



INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA

Departamento de Matemática

**Modelo de Otimização Estocástico Multietapa para
Licitação em Mercados de Energia e Serviços de
Sistema de uma Central Solar Fotovoltaica**

JULIANA JACINTA DA SILVA PEREIRA

(Licenciada)

Dissertação para obtenção do grau de mestre em Matemática Aplicada à Indústria, na
Área de Especialização de Tratamento de Dados

Orientadores:

Doutora Ana Alexandra Antunes Figueiredo Martins

Doutor Jorge Alberto Mendes de Sousa

Júri:

Presidente: Doutor Luís Manuel Ferreira da Silva

Vogais: Doutora Ana Alexandra Antunes Figueiredo Martins

Doutor Filipe Santiago Cal

Setembro de 2024

Modelo de Otimização Estocástico Multietapa para Licitação em Mercados de Energia e Serviços de Sistema de uma Central Solar Fotovoltaica

JULIANA JACINTA DA SILVA PEREIRA

(Licenciada)

Dissertação para obtenção do grau de mestre em Matemática Aplicada à Indústria, na
Área de Especialização de Tratamento de Dados

Orientadores:

Doutora Ana Alexandra Antunes Figueiredo Martins, ISEL

Doutor Jorge Alberto Mendes de Sousa, ISEL

Júri:

Presidente: Doutor Luís Manuel Ferreira da Silva, ISEL

Vogais: Doutora Ana Alexandra Antunes Figueiredo Martins, ISEL

Doutor Filipe Santiago Cal, ISEL

Setembro de 2024

Agradecimentos

A concretização deste trabalho final de curso simboliza a conclusão de uma etapa essencial da minha formação académica, que não teria sido alcançada sem o apoio e contributo de várias pessoas ao longo da minha vida escolar.

Em primeiro lugar, queria expressar o meu profundo agradecimento aos meus orientadores, Professora Doutora Ana Alexandra Antunes Figueiredo Martins e Professor Doutor Jorge Alberto Mendes de Sousa, por todo o empenho, paciência e incentivo ao longo de todo este processo, e sinto-me profundamente grata pelo tempo que dedicaram às minhas dúvidas e à revisão deste projeto.

Gostaria de expressar o meu sincero agradecimento a todos os professores que me acompanharam ao longo do curso, pelo conhecimento e dedicação que sempre demonstraram, e de um modo especial ao Professor Doutor Luís Manuel Ferreira da Silva, coordenador do curso, pelo apoio e orientação ao longo destes dois anos.

Quero ainda agradecer ao Engenheiro Berto Martins e ao Engenheiro Ricardo Covas da EDP pela sua disponibilidade e orientação prestada ao longo deste projeto. O seu apoio e conhecimento foram essenciais para a concretização deste trabalho.

Um agradecimento especial à minha família e amigos, a forma como nunca me deixaram desistir nos momentos mais desafiantes desta dissertação.

Declaração de integridade

Declaro que esta dissertação é o resultado da minha investigação pessoal e independente. O seu conteúdo é original e todas as fontes listadas nas referências bibliográficas foram consultadas e estão devidamente mencionadas no texto. Mais declaro que todas as referências científicas e técnicas relevantes para o desenvolvimento do trabalho estão devidamente citadas e constam das referências bibliográficas.

O autor

Lisboa, 30 de Setembro de 2024

Resumo

O preço da energia é altamente volátil no Mercado Ibérico de Eletricidade (MIBEL) e nos diversos mercados de Serviços de Sistema, devido a condições meteorológicas, fatores económicos e outros elementos influentes. Assim, os agentes de mercado encontram dificuldades em licitar de forma otimizada para maximizar os seus lucros.

O objetivo deste trabalho consiste em desenvolver um modelo de otimização estocástico multietapa que otimiza as licitações para o dia seguinte nos diversos mercados de energia, considerando a previsão de produção de energia de um parque fotovoltaico com capacidade total de 100 MW.

Para atingir esta finalidade, este trabalho apresenta uma breve explicação sobre os mercados de energia, permitindo, assim, a construção do modelo com base no funcionamento deste mercados. A revisão da literatura também é um elemento importante, uma vez que analisa os métodos que são utilizados neste âmbito por outros autores.

A construção de um modelo de otimização estocástico é um aspeto que distingue este trabalho, uma vez que permite, de certa forma, capacitar um agente de mercado a tomar decisões informadas em cenários de incerteza, fornecendo as potenciais flutuações dos preços de energia em cada mercado. Uma das etapas deste modelo, inclui o mercado de Reserva de Regulação Secundária, sendo este também um fator diferenciador relativo a outros trabalhos.

O produtor que gere a central fotovoltaica pode utilizar os resultados obtidos e a análise de sensibilidade a alguns dos parâmetros do modelo, para licitar nos diversos mercados, tendo em conta o nível de risco que está disposto a assumir.

Palavras-chave: Mercados de Energia; Geração de Cenários; Métodos de Previsão; Otimização Estocástica Multietapa.

Abstract

The price of electricity is highly volatile in the Iberian Electricity Market (MIBEL) and in various System Services markets, due to weather conditions, economic factors, and other influential elements. As a result, market agents face difficulties in optimizing their bidding strategies to maximize their profits.

The aim of this work is to develop a multistage stochastic optimization model that optimizes bids for the following day across various energy markets, considering the forecasted energy production of a photovoltaic plant with a total capacity of 100 MW.

To achieve this objective, this work presents an explanation of all energy markets, thus enabling the construction of the model based on the functioning of these markets. A literature review is also an important element, as it analyzes the methods used in this field by other authors.

The construction of a stochastic optimization model is an aspect that distinguishes this work, as it allows market agents to make informed decisions in uncertain scenarios, providing insights into the price fluctuations of electricity in each market. One of the stages of this model includes the Secondary Regulation Reserve market, which is also a differentiating factor compared to other works.

The producer managing the photovoltaic power plant can use the obtained results, along with the sensitivity analysis of some of the model's parameters, to bid in the various markets, taking into account the level of risk they are willing to assume.

Keywords: Electricity Markets; Scenario generation; Forecasting Methods; Multistage Stochastic Optimization.

Índice

1	Introdução	1
1.1	Objetivos	1
1.2	Estrutura	2
2	Mercados de Energia	3
2.1	Mercado Ibérico de Eletricidade - MIBEL	3
2.2	Mercado de Serviço de Sistema	5
3	Estado da Arte	7
3.1	Trabalhos Anteriores em Previsão	7
3.2	Modelos de Licitação Ótima	15
3.3	Súmula de Artigos	18
4	Metodologia	19
4.1	Otimização Estocástica a Duas Etapas	19
4.1.1	Forma Extensiva	21
4.2	Otimização Estocástica Multietapa	21
4.3	Geração de Cenários	22
4.3.1	Métodos de Previsão - LSTM	22
4.3.2	Algoritmo de <i>clustering k-medoids</i>	24
4.4	Formulação do Modelo Estocástico Multimercado	25
5	Exemplo de Aplicação	29
5.1	Análise e Interpretação dos Dados	29
5.1.1	Fonte de Dados	29
5.1.2	Análise de Dados	29
5.2	Geração de Cenários	33
5.3	Análise de Resultados	36

6 Conclusões e Trabalho Futuros	41
Bibliografia	43

Lista de Figuras

2.1	Estrutura de negociação de energia no MIBEL. [Imagem retirada de [7]]	4
2.2	Curva de Oferta para a Hora 1 do dia 19-02-2024.	4
2.3	Horizonte de Licitação nos Mercados - MIBEL	5
2.4	RRT para a Hora 1 do dia 19-02-2024.	6
2.5	Horário de Licitação nos Mercados - Serviços de Sistema	6
3.1	Matriz de Confusão dos modelos RF, LGB e XGB. [Imagem retirada de [14]]	9
3.2	Modelo LSTM bidirecional. [Imagem retirada de [15]]	11
3.3	Modelo MH RNN DNN. [Imagem retirada de [17]]	13
3.4	Aproximação de problemas de otimização estocástica. [Imagem retirada de [19]]	16
4.1	Árvore com 7 cenários	22
4.2	<i>Forget Gate</i> [Imagem retirada de [21]]	23
4.3	<i>Input Gate</i> [Imagem retirada de [21]]	23
4.4	<i>Output Gate</i> [Imagem retirada de [21]]	24
5.1	Preços de Energia do Mercado Diário	30
5.2	<i>Boxplots</i> do Mercado Diário: Ano 2021, 2022 e 2023	30
5.3	Dia de Inverno: 10-01-2022	31
5.4	Dia de Verão: 10-07-2022	31
5.5	Preço da Energia na Banda Secundária	32
5.6	<i>Boxplots</i> da Banda Secundária: Anos de 2021, 2022 e 2023	32
5.7	Mercado de Serviços de Sistema: Dia 08-05-2023	33
5.8	Cenários dos Mercados de Energia	34
5.9	Cenários dos Mercados de Energia	35
5.10	Árvore de cenários	35

5.11	Resultado 1: $\alpha = 0.2, \beta = 0.1$	36
5.12	Resultado 1: $\alpha = 0.2, \beta = 0.3$	37
5.13	Resultado 3: $\alpha = 0.2, \beta = 0.1$	38
5.14	Resultado 4: $\alpha = 0.2, \beta = 0.3$	38

Lista de Tabelas

3.1	Variáveis por etapa do modelo de otimização estocástico	18
4.1	Variáveis por etapa do modelo de otimização estocástico multimercado	27
5.1	Medidas Estatísticas: Mercado Diário	31
5.2	Medidas Estatísticas: Banda Secundária	33
5.3	Coefficiente de <i>Silhouette</i>	34
5.4	Probabilidades de cada Medóide	35
5.5	Preços cenário 1 da hora 10	37
5.6	Resultados: Hora 13	38

Lista de Siglas

<i>EDP</i>	Energia De Portugal
<i>MIBEL</i>	Mercado Ibérico de Eletricidade
<i>ORT</i>	Operador de Rede de Transporte
<i>REN</i>	Redes Energéticas Nacionais
<i>RRP</i>	Reserva de Regulação Primária
<i>RRS</i>	Reserva de Regulação Secundária
<i>RRT</i>	Reserva de Regulação Terciária
<i>DAM</i>	Mercado Diário
<i>IDM</i>	Mercado Intradiário
<i>BM</i>	Mercados de Serviços de Sistema

Capítulo 1

Introdução

Com a forte introdução de fontes de energias renováveis, com o objetivo de cumprir metas de sustentabilidade e descarbonização, surgem implicações significativas nos mercados energia, incluindo o Mercado Ibérico de Eletricidade (MIBEL) e os Mercados de Serviços de Sistema. O preço da energia nestes mercados é bastante volátil, uma vez que depende principalmente das condições climáticas ou de fatores económicos, nomeadamente, o aumento do preço do gás natural.

Durante períodos de alta geração de energia renovável, os preços da eletricidade tendem a diminuir devido à maior oferta por parte dos agentes produtores. Por outro lado, durante períodos de baixa geração de energia, os preços podem aumentar devido à escassez de oferta. Assim, o grau de incerteza e instabilidade em relação à previsão e disponibilidade deste tipo de recursos é bastante elevado, refletindo-se diretamente nas flutuações de preços.

Consequentemente, os agentes de mercado encontram dificuldades consideráveis ao licitar nos diversos mercados de energia, com o objetivo de maximizar os seus lucros. Assim, é necessário encontrar estratégias de licitação ótima, uma vez que a incerteza associada à produção de energia renovável e respetivos preços é elevada. Torna-se crucial desenvolver modelos de otimização que integrem cenários de incerteza e análises de risco, permitindo aos agentes de mercado tomar decisões mais informadas e adaptativas consoante as condições de mercado.

1.1 Objetivos

Para alcançar o objetivo principal desta dissertação, que consiste em construir um modelo de otimização estocástico multimercado, será, em primeiro lugar, necessário compreender as regras de licitação nos mercados associados ao MIBEL, nomeadamente, o mercado diário e os vários intradiários, assim como nos mercados de serviços de sistema, em particular no mercado de Banda Secundária, e o mercado de Reserva de Regulação Terciária.

Perante um produtor de energia que opera uma central fotovoltaica com capacidade

máxima de 100MW, o objetivo deste modelo de otimização é auxiliar esse produtor a licitar nos diversos mercados, a energia que produz, maximizando os seus lucros. Neste trabalho será desenvolvido o modelo de otimização em linguagem de programação *python*.

O modelo de otimização será alimentado por cenários de preços associados a diversos mercados de energia. Assim, é necessário consultar a literatura sobre como autores anteriores realizaram este processo. Desta forma, estes cenários de preços serão gerados com métodos de aprendizagem automática, nomeadamente, redes neuronais recorrentes.

Com base nos resultados obtidos pelo modelo de otimização estocástico, o objetivo final é realizar uma análise de sensibilidade a determinados parâmetros do modelo. Esta análise tem como finalidade ajudar o produtor a formular as suas licitações consoante o grau de incerteza associado a cada cenário e a variabilidade do lucro esperado.

1.2 Estrutura

Este trabalho encontra-se dividido em 6 capítulos:

- o primeiro, introduz o tema e os objetivos principais desenvolvidos nesta dissertação;
- no segundo capítulo é explicado o funcionamento dos mercados de energia associados ao MIBEL e aos Serviços de Sistema;
- no terceiro capítulo é apresentada a revisão da literatura, onde se analisa os principais métodos para prever preços em mercados de energia e os modelos de otimização estocásticos anteriormente construídos;
- o quarto capítulo descreve toda a metodologia presente nos conceitos da dissertação, nomeadamente, otimização estocástica a duas etapas e multietapas, a formulação do modelo utilizado, a arquitetura das redes *Long Short Term Memory* (LSTM) e o algoritmo *k-medoids*;
- o quinto capítulo apresenta e analisa todos os resultados obtidos;
- por fim, o capítulo 6 apresenta algumas conclusões e trabalhos que possam ser resolvidos futuramente.

Capítulo 2

Mercados de Energia

Neste capítulo 2, será apresentada uma explicação sobre o funcionamento dos mercados de energia, nomeadamente, o Mercado Diário (*Day-Ahead*, DA), os diversos Mercados Intradiários de leilões (*Intraday*, ID) e os mercados associados aos Serviços de Sistema. Dentro destes, destaca-se a Reserva de Regulação Primária (RRP), a Reserva de Regulação Secundária (RRS) e Reserva de Regulação Terciária (RRT).

É importante referir que todos estes mercados estão em constante atualização, o que significa que as regras de cada mercado podem alterar, influenciando, por sua vez, as suas dinâmicas. Estas mudanças têm como objetivo adaptar o funcionamento dos mercados às novas realidades do setor elétrico, promovendo, assim, uma maior flexibilidade e eficiência na gestão da oferta e procura de energia.

2.1 Mercado Ibérico de Eletricidade - MIBEL

A 1 de julho de 2007, foi estabelecido o Mercado Ibérico de Eletricidade (MIBEL) com o propósito de criar um mercado unificado de energia elétrica entre Portugal e Espanha, para proporcionar benefícios aos consumidores dos dois países. A partir desse momento, foi possível às empresas produtoras de energia elétrica, em Portugal e Espanha, licitarem a sua energia a consumidores, também de ambos os países.

A criação do MIBEL também contribuiu para aumentar a segurança do abastecimento energético, permitindo que as fontes de energia fossem mais variadas. A interconexão das redes elétricas de Portugal e Espanha facilitou o uso de energias renováveis, favorecendo a transição para um modelo energético mais sustentável.

No âmbito deste mercado, o polo português é responsável pelos contratos a prazo onde a energia elétrica é negociada para períodos de semanas, meses ou anos, enquanto que, o polo espanhol está encarregue de gerir o mercado diário e intradiário. Ainda existe o mercado de serviços de sistema, contudo, este não está integrado no MIBEL [7]. Na figura 2.1 está representado a estrutura de negociação de energia no MIBEL.

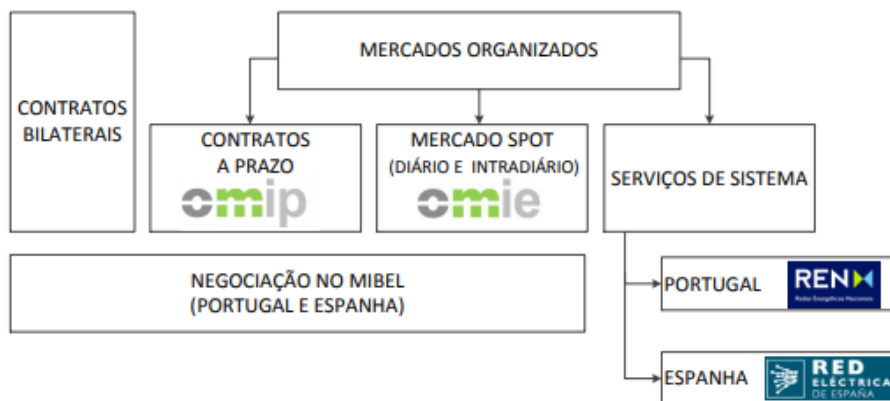


Figura 2.1: Estrutura de negociação de energia no MIBEL. [Imagem retirada de [7]]

No mercado diário, as transações de energia elétrica são realizadas para cada hora do dia seguinte, por intermediação de agentes de mercado que submetem ofertas de compra e venda. Destas propostas resulta a curva de oferta que é determinada pela ordenação crescente dos preços das ofertas de venda, ao passo que a curva de procura é estabelecida por ordem decrescente dos preços das ofertas de compra. O preço e o volume de energia são estabelecidos pelo cruzamento entre a curva de oferta e procura, para cada hora [7]. O gráfico seguinte representa a curva de oferta da hora 1 do dia 19-02-2024. A informação para elaborar este gráfico é pública, e é disponibilizada em[8].

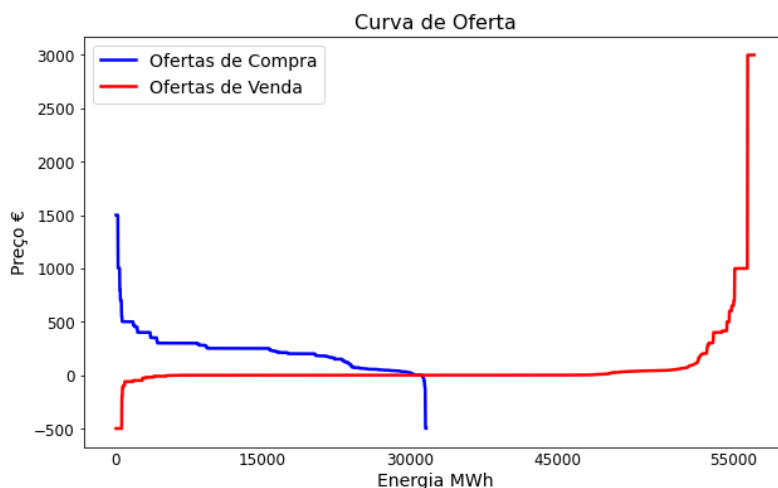


Figura 2.2: Curva de Oferta para a Hora 1 do dia 19-02-2024.

Para ajustar os valores de produção e consumo do mercado diário com base em informações mais recentes, existe o mercado intradiário, realizado em 3 sessões. Através de cada mercado intradiário, os agentes de mercado têm a possibilidade de comprar e vender energia, permitindo-lhes adaptar as suas estratégias de licitação de acordo com as flutuações que possam ocorrer ao longo do dia [11]. A figura seguinte mostra os horários de fecho de cada um dos mercados e o horizonte temporal disponível para

2.2. MERCADO DE SERVIÇO DE SISTEMA

para cada hora do dia seguinte, onde o preço é fixado em €/MW. A REN controla estas centrais elétricas, aumentando a sua potência quando o consumo supera a produção de energia e reduzindo-a quando consumo é inferior à produção, respeitando sempre os limites definidos no mercado.

Quando, eventualmente, a RRS não é suficiente para estabelecer o equilíbrio, ou seja, quando é atingido o limite máximo ou mínimo de banda contratada, torna-se necessário restaurar esse equilíbrio mobilizando a Reserva de Regulação de Terciária (RRT). Este serviço é remunerado e é realizado no final de cada uma das 3 sessões do mercado intradiário. A REN, por sua vez, organiza todas as ofertas numa curva de mérito, onde as ofertas para aumentar a potência são organizadas por ordem crescente de preço, enquanto que as ofertas para diminuir a potência são organizadas por ordem decrescente de preço [12]. Para a hora 1 do dia 19-02-2024, a curva de mérito para aumentar ou diminuir a potência está representado na Figura 2.4.




Figura 2.4: RRT para a Hora 1 do dia 19-02-2024.

Esta reserva é particularmente utilizada quando existem diferenças significativas na previsão do consumo, saídas de emergência de grupos geradores e variações consideráveis de geração eólica. A saída repentina de grupos geradores deve-se a falhas mecânicas, sobrecargas inesperadas, danos provocados por condições climáticas extremas, entre outras. A Figura 2.5 indica a programação horária da Reserva de Regulação Secundária. Relativamente à Reserva de Regulação Terciária é possível disponibilizar ofertas de energia, tanto a subir como a descer até 25 minutos antes da hora alvo. Esta flexibilidade é fundamental para assegurar a estabilidade do sistema elétrico.




Figura 2.5: Horário de Licitação nos Mercados - Serviços de Sistema

Capítulo 3

Estado da Arte

Com o intuito de obter uma compreensão abrangente do tema, procedeu-se a uma análise de diversos artigos. Como tal, neste capítulo 3, serão apresentadas as ideias principais, sobre estudos e contribuições no âmbito dos mercados de energia, nomeadamente, os fatores que influenciam o preço da energia e os métodos utilizados para prever preços. Também será importante verificar que tipos de modelos de otimização os autores utilizam para realizar licitação em mercados de energia.

Os primeiros artigos mencionados dizem respeito ao mercado de serviços de sistema, onde serão apresentados os desafios enfrentados na gestão do equilíbrio entre a produção e o consumo de energia elétrica, e os métodos utilizados para prever preços e quantidades de energia. Depois será apresentado um artigo que introduz um modelo de otimização estocástico multietapa que constitui a base desta dissertação.

3.1 Trabalhos Anteriores em Previsão

O artigo [13] revelou-se especialmente interessante para explicar a relação entre a variabilidade das fontes de energia eólica e solar, e os serviços de sistema. Os autores apresentaram as três principais ligações entre ambos, nomeadamente, o impacto que erros de previsão das renováveis têm nas reservas de regulação, a prestação de serviços de estabilidade pelos produtores de energias renováveis, e por último, as medidas para melhorar as previsões através da aplicação de taxas de desequilíbrio.

Os autores retiraram algumas conclusões deste estudo. A primeira dita que os fatores determinantes do equilíbrio dependem de diversos elementos, não se restringindo apenas ao erro de previsão da energia eólica e solar. A segunda contradiz as informações teóricas, uma vez que, na Alemanha, apesar do aumento significativo da capacidade de energias renováveis, as reservas diminuíram 15%, indicando que existem outros fatores mais importantes do que as fontes renováveis. Por fim, a terceira conclusão incide na estrutura do mercado de serviço de sistema, uma vez que pode estabelecer obstáculos que desmotivam a participação dos produtores de energias renováveis. Estas barreiras podem derivar de requisitos de entrada demasiado rígidos ou de procedimentos

complexos que dificultam a eficaz integração no mercado.

Por um lado, é importante perceber os fatores que afetam as previsões do consumo de energia, especialmente quando se considera, fontes de energias renováveis, conforme discutido no artigo [13]. Por outro lado, é fundamental identificar o sinal de desequilíbrio, isto é, quando o consumo de energia excede a produção, e por esta razão é necessário uma central hídrica começar a turbinar, ou seja, produzir energia. No entanto, quando o consumo é menor que a produção, não é necessário gerar mais energia, e por isso existe a necessidade de bombear, para manter o equilíbrio do sistema. Neste contexto, já existe trabalho desenvolvido por parte do autores do artigo [14].

Um dos objetivo dos autores do artigo [14] era prever o preço da energia no mercado de serviços de sistema com recurso a métodos de inteligência artificial, utilizando vários tipos de algoritmos de aprendizagem automática. Esta abordagem é composta por duas etapas, sendo a primeira a identificação do sinal de desequilíbrio e a segunda melhorar significativamente o desempenho da previsão de preços.

A primeira etapa neste processo consistiu na recolha de quatro conjuntos de dados públicos provenientes do mercado romeno entre 1 de janeiro de 2021 e 31 de dezembro de 2022. As variáveis extraídas compõem parte dos dados de entrada dos algoritmos de aprendizagem automática destinados a prever o sinal de desequilíbrio para o dia seguinte representado por \widehat{IS}_{BM}^{h+24} , que assume valores no conjunto $\{0, 1\}$. Os dados de entrada (XIS) são os seguintes:

$$XIS^{h+24} = [P_{DAM}^{h+24}, Q_{DAM}^{h+24}, P_{BM+}^h, P_{BM-}^h, Fin_{BM}^h, FW_{IDM}^{h+24}, F_{PV_{IDM}}^{h+24}, FW_{DAM}^{h+24}, F_{PV_{DAM}}^{h+24}, C^h, G^h, G_k^h, Ex^h] \quad (3.1)$$

onde

- $P_{DAM}^{h+24}, Q_{DAM}^{h+24}$ representam o preço e a quantidade negociada no mercado diário (DAM);
- P_{BM+}^h, P_{BM-}^h são os preços por hora no mercado de serviços de sistema (BM- do inglês *Balancing Market*) do dia atual para o excesso e défice de energia face ao consumo;
- Fin_{BM}^h é a neutralidade financeira;
- $F_{PV_{IDM}}^{h+24}, FW_{IDM}^{h+24}$ são a previsão para o dia seguinte da produção fotovoltaica (PV) e eólica (W) para o mercado intradiário (IDM);
- $F_{PV_{DAM}}^{h+24}, FW_{DAM}^{h+24}$ são a previsão para o dia seguinte da produção fotovoltaica (PV) e eólica (W) para o mercado diário (DAM);
- C^h é o consumo total por cada hora;
- G^h é a geração total por parte das várias fontes de energia (carvão, petróleo e gás, hidro, eólica, solar - PV , biomassa, nuclear) e G_k^h é o tipo de gerador;

- Ex^h é a venda ou a troca de energia com a Operadora do Sistema de Transmissão Romena.

Ao conjunto de dados de entrada ainda foram adicionadas algumas variáveis complementares, nomeadamente:

- $P_{BM+}^{h-24}, P_{BM-}^{h-24}$ que representam o preço para o excesso e o déficit de energia do dia anterior;
- $P_{BM+}^{h-48}, P_{BM-}^{h-48}$ que representam o o preço para o excesso e o déficit de energia do antepenúltimo dia;
- $\overline{P_{BM+}^{h-}}, \overline{P_{BM-}^{h-}}$ que são as médias dos preços do excesso e do déficit de energia;

Por fim, foram treinados dez algoritmos de aprendizagem automática para determinar o sinal de desequilíbrio: *Logistic Regression (LR)*, *Stochastic Gradient Descent (SGD)*, *eXtreme Gradient Boosting(XGB)*, *Decision Tree (DT)*, *Random Forest (RF)*, *Multi-Layer Perceptron (MLP)*, *Light Gradient Boosting (LGB)*, *Quadratic Determinant Analysis (QDA)*, *K-Neighbour (KN)*, *Ada Booster (AB)*. Com base nas métricas de comparação destes algoritmos, nomeadamente, a matriz de confusão e a curva ROC, os autores deste artigo concluíram que o melhor método para prever era o *Random Forest* com uma taxa de acertos de 74%, seguido do *LGB* com 72% e *XGB* com 71%, uma vez que foram os que obtiveram a melhor taxa de desempenho. A matriz de confusão dos modelos com maior desempenho é apresentada na Figura seguinte.




Figura 3.1: Matriz de Confusão dos modelos RF, LGB e XGB. [Imagem retirada de [14]]

A previsão de sinal é obtida através de

$$\widehat{IS_{BM}^{h+24}} = RF.predict(XIS^{h+24}). \quad (3.2)$$

A etapa seguinte foi prever o preço para o dia seguinte do mercado de serviços de sistema (XP^{h+24}), com base na previsão de sinal ($\widehat{IS_{BM}^{h+24}}$) efetuada anteriormente, e dos dados de entrada (XIS^{h+24}). Os autores utilizaram cinco algoritmos de aprendizagem

automática regressivos, nomeadamente, *Random Forest Regressor (RFR)*, *Voting Regressor (VR)*, *Light Gradient Boosting Regressor (LGBR)*, *Histogram Gradient Boosting Regressor (HGBR)* e *eXtreme Gradient Boosting Regressor (XGBR)*. O resultado final considerado pelos autores do artigo foi a média das previsões dos cinco algoritmos, ou seja:

$$\widehat{P}_{BM^+}^{h+24}, \widehat{P}_{BM^-}^{h+24} = \frac{\sum_{m=1}^5 fR_m.predict(XP^{h+24})}{5} \quad (3.3)$$

Este artigo contribuiu significativamente para compreender quais as potenciais variáveis que são utilizadas na previsão do preço de energia. Contudo, deve-se adaptar o estudo à dinâmica portuguesa, especialmente no que se refere às fontes de energia renováveis mais preponderantes do país.

O artigo [15] foi desenvolvido com o mesmo propósito do artigo [14], ou seja, prever preços e quantidades de energia no mercado de serviços de sistema. A abordagem adotada neste artigo, consistiu na aplicação de métodos de aprendizagem automática, nomeadamente, redes neuronais recorrentes do tipo *Long Short Term Memory (LSTM)*. Os autores optaram por estas redes devido à dependência temporal presente nos dados, desenvolvendo o problema através de duas abordagens: a primeira consiste na aplicação de redes LSTM bidirecionais utilizando apenas uma variável, enquanto que na segunda são aplicadas as mesmas redes, mas considerando várias variáveis explicativas, que os autores consideram influenciar tanto o preço como a quantidade de energia. Essas variáveis incluem a quantidade de energia oferecida pelos participantes do mercado para aumentar ou diminuir a energia da rede elétrica, o consumo total, a produção total, o preço da energia negociada para o dia seguinte e a quantidade de energia eólica produzida. É relevante salientar que os autores aplicaram ambas as abordagens tanto para o preço como para a quantidade.

As redes LSTM bidirecionais representam uma evolução das redes LSTM convencionais, na medida em que possuem a capacidade de processar uma sequência de dados em duas direções, permitindo assim combinar informações tanto do passado como do futuro. Esta competência surge da introdução de duas camadas LSTM distintas. Uma delas processa os dados na direção temporal padrão (*forward LSTM*), enquanto que a outra processa os dados na direção oposta (*backward LSTM*). Estas redes são particularmente utilizadas em tarefas de processamento de linguagem natural, reconhecimento de fala, e previsão de séries temporais. A figura seguinte ilustra o modelo de uma rede LSTM bidirecional.

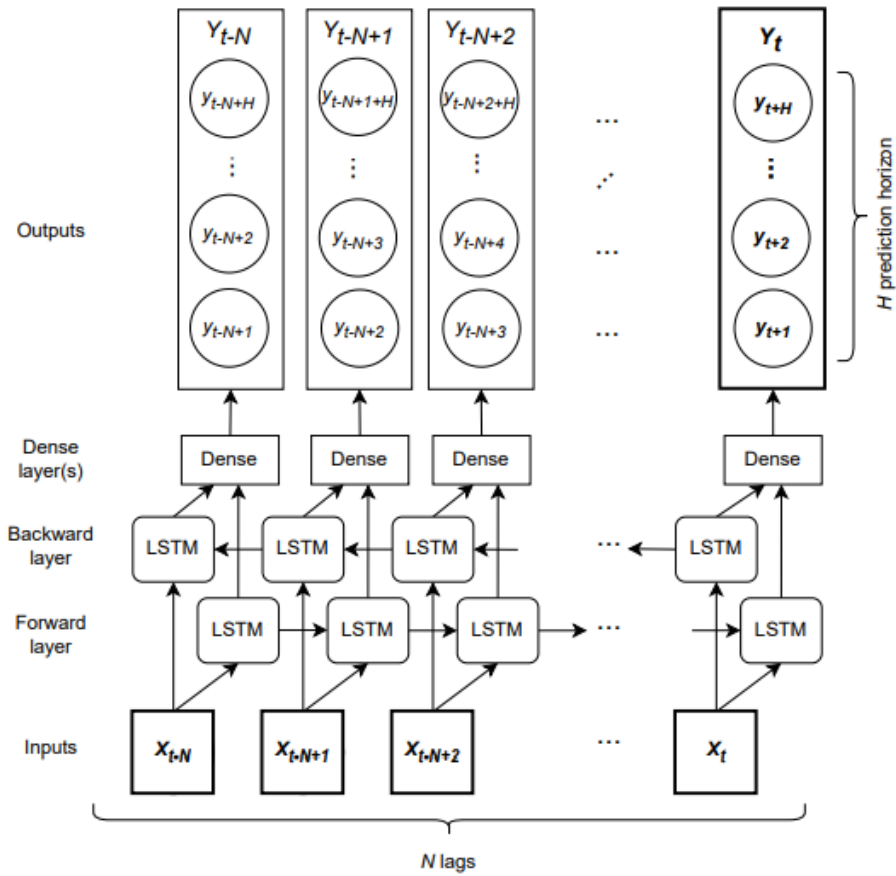


Figura 3.2: Modelo LSTM bidirecional. [Imagem retirada de [15]]

Depois de efetuar o treino do modelo, os autores do artigo retiraram algumas conclusões importantes. Dos resultados obtidos, verificou-se que o preço de mercado negociado para o dia seguinte influencia negativamente o desempenho tanto do modelo unidimensional como bidimensional. De forma geral, os modelos para as previsões do volume de energia têm um desempenho superior ao do preço de energia. Com base nos valores de *Root Mean Square Error* (RMSE), os autores concluíram que as redes LSTM não são as mais indicadas para fazer previsão neste contexto. A explicação sugerida é que se os dados de entrada da rede não forem pertinentes, acabam por introduzir ruído no modelo, afetando negativamente as previsões.

Este artigo desempenhou um papel crucial no desenvolvimento desta dissertação, fornecendo orientações sobre a limitação das redes LSTM bidirecionais no contexto do mercado de serviços de sistema. Ao mesmo tempo destacou a importância da seleção adequada de variáveis explicativas para melhorar a precisão das previsões e evitar que o modelo seja treinado com dados ruidosos.

O estudo realizado recentemente na universidade *College Cork* na Irlanda [17] segue a mesma linha de pensamento dos dois artigos anteriores, na medida em que utiliza modelos de inteligência artificial com o objetivo de prever preços de energia no mercado de serviços de sistema. Neste estudo os autores consideraram os 48 preços (24 horas)

3.1. TRABALHOS ANTERIORES EM PREVISÃO

mais recentes para prever os próximos 16 (8 horas), o que significa que a variável de resposta é

$$Y_t = [BMP_{t+2}, \dots, BMP_{t+17}] \quad (3.4)$$

sendo BMP o preço do mercado de serviços de sistema. As variáveis explicativas são divididas em dois grupos: dados históricos e dados futuros. Os primeiros incluem o preço e a quantidade registada nas 24 horas anteriores, a diferença entre o valor previsto e o valor real do vento, valores do interconector e os preços do mercado diário das últimas 24 horas, enquanto que os segundos referem-se à previsão de energias renováveis, previsão da procura, preços para o mercado diário, programação líquida dos interconectores e a quantidade de notificações físicas. Todas as variáveis explicativas que ainda não foram observadas correspondem ao horizonte temporal de 8 horas.

Para prever o preço, os autores utilizaram vários métodos, na tentativa de verificar qual apresentava melhores resultados. Apesar da diversidade de algoritmos de aprendizagem automática, ainda procederam ao treino do mesmo para períodos de 30, 60, 90 e 365 dias. Os algoritmos aplicados foram:

- *Naive* - Este algoritmo não é o mais indicado para efetuar previsões, uma vez que assume que os valores das últimas 8 horas observadas são iguais aos das 8 horas seguintes, o que implica que o que se pretende prever será sempre igual ao que foi registado previamente, tornando esta abordagem por parte dos autores inútil.
- *LASSO Estimated AR (LEAR)* - É um método que utiliza séries temporais autoregressivas que inclui a regularização LASSO para melhorar o desempenho e a seleção de características.
- *Random Forest (RF)* - É um método de aprendizagem automática supervisionado baseado em *ensemble learning*, que consiste na fusão de vários modelos de previsão mais simples que são treinados para a mesma tarefa, ou seja, a Floresta Aleatória constrói múltiplas árvores de decisão e funde-as obtendo previsões mais estáveis.
- *Support Vector Regression (SVR)* - É um modelo de aprendizagem supervisionada que utiliza vetores de suporte que influenciam a orientação e posição de um hiperplano para minimizar os erros de previsão.
- *Extreme Gradient Boosting (XGB)* - Tal como o RF, este algoritmo combina várias árvores de decisão. A sua principal característica reside na construção de árvores de decisão sequenciais para corrigir os erros dos modelos anteriores.
- *Multi-Headed RNN DNN Model (MH-RNN-DNN)* - Este modelo é a fusão de dois algoritmos de aprendizagem profunda que combina as arquiteturas LSTM (redes neuronais recorrentes) e DNN (redes neuronais densas). Esta abordagem híbrida tem como objetivo incorporar, no ramo LSTM, uma camada recorrente para os dados já observados, enquanto que no ramo DNN são utilizadas camadas densas para dados futuros. A estrutura deste algoritmo está detalhado na Figura 3.3.

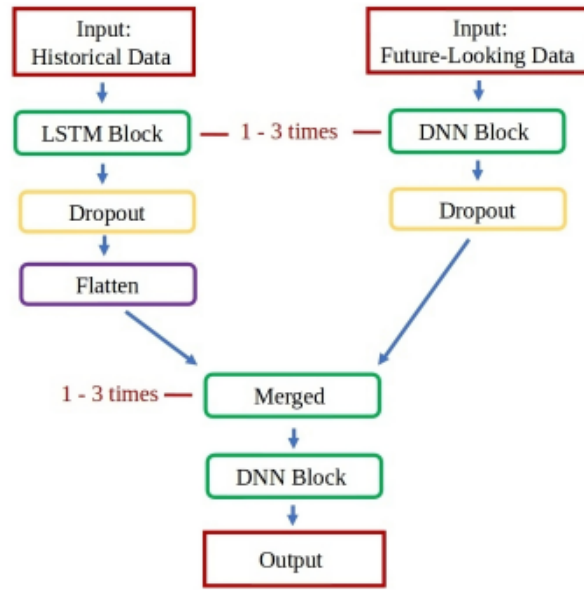


Figura 3.3: Modelo MH RNN DNN. [Imagem retirada de [17]]

- *Single-Headed DNN Model* (SH-DNN) - Este algoritmo é semelhante ao anterior, contudo, foca-se apenas na estrutura do ramo DNN.

Para comparar os métodos anteriores, os autores aplicaram as seguintes métricas:

$$\text{Mean Absolute Error (MAE)} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.5)$$

$$\text{Root Mean Squared Error (RMSE)} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.6)$$

$$\text{symmetric Mean Absolute Percentage Error (sMAPE)} = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\frac{(|y_i| + |\hat{y}_i|)}{2}} \quad (3.7)$$

onde y_i são os valores reais, \hat{y}_i são os valores previstos pelo modelo, e n é o número total de observações.

Com base nas métricas mencionadas anteriormente, os autores concluíram que o modelo LEAR é aquele que se destaca para prever os preços de energia no mercado de serviços de sistema, com poucas exceções para conjuntos de treino menores. Outro dos objetivos dos autores era verificar se os modelos SH-DNN e MH-RNN-DNN, que apresentavam boas previsões no mercado diário, mantinham o desempenho no mercado de serviço de sistema, constatando que esses modelos encontraram dificuldades em prever os preços na parte mais volátil.

Neste estudo foi interessante constatar que algoritmos de aprendizagem automática mais simples superaram os algoritmos de aprendizagem profunda. Esta observação

é particularmente relevante, uma vez que os modelos de aprendizagem profunda são conhecidos pela sua complexidade e capacidade de extrair informações intrínsecas do conjuntos de dados. No entanto, mesmo com essa complexidade, estes modelos não conseguiram superar os modelos mais simples em termos de precisão na previsão de preços de energia no mercado de serviços de sistema.

O artigo que se segue apresenta uma abordagem totalmente diferente dos artigos previamente descritos. Em [18], o autor propõe um algoritmo que prevê o desequilíbrio energético no mercado de serviço de sistema, avaliando probabilisticamente todos os cenários possíveis para cada hora, e recomenda a quantidade e o preço de energia de modo que os custos de energia nas reservas de regulação não sejam aumentados, em tempo real. A principal característica introduzida pelo autor foi a incorporação de natureza estocástica do desequilíbrio energético. Foram realizados quatro casos de estudo com dados da República Checa utilizando o método de Monte Carlo.

Em primeiro lugar, o autor parte do pressuposto que a previsão do desequilíbrio de energia assume distribuição gaussiana com média zero e desvio padrão $\sigma_{\Delta\hat{E}}^2(h)$ para cada hora h . É expectável que à medida que período de tempo aumente, o erro de previsão também aumento, o que se traduz através de

$$\sigma_{\Delta\hat{E}}^2(h_2) > \sigma_{\Delta\hat{E}}^2(h_1) \quad \text{para} \quad h_2 > h_1. \quad (3.8)$$

Quando existe um desequilíbrio no sistema elétrico, os custos totais esperados para a ativação de uma reserva de regulação é

$$N_E(h) = c_{ORT}(h) \cdot E_{ORT}(h) + \sum_k p_k(h) \cdot N_{kE}(h) \quad (3.9)$$

onde

- $c_{ORT}(h)$ é o preço de energia do equilíbrio obtida no mercado pelo operador de rede de transporte;
- $E_{ORT}(h)$ é a quantidade de energia do equilíbrio obtida no mercado pelo operador de rede de transporte;
- $p_k(h)$ é a probabilidade da energia de desequilíbrio pertencer ao intervalo k na hora h ;
- $N_{kE}(h)$ é o custo de ativação da reserva de regulação para compensar o desequilíbrio de energia quando pertence ao intervalo k na hora h .

Escolhendo um nível de probabilidade p_{conf} , a quantidade de energia do equilíbrio $E_{ORT}(h)$ é encontrada a partir da relação seguinte

$$prob \left(\Delta\hat{E}(h) > E_{TSO}(h) \right) \geq p_{conf}. \quad (3.10)$$

Com $E_{ORT}(h)$ estabelecido, o preço de energia do equilíbrio $c_{ORT}(h)$ é obtido através de

$$c_{ORT}(h) \leq \frac{\sum_k p_k(h)[N_k(h) - N_{kE}(h)]}{E_{ORT}(h)}. \quad (3.11)$$

Como mencionado anteriormente, foram realizados quatro casos de estudo. No primeiro caso, não se recorre aos serviços de sistema, uma vez que o desequilíbrio entre o consumo e a produção é corrigido pela reserva de regulação primária. No segundo caso, para cada hora, a quantidade de energia que é necessário os serviços de sistema repor tem um nível de confiança de $p_{conf} = 0.8$. O caso seguinte possui características semelhantes ao anterior, contudo utiliza um nível de confiança de $p_{conf} = 0.65$. No último caso, pressupõe-se que a energia disponibilizada pelos serviços de sistema é exatamente igual ao desvio entre o consumo e a produção. Isso implica a inexistência de erro, tornando este caso irrealista, sendo utilizado apenas como ponto de referência para comparação com os casos anteriores.

Segundo o autor, o estudo realizado foi concluído com sucesso, uma vez que, através do algoritmo proposto, os custos totais de energia de reservas de regulação diminuíram. O autor ainda realça que quanto maior for a quantidade de energia disponibilizada pelas reservas de regulação dos serviços de sistema, maior será a necessidade de equilibrar a produção e o consumo de energia, uma vez que o operador da rede de transporte necessita de algum tempo para repor as reservas e devido à incerteza associada na previsão do consumo de energia. É de realçar que quando os mercados de serviços de sistema são utilizados de forma ativa, os preços tendem a diminuir por consequência da elevada oferta de energia.

3.2 Modelos de Licitação Ótima

Os autores do artigo [19], apresentam um modelo baseado em otimização estocástica multietapa, com o intuito de incorporar incerteza nos mercados de energia. Para os agentes de mercados, é importante incluir esta incerteza nos modelo de otimização, de forma a submeter ofertas seguras e maximizar os benefícios, uma vez que esta incerteza está associada, entre outros fatores, à quantidade de energia a ser produzida no dia seguinte. A abordagem proposta otimiza a estratégia de licitação, no mercado diário (DA), nos diferentes intradiários (ID) e no mercado de serviços de sistema (BM) que correspondem às diversas etapas do modelo. Em 2022, a principal contribuição dos autores foi introduzir um algoritmo estocástico multietapa, que incluía também os seis mercados intradiários, visto que, até então, os modelo existentes na literatura apenas contemplavam o mercado diário e de serviço de sistema. Neste estudo o agente de mercado representa uma central elétrica virtual composta por uma central eólica, uma central solar fotovoltaica e um sistema de armazenamento de energia em baterias.

O modelo de otimização estocástico multietapa é definido como um problema de programação linear, desde que a função objetivo, $Q(x, \xi)$, e as restrições sejam lineares

3.2. MODELOS DE LICITAÇÃO ÓTIMA

nas variáveis de decisão x_T . A formulação de cada uma das etapas está incorporada na função objetivo através das várias camadas de valores esperados, \mathbb{E} , que, por sua vez, incluem a incerteza ξ_T , associada a cada etapa, como demonstrado na expressão seguinte

$$\min\{Q(x, \xi) = c_0x_0 + \mathbb{E}[\min c_1(\xi_1)x_1 + \mathbb{E}[\min c_2(\xi_2)x_2 + \mathbb{E}[\dots + \mathbb{E}[\min c_T(\xi_T)x_T]]]] : x \in \mathbb{X}(\xi)\}. \quad (3.12)$$

Para resolver este tipo de problemas é essencial encontrar funções mensuráveis apropriadas, isto é, $x_T \triangleleft \mathcal{F}_T$. Contudo, na maior parte dos casos é necessário recorrer a técnicas de aproximação que consistem em substituir o problema original, por uma versão mais simples do mesmo. Deste modo, a distribuição de probabilidade geral P é substituída por uma distribuição mais simples, \tilde{P} , que possui um suporte finito. Consequentemente, dado que a solução \tilde{x}^* do problema aproximado é definida num espaço de probabilidade distinto, esta não pode ser considerada diretamente como solução do problema original. Por esse motivo, torna-se necessário utilizar uma função de extensão $e_x : \tilde{x} \mapsto x \in \mathbb{X}$, que converte a solução do problema aproximado numa solução válida para o problema original. A Figura 3.4 ilustra o processo de obtenção das soluções numéricas para problemas de otimização estocástica.

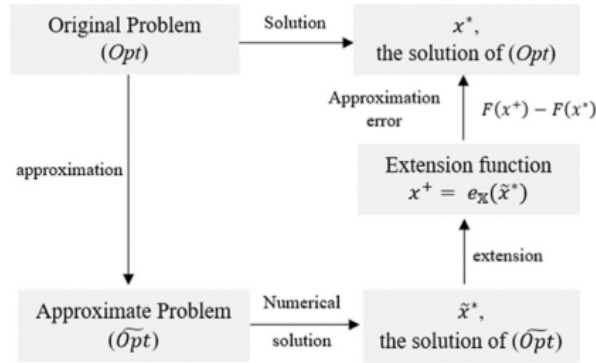


Figura 3.4: Aproximação de problemas de otimização estocástica. [Imagem retirada de [19]]

O problema de otimização formulado pelos autores deste artigo, visa maximizar o lucro esperado de um agente de mercado nas diferentes sessões dos mercado de energia (DA, ID e BM), isto é,

$$\max \left(I^{DA} + \sum_1^S I^{ID^s} + I^{BM} \right) \quad (3.13)$$

em que,

$$I^{DA} = \sum_{\omega} \pi_{\omega} \left(\sum_t^T P_{BID}^{DA}(t) \cdot \Gamma_{\omega}^{DA}(t) \right), \forall t \in T, \forall \omega \in \Omega \quad (3.14)$$

$$I^{ID^s} = \sum_{\omega} \pi_{\omega} \left(\sum_t^T P_{BID}^{ID^s}(t) \cdot \Gamma_{\omega}^{ID^s}(t) \right), \forall s \in S, \forall t \in T, \forall \omega \in \Omega \quad (3.15)$$

$$I^{BM} = \sum_{\omega} \pi_{\omega} \left(\sum_t^T P_{BM}^{+}(t) \cdot \Gamma_{\omega}^{DA}(t) \cdot r_{BM,\omega}^{+}(t) \right) - \sum_{\omega} \pi_{\omega} \left(\sum_t^T P_{BM}^{-}(t) \cdot \Gamma_{\omega}^{DA}(t) \cdot r_{BM,\omega}^{-}(t) \right). \quad (3.16)$$

Para cada hora do dia, as variáveis de decisão $P_{BID}^{DA}(t)$ e $P_{BID}^{ID^s}(t)$ representam, respetivamente, as decisões ótimas de licitação no mercado diário e em cada uma das sessões do mercado intradiário, com $s = \{1, 2, 3, 4, 5, 6\}$. A cada uma dessas variáveis de licitação está associado o respetivo preço de energia, $\Gamma_{\omega}^{DA}(t)$ e $\Gamma_{\omega}^{ID^s}(t)$ de cada mercado. Através destas variáveis é possível calcular o lucro do mercado diário (I^{DA}) e do mercado intradiário (I^{ID^s}). Ω representa o conjunto de cenários.

A receita associada ao mercado de serviços de sistema funciona de forma distinta, podendo assumir valores positivos ou negativos, consoante o desequilíbrio seja favorável ou desfavorável ao sistema. As variáveis $P_{BM}^{+}(t)$ e $P_{BM}^{-}(t)$ caracterizam, respetivamente, o desequilíbrio de potência positivo e negativo negociado no mercado BM . Adicionalmente, é necessário calcular os coeficientes de escala $r_{BM,\omega}^{+}(t)$ e $r_{BM,\omega}^{-}(t)$ que relaciona os preços de desequilíbrio (positivos e negativos) em relação aos preços do mercado diário $\Gamma_{\omega}^{DA}(t)$. É importante realçar que todas as receitas de cada mercado são somadas para cada cenário ω , sendo que a cada cenário está associada uma probabilidade π_{ω} .

Para completar a formulação do modelo, é fundamental definir as restrições associadas ao problema, particularmente nos mercados diário, intradiário e serviços de sistema. Estas restrições de desigualdade procuram garantir que as licitações não excedam as quantidades de energia previstas produzir por uma central eólica e uma central solar fotovoltaica. Além disso, é necessário incluir restrições relacionadas com o sistema de armazenamento de energia, que é utilizado para minimizar o impacto dos desequilíbrios de potência no mercado de serviços de sistema. Todas estas restrições podem ser analisadas em detalhe em [19].

O primeiro passo executado pelos autores do artigo consistiu em gerar 1000 cenários para a produção eólica e solar, assim como para os preços dos mercados de energia, utilizando redes neuronais artificiais. Em seguida, foi aplicado o algoritmo *k-medoids* para agrupar os cenários em *clusters*, com o objetivo de identificar os centróides de cada *cluster* e determinar as respetivas probabilidades. O passo final envolveu construir o modelo de otimização estocástica para um dia de mercado e analisar os resultados. A tabela 3.1 resume as variáveis que são utilizadas em cada etapa do modelo de otimização. Note-se que as variáveis $P_{CHA}(t)$, $P_{DIS}(t)$, $E_{BAT}(t)$ e $P_{CURT}(t)$ na etapa 8 são relativas

3.3. SÚMULA DE ARTIGOS

ao sistema de armazenamento e a questões técnicas.

Etapa	Sessão de Mercado	Variáveis Fixas	Variáveis Estocásticas	Variáveis de Decisão
1	DA	-	$\hat{P}_\omega^{DA}(t)$ $\Gamma_\omega^{DA}(t)$	$P_{BID}^{DA}(t)$
2	ID1	$P_{BID}^{DA}(t)$	$\hat{P}_\omega^{ID1}(t)$ $\Gamma_\omega^{ID1}(t)$	$P_{BID}^{ID1}(t)$
3	ID2	$P_{BID}^{DA}(t), P_{BID}^{ID1}(t)$	$\hat{P}_\omega^{ID2}(t)$ $\Gamma_\omega^{ID2}(t)$	$P_{BID}^{ID2}(t)$
4	ID3	$P_{BID}^{DA}(t), P_{BID}^{ID1}(t), P_{BID}^{ID2}(t)$	$\hat{P}_\omega^{ID3}(t)$ $\Gamma_\omega^{ID3}(t)$	$P_{BID}^{ID3}(t)$
5	ID4	$P_{BID}^{DA}(t), P_{BID}^{ID1}(t)$ $P_{BID}^{ID2}(t), P_{BID}^{ID3}(t)$	$\hat{P}_\omega^{ID4}(t)$ $\Gamma_\omega^{ID4}(t)$	$P_{BID}^{ID4}(t)$
6	ID5	$P_{BID}^{DA}(t), P_{BID}^{ID1}(t), P_{BID}^{ID2}(t),$ $P_{BID}^{ID3}(t), P_{BID}^{ID4}(t)$	$\hat{P}_\omega^{ID5}(t)$ $\Gamma_\omega^{ID5}(t)$	$P_{BID}^{ID5}(t)$
7	ID6	$P_{BID}^{DA}(t), P_{BID}^{ID1}(t), P_{BID}^{ID2}(t),$ $P_{BID}^{ID3}(t), P_{BID}^{ID4}(t), P_{BID}^{ID5}(t)$	$\hat{P}_\omega^{ID6}(t)$ $\Gamma_\omega^{ID6}(t)$	$P_{BID}^{ID6}(t)$
8	BM	$P_{BID}^{DA}(t), P_{BID}^{ID1}(t), P_{BID}^{ID2}(t),$ $P_{BID}^{ID3}(t), P_{BID}^{ID4}(t), P_{BID}^{ID5}(t)$ $P_{BID}^{ID6}(t)$	$r_{BM,\omega}^+(t)$ $r_{BM,\omega}^-(t)$	$P_{BM}^+(t), P_{BM}^-(t)$ $P_{CHA}(t), P_{DIS}(t)$ $E_{BAT}(t), P_{CURT}(t)$

Tabela 3.1: Variáveis por etapa do modelo de otimização estocástico

Neste artigo, o aspeto mais relevante a destacar é a metodologia utilizada pelos autores para alcançar os resultados, e não os resultados em si. Para esta dissertação a análise detalhada da metodologia é crucial, pois permite adaptar e potencialmente melhorar o processo para contextos semelhantes, assegurando a robustez e a eficácia da investigação.

3.3 Súmula de Artigos

A revisão da literatura revelou-se um passo importante, pois evidenciou a complexidade inerente à previsão de preços no mercado de serviços de sistema. Embora o objetivo principal desta dissertação não esteja exclusivamente centrado na previsão de preços neste mercado específico, mas sim dos diferentes mercados de energia, foi essencial compreender os métodos aplicados e as dificuldades enfrentadas por outros autores. Os modelos de licitação ótima são bastante sensíveis às variações de preços, o que, por sua vez influencia diretamente a capacidade de maximização de lucros, e por este motivo ser tão importante prever preços da melhor forma. Também é importante realçar a metodologia presente no último artigo pois inclui cenários probabilísticos de preços e um modelo de otimização estocástica multietapa que é algo pouco frequente nesta área.

Capítulo 4

Metodologia

Os problemas de otimização estocástica surgem sempre que é necessário tomar decisões sob incerteza. Em vez de supor que todos os parâmetros são conhecidos, estes modelos incorporam variáveis aleatórias para representar a incerteza. Esta abordagem é fundamental para suportar a variabilidade que caracteriza muitos cenários do quotidiano, como por exemplo, na área de finanças, energia, logística, entre outras. Assim, a metodologia que abrange este tipo de modelo difere substancialmente dos modelos de otimização determinísticos.

Neste capítulo 4, será formulado com detalhe um modelo de otimização estocástica a duas etapas, que posteriormente irá servir de base para a generalização do modelo multietapa. Nesta secção será apresentado o modelo de otimização estocástico multimercado, que constitui parte do trabalho desenvolvido nesta dissertação. Serão introduzidas técnicas para prever preços nos diversos mercados de energia, com destaque para as redes LSTM (*Long Short-Term Memory*), que serão utilizadas para gerar cenários de preços desses mercados. A esses cenários será aplicado o algoritmo de *clustering k-medoid*, pelo que este capítulo também abordará essa metodologia.

4.1 Otimização Estocástica a Duas Etapas

O problema clássico de otimização estocástica a duas etapas é um modelo de programação linear, que utiliza a primeira etapa para tomar uma decisão inicial sem conhecer os valores dos parâmetros incertos. Após a sua obtenção, o agente de decisão realiza novas escolhas com o objetivo de corrigir possíveis efeitos negativos resultantes da decisão tomada na etapa anterior. De um modo geral estes problemas são definidos da seguinte forma:

$$\begin{aligned} \min \quad & z = \mathbf{c}^T x + \mathbb{E}_\xi [\min q(\omega)^T y(\omega)] \\ \text{s.a.} \quad & \mathbf{A}x = \mathbf{b}, \\ & T(\omega)x + \mathbf{W}y(\omega) = h(\omega), \\ & x \geq 0, y(\omega) \geq 0 \end{aligned} \tag{4.1}$$

4.1. OTIMIZAÇÃO ESTOCÁSTICA A DUAS ETAPAS

em que os vetores \mathbf{c} e \mathbf{b} estão definidos em \mathbb{R}^{n_1} e \mathbb{R}^{m_1} , respetivamente. A matriz \mathbf{A} tem dimensão $m_1 \times n_1$ e a matriz de recurso \mathbf{W} tem dimensão $m_2 \times n_2$. Esta formulação considera que a matriz \mathbf{W} é fixa, o que permite caracterizar a região de viabilidade do problema, ou seja, o conjunto de todas as soluções que satisfazem as restrições. Esta abordagem facilita a implementação e execução computacional dos métodos de otimização. Naturalmente, x é a variável de decisão da primeira etapa e $y(\omega)$ a variável de decisão da segunda etapa. Cada evento aleatório $\omega \in \Omega$, influencia todas as componentes estocásticas do problema, representado através do vetor ξ :

$$\xi^T(\omega) = (q(\omega)^T, h(\omega)^T, T_1(\omega), \dots, T_{m_2}(\omega)) \quad (4.2)$$

constituído por $N = n_2 + m_2 + (m_2 \times n_1)$ componentes. $T_i(\omega)$ é a i -ésima linha da matriz $T(\omega)$ com dimensão $m_2 \times n_1$, $q(\omega) \in \mathbb{R}^{n_2}$ e $h(\omega) \in \mathbb{R}^{m_2}$. Ainda é importante referir que $\Xi \subseteq \mathbb{R}^N$ é o suporte de ξ , isto é, o menor subconjunto fechado em \mathbb{R}^N tal que $P\{\xi \in \Xi\} = 1$ e que todas as restrições se verificam quase seguramente.

Para facilitar a resolução, o modelo estocástico anterior pode ser reformulado como um problema determinístico equivalente da seguinte forma:

$$\begin{aligned} \min \quad & z = \mathbf{c}^T x + \mathfrak{L}(x) \\ \text{s.a.} \quad & \mathbf{A}x = \mathbf{b}, \\ & x \geq 0, \end{aligned} \quad (4.3)$$

sendo que $\mathfrak{L}(x) = \mathbb{E}_\xi [Q(x, \xi(\omega))]$ e o valor ótimo do problema da segunda etapa é determinado da seguinte forma:

$$Q(x, \xi(\omega)) = \min_y \{q(\omega)^T y \mid Wy = h(\omega) - T(\omega)x, y \geq 0\}. \quad (4.4)$$

O problema determinístico equivalente ilustram a sequência de eventos no problema de recurso. Inicialmente, são determinadas as decisões sobre as realizações futuras de ξ , na presença de incerteza. Na etapa seguinte, o valor real de ξ torna-se conhecido, permitindo a implementação de ações corretivas, y , para remediar eventuais decisões da etapa anterior. As decisões de primeiro estágio, no entanto, são escolhidas tendo em consideração os seus efeitos futuros. Esses efeitos são medidos pela função de recurso, \mathfrak{L} , que calcula o valor esperado de tomar a decisão x .

Quando T não é estocástico, a formulação do problema anterior pode ser reajustado do seguinte modo:

$$\begin{aligned} \min \quad & z = \mathbf{c}^T x + \Psi(\chi) \\ \text{s.a.} \quad & \mathbf{A}x = \mathbf{b}, \\ & Tx - \chi = 0, \\ & x \geq 0, \end{aligned} \quad (4.5)$$

onde $\Psi(\chi) = \mathbb{E}_\xi [\Psi(\chi, \xi(\omega))]$ e $\Psi(\chi, \xi(\omega)) = \{\min q(\omega)^T y \mid Wy = h(\omega) - \chi, y \geq 0\}$. Ao escolher a variável de decisão x , estamos a gerar uma oferta futura χ , através da

relação $\chi = Tx$, com dimensão m_2 . Assim, uma vez revelada a incerteza, é necessário comparar a proposta χ com os resultados reais $h(\omega)$, para que as diferenças entre ambos sejam geridas através das decisões de recurso, y .

4.1.1 Forma Extensiva

Computacionalmente, a forma extensiva transforma problemas estocásticos em problemas lineares determinísticos, permitindo a representação completa do problema, incluindo todas as variáveis e restrições de cada cenário. Esta representação é útil para resolver problemas estocásticos complexos, embora possa resultar em modelos de grande escala. A transformação para a forma extensiva facilita a utilização de algoritmos de programação linear, tais como, o método *simplex*, *gurobi*, *glpk*, entre outros.

Para viabilizar esta abordagem, assumimos que o vetor aleatório ξ tem suporte finito e que p_k é probabilidade associada a cada cenário, com $k = 1, \dots, K$. Com base nestas suposições, o resultado é um problema linear de grande escala, que denominamos forma extensiva (EF - do inglês *Extensive Form*). Em termos matemáticos, a definição é a seguinte:

$$\begin{aligned} \min \quad & \mathbf{c}^T x + \sum_{k=1}^K p_k q_k^T y_k \\ \text{s.a.} \quad & \mathbf{A}x = \mathbf{b}, \\ & T_k x + W y_k = h_k \\ & x \geq 0, y_k \geq 0. \end{aligned} \tag{4.6}$$

Para compreender melhor a notação exposta ao longo deste dissertação é recomendável consultar o livro [20], uma vez que este expõe uma variedade de exemplos que permitem explorar o tema em maior profundidade.

4.2 Otimização Estocástica Multietapa

Na secção 4.1 foi formalizado um problema de otimização estocástica com duas etapas. Contudo, a maior parte dos problemas do dia-a-dia exige uma série de decisões que se ajustam em função de eventos que evoluem ao longo do tempo. Deste modo, é necessário formalizar modelos que considerem múltiplas etapas. Para um número de etapas H superior a 2, o algoritmo define-se da seguinte forma

$$\begin{aligned} \min z = \quad & \mathbf{c}^1 x^1 + \mathbb{E}_{\xi^2}[\min \mathbf{c}^2(\omega) x^2(\omega^2) + \dots + \mathbb{E}_{\xi^H}[\min \mathbf{c}^H(\omega) x^H(\omega^H)]] \dots] \\ \text{s.a.} \quad & W^1 x^1 = \mathbf{h}^1, \\ & T^1(\omega^2) x^1 + W^2 x^2(\omega) = \mathbf{h}^2(\omega^2), \\ & \vdots \\ & T^{H-1}(\omega^H) x^{H-1}(\omega^{H-1}) + W^H x^H(\omega^H) = \mathbf{h}^H(\omega), \\ & x^1 \geq 0, x^t(\omega^t) \geq 0, \quad t = 2, \dots, H. \end{aligned} \tag{4.7}$$

Os vetores \mathbf{c}^1 e \mathbf{h}^1 são conhecidos em \mathbb{R}^{n_1} e \mathbb{R}^{m_1} , respectivamente. O vetor estocástico $\xi^t(\omega)^T = (\mathbf{c}^t(\omega)^T, \mathbf{h}^t(\omega)^T, T_1^{t-1}(\omega), \dots, T_{m_t}^{t-1})$ é N_t -dimensional definido no espaço de probabilidade $(\Omega, \Sigma^t, \mathbb{P})$, em que $\Sigma^t \subset \Sigma^{t+1}$ para todo o $t = 2, \dots, H$. A matriz W^t tem dimensão $m_t \times n_t$. Ainda é importante referir que as decisões x dependem do histórico até ao instante t , que é indicado por ω^t , e Ξ^t é o suporte de ξ_t . A formulação restante para um exemplo financeiro pode ser analisada em detalhe no [20].

Nos problemas de otimização estocástica multietapa, é comum representar os cenários através de um esquema em árvore. A Figura 4.1 ilustra um modelo com 4 etapas, onde cada etapa é representada pelas bifurcações ao longo da árvore. As folhas desta árvore simbolizam o número total de cenários do modelo, que, neste exemplo, são 7. A árvore permite visualizar como os cenários evoluem ao longo das etapas, começando numa única raiz e ramificando-se em diferentes direções à medida que avançamos para os estágios seguintes. Cada bifurcação na árvore corresponde a uma possível realização dos eventos, refletindo as diferentes possibilidades que podem ocorrer em cada estágio. Dessa forma, torna-se evidente a evolução exponencial da complexidade dos problemas à medida que se adicionam ramificações e etapas.

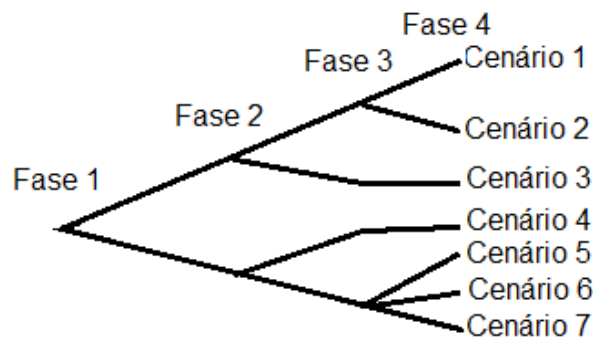


Figura 4.1: Árvore com 7 cenários

4.3 Geração de Cenários

4.3.1 Métodos de Previsão - LSTM

As *Long Short-Term Memory*, ou simplesmente LSTM, é um tipo de Rede Neuronal Recorrente (RNN) reconhecida pelo seu desempenho na previsão de séries temporais. Esta técnica foi desenvolvida para resolver problemas em que é fundamental detetar dependências de longo prazo em dados complexos. Devido a esta capacidade, estas redes são bastante utilizadas em processamento de linguagem natural, reconhecimento de voz, previsões de preços de ações, entre outras aplicações.

A componente principal das redes LSTM é a célula de memória, que controla do fluxo de informação através de três *Gates*: *Forget Gate*, *Input Gate* e a *Output Gate*. A primeira decide quais as informações que devem ser eliminadas da célula de memória,

isto é, a função de ativação sigmoide (σ) recebe os vetores h_{t-1} (saída da célula anterior) e x_t (entrada atual), e, caso o valor resultante seja 0 essa característica é esquecida; por outro lado, valores iguais de 1 indicam que a informação será utilizada futuramente. A Figura 4.2 resume a fase *Forget Gate* da célula de memória.




Figura 4.2: *Forget Gate* [Imagem retirada de [21]]

A adição de informação útil à célula é realizada pelo *Input Gate*, que está apresentada na Figura 4.3. Nesta fase existem duas etapas, a primeira é semelhante ao *Forget Gate* que filtra os valores através de uma função de ativação sigmoide e a segunda filtra os dados com a função tangente hiperbólica (\tanh). O resultado de ambas é multiplicado para obter as informações desejadas.




Figura 4.3: *Input Gate* [Imagem retirada de [21]]

Por fim, o *Output Gate* controla a quantidade de informação que é extraída da célula de memória e transmitida como saída para a próxima unidade da LSTM. Este controle é essencial para ajustar a dinâmica temporal das dependências capturadas pela rede. A Figura 4.4 representa esta fase.




Figura 4.4: *Output Gate* [Imagem retirada de [21]]

4.3.2 Algoritmo de *clustering k-medoids*

O algoritmo *k-medoids* é um método de *clustering* utilizado para dividir um conjunto de dados em k grupos, onde cada grupo é representado por um *medoid*. Um *medoid* é o ponto que minimiza a soma das distâncias em relação a todos os outros pontos no *cluster*, sendo o mais representativo daquele grupo. Este método difere do algoritmo *k-means*, que é mais utilizado, na medida em que o representante do grupo é uma observação real, enquanto que no *k-means* é a média dos valores observados. As etapas do método *k-medoids* são as seguintes [22]:

- **Etapa 1:** Definir o número de *clusters* que se pretende formar, e atribuir, de forma aleatória, k pontos como *medoids*.
- **Etapa 2:** Calcular a distância euclidiana entre cada ponto do conjunto de dados e os *medoids* inicialmente estabelecidos.
- **Etapa 3:** Identifica o ponto central que minimiza a soma das distâncias aos pontos do *cluster*, tornando-o o novo *medoids*.
- **Etapa 4:** Repete-se o processo de retribuição e cálculo dos novos *medoids* até os *clusters* estabilizarem.

O número de *clusters* em cada mercado de energia foi definido com base no coeficiente de *Silhouette*. Este coeficiente é uma métrica que avalia a qualidade dos *clusters*, permitindo medir a separação e a coesão dos grupos formados. Esta medida é calculada a seguinte forma para cada ponto i :

$$S_i = \frac{b_i - a_i}{\max(b_i, a_i)} \quad (4.8)$$

sendo a_i a distância média intracluster e reflete a proximidade do ponto i aos restantes elementos do próprio grupo. Por outro lado, b_i é a distância média intercluster que avalia a forma como os *clusters* estão separados. O resultado final S_i varia entre -1 e 1, e quanto mais próximo este valor estiver de 1, melhor estará agrupado o ponto i . O

valor final do coeficiente de *Silhouette* de cada *cluster* será a média de todos S_i dos pontos que pertencem a cada grupo.

Neste trabalho, este método foi aplicado não a pontos, mas sim a cenários de preços, ou seja, séries temporais de 24 preços. Para aplicar os algoritmos de *clustering* a séries temporais é necessário utilizar distâncias adequadas a este tipo de dados, que neste caso foi a distância euclidiana [23, 24].

4.4 Formulação do Modelo Estocástico Multimercado

Neste projeto, o modelo de otimização estocástico multimercado é baseado num problema de programação linear. Tal como detalhado na secção 4.1, tanto a função objetivo como as diversas restrições serão formuladas matematicamente como o problema determinístico equivalente ao problema estocástico.

A função objetivo maximiza o lucro esperado de um agente de mercado que licita nos diversos mercados de energia ($DA, ID1, B, ID2, R^{3-}, R^{3+}$). Esta função é definida da seguinte forma:

$$\max \left(I^{DA} + \sum_{s=1}^2 I^{ID^s} + I^{BM} \right) \quad (4.9)$$

em que,

$$I^{DA} = \sum_{\omega=1}^{\Omega} \pi_{\omega} \left(\sum_{t=1}^{24} P_{BID}^{DA}(t) \cdot \Lambda_{\omega}^{DA}(t) \right) \quad (4.10)$$

$$I^{ID^s} = \sum_{\omega=1}^{\Omega} \pi_{\omega} \left(\sum_{t=1}^{24} P_{BID}^{ID^s}(t) \cdot \Lambda_{\omega}^{ID^s}(t) \right), s = \{1, 2\} \quad (4.11)$$

$$I^{BM} = \sum_{\omega=1}^{\Omega} \pi_{\omega} \left(\sum_{t=1}^{24} [P^B(t)\Lambda_{\omega}^B + P^{3+}(t)\Lambda_{\omega}^{3-}(t) + P^{3-}(t)\Lambda_{\omega}^{3-}(t)] \right). \quad (4.12)$$

A componente I^{DA} representa o lucro esperado no mercado diário, enquanto que a componente I^{ID^s} representa o lucro esperado no mercado intradiário 1 e 2. Para os mercados associados aos serviços de sistema, ou seja, Banda secundária (B) e Reserva terciária a subir (R^{3+}) ou a descer (R^{3-}), o lucro esperado é dado por I^{BM} .

As variáveis de decisão P_{BID}^M , com $M = \{DA, ID1, ID2\}$, representam a energia licitada em cada mercado M , para cada hora $t = 1, \dots, 24$. As variáveis P^B , P^{3+} e P^{3-} também são variáveis de decisão, mas referem-se à potência disponibilizada na banda secundária, e à energia utilizada na reserva terciária a subir e na reserva terciária a descer, respetivamente. Cada variável $\Lambda_{\omega}^m(t)$ representa o preço de energia nos diversos mercados, para cada hora.

A primeira etapa do modelo de otimização refere-se ao mercado diário 2.3. Neste, apenas é possível vender energia, estando limitados à previsão da potência máxima

4.4. FORMULAÇÃO DO MODELO ESTOCÁSTICO MULTIMERCADO

produzida para cada hora. Ainda será exigido que parte da energia seja licitado neste mercado, isto é,

$$\alpha \hat{P}_{PV}(t) \leq P_{BID}^{DA}(t) \leq \hat{P}_{PV}(t), \quad t = 1, \dots, 24. \quad (4.13)$$

Posteriormente, será evidenciada a influência do α dos resultados das licitações e respectivas receitas. A otimização das licitações de energia do mercado $ID1$ é realizada na segunda etapa do modelo. O valor da previsão da potência produzida não é atualizado ao longo do modelo, sendo, por isso, necessário apenas assegurar que não se venda mais energia do que a que foi produzida e já licitada no mercado anterior. Neste mercado, é possível vender e comprar energia, considerando que não se pode comprar mais energia que àquela que se vendeu no mercado anterior. A restrição que se resume a esta etapa é,

$$0 \leq P_{BID}^{ID1}(t) + P_{BID}^{DA}(t) \leq \hat{P}_{PV}(t), \quad t = 1, \dots, 24. \quad (4.14)$$

A terceira etapa do modelo estocástico diz respeito à potência disponibilizada na banda secundária. Para relembrar, este mercado é gerido pela REN, dado que se trata de um mercado de ajustes, destinado a equilibrar o consumo e a produção. O agente disponibiliza potência neste mercado, ficando posteriormente a REN responsável pelo controlo da sua central, permitindo aumentar até metade ou reduzir até metade a produção de energia previamente contratada, de acordo com as necessidades operacionais. Como no mercado anterior, é necessário garantir que não se venda mais que as previsões estabelecidas e as quantidades licitadas, isto é

$$0 \leq P_{BID}^{DA}(t) + P_{BID}^{ID1}(t) \leq \hat{P}_{PV}(t), \quad t = 1, \dots, 24 \quad (4.15)$$

$$0 \leq P_{BID}^{DA}(t) + P_{BID}^{ID1}(t) + P^{B+}(t) - P^{B-}(t) \leq \hat{P}_{PV}(t), \quad t = 1, \dots, 24 \quad (4.16)$$

$$0 \leq P^{B+}(t) \leq \frac{1}{2} P^B(t), \quad t = 1, \dots, 24 \quad (4.17)$$

$$0 \leq P^{B-}(t) \leq \frac{1}{2} P^B(t), \quad t = 1, \dots, 24 \quad (4.18)$$

$$0 \leq P^{B+}(t) \leq \beta P_{ORT}^{B+}(t), \quad t = 1, \dots, 24 \quad (4.19)$$

$$0 \leq P^{B-}(t) \leq \beta P_{ORT}^{B-}(t), \quad t = 1, \dots, 24. \quad (4.20)$$

As variáveis P^{B-} e P^{B+} representam a potência que foi necessário disponibilizar a descer ou a subir, no mercado de Reserva de Regulação Secundária (RRS). O valor de β será ajustado em função do nível de flexibilidade atribuído ao modelo. As próximas restrições referem-se ao mercado intradiário 2, que corresponde à quarta etapa do modelo de otimização. Neste mercado, tal como no anterior, também é permitido comprar e vender energia.

$$0 \leq P_{BID}^{DA}(t) + P_{BID}^{ID1}(t) + P_{BID}^{ID2}(t) \leq \hat{P}_{PV}(t), \quad t = 1, \dots, 24 \quad (4.21)$$

$$0 \leq P_{BID}^{DA}(t) + P_{BID}^{ID1}(t) + P^{B+}(t) - P^{B-}(t) + P_{BID}^{ID2}(t) \leq \hat{P}_{PV}(t), \quad t = 1, \dots, 24. \quad (4.22)$$

A última etapa do modelo corresponde à reserva de regulação terciária (RRT), que representa a última oportunidade para efetivamente entregar energia. Este mercado permite responder a imprevistos e a correção de desequilíbrios que possam surgir nas etapas anteriores. As restrições associadas a este mercado são:

$$0 \leq P_{BID}^{DA}(t) + P_{BID}^{ID1}(t) + P^{B+}(t) - P^{B-}(t) + P_{BID}^{ID2}(t) + P^{3+}(t) - P^{3-}(t) \leq \hat{P}_{PV}(t), \quad t = 1, \dots, 24. \quad (4.23)$$

$$0 \leq P^{3+}(t) \leq \beta P_{ORT}^{3+}(t), \quad t = 1, \dots, 24 \quad (4.24)$$

$$0 \leq P^{3-}(t) \leq \beta P_{ORT}^{3-}(t), \quad t = 1, \dots, 24. \quad (4.25)$$

O valor de β posteriormente será definido para verificar o impacto nos resultados obtidos. É importante referir que todas as restrições mencionadas são definidas para cada cenário ω .

A tabela seguinte apresenta um resumo detalhado de cada etapa do modelo, incluindo as variáveis de decisão, as variáveis estocásticas, as restrições aplicáveis e as variáveis fixas. Este resumo permite compreender de forma clara a estrutura do modelo em cada fase, facilitando a visualização do comportamento do modelo ao longo das diferentes etapas de otimização.

Etapa	Sessão de Mercado	Variáveis Fixas	Variáveis Estocásticas	Variáveis de Decisão
1	DA	$\hat{P}_{PV}(t)$	$\Lambda_{\omega}^{DA}(t)$	$P_{BID}^{DA}(t)$
2	ID1	$P_{BID}^{DA}(t), \hat{P}_{PV}(t)$	$\Lambda_{\omega}^{ID1}(t)$	$P_{BID}^{ID1}(t)$
3	B	$P_{BID}^{ID1}(t), P_{BID}^{DA}(t), \hat{P}_{PV}(t)$	$\Lambda_{\omega}^B(t)$	$P^{B+}(t), P^{B-}(t)$
4	ID2	$P_{BID}^{DA}(t), P_{BID}^{ID1}(t), P^{B+}(t), P^{B-}(t), \hat{P}_{PV}(t)$	$\Lambda_{\omega}^{ID2}(t)$	$P_{BID}^{ID2}(t)$
5	R^{3-}, R^{3+}	$P_{BID}^{DA}(t), P_{BID}^{ID1}(t), P_{BID}^{ID2}(t), P^{B+}(t), P^{B-}(t), \hat{P}_{PV}(t)$	$\Lambda_{\omega}^{3-}(t), \Lambda_{\omega}^{3+}(t)$	$P^{3+}(t), P^{3-}(t)$

Tabela 4.1: Variáveis por etapa do modelo de otimização estocástico multimercado

4.4. FORMULAÇÃO DO MODELO ESTOCÁSTICO MULTIMERCADO

Capítulo 5

Exemplo de Aplicação

De forma genérica para alcançar os objetivos desta dissertação foi necessário efetuar os passos seguintes:

- Recolha e análise de dados;
- Geração de cenários para os diversos mercados de energia, relativos a 30-04-2022;
- Aplicação do algoritmo de *clustering k-medoid* aos cenários gerados;
- Construção do modelo de otimização estocástica multietapa;
- Discussão de resultados obtidos.

Neste capítulo serão apresentados os resultados relativos aos tópicos mencionados anteriormente.

5.1 Análise e Interpretação dos Dados

5.1.1 Fonte de Dados

Para o desenvolvimento deste projeto, é fundamental recolher dados de fontes devidamente informadas. Nesse sentido, os dados relativos aos preços do mercado diário (*DA*), intradiário 1 (*ID1*) e intradiário 2 (*ID2*), referentes a Portugal, foram obtidos a partir do OMIE, [8]. Os preços da banda secundária e da reserva terciária, tanto a subir como a descer foram recolhidos de [9], visto que a REN, enquanto operador de rede de transporte português, é responsável pela coordenação destes mercados. Adicionalmente, no âmbito deste projeto ainda foi necessário reunir a quantidade de energia fotovoltaica produzida em Portugal, conforme registado em [10]. Os dados históricos são horários e referem-se aos anos 2021, 2022 e 2023.

5.1.2 Análise de Dados

Após a recolha dos dados, torna-se essencial proceder à sua análise com o intuito de identificar e extrair informações relevantes. Este processo é crucial, pois permite não

5.1. ANÁLISE E INTERPRETAÇÃO DOS DADOS

só interpretar padrões e tendências subjacentes, mas também revelar correlações entre diferentes variáveis que podem não ser evidentes à primeira vista.

Neste tipo de dados é importante adquirir sensibilidade, uma vez que os preços variam entre mercados, anos, meses e até mesmo ao longo do dia. As dinâmicas que caracterizam um dia de inverno, por exemplo, diferem substancialmente das que ocorrem num dia de verão. Essas diferenças influenciam diretamente a forma como o agente de mercado licita, e por isso, é essencial adaptar as abordagens de acordo com as condições temporais e sazonais para otimizar as decisões de mercado. Os gráficos desta secção foram elaborados para evidenciar essas diferenças, bem como o cálculo de várias estatísticas. O gráfico da figura 5.1 representa o preço da energia no mercado diário ao longo dos anos de 2021, 2022 e 2023.




Figura 5.1: Preços de Energia do Mercado Diário

É possível observar que os preços apresentaram uma tendência crescente a partir segundo semestre de 2021, e que apenas começaram a diminuir no último trimestre de 2022, estabilizando ao longo do ano de 2023. Em Março de 2022, registou-se um dia em que o preço da energia atingiu um pico de cerca de 650€/MWh, sendo um claro outlier, neste últimos anos, no mercado diário. O ano de 2021 foi menos volátil em comparação com os anos de 2022 e 2023. A figura 5.2 representa, através de *boxplots*, os preços de energia no mercado diário de cada ano recolhido.




Figura 5.2: *Boxplots* do Mercado Diário: Ano 2021, 2022 e 2023

Através das *Boxplots* anteriores pode-se constatar que a mediana do ano 2022 é superior à dos outros anos e que apresenta maior quantidade de *outliers*. Pode-se ainda interpretar a tabela 5.1, que comprova as afirmações anteriores. Nos anos de 2021 e 2022, o coeficiente de assimetria é positivo (com uma cauda longa à direita), o que indica uma maior concentração de valores abaixo da média. Em contrapartida, no ano de 2023, o coeficiente de assimetria é negativo (com uma cauda longa à esquerda), refletindo uma concentração de valores acima da média daquele ano. De forma semelhante, poderia-se analisar os restantes mercados de energia.

	2021	2022	2023
Média	112.01	167.89	88.27
Mediana	89.48	163.95	92.5
Desvio Padrão	74.7	69.1	39.94
Coefficiente de Variação	149.94	242.97	221.01
Coefficiente de Assimetria	1.06	1.03	-0.42

Tabela 5.1: Medidas Estatísticas: Mercado Diário

As Figuras 5.3 e 5.4 representam o preço da energia ao longo de 24 horas, respectivamente, num dia de inverno e num dia de verão, em diversos mercados de energia do OMIE. A análise dos gráficos revela que os preços tendem a ser superiores durante o inverno em comparação com o verão, no entanto em ambos os períodos não há uma tendência clara ao longo do dia, o que de certa forma, dificulta o trabalho de um agente de mercado.




Figura 5.3: Dia de Inverno: 10-01-2022

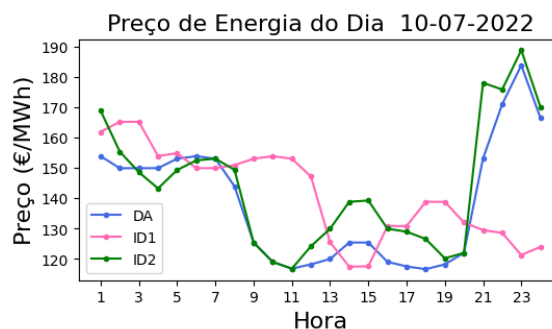


Figura 5.4: Dia de Verão: 10-07-2022

De igual modo, é relevante proceder à análise dos dados referentes aos mercados de serviços de sistema, nomeadamente, a Banda Secundária, Reserva Terciária a Subir e a Reserva Terciária a Descer. O gráfico da Figura 5.5 indica, no ano de 2021, que os preços da Banda Secundária foram os mais baixos e apresentaram menor volatilidade. Em contrapartida, no ano de 2023, destacam-se três preços que atingiram picos nunca antes registados.

5.1. ANÁLISE E INTERPRETAÇÃO DOS DADOS

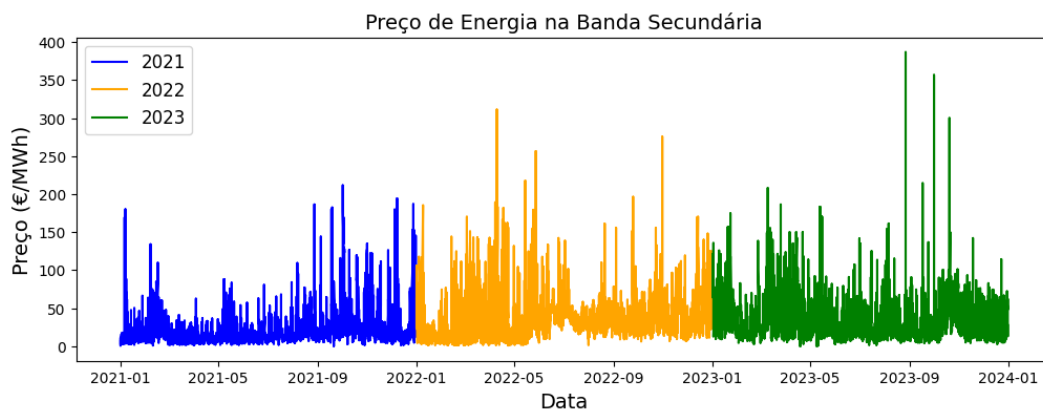


Figura 5.5: Preço da Energia na Banda Secundária

A Figura 5.6 destaca que, no ano de 2021, tanto a mediana como a amplitude interquartil são inferiores às dos anos subsequentes, o que sugere uma menor variabilidade. Em todos os anos, observa-se uma quantidade significativa de *outliers*, o que reflete a incerteza inerente a estes mercados de energia. Estes *outliers* representam valores atípicos que se desviam consideravelmente, sendo muitas vezes resultado de eventos imprevisíveis, como flutuações inesperadas na procura e na oferta ou em alterações nas condições meteorológicas. A presença destes *outliers* destaca a natureza volátil dos mercados de energia, onde os preços podem sofrer picos inesperados, em resposta a fatores externos, evidenciando a dificuldade de prever com precisão os comportamentos do mercado. A sua persistência ao longo dos anos reforça a complexidade associada à gestão nestes mercados.




Figura 5.6: *Boxplots* da Banda Secundária: Anos de 2021, 2022 e 2023

A Tabela 5.2 indica algumas medidas estatísticas importantes, relativas à Banda Secundária, que comprovam várias afirmações anteriores. O coeficiente de assimetria no ano de 2021 foi o mais elevado (3.18) e indica uma cauda longa à direita, provocada pela quantidade de *outliers* presentes nesse ano.

	2021	2022	2023
Média	23.69	40.51	39.53
Mediana	16.65	33.06	28.85
Desvio Padrão	23.88	31.42	34.71
Coefficiente de Variação	98.18	128.91	113.87
Coefficiente de Assimetria	3.18	1.97	2.9

Tabela 5.2: Medidas Estatísticas: Banda Secundária

O gráfico da Figura 5.7 mostra como variou o preço da potência disponibilizada pela na Banda Secundária (B) e o preço da energia na Reserva Terciária a Descer (R^{3-}) e na Reserva Terciária a Subir (R^{3+}), no dia 8 de maio de 2023. Pose-se observar que parece não existir nenhuma tendência, neste período de 24 horas.




Figura 5.7: Mercado de Serviços de Sistema: Dia 08-05-2023

5.2 Geração de Cenários

O processo de geração de cenários para alimentar o modelo de otimização estocástica foi baseado no artigo [19]. Este processo está dividido em duas etapas: a primeira envolve geração de cenários através de redes neurais artificiais, enquanto que a segunda aplica o algoritmo de *clustering k-medoid*.

Com o objetivo de produzir cenários com uma certa variabilidade, foram gerados 500 cenários, recorrendo a várias arquiteturas de redes neurais, que se distinguem pelo número de neurónios e pelo número de camadas ocultas utilizadas. Estes cenários foram elaborados para as seguintes variáveis:

- \hat{P}_{PV} - Potência Fotovoltaica produzida;
- Λ^{DA} - Preço de Energia no Mercado Diário;
- Λ^{ID^1} - Preço de Energia no Mercado Intradiário 1;
- Λ^B - Preço da Potência disponibilizada na Banda Secundária;

5.2. GERAÇÃO DE CENÁRIOS

- Λ^{ID^2} - Preço de Energia no Mercado Intradiário 2;
- $\Lambda^{R^{3+}}$, $\Lambda^{R^{3-}}$ - Preço de Energia na Reserva Terciária a Subir e a descer, respetivamente.

De acordo com as figuras 2.3 e 2.5, os mercados de energia ocorrem em momentos diferentes ao longo do dia. Como tal, os cenários foram criados com base em informação proveniente dos mercados que já se realizaram. Por exemplo, para a previsão dos preços da banda secundária foram considerados os 48 preços anteriores, que correspondem aos valores licitados tanto no mercado diário como no mercado intradiário 1.

Após a criação de todos os cenários, foi aplicado o algoritmo *k-medoid* com o intuito de agrupar os cenários em diferentes *clusters*, de modo a identificar os cenários mais representativos de cada mercado. O número de *clusters* nos mercados *DA*, *ID1*, *B* e *ID2* variou em função do maior coeficiente de *Silhouette*, e por isso foram considerados 2 grupos em *DA*, 3 no *ID1*, 3 na *B* e 2 grupos no *ID2*. Esses valores são apresentados na tabela 5.3. Ainda referir que os cenários da produção de potência fotovoltaica foram gerados em conjunto com os preços do mercado diário, uma vez que este mercado marca o início das licitações para o dia seguinte. Assim, os medóides atribuídos à produção fotovoltaica correspondem aos cenários associados aos medóides do mercado diário.

Número de <i>Clusters</i>	2	3	4
DA	0.19	0.16	0.13
ID1	0.35	0.37	0.27
B	0.28	0.31	0.19
ID2	0.38	0.28	0.18

Tabela 5.3: Coeficiente de *Silhouette*

Contudo, para R^{3-} e R^{3+} , foi selecionado um único centróide, uma vez que ambos os mercados ocorrem em simultâneo e, para simplificar a estrutura em árvore que será construída pelo modelo estocástico, conforme mencionado na secção 4.2. As Figuras 5.8 e 5.9 representam todos os cenários e os respetivos centróides nos diversos mercados de energia.

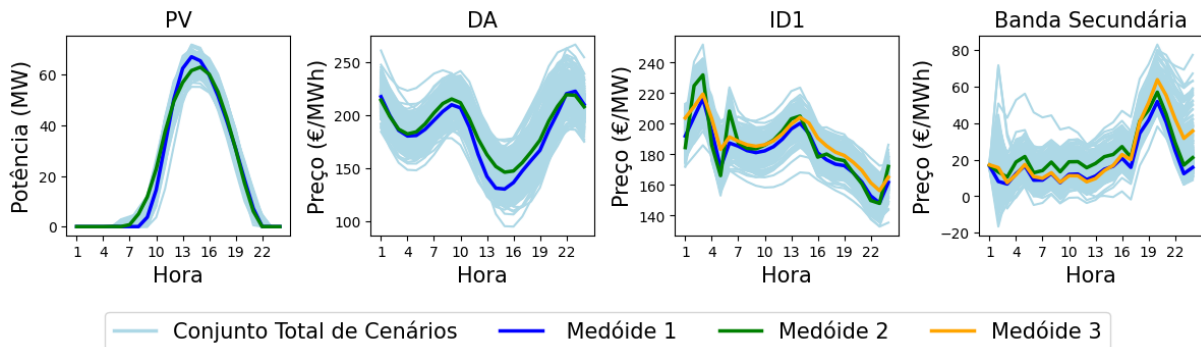


Figura 5.8: Cenários dos Mercados de Energia




Figura 5.9: Cenários dos Mercados de Energia

A cada centróide está associado uma probabilidade p_i^m , onde i refere-se a um centróide de um mercado $m = \{DA, ID1, B, ID2, R^{3-}, R^{3+}\}$. Esta probabilidade é obtida através do quociente entre o número de observações do grupo do medóide i no mercado m e do número total de cenários, que neste caso é 500. Estes centróides serão utilizados para construir uma árvore de decisão que servirá de base ao modelo de otimização estocástico multietapa. Cada ramificação desta árvore representará um novo cenário conjunto, com uma probabilidade π_ω associada, que é calculada a partir da combinação das probabilidade (p_i^m) de todos os centróide de cada mercado. As probabilidades de cada medóide (p_i^m) dos diferentes mercados são apresentadas na tabela seguinte.

	DA	ID1	B	ID2	R3+ / R3-
Medóide 1	0.372	0.392	0.434	0.396	1
Medóide 2	0.628	0.320	0.408	0.604	—
Medóide 3	—	0.288	0.158	—	—

Tabela 5.4: Probabilidades de cada Medóide

Através da tabela anterior, torna-se mais simples calcular a probabilidade π_ω de cada cenário representado na árvore ilustrada na Figura 5.10. Por exemplo, o cenário 1 corresponde aos medóides 1 de cada mercado, pelo que a probabilidade associada a este cenário é $\pi_1 = 0.372 \times 0.392 \times 0.434 \times 0.396 \times 1 \simeq 0.025$.




Figura 5.10: Árvore de cenários

5.3 Análise de Resultados

Um produtor de energia dispõe de uma central fotovoltaica, e o seu objetivo é participar nos diversos mercados de energia de modo a maximizar os seus lucros no dia 30-04-2022. Para dois cenários distintos de produção fotovoltaica, \hat{P}_{PV} , o produtor aplicou o modelo proposto nesta dissertação para determinar as melhores licitações em ambas as situações, tendo em conta 36 cenários de preços para os diversos mercados de energia.

Este produtor tem o intuito de realizar uma análise de sensibilidade aos parâmetros do modelo α e β , para posteriormente licitar com base em várias hipóteses analisadas. O valor de α corresponde à percentagem mínima no mercado diário, que o produtor pode vender em cada hora, e o β representa a percentagem máxima de potência a subir ou a descer na banda secundária. Além disso o β também reflete o valor da percentagem máxima de energia a subir ou a descer na Reserva de Regulação Terciária.

Os primeiros resultados obtidos estão representados na figura 5.11, onde foram utilizado os parâmetros $\alpha = 0.2$ e $\beta = 0.1$. Os valores positivos indicam ofertas de venda, enquanto que, os valores negativos são ofertas de compra. Nas horas onde não existe radiação solar, o produtor sabe que não tem energia para licitar e por isso o modelo está de acordo com a realidade nestas horas. Na hora 10 o resultado ótimo é vender 14.52 MW no mercado diário, de seguida comprar a mesma quantidade no mercado intradiário 1 e posteriormente vendê-la no intradiário 2. Este jogo entre compra e venda de energia, pode parecer insignificante, contudo, tende em conta os 36 cenários de preços, o modelo prevê uma redução de preços no mercado intradiário 1. Deste modo, a melhor estratégia é vender toda a produção no mercado diário, comprar a mesma quantidade no mercado intradiário 1 e, em seguida, vender no intradiário 2, maximizando assim os lucros.




Figura 5.11: Resultado 1: $\alpha = 0.2$, $\beta = 0.1$

Na tabela seguinte estão os preços do cenário 1 da hora 10. Nesta hora o produtor lucra $207.27 \times 14.52 - 182.32 \times 14.52 + 199.11 \times 14.52 = 3253.35$ €. Se apenas licitasse

no mercado diário o lucro seria de $207.27 \times 14.52 = 3009.56\text{€}$. Assim, neste cenário 1 na hora 10, o produtor nos mercados associados ao MIBEL, lucra 243.79€ , ao aplicar o modelo proposto.

Preço DA	207.27
Preço ID1	182.32
Preço ID2	199.11

Tabela 5.5: Preços cenário 1 da hora 10

O balanço final de energia representado no gráfico 5.11 corresponde a

$$BF(t) = P_{BID}^{DA}(t) + P_{BID}^{ID^1}(t) + P_{BID}^{ID^2}(t) + P^{3+}(t) - P^{3-}(t), \quad (5.1)$$

ou seja, é a quantidade de energia física que o produtor entregou em cada hora. Por exemplo, para a hora 10 o produtor fisicamente não entregou energia, no entanto, conseguiu obter lucro nesta hora devido ao mercado financeiro. Nesta hora a reserva terciária a descer compensou o que foi vendido no intradiário 2, e por isso, o balanço final é zero. Neste exemplo, o valor esperado do lucro, tendo em conta os 36 cenários de preços e respetivas probabilidades é de 151337.24€ , calculado através de 4.9.

O exemplo seguinte, representado na figura 5.12, difere do anterior devido ao aumento da liberdade do parâmetro β para 30%. Este ajuste do parâmetro β aumenta a flexibilidade do produtor, na distribuição dos seus recursos na banda secundária e na reserva de regulação terciária. Relativamente à banda secundária, uma maior disponibilização de potência permite uma resposta mais eficaz nas flutuações de curto prazo da rede elétrica, e pode permite ao produtor a obtenção de mais lucros pela oferta de capacidade, mesmo quando não há ativação da mesma. Para a reserva terciária, tanto a subir como a descer, o aumento deste parâmetro permite disponibilizar mais energia para combater desequilíbrios significativos entre a produção e o consumo, o que resulta num aumento de receitas para o produtor. Como tal o valor esperado do lucro neste exemplo foi de 188386.33€ .




Figura 5.12: Resultado 1: $\alpha = 0.2$, $\beta = 0.3$

5.3. ANÁLISE DE RESULTADOS

Neste exemplo, no cenário 1 o lucro esperado no mercado de reserva terciária foi de 64121.67€, enquanto que no exemplo anterior foi de 27072.58€. A diferença entre ambos os valores comprova a flexibilidade fornecida ao modelo de otimização, e que retrata o mercado de em questão. Com uma previsão de produção de 67.04 MW na hora 13, os resultados ótimos estão representados na tabela seguinte.

	PV	DA	ID1	B+	B-	ID2	R3+	R3-
Hora 13	67.04	12.48	49.94	0.00	25.95	0.00	54.996	44.886

Tabela 5.6: Resultados: Hora 13

O produtor tem outra previsão de produção de energia. Assim, a melhor forma de auxiliar nas suas licitações é aplicar o modelo com essa mesma previsão, mantendo os mesmos 36 cenários de preços e respectivas probabilidades. As figuras 5.13 e 5.14 representam as licitações ótimas nos diversos mercados e para diferentes parâmetros β .




Figura 5.13: Resultado 3: $\alpha = 0.2$, $\beta = 0.1$




Figura 5.14: Resultado 4: $\alpha = 0.2$, $\beta = 0.3$

Para o caso em que $\beta = 0.1$, o lucro esperado é de 157291.42 €. Quando $\beta = 0.3$ o resultado esperado obtido é de 196450.52€. Este valores são sensivelmente superiores aos exemplos apresentados anteriormente, o que significa que o produtor prevê produzir mais potencia neste cenário. Em todos os exemplo o produtor entrega mais energia na hora 13, que corresponde a uma hora de maior radiação solar.

Analisando estes vários exemplos, o produtor deve ponderar cuidadosamente como irá licitar, tendo em conta o risco associado a cada cenário. A variabilidade nos lucros esperados, implica que a estratégia de licitação deve se adaptar às condições de mercado. O produtor deve analisar o risco associado à incerteza dos preços e à previsão da produção de energia.

Capítulo 6

Conclusões e Trabalho Futuros

O objetivo desta dissertação era compreender e analisar como funcionam os mercados de energia, com a finalidade de desenvolver um modelo de otimização estocástica que abrange múltiplos mercados. O propósito central do modelo é maximizar o lucro esperado de um produtor de energia que opera uma central fotovoltaica com capacidade de 100 MW. Cada etapa do modelo está associado um mercado de energia, seguindo a sequência temporal das operações de licitação.

Para alcançar este objetivo foi necessário gerar 500 cenários de preços do mercado diário (*DA*), intradiário 1 (*ID1*), banda secundária (*B*), intradiário 2 (*ID2*) e reserva de regulação terciária (*RRT*). A geração destes cenários foi efetuada através de redes neurais recorrentes do tipo LSTM (*Long Short-Term Memory*), uma vez que se revelaram particularmente eficiente em trabalhos anteriores de previsão de preços em mercados de energia. Após a criação dos cenários aplicou-se um algoritmo de *clustering k-medoids*, que permitiu identificar os cenários mais representativos de cada mercado e respetivas probabilidades. Os medóides obtidos foram utilizados para construir uma árvore de decisão, onde cada caminho representa novas combinações de preços dos diferentes mercados. A estes novos cenários foi atribuída uma probabilidade condicionada, essencial para o funcionamento do modelo estocástico multimercado.

Apesar deste modelo ter em conta alguma incerteza associada aos preços dos diferentes mercados, este modelo dependerá sempre da previsão de produção de energia por parte deste produtor, o que implica oscilações no lucro esperado. O resultado obtido corresponde à melhor estratégia de licitação para todos os cenários considerados. Cada um dos cenários apresenta um lucro esperado, no entanto, o lucro final do modelo é calculado através da ponderação de todos esses lucros esperados, refletindo uma abordagem sólida que considera a variabilidade dos preços em diferentes condições de mercado.

Futuramente seria pertinente enriquecer o modelo de otimização proposto, incorporando todas as restrições que refletem de forma abrangente as dinâmicas de funcionamento de todos os mercados de energia, e eventualmente, integrar novos mercados, que possam surgir no contexto energético. As regras inerentes aos mercados de energia estão

em constantes alterações, e por isso, seria interessante trabalhar o modelo proposto nesta dissertação com licitações efetuadas de intervalos de 15 minutos. Esta abordagem é particularmente interessante uma vez que as licitações em Espanha e em diversos países da Europa, já é realizada com este espaçamento temporal. A capacidade de modelar decisões em intervalos curtos é crucial, uma vez que as condições de mercado podem variar significativamente em períodos tão curtos. Pode-se ainda adaptar este tipo de modelos a centrais hidroelétricas com bombagem, com a vantagem de produzir energia a qualquer hora, nomeadamente quando existe mais necessidade, isto é, quando o consumo excede a produção. Nestas centrais é possível licitar para todas as 24 horas do dia seguinte. Além disso, o modelo poderia ser expandido para incluir uma combinação de centrais fotovoltaicas, hidroelétricas com bombagem e baterias. Pretendo ainda continuar a desenvolver este projeto nos próximos 6 meses, como bolsista de um projeto de investigação.

Bibliografia

- [1] Sousa. J, Teixeira. F, Faias. S. Impact of a price-maker pumped storage hydro unit on the integration of wind energy in power systems, *ENERGY (Elsevier)*, 2014.
- [2] Fernandes. F, Sousa. J, Lagarto. J, Santana. J . Scheduling of a pumped-storage hydro in the day-ahead market and in the secondary reserve market, *15th International Conference on the European Energy Market*, 2018.
- [3] Fernandes. F, Sousa. J, Lagarto. J, Santana. J . Multi-market optimal scheduling of a power generation portfolio with a price-maker pumped-storage hydro unit, *13th International Conference on the European Energy Market*, 2016.
- [4] Fernandes. F, Sousa. J, Lagarto. J, Santana. J, Martins. B . Optimal scheduling of a pumped storage hydro unit in the day-ahead and secondary reserve electricity market, *12th International Conference on the European Energy Market*, 2015.
- [5] Algarvio. H, Sousa. J, Lagarto. J, Lopes. F. Power Producers Trading Electricity in both Pool and Forward Markets, *IEEE Computer Society Press*, 2014.
- [6] Sousa. J, Martins. A. Optimal Renewable Generation Mix of Hydro, Wind and Photovoltaic for Integration into the Portuguese Power System, *10th International Conference on the European Energy Market*, 2013.
- [7] Damião. J, Análise do Mercado de Serviços de Regulação de Frequência Secundária e Terciária no Sistema Elétrico Português, *ISEL*, 2015.
- [8] Omie, Resultados de Mercado, disponível em: URL <https://www.omie.es/pt>, acesso em fevereiro de 2024.
- [9] REN, Sistema de Informação de Mercado de Energia, disponível em: URL <https://mercado.ren.pt/PT/Electr>, acesso em fevereiro de 2024.
- [10] Entsoe, Transparency Platform, disponível em: URL <https://newtransparency.entsoe.eu/>, acesso em Abril de 2024.
- [11] Fernandes. F, Despacho de uma Central Hídrica Reversível no Mercado Diário e no Mercado de Banda Secundária, *IST*, 2017.

- [12] Pinto. M, Otimização da carteira de ativos de geração de energia elétrica de uma empresa que atua no mercado diário do MIBEL e no mercado de reserva secundária, *ISEL*, 2017.
- [13] Hirth. L,Ziegenhagen. I, Balancing power and variable renewables: Three links *Elsevier, Renewable and Sustainable Energy Reviews* , 2015.
- [14] Bâra. A, Oprea. S, Ciurea. C, Improving the strategies of the market players using an AI-powered price forecast for electricity market, *Department of Economic Informatics and Cybernetics, Bucharest University of Economic Studies, Bucharest, Romania*, 2023.
- [15] Backe. S, Sørensen. S, Bordvik. A, Tiwari. S, Andresen. C, Predictions of prices and volumes in the Nordic balancing markets for electricity, *International Conference on the European Energy Market*, 2023.
- [16] Medium, Understanding Bidirectional LSTM for Sequential Data Processing, disponível em: URL <https://medium.com/@anishnama20/understanding-bidirectional-lstm-for-sequential-data-processing-b83d6283befc>, acesso em fevereiro de 2024.
- [17] Connor. C, Collins. J, Prestwich. S, Visentin. A, Electricity Price Forecasting in the Irish Balancing Market, *University College Cork* , 2024
- [18] Havel. P, Utilization of Real-Time Balancing Market for Transmission System Control Under Uncertainty, *IEEE transactions o power systems* , 2014.
- [19] Silva. A, Pousinho. H.M.I., Estanqueiro. A A multistage stochastic approach for the optimal bidding of variable renewable energy in the day-ahead, intraday and balancing markets, *Elsevier*, 2022.
- [20] Birge. J, Louveaux. F., Introduction to Stochastic Programming, *Springer*, Second Edition.
- [21] Medium, Redes Neurais LSTM, disponível em: URL <https://medium.com/turing-talks/turing-talks-27-modelos-de-predi%C3%A7%C3%A3o-lstm-df85d87ad210>, acesso em Setembro de 2024.
- [22] Medium, Exploring the World of Clustering: K-Means vs. K-Medoids, disponível em: URL <https://medium.com/@prasanNH/exploring-the-world-of-clustering-k-means-vs-k-medoids-f648ea738508>, acesso em Setembro de 2024.
- [23] Maharaj. E, Urso. P., Caiado. J. Time Series Clustering and Classification, *CRC Press*, Taylor & Francis Group.

BIBLIOGRAFIA

- [24] Kaufman. L, Rousseeuw. P. Finding Groups in Data, An Introduction to Cluster Analysis, *Wiley Interscience*.