de-27-de-dezembro-de-2018-57218754>.
- [6] EPE; CCEE; ONS. *Plano Decenal de Expansão de Energia 2030*. 2021.
- [7] MARZANO, L. G. B.; MELO, A. C. G.; SOUZA, R. C. An approach for portfolio optimization of energy contracts in the brazilian electric sector. *2003 IEEE Bologna Power Tech Conference Proceedings*, IEEE, 2004.
- [8] MOHAGHEGHI, V.; MOUSAVI, S. M.; ANTUCHEVIČIENĖ, J.; MOJTAHEDI, M. Project Portfolio Selection Problems: A Review of Models, Uncertainty Approaches, Solution Techniques, and Case Studies. *Technological and Economic Development of Economy*, v. 25, n. 6, p. 1380–1412, 2019. ISSN 20294921.
- [9] KALAYCI, C. B.; ERTENLICE, O.; AKBAY, M. A. A comprehensive review of deterministic models and applications for mean-variance portfolio optimization. *Expert Systems with Applications*, Elsevier Ltd, v. 125, p. 345–368, 2019. ISSN 09574174. Disponível em: <<https://doi.org/10.1016/j.eswa.2019.02.011>>.
- [10] DOERING, J.; KIZYS, R.; JUAN, A. A.; FITó Àngels; POLAT, O. Metaheuristics for rich portfolio optimisation and risk management: Current state and future trends. *Operations Research Perspectives*, v. 6, p. 100121, 2019. ISSN 2214-7160.
- [11] BOSA, D. A.; TORTELLI, O. L. Risk management and portfolio optimization of electric power trading. *SBSE 2018 - 7th Brazilian Electrical Systems Symposium*, p. 1–7, 2018.

- [12] RIBEIRO, M. G. *Otimização de Portfólios de Comercialização de Energia no Brasil*. Tese (Doutorado) — FGV, 2017. Disponível em: <http://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/18536/Tese_MGuerreiro_Versaofinal.pdf?sequence=1&isAllowed=y>.
- [13] MAIA, D. N.; MARZANO, L. G. B. Otimização De Portfólio De Contratos De Energia Sob a Ótica De Uma Empresa Com Vários Ativos De Geração. *SBPO*, 2018. Disponível em: <<https://proceedings.science/p/85458>>.
- [14] CAMARGO, L. A. S.; RAMOS, D. S.; GUARNIER, E.; BALAN, M. H. Definições de parâmetros de negociação para operações de swap e precificação de contratos contendo cláusula de flexibilidade com suporte de modelo de otimização estocástica e análise de risco versus retorno. *SNPTEE 2017 - XXIV Seminário Nacional de Produção e Transmissão de Energia Elétrica*, 2017.
- [15] MARKOWITZ, H. Portfolio selection. *The Journal of Finance*, Wiley, v. 7, n. 1, p. 77–91, 1952.
- [16] STREET, A.; BARROSO, L. A.; FLACH, B.; PEREIRA, M. V.; GRANVILLE, S. Risk constrained portfolio selection of renewable sources in hydrothermal electricity markets. *IEEE Transactions on Power Systems*, v. 24, n. 3, p. 1136–1144, 2009. ISSN 08858950.
- [17] CAMARGO, L. A. S. *Estratégias de comercialização e investimento, com ênfase em energias renováveis, suportadas por modelos de otimização especializados para avaliação estocástica de risco x retorno*. Tese (Doutorado) — USP, 2015.
- [18] CAMARGO, L. A. S.; LEONEL, L. D.; RAMOS, D. S.; STUCCHI, A. G. D. A risk averse stochastic optimization model for wind power plants portfolio selection. *2020 International Conference on Smart Energy Systems and Technologies (SEST)*, p. 1–6, 2020.
- [19] FANZERES, B.; STREET, A.; BARROSO, L. A. Contracting strategies for renewable generators: A hybrid stochastic and robust optimization approach. *IEEE Transactions on Power Systems*, v. 30, n. 4, p. 1825–1837, 2015. ISSN 08858950.
- [20] FANZERES, B.; STREET, A.; BARROSO, L. Contracting strategies for generation companies with ambiguity aversion on spot price distribution. *2014 Power Systems Computation Conference*, 2014.
- [21] RAGUENET, E.; DIENE, O. Decision support system for a portfolio of a hydroelectric company in the brazilian market. *2019 16th International Conference on the European Energy Market (EEM)*, p. 1–6, 2019.
- [22] FERREIRA, F. G. D. C.; GANDOMI, A. H.; CARDOSO, R. T. N. Artificial intelligence applied to stock market trading: A review. *IEEE Access*, v. 9, p. 30898–30917, 2021. ISSN 21693536.
- [23] ANSELMO, R. D. J.; AGUSTO, A. A.; SOUZA, J. C. S. de; FILHO, M. B. do C. Investigaç o de meta-heur sticas para otimizaç o de portf lio de energia el trica. *Anais do Congresso Brasileiro de Autom tica - CBA*, XXIV, n. 1534, p. 1–8, 2022.

- [24] RIBEIRO, L. H. M. *Risco De Mercado Na Comercialização De Energia Elétrica: Uma Análise Estruturada Com Foco No Ambiente De Contratação Livre*. 2015.
- [25] FREIRE, L.; STREET, A.; LIMA, D. A.; BARROSO, L. A. A hybrid milp and benders decomposition approach to find the nucleolus quota allocation for a renewable energy portfolio. *IEEE Transactions on Power Systems*, v. 30, n. 6, 2015. ISSN 08858950.
- [26] GUDER, R. *Otimização De Portfólios De Contratos De Energia Elétrica Utilizando Algoritmos Genéticos Multiobjetivo*. 2009.
- [27] PASSOS, A. C.; STREET, A.; BARROSO, L. A. A dynamic real option-based investment model for renewable energy portfolios. *IEEE Transactions on Power Systems*, v. 32, n. 2, p. 883–895, 2017. ISSN 08858950.
- [28] ARANHA, A. S.; STREET, A.; FERNANDES, C.; GRANVILLE, S. Risk-constrained optimal dynamic trading strategies under short and long-term uncertainties. *IEEE Transactions on Power Systems*, 2022.
- [29] ARANHA, A. S. V. D. *Otimização De Estratégias Dinâmicas De Comercialização De Energia Com Restrições De Risco Sob Incertezas De Curto E Longo Prazo*. 2021. Disponível em: <<https://www.maxwell.vrac.puc-rio.br/colecao.php?strSecao=resultadonrSeq=56114@1>>.
- [30] PUTERMAN, M. L. *Markov Decision Processes: Discrete Stochastic Dynamic Programming*. [S.l.]: John Wiley & Sons, 2014.
- [31] BBCE, B. B. de Comercialização de E. *BBCE - Balcão Brasileiro de Comercialização de Energia*. 2023. Disponível em: <<https://www.bbce.com.br>>.
- [32] BIRGE, J. R.; LOUVEAUX, F. *Introduction to Stochastic Programming*. New York, NY, USA: Springer New York, NY, 2011.
- [33] BÄUERLE, N.; GLAUNER, A. Markov decision processes with recursive risk measures. *European Journal of Operational Research*, v. 296, n. 3, p. 953–966, 2022. ISSN 0377-2217. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S037722172100360X>>.
- [34] URYASEV, S.; ROCKAFELLAR, R. T. Conditional value-at-risk: Optimization approach. *Stochastic Optimization: Algorithms and Applications*, Springer US, Boston, MA, p. 411–435, 2001. Disponível em: <https://doi.org/10.1007/978-1-4757-6594-6_17>.
- [35] GLOVER, F.; KOCHENBERGER, G. A. (Ed.). *Handbook of Metaheuristics*. Boston, MA, USA: Springer, 2003.
- [36] STREET, A. *Equivalente Certo e Medidas De Risco Em Decisões De Comercialização De Energia Elétrica*. Tese (Doutorado) — PUC-Rio, 2 2008.
- [37] MACAMBIRA, A. F. U. dos S.; MACULAN, N.; CABRAL, L. dos A. F.; PINTO, L. de L. *Programação Linear*. [s.n.], 2016. Disponível em: <<https://www.cos.ufrj.br/uploadfile/publicacao/3065.pdf>>.

- [38] HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman, 2001.
- [39] FEINBERG, E.; SHWARTZ, A. *Handbook of Markov Decision Processes: Methods and Applications*. [S.l.: s.n.], 2002. ISBN 0792374592.
- [40] PELLEGRINI, J.; WAINER, J. Processos de decisão de markov: um tutorial. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 133–179, Dec. 2007. Disponível em: <https://seer.ufrgs.br/index.php/rita/article/view/rita_v14_n2_p133-179>.
- [41] RUSSELL, S. J.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 4. ed. [S.l.]: Pearson Education, 2021. ISBN 9781292401171.
- [42] HOWARD, R. A. *Dynamic Programming And Markov Processes*. Technology Press of Massachusetts Institute of Technology, 1960. Disponível em: <<https://books.google.com.br/books?id=fXJEAAAIAAJ>>.
- [43] BORGES, I. O. *Estratégias para Otimização do algoritmo de Iteração de Valor Sensível a Risco*. 2018. Disponível em: <<https://teses.usp.br/teses/disponiveis/100/100131/tde-09012019-103826/pt-br.php>>.
- [44] BORKAR, V.; JAIN, R. Risk-constrained markov decision processes. *IEEE Transactions on Automatic Control*, v. 59, n. 9, p. 2574–2579, 2014.
- [45] NETO, E. L. P.; FREIRE, V.; DELGADO, K. V. Risk sensitive markov decision process for portfolio management. In: *Advances in Soft Computing: 19th Mexican International Conference on Artificial Intelligence, MICAI 2020, Mexico City, Mexico, October 12–17, 2020, Proceedings, Part I*. Berlin, Heidelberg: Springer-Verlag, 2020. p. 370–382. ISBN 978-3-030-60883-5. Disponível em: <https://doi.org/10.1007/978-3-030-60884-2_27>.
- [46] DOMAHIDI, A.; CHU, E.; BOYD, S. ECOS: An SOCP solver for embedded systems. *European Control Conference - ECC*, p. 3071–3076, 2013.
- [47] DíEZ, F. J.; YEBRA, M.; BERMEJO, I.; PALACIOS-ALONSO, M. A.; CALLEJA, M. A.; LUQUE, M.; PÉREZ-MARTÍN, J. Markov influence diagrams: A graphical tool for cost-effectiveness analysis. *Medical Decision Making*, v. 37, n. 2, p. 183–195, 2017. PMID: 28076183. Disponível em: <<https://doi.org/10.1177/0272989X16685088>>.