



Sistema de Apoio à Decisão Multi-Agente para a Negociação de Contratos Bilaterais em Mercados de Energia Elétrica

FRANCISCO SAMUEL PAIVA DA SILVA

Outubro de 2019

Sistema de Apoio à Decisão Multi-Agente para a Negociação de Contratos Bilaterais em Mercados de Energia Elétrica

Francisco Samuel Paiva da Silva

**Dissertação para obtenção do Grau de Mestre em
Engenharia Informática, Área de Especialização em
Sistemas de Informação e Conhecimento**

**Orientador: Doutora Isabel Praça
Co-Orientador: Doutor Tiago Pinto**

Júri:
Presidente:

Vogais:

«À minha mãe»

«Nunca desistas!»

Hipico

Resumo

Ao longo das últimas décadas, os mercados de energia elétrica têm sofrido grandes alterações no seu funcionamento de forma a dar resposta aos desafios emergentes. Essa evolução contribuiu para um grande aumento da sua complexidade e imprevisibilidade, dificultando a participação das entidades envolvidas. De forma a possibilitar lidar com a dificuldade identificada, surgiram várias ferramentas para o estudo dos mercados, permitindo a análise das diversas entidades envolvidas, as suas interações assim como as regras em vigor. No entanto, as soluções existentes são principalmente focadas nos modelos de mercado baseados em leilão, apresentando um apoio muito reduzido, e em alguns casos inexistente, ao modelo de mercado baseado na negociação de contratos bilaterais.

Com o intuito de colmatar a necessidade identificada, a presente dissertação propõe o desenvolvimento de um sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais em mercados de energia elétrica. Para esse fim, o sistema oferece apoio à decisão nas fases de pré-negociação e negociação de contratos bilaterais.

Na fase de pré-negociação são identificados os oponentes, assim como a quantidade de energia a transacionar com cada um e o respetivo preço esperado, de forma a potenciar o maior benefício para o *player* apoiado, tendo em conta os seus objetivos. A recomendação final resulta da reunião de vários processos, incluindo: deteção de contextos de negociação; geração de cenários de negociação alternativos; aprendizagem sobre qual o método de geração de cenários mais realista; análise das ações possíveis que o *player* pode tomar; gestão de risco, considerando a reputação de cada oponente; e o processo de decisão que permite a adoção de diferentes estratégias para a identificação da ação com maior benefício.

Na fase de negociação é identificada, a cada oferta/contra-oferta, a melhor estratégia que o *player* apoiado pode seguir com determinado oponente, num determinado contexto, de forma a obter o melhor resultado possível na sua negociação. A recomendação resulta de um processo de aprendizagem, inspirado no funcionamento das redes neuronais artificiais, de forma a confrontar informação de fontes distintas: experiência pessoal e partilhada por outros *players* acerca do oponente, dos oponentes com um perfil de negociação semelhante e de todos os oponentes no geral. Este processo tem como componentes chave: a deteção do contexto de negociação; identificação de perfis de negociação; atribuição de pesos às diferentes fontes de informação conforme o seu contributo; e gestão de credibilidade de cada *player* tendo em conta a qualidade da informação partilhada.

Os modelos desenvolvidos são integrados em diferentes agentes, capazes de se adaptarem a diferentes contextos de negociação e comportamentos dos oponentes em questão. Para esse efeito são aplicados conceitos de aprendizagem automática, matemática e negociação automática. A solução proposta é testada e validada através de simulação utilizando cenários baseados em dados reais do mercado ibérico de energia elétrica.

Palavras-chave: Contratos Bilaterais, Aprendizagem Automática, Mercados de Energia Elétrica, Negociação Automática, Sistema de Apoio à Decisão, Sistema Multi-Agente

Abstract

Over the last few decades, electricity markets have undergone major changes in their operation in order to respond to the emerging challenges. This evolution has contributed to a great increase in its complexity and unpredictability, making it difficult for the involved entities to participate. In order to deal with the difficulty identified, several tools emerged for the study of markets, allowing the analysis of the various involved entities, their interactions as well as the applicable rules. However, existing solutions are mainly focused on auction-based market models, with very limited, and in some cases non-existent, support for the market model based on the bilateral contracts negotiation.

In order to address the identified need, this dissertation proposes the development of a multi-agent decision support system for the negotiation of bilateral contracts in electricity markets. To this end, the system provides support for the decision in the pre-negotiation and negotiation phases of bilateral contracts.

In the pre-negotiation phase, the opponents are identified, as well as the amount of energy to be transacted with each one and its expected price, in order to maximize the benefit to the supported player, taking into account its objectives. The final recommendation results from the reunion of several processes, including: detection of negotiation contexts; generation of alternative negotiation scenarios; learning about which method of scenario generation is the most realistic; analysis of possible actions that player can take; risk management, taking into account the reputation of each opponent; and the decision process that allows the adoption of different strategies for the identification of the action with greater benefit.

In the negotiation phase, at each offer/counter-offer, is identified the best strategy that the supported player can follow with a certain opponent, in a given context, in order to obtain the best possible outcome in its negotiation. The recommendation results from a learning process, inspired by the operation of artificial neural networks, in order to confront information from different sources: personal experience shared by other players about the opponent; opponents with a similar negotiating profile; and of all opponents in general. This process has as key components: the detection of the negotiation context; identification of negotiation profiles; attribution of weights to the different sources of information according to their contribution; and credibility management of each player taking into account the quality of the shared information.

The developed models are integrated in different agents, able to adapt to different contexts of negotiation and behaviors of the opponents in matter. For this purpose, concepts of machine learning, mathematics and automated negotiation are applied. The proposed solution is tested and validated through simulation, using scenarios based on real data from the Iberian electricity market.

Agradecimentos

Em primeiro lugar quero agradecer aos meus orientadores Doutora Isabel Praça e Doutor Tiago Pinto por todo o apoio prestado. Tenho a sorte de ser acompanhado por eles desde o estágio da licenciatura e têm sido um enorme exemplo de profissionalismo, sabedoria e, acima de tudo, serem excelentes seres humanos.

Em segundo lugar quero agradecer aos amigos do GECAD que são muito mais do que colegas de trabalho. A união e amizade dentro e fora do local de trabalho revelou-se muito importante para conseguir ultrapassar as barreiras mais difíceis. Muito obrigado.

Aos meus pais, os meus maiores ídolos, espero que reconheçam em mim a maior gratidão do mundo por tudo o que me deram e, acima de tudo, pelo excelente exemplo que me deram ao serem lutadores, persistentes e incansáveis. Fizeram tudo para alcançar os seus sonhos e conseguiram. Converteram o nada em tudo. Garantiram que todos os seus filhos tivessem tudo o que precisassem, apesar de eles próprios não terem tido. Em especial, quero agradecer à minha mãe que durante a maior parte da minha existência teve de ser uma super mãe, compensando a doença do meu pai. Hoje acusa um enorme desgaste e tem dificuldade em lembrar-se de tudo. Contudo, eu sei o gosto que tens em que aumente a minha formação e todo o apoio que me deste. Desculpa se me atrasei mas espero finalmente dar-te esse gosto. Esta dissertação é para ti.

Quero também agradecer a todo o apoio manifestado pelos meus amigos (que inclui os magníficos sobrinhos) e familiares, assim como a compreensão por não conseguir dedicar-lhes todo o tempo que merecem.

Por último, a mais importante, a minha alma gémea Brígida. Passamos por momentos muito difíceis juntos mas sempre tivemos um ao outro para nos mantermos no caminho certo. O teu apoio incondicional tem sido fundamental para o meu equilíbrio. Obrigado por acreditares em mim mais do que eu próprio. Espero ser capaz de tudo o que imaginas. Pelo menos tu mereces que eu o seja.

Conteúdo

Lista de Figuras	xiii
Lista de Tabelas	xv
Lista de Acrónimos	xvii
1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.3 Contribuições	4
1.4 Estrutura do Documento	6
2 Contexto e Estado de Arte	7
2.1 Mercados de Energia Elétrica	7
2.1.1 Modelos Reguladores	8
2.1.2 Contratos Bilaterais	10
2.2 Análise de Valor de Negócio	12
2.2.1 Identificação e Análise de Oportunidade	13
2.2.2 Geração e Enriquecimento de Ideias	14
Apoio à Decisão na Fase de Pré-Negociação	14
Apoio à Decisão na Fase de Negociação	16
2.2.3 Seleção de Ideia e Definição de Conceito	17
2.2.4 Valor para o cliente	17
2.2.5 Modelo de Negócio	19
2.2.6 Rede de Valor	23
2.2.7 Analytic Hierarchy Process (AHP)	23
2.3 Aprendizagem e Negociação em Sistemas Multi-Agente	24
2.3.1 Sistemas Multi-Agente	24
<i>Frameworks</i>	25
2.3.2 Negociação Automática	26
Preliminares	27
Pré-Negociação	28
Negociação	31
Renegociação	33
2.3.3 Aprendizagem Automática	34
<i>Frameworks</i>	34
2.4 Sistemas de Apoio à Decisão para Mercados de Energia Elétrica	36
2.4.1 Simulação de Mercados de Energia Elétrica	36
2.4.2 Sistemas de Negociação de Contratos de Energia	38
EMCAS	38
GENIUS	39

MAN-REM	40
MASCEM	41
2.5 Conclusões	42
3 Solução Proposta	45
3.1 Modelo de Apoio à Decisão para Pré-Negociação	46
3.1.1 Módulo de Identificação de Contexto	47
3.1.2 Módulo de Avaliação de Reputação	48
3.1.3 Definição de Cenários	49
3.1.4 Ações Possíveis	50
3.1.5 Processo de Decisão	51
3.1.6 Otimização	52
3.2 Modelo de Apoio à Decisão para Negociação	55
3.2.1 Módulo de Identificação de Perfis	59
3.3 Modelo de Dados	60
3.4 Modelo Multi-Agente	66
3.4.1 Processo de Apoio à Fase de Pré-negociação	68
3.4.2 Processo de Apoio à Fase de Negociação	71
3.5 Modelo de Classes	75
4 Casos de Estudo	83
4.1 Caso de Estudo de Apoio à Fase de Pré-negociação	83
4.1.1 Pré-processamento de Dados	83
4.1.2 Geração de Contextos	86
4.1.3 Cenário	90
4.1.4 Teoria de Jogos	93
Método de Decisão Pessimista	97
Método de Decisão Otimista	99
4.1.5 Otimização	100
Método de Decisão Pessimista	100
Método de Decisão Otimista	102
Avaliação de Tempo de Execução	104
4.1.6 Aprendizagem por reforço	104
Método de Decisão Mais Provável	111
4.2 Caso de Estudo de Apoio à Fase de Negociação	112
4.2.1 Pré-processamento de Dados	113
4.2.2 Cenário	113
4.2.3 Negociação	119
4.2.4 Rede de Aprendizagem	123
4.3 Conclusões	126
5 Conclusão	129
Bibliografia	131

Lista de Figuras

2.1	Mercado Simétrico (Isabel Praça et al. 2003).	9
2.2	Mercado Assimétrico (Isabel Praça et al. 2003).	9
2.3	Modelo de relacionamento de construção de NCD (Koen et al. 2002).	12
2.4	Modelo canvas.	22
2.5	Interação entre os agentes do simulador EMCAS para a negociação de contratos bilaterais.	38
2.6	Arquitetura do GENIUS.	39
3.1	Processo de decisão na fase de pré-negociação, baseado em teoria de jogos.	46
3.2	Rede de aprendizagem.	58
3.3	Modelo de dados [UML] relativo ao <i>Player</i> , Contexto, Contrato e Reputação.	61
3.4	Modelo de dados [UML] relativo ao processo de previsão e aprendizagem por reforço.	62
3.5	Modelo de dados [UML] relativo ao processo de geração de todas as ações possíveis e avaliação da sua utilidade.	63
3.6	Modelo de dados [UML] para registo das estratégias de negociação.	64
3.7	Modelo de dados [UML] para registo e avaliação das estratégias, fontes de informação e métodos de pesagem.	65
3.8	Modelo do SMA proposto.	67
3.9	Comunicações no início do processo de apoio à fase de pré-negociação.	68
3.10	Diagrama de sequência [UML] de comunicações para a identificação do contexto e cenário mais provável.	69
3.11	Diagrama de sequência [UML] de comunicações para geração de cenários.	70
3.12	Diagrama de sequência [UML] de comunicações para avaliação de reputação e pesquisa melhor ação.	70
3.13	Diagrama de sequência [UML] de comunicações para atualização das avaliações dos AAR.	71
3.14	Diagrama de sequência [UML] de comunicações no início do processo de apoio à fase de negociação.	72
3.15	Diagrama de sequência [UML] de comunicações para identificação do contexto, análise do perfil e obtenção de credibilidade.	72
3.16	Diagrama de sequência [UML] de comunicações para obtenção da melhor estratégia a recomendar.	73
3.17	Diagrama de sequência [UML] de comunicações para obtenção da oferta a licitar e futuras interações.	74
3.18	Diagrama de sequência [UML] de comunicações para atualização das avaliações de acordo com resultado da negociação.	75
3.19	Diagrama de classes [UML] do Sistemas Multi-Agente (SMA) (visão geral).	76
3.20	Diagrama de classes [UML] do pacote de um agente.	78
3.21	Diagrama de classes [UML] da base de conhecimento do agente <i>Geracao-Cenarios</i> .	79

3.22	Diagrama de classes [UML] da base de conhecimento do agente <i>AnalisePerfis</i> .	80
3.23	Diagrama de classes [UML] da base de conhecimento do agente <i>AARSuperior</i> .	81
3.24	Diagrama de classes [UML] da base de conhecimento do agente <i>RedeAprendizagem</i> .	82
4.1	Perfis de negociação para geração de preços dos contractos.	85
4.2	Valor médio da silhueta para diferentes números de grupos de <i>players</i> .	86
4.3	Perfis semanal de preços de mercado das últimas semanas.	87
4.4	Valor médio da silhueta para diferentes números de grupos.	88
4.5	Contextos de negociação.	89
4.6	Tempo de execução do método de decisão baseado em teoria de jogos.	91
4.7	Cenário RNA_500.	93
4.8	Cenário RNA_1000.	93
4.9	Cenário MSV_500.	94
4.10	Cenário MSV_1000.	94
4.11	Cenário Média.	94
4.12	Cenário AD.	95
4.13	Cenário FA.	95
4.14	Cenário KVMP.	95
4.15	Cenário RL.	96
4.16	Valor global de utilidade de cada cenário para diferentes níveis de risco.	97
4.17	Comparação do preço total das ações recomendadas para o método de decisão Pessimista.	102
4.18	Comparação do preço total das ações recomendadas para o método de decisão Otimista.	103
4.19	Tempo de execução do método de decisão baseado em otimização.	104
4.20	Processo de aprendizagem do AAR Superior para o contexto 3 do <i>Player 4</i> .	106
4.21	Processo de aprendizagem do AAR Q-Learning para o contexto 3 do <i>Player 4</i> , sobre o cenário mais provável.	110
4.22	Cenário Mais Provável	111
4.23	Perfil de negociação das estratégias na compra de energia.	116
4.24	Similaridade entre as estratégias de negociação.	118
4.25	Classificação da estratégia do <i>Player 1</i> ao fim de três iterações.	121
4.26	Classificação da estratégia do <i>Player 1</i> ao fim de seis iterações.	122
4.27	Pesos e avaliações da rede de aprendizagem no início da negociação com o <i>Player 1</i> no contexto 3.	124
4.28	Pesos e avaliações da rede de aprendizagem na segunda negociação com o <i>Player 1</i> no contexto 3	125
4.29	Pesos e avaliações da rede de aprendizagem na quinta negociação com o <i>Player 1</i> no contexto 3	126

Lista de Tabelas

2.1	Proposta longitudinal de valor	18
2.2	Principais fases de negociação automática, adaptado de (Fernando Lopes, Wooldridge e Novais 2008) (tradução livre do autor).	26
3.1	Exemplo de ações possíveis.	50
4.1	Visão geral do <i>dataset</i>	84
4.2	Grupos dos <i>players</i>	86
4.3	Preço médio por contexto.	89
4.4	Similaridade entre contextos.	90
4.5	Número de ações possíveis ao negociar diferentes volumes de energia com diferentes números de oponentes.	90
4.6	Cenário do caso de estudo.	91
4.7	Possíveis oponentes.	92
4.8	Cenários / Métodos de previsão.	92
4.9	Reputação final dos possíveis oponentes.	97
4.10	Ação recomendada ao aplicar teoria de jogos e método de decisão Pessimista, para diferentes níveis de risco.	98
4.11	Ação recomendada ao aplicar teoria de jogos e método de decisão Otimista, para diferentes níveis de risco.	99
4.12	Configuração do método de otimização.	100
4.13	Ação recomendada ao aplicar otimização e método de decisão Pessimista, para diferentes níveis de risco.	101
4.14	Ação recomendada ao aplicar otimização e método de decisão Otimista, para diferentes níveis de risco.	103
4.15	Resultados de aprendizagem do AAR Superior para cada contexto de cada player.	105
4.16	Resultados de aprendizagem do AAR Superior para cada contexto.	106
4.17	Resultados de aprendizagem do AAR Q-Learning para cada contexto de cada player.	108
4.18	Continuação: Resultados de aprendizagem do AAR Q-Learning para cada contexto de cada player.	109
4.19	Resultados de aprendizagem do AAR Q-Learning para cada contexto.	109
4.20	Cenário mais provável para cada <i>player</i> para o contexto 3.	111
4.21	Ação recomendada ao aplicar teoria de jogos e método de decisão Mais Provável, para diferentes níveis de risco.	112
4.22	Cenário do caso de estudo.	114
4.23	Estratégias de negociação.	114
4.24	Contra-estratégias dos grupos de estratégias.	115
4.25	Perfil de negociação das estratégias na compra de energia.	116
4.26	Estratégias do oponente nos diferentes contextos.	119

4.27 Resultados de negociação com *Player 1* nos diferentes contextos. 120

Lista de Acrónimos

AAR	Algoritmo de Aprendizagem por Reforço.
AHP	Analitic Hierarchy Process.
ALBidS	Adaptive Learning strategic Bidding System.
AMES	Agent-based Modelling of Electricity Systems.
DAO	Data Access Object.
EMCAS	Electricity Market Complex Adaptive System.
FFE	Fuzzy Front End.
GENIUS	General Environment for Negotiation with Intelligent Multi-Purpose Usage Simulation.
I&D	Investigação e Desenvolvimento.
IA	Inteligência Artificial.
IAD	Inteligência Artificial Distribuída.
JADE	Java Agent DEvelopment Framework.
MAN-REM	Multi-Agent Negotiation and Risk Management in Electricity Markets.
MASCEM	Multi-Agent Simulator for Competitive Electricity Markets.
MEE	Mercados de Energia Elétrica.
MSV	Máquinas de Suporte Vetorial.
NCD	New Concept Development.
NPD	New Product Development.
PSO	Particle Swarm Optimization.
RDP	Resolução Distribuída de Problemas.
RNA	Redes Neurais Artificiais.
SEPIA	Simulator for Electric Power Industry Agents.
SGBD	Sistema de Gestão de Base de Dados.
SMA	Sistemas Multi-Agente.
SREMS	Short-Medium Run Electricity Market Simulator.

Capítulo 1

Introdução

1.1 Motivação

Nas últimas décadas, os Mercados de Energia Elétrica (MEE) sofreram inúmeras mudanças de forma a dar resposta às necessidades da sociedade, enfrentando vários desafios. Um dos principais foi a profunda reestruturação que o setor sofreu com a sua liberalização, aumentando a sua competitividade e consequentemente a sua complexidade (Kaur et al. 2014). No entanto os desafios continuam a surgir e hoje em dia os MEE tentam dar a melhor resposta possível ao crescente uso de energia de fontes renováveis. Para esse efeito, surge a necessidade de alargar os mercados a participantes de menores dimensões, o que tem levado à necessidade de integração de mercados, aumentando a sua abrangência.

O aumento da complexidade dos MEE e a sua constante evolução, que os torna cada vez mais imprevisíveis, tem um grande impacto no processo de tomada de decisão das entidades participantes. A sua capacidade de adaptação às mudanças está dependente da análise do seu comportamento no mercado, e identificação das melhores estratégias a seguir (Sioshansi 2013). Para esse efeito, as entidades envolvidas necessitam de ferramentas que lhes permitam compreender os diferentes mecanismos de mercado e interações entre as diversas entidades.

Os *players* têm interesse em adaptar o seu comportamento de forma a maximizar os seus lucros enquanto que os operadores de mercado podem tirar grande partido de um ambiente controlado onde possam testar alterações ao atual funcionamento dos mercados. Para este efeito, tem havido uma crescente adoção de ferramentas de simulação com o objetivo de modelar os diversos mecanismos de mercado, as entidades nele envolvidas e as suas interações. O uso dessas ferramentas permite analisar os mercados em detalhe e verificar o impacto de cada alteração ao mesmo, seja ao nível das regras, das interações entre as entidades, ou diferentes estratégias por parte de cada entidade simulada. Tendo em conta o número de entidades envolvidas nos mercados, as complexas interações entre elas, as suas diferentes estratégias, tem sido recorrente o uso de sistemas multi-agente. Alguns dos simuladores com maior impacto neste setor são: Agent-based Modelling of Electricity Systems (AMES) (Li e Tesfatsion 2009), Electricity Market Complex Adaptive System (EMCAS) (Koritarov 2004) e Multi-Agent Simulator for Competitive Electricity Markets (MASCEM) (Isabel Praça et al. 2003; Gabriel Santos et al. 2016).

Apesar de provarem a sua grande utilidade no estudo dos MEE, foi identificada uma limitação comum aos principais simuladores deste meio: a falta de capacidade de aprendizagem adaptativa de forma a tornar o apoio às entidades de mercado mais eficaz. As ferramentas existentes eram, até então, incapazes de permitir aos *players* dos mercados otimizarem os

seus lucros. Perante a limitação identificada, foi desenvolvido o sistema Adaptive Learning strategic Bidding System (ALBidS) (Tiago Pinto, Vale, T. M. Sousa et al. 2014) com o intuito de oferecer essas capacidades às ferramentas que as pretendam adotar. O potencial desta ferramenta foi confirmado pela integração com o simulador MASCEM, provando a sua fácil integração e capacidade de otimização dos lucros dos *players*.

O surgimento do ALBidS juntamente com as ferramentas de simulação já existentes, tornaram possível um estudo dos mercados cada vez mais completo. No entanto as soluções atuais ainda têm uma grande margem de progresso. Ao analisar as mesmas é possível verificar que apenas os modelos de mercado baseados em leilão são profundamente explorados, enquanto que os modelos baseados em contratos bilaterais são representados de forma menos aprofundada. No entanto estes modelos têm um grande impacto no setor e a sua sub-exploração tem impacto na qualidade dos estudos de mercado. Para além disso, os *players* que realizam negociações bilaterais não têm o mesmo apoio no que diz respeito à otimização do seu lucro, uma vez que o sistema ALBidS é apenas focado nos modelos baseados em leilão.

De forma a dar resposta à limitação identificada, surge a necessidade de desenvolvimento de uma ferramenta de apoio aos negociadores de contratos bilaterais nos MEE. Para esse efeito, é importante fornecer-lhes uma capacidade de aprendizagem adaptativa que lhes permita otimizar os seus lucros, através da constante análise do desempenho nas negociações, tendo em conta os diferentes perfis de negociação dos oponentes em diferentes contextos.

O estabelecimento de contratos bilaterais, nos MEE, segue um processo de negociação semelhante a outros domínios. Um estudo aprofundado sobre aprendizagem automática (Fernando Lopes, Wooldridge e Novais 2008) demonstra isso mesmo. No artigo, são enumeradas as principais fases de negociação: Preliminares, Pré-negociação, Negociação e Re-negociação. No domínio em questão, há especial interesse em oferecer apoio na fase de pré-negociação (incluindo a fase preliminar), quando o *player* se prepara para a negociação em si, e negociação, recomendando-lhe a melhor estratégia a seguir em cada momento. A última fase não é considerada dado que os contratos estabelecidos são definitivos e não podem ser renegociados. Fernando Lopes, Wooldridge e Novais 2008 identifica várias limitações nos principais modelos de negociação automatizada existentes, onde esta dissertação pode dar um grande contributo, independentemente do seu foco nos MEE.

1.2 Objetivos

Esta dissertação tem o propósito de desenvolver um sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais em MEE. O sistema a desenvolver deve fornecer uma capacidade de aprendizagem adaptativa que permita aos *players* otimizarem o seu lucro na negociação de contratos bilaterais. Para esse fim, pretende-se oferecer apoio à decisão nas duas fases que constituem essas negociações: pré-negociação e negociação.

Na fase de pré-negociação o sistema deve permitir ao *player* apoiado a fácil seleção do(s) melhor(es) oponente(s) com quem negociar, de forma a otimizar o seu lucro, tendo em conta os seus objetivos. A seleção do(s) melhor(es) oponente(s) resulta da determinação da melhor distribuição possível da quantidade total a negociar, pelos vários oponentes possíveis, que potencie o maior lucro. Para esse efeito é necessária a geração de um cenário, ou seja, determinação do preço esperado para cada oponente para as várias quantidades de energia

elétrica, no contexto em que a negociação irá decorrer. O contexto da negociação deve ser identificado, uma vez que diferentes contextos podem implicar diferentes comportamentos dos possíveis oponentes. Para além disso, vários cenários devem ser considerados de forma a aumentar o apoio ao *player*, preparando-o para várias possibilidades. Perante os vários cenários, é importante garantir ao *player* diferentes métodos de decisão, permitindo-lhe adotar diferentes estratégias consoante os seus objetivos. Contudo, é também pretendido disponibilizar uma gestão de risco, permitindo ao *player* suportado especificar o impacto da reputação de cada oponente na recomendação final. Para esse efeito, o sistema deve calcular a reputação de cada oponente, tendo em conta a opinião do *player* assim como de outros *players*, e permitir-lhe gerir os pesos de cada componente que determina a reputação de um oponente.

Na fase de negociação, é necessário auxiliar o *player* apoiado, indicando-lhe a melhor estratégia a seguir para cada oferta e contra-oferta, de forma a maximizar o resultado da negociação. Para esse efeito, o sistema deverá disponibilizar várias estratégias de negociação e ir atualizando a relevância de cada uma, quando aplicada a um determinado oponente, consoante o resultado obtido. A estratégia recomendada será sempre a estratégia com melhor pontuação. A avaliação de cada estratégia deverá ser realizada por diferentes métodos, e também eles deverão ser avaliados, de forma a perceber, em cada momento, qual é o método mais apropriado. Para além de considerar a informação adquirida pelo *player* apoiado, ao longo das suas negociações, também é importante ter em conta a informação disponibilizada por outros *players*. No entanto, essa informação deverá ter uma medida de credibilidade associada, tendo em conta que o *player* poderá estar a passar uma informação incorreta, seja por estratégia ou falta de conhecimento. Ao ter acesso à experiência do *player* apoiado e de outros *players*, é também interessante ter em conta a informação de *players* com o mesmo perfil de negociação do oponente em questão, assim como a informação geral de todos os *players*. Cada uma destas fontes de informação deverá ter o seu peso ajustado ao impacto que as mesmas têm nos resultados do *player* apoiado. Assim como na fase de pré-negociação, é importante considerar informação relativa ao mesmo contexto em que a negociação está a decorrer. Para esse efeito é utilizado o mesmo módulo de identificação de contexto.

Em suma, o sistema a desenvolver deverá cumprir os seguintes objetivos:

1. Identificação da melhor distribuição da quantidade total de energia elétrica a transacionar, pelos oponentes possíveis, de forma a otimizar o lucro do *player*, consoante os seus objetivos;
 - (a) Determinação do contexto da negociação
 - (b) Análise das distribuições possíveis
 - i. Análise de todas distribuições possíveis
 - ii. Métodos alternativos que permitam balancear o tempo de execução com a qualidade dos resultados
 - (c) Geração de vários cenários alternativos para o contexto da negociação
 - i. Vários métodos de geração de cenários
 - ii. Avaliação do realismo de cada método de geração de cenários para cada contexto para cada oponente

- (d) Gestão de risco, permitindo ao *player* apoiado definir o impacto da reputação de cada oponente na seleção da melhor distribuição
 - i. Cálculo da reputação de cada oponente tendo em conta as preferências do *player* apoiado
 - (e) Disponibilização de vários métodos de decisão
 - i. Pessimista
 - ii. Otimista
 - iii. Mais provável
2. Acompanhamento da negociação entre o *player* apoiado e um determinado oponente, indicando a melhor estratégia a seguir, em cada momento da negociação;
- (a) Determinação do contexto da negociação
 - (b) Determinação do perfil de negociação do oponente
 - (c) Disponibilização de várias estratégias de negociação
 - (d) Avaliação do resultado da utilização de cada estratégia para cada oponente
 - i. Vários métodos de avaliação
 - ii. Identificação do melhor método de avaliação, em cada momento, consoante os resultados das negociações
 - (e) Identificação da melhor estratégia a utilizar em cada momento ao analisar:
 - i. Experiência em negociações com o oponente
 - ii. Experiência em negociações com *players* com perfil semelhante
 - iii. Experiência geral em negociações com todos os *players*
 - (f) Consideração da experiência de outros *players*
 - i. Medida de credibilidade de cada *player*
 - (g) Atualização do peso de cada fonte de informação na seleção da estratégia a recomendar, conforme os resultados obtidos
 - i. Consideração de diferentes técnicas de atribuição de pesos
3. Simulação e validação utilizando dados reais

1.3 Contribuições

No âmbito desta dissertação, foram publicados e apresentados 9 artigos científicos:

- Francisco Silva, Brígida Teixeira, Tiago Pinto, Isabel Praça, Goreti Marreiros e Zita Vale. (2017). Decision Support System for the Negotiation of Bilateral Contracts in Electricity Markets. Em: Ambient Intelligence – Software and Applications – 8th International Symposium on Ambient Intelligence (ISAml 2017). Ed. por Juan F. De Paz et al. Cham: Springer International Publishing, pp. 159–166. isbn: 978-3-319-61118-1.

- Francisco Silva, Tiago Pinto, Isabel Praça e Zita Vale. (2018). Decision Support System for the Negotiation of Bilateral Contracts in Electricity Markets. Em: Trends in Cyber-Physical Multi-Agent Systems. The PAAMS Collection - 15th International Conference, PAAMS 2017. Ed. por Fernando De la Prieta et al. Cham: Springer International Publishing, pp. 305–306. isbn: 978-3-319-61578-3.
- Jaime Rodríguez-Fernández, Tiago Pinto, Francisco Silva, Isabel Praça, Zita Vale, Juan Manuel Corchado. Bilateral contract prices estimation using a Q-learning based approach. 2017 IEEE Symposium Series on Computational Intelligence (SSCI), 27 de Novembro a 1 de Dezembro de 2017, Honolulu, USA.
- Francisco Silva, Ricardo Faia, Tiago Pinto, Isabel Praça, Zita Vale. Optimizing Opponents Selection in Bilateral Contracts Negotiation with Particle Swarm. Em: Highlights of Practical Applications of Agents, Multi-Agent Systems, and Complexity: The PAAMS Collection. PAAMS 2018. Communications in Computer and Information Science, vol 887. Springer, Cham.
- Jaime Rodriguez-Fernandez, Tiago Pinto, Francisco Silva, Isabel Praça, Zita Vale, Juan Manuel Corchado. Reputation Computational Model to Support Electricity Market Players Energy Contracts Negotiation. Em: Highlights of Practical Applications of Agents, Multi-Agent Systems, and Complexity: The PAAMS Collection. PAAMS 2018. Communications in Computer and Information Science, vol 887. Springer, Cham.
- Angelo Pinto, Tiago Pinto, Francisco Silva, Isabel Praça, Zita Vale, Juan Manuel Corchado. Automated combination of bilateral energy contracts negotiation tactics. 2018 IEEE Power & Energy Society General Meeting (PESGM), 5 a 10 de Agosto de 2018, Portland, EUA.
- Francisco Silva, Gabriel Santos, Isabel Praça, Zita Vale. A context-based building security alarm through power and sensors analysis. Energy Informatics - 7th DACH+ Conference on Energy Informatics. Oldemburgo, Alemanha, 10 de Outubro de 2018.
- Francisco Silva, Tiago Pinto, Isabel Praça, Zita Vale. Identifying Most Probable Negotiation Scenario in Bilateral Contracts with Reinforcement Learning. WorldCist'19 - 7th World Conference on Information Systems and Technologies. Ilha da Toxa, Espanha, 16 a 19 de Abril de 2019
- Francisco Silva, Tiago Pinto, Isabel Praça, Zita Vale. Demonstration of Decision Support System for Opponents Selection in Electricity Markets Bilateral Negotiations. AAMAS - International Conference on Autonomous Agents and Multiagent Systems. Montreal, Canadá, 13 a 17 de Maio de 2019.

Para além dos artigos de conferência mencionados, também foi aceite e publicado um artigo de revista:

- Jaime Rodriguez-Fernandez, Tiago Pinto, Francisco Silva, Isabel Praça, Zita Vale, Juan Manuel Corchado. Context aware Q-Learning-based model for decision support in the negotiation of energy contracts. International Journal of Electrical Power & Energy Systems (IJEPES), vol. 104, pp. 489-501. DOI: 10.1016/j.ijepes.2018.06.050

As publicações atuais apenas cobrem uma pequena parte do sistema proposto, pelo que se perspetiva um número bastante superior de publicações, resultantes do trabalho desenvolvido nesta dissertação.

1.4 Estrutura do Documento

Este documento contém quatro capítulos. Após este capítulo introdutório, o Capítulo 2 descreve a evolução dos MEE ao longo das últimas décadas, identificando as suas consequências para as entidades envolvidas. Na análise aos MEE são também descritos os principais modelos reguladores, com foco no modelo de contratos bilaterais. Após a análise dos MEE, é apresentada a análise de valor de negócio do produto proposto nesta dissertação, detalhando o processo de inovação, o valor para o cliente, o modelo de negócio, a rede de valor e aplicabilidade do método Analytic Hierarchy Process (AHP) no processo de identificação de valor. Tendo em conta o resultado da análise de valor, são apresentados conceitos essenciais ao desenvolvimento de uma solução para colmatar a necessidade identificada: sistemas multi-agente, uma solução recorrente para a simulação de MEE; negociação automática, importante para a compreensão e implementação do processo de negociação em si, através da análise das suas principais fases e componentes de cada fase; e aprendizagem automática, essencial para dotar os agentes de capacidade de aprendizagem. A análise dos principais conceitos é sucedida pelo levantamento das principais soluções para os MEE em geral e da negociação de contratos bilaterais em particular.

O Capítulo 3 apresenta a solução proposta para colmatar as necessidades identificadas no capítulo anterior. Para esse fim é apresentado o conceito definido de sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais em MEE. A explicação do conceito é separado pelas duas fases de negociação suportadas pelo sistema: pré-negociação e negociação. Uma vez que o funcionamento do sistema proposto tem uma grande dependência da sua análise de dados e geração de novos dados, é apresentado o modelo de dados da base de dados a implementar. Por último é apresentado o Sistemas Multi-Agente (SMA) a desenvolver, identificando os agentes que o constituem e as principais interações entre eles.

No Capítulo 4, são apresentados os casos de estudo que permitem avaliar o funcionamento do sistema proposto, de forma a identificar se foram cumpridos os objetivos propostos.

Por último, no Capítulo 5 são apresentadas as conclusões a retirar do trabalho desenvolvido assim como a perspectiva de trabalho futuro.

Capítulo 2

Contexto e Estado de Arte

Os MEE têm aumentado consideravelmente a complexidade do seu funcionamento ao longo das últimas décadas. O maior impacto foi verificado aquando da liberalização do setor (Kaur et al. 2014). O grande aumento da competitividade do setor tornou-o mais complexo, o que dificultou a participação das várias entidades envolvidas. Essas entidades começaram a precisar de auxílio no estudo do setor, de forma a compreender como devem proceder e quais as melhores estratégias a seguir (Sioshansi 2013).

O presente capítulo pretende dar resposta a várias questões, tais como: qual é o valor do produto a desenvolver nesta dissertação para quem o adquirir; Como funcionam os MEE e quais os seus principais modelos; como funcionam as negociações de contratos bilaterais em MEE; o porquê da simulação multi-agente ser a principal abordagem para o estudo de MEE; que ferramentas de simulação multi-agente existem para o estudo de MEE; quais dessas ferramentas suportam o modelo de contratos bilaterais; que ferramentas fora do domínio dos MEE poderiam ser consideradas; quais as principais metodologias de negociação de contratos de energia elétrica; quais as principais abordagens à negociação entre agentes; como dotar os agentes de capacidade de aprendizagem.

Para este propósito, após a introdução deste capítulo, é apresentado o funcionamento dos MEE, com foco nos seus modelos reguladores, incluindo a negociação de contratos bilaterais. Após a análise aos MEE, surge a análise de valor de negócio do produto a desenvolver nesta dissertação, apresentando o seu valor para o cliente, o modelo de negócio associado, a sua rede de valor e aplicabilidade do método AHP no processo de identificação de valor. A secção seguinte, Aprendizagem e Negociação em Sistemas Multi-Agente, apresenta os conceitos essenciais à compreensão do funcionamento dos sistemas apresentados posteriormente. Os principais temas são os sistemas multi-agente, frequentemente aplicados neste contexto; negociação automática, essencial nos sistemas que suportam negociação entre agentes; e por último, o conceito de aprendizado de máquina, importante na aprendizagem dos agentes. O capítulo termina com uma análise aos sistemas de apoio à decisão para os MEE, abordando as soluções existentes para o estudo de MEE, com foco nas ferramentas que suportam negociação de contratos bilaterais, assim como as principais metodologias utilizadas.

2.1 Mercados de Energia Elétrica

Os MEE surgiram após uma profunda reestruturação do setor elétrico, com o intuito de aumentar a competitividade no setor e consequentemente apresentar um melhor serviço aos consumidores de energia (Kaur et al. 2014). O seu funcionamento requer o envolvimento de várias entidades como os Compradores e Vendedores de energia, o Operador de Mercado

(responsável por definir o preço de mercado e consequentemente validar quais as ofertas de compra e venda aceites em cada período de negociação), e o Operador de Sistema (responsável pela gestão da rede de transmissão e respetivas restrições técnicas). Essas entidades têm diversas interações entre elas, que se podem tornar bastante complexas. O sucesso dos MEE depende de uma operação eficiente do mercado, o que requer a existência de regras complexas e regulamentos que os salvaguardem. No entanto, o meio está em constante evolução, o que envolve uma frequente atualização das suas regras e entidades envolvidas (Ilic, Galiana e Fink 2013). Surgem novas entidades como o Agregador, que permite a vários *players* de menor dimensão unirem-se para poderem competir com *players* maiores. Para além disso, surgem novas formas de participar através da introdução de recursos energéticos distribuídos (introdução de pequenas fontes de energia, instaladas perto do consumidor para dar resposta à sua necessidade regular) assim como a evolução do papel do consumidor, deixando de apenas consumir mas passando também a ser capaz de fornecer energia à rede (Kubli, Loock e Wüstenhagen 2018; Quadri, Bhowmick e Joshi 2018).

Os fatores externos aos MEE também lhes apresentam grandes desafios. Prova disso é a necessidade mundial de aumentar o uso de energia de fontes renováveis, como forma de reduzir a emissão de gases com efeito de estufa. Um exemplo disso são as metas definidas pela União Europeia, que tem o ambicioso objetivo de reduzir a emissão de gases em 80% em 2050 (Commission 2018c), comparativamente com os níveis apresentados em 1990. Para chegar a esse objetivo, foram definidas três metas intermédias: aumento da contribuição das fontes de energia renovável no consumo total da Europa para 20%, em 2020 (Commission 2018a) e 27% em 2030 (Commission 2018b). Os últimos resultados demonstram que a União Europeia está no rumo correto para atingir os seus objetivos, ao dobrar a contribuição das fontes de energia renováveis de 8.5% em 2004 para 17% em 2016 (Commission 2018d).

O grande aumento de fontes de energia renovável nos MEE adiciona-lhes complexidade e imprevisibilidade uma vez que parte dessas fontes são difíceis de prever, como é o caso das energias eólica e solar. Contudo, estas fontes de energia têm um papel muito importante na sustentabilidade do crescimento dos MEE (Fernando Lopes e Coelho 2018).

Desde cedo que o estudo dos MEE se tornou muito importante, devido às interações complexas entre as suas diversas entidades, assim como as constantes mudanças nas suas regras e surgimento de novas entidades. No entanto, a importância do estudo dos MEE, para as entidades envolvidas, não para de aumentar devido ao grande aumento do uso de fontes de energia renovável, que torna este meio cada vez mais complexo e imprevisível. O estudo dos MEE pode ter diferentes finalidades consoante a entidade. Os *players* pretendem compreender melhor o funcionamento dos mercados, adaptando-se às suas mudanças, e tentando maximizar o seu lucro. Por outro lado, os reguladores de mercado pretendem garantir o correto funcionamento dos mercados, procurando melhorias e preparando-se para alterações futuras. O papel dos reguladores é de elevada responsabilidade uma vez que uma falha no sistema energético pode dar origem a problemas sérios como foi o caso de alguns apagões ocorridos no passado (por exemplo o apagão nos Estados Unidos em 14 de agosto de 2003).

Na secção seguinte são apresentados os principais modelos reguladores dos MEE.

2.1.1 Modelos Reguladores

Geralmente, nos MEE, os *players* podem participar em quatro tipos de mercados: Mercado de Bolsa, Mercado Complexo, Contratos Bilaterais e Mercado de Ajustes.

O Mercado de Bolsa (Klemperer 1999; Song e Amelin 2018) é um mercado diário com o objetivo de negociar energia elétrica para os períodos de negociação do dia seguinte. O número de períodos pode ser de 24 (um por cada hora) ou de 48 (um por cada meia-hora) (OMEL 2018). Este tipo de mercado pode ser Simétrico, o mais comum, ou Assimétrico, dependendo de como as ofertas são criadas e validadas. No tipo Simétrico, para cada um dos períodos, os *players* definem a quantidade de energia elétrica que pretendem transacionar e o preço limite (preço máximo no caso de compra e mínimo no caso de venda). O Operador de Mercado ordena as ofertas, as de compra de-crescentemente e as de venda crescentemente, e aceita as ofertas até as curvas de compra e venda se cruzarem (ver Figura 2.1). O preço de mercado é definido pelo ponto onde as linhas se cruzam e só são aceites as ofertas de compra acima desse preço e as ofertas de venda abaixo. No tipo Assimétrico, só são definidas ofertas de venda. Os compradores apenas indicam uma estimativa da quantidade a comprar, sendo obrigados a pagar o preço definido no mercado. O Operador de Mercado aceita as ofertas de venda necessárias para satisfazer a procura, por ordem crescente do seu preço. O preço de mercado é definido pelo preço da última oferta de venda aceite (ver Figura 2.2).

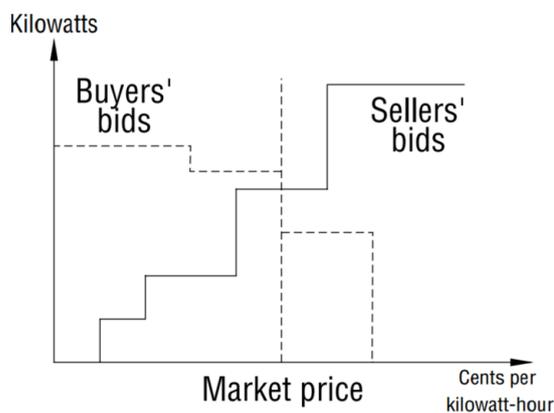


Figura 2.1: Mercado Simétrico (Isabel Praça et al. 2003).

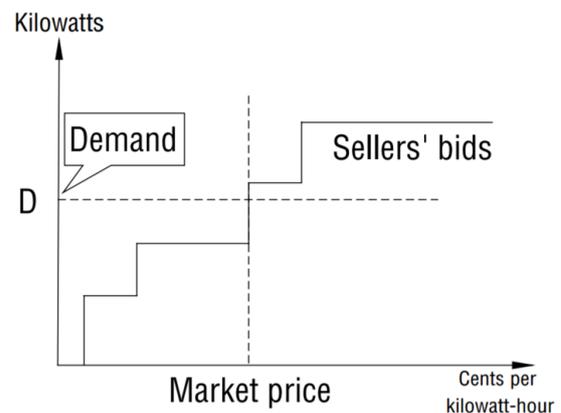


Figura 2.2: Mercado Assimétrico (Isabel Praça et al. 2003).

O Mercado Complexo (G. Santos, T. Pinto et al. 2011) é idêntico ao Mercado de Bolsa com a diferença que este permite aos vendedores definirem restrições, protegendo-os de negociações indesejadas. Os vendedores podem indicar pelo menos uma das quatro restrições possíveis: Indivisibilidade, Gradiente de Carga, Ingressos Mínimos e Paragem Programada. A Indivisibilidade permite definir um valor mínimo de funcionamento para a primeira fração de cada período. O Gradiente de Carga garante a proteção de mudanças abruptas de produção entre períodos, através da definição da diferença máxima entre a potência inicial e final, entre períodos. A restrição dos Ingressos Mínimos permite aos vendedores definirem o lucro mínimo desejado para se manterem em mercado. Esse valor resulta da soma de uma quantidade fixa com uma remuneração variável por cada kWh transacionado. Por último, a Paragem Programada, permite aos vendedores que se retirem de mercado, devido à insatisfação da condição de Ingressos Mínimos, realizarem uma paragem programada no dia seguinte, num máximo de três horas, evitando uma paragem abrupta entre o dia da negociação e o dia seguinte.

O Mercado de Ajustes (Jie, Tsuji e Uchida 2017), funciona como um complemento aos restantes mercados, permitindo aos *players* que neles participaram, fazer pequenos ajustes

face a valores imprevistos de consumo/produção. A participação neste mercado é voluntária e os *players* podem mudar de posição, ou seja, compradores podem apresentar ofertas de venda e vendedores podem apresentar ofertas de compra, consoante as suas necessidades energéticas. Neste mercado também podem ser definidas condições complexas, como no Mercado Complexo, com a particularidade das mesmas não serem exclusivas a vendedores, alargando a sua disponibilidade aos compradores.

Por último, o Mercado baseado em Contratos Bilaterais tem um funcionamento bastante distinto dos restantes, uma vez que os *players* negociam diretamente entre si. Desta forma, os *players* têm um maior controlo do lucro, espaço e tempo associados às transações. Este tipo de mercado é analisado em detalhe na secção 2.1.2.

2.1.2 Contratos Bilaterais

Os contratos bilaterais, no âmbito dos MEE, são contratos estabelecidos entre duas entidades, um comprador e um vendedor, para a transação de energia entre ambos, sem o envolvimento de uma terceira entidade. A transação é normalmente realizada várias semanas ou meses após a realização do contrato (Algarvio e Fernando Lopes 2014), e habitualmente tem as seguintes especificações: datas e horas de início e de fim; preço por hora (€/MWh) e quantidades de energia (MW) variáveis ao longo do contrato; e por último um intervalo de horas relativo à entrega do contrato. Os *players* podem recorrer a três formas distintas de efetuar transações bilaterais (Kirschen e Strbac 2004):

1. Contratos de longo prazo personalizados – Contratos flexíveis dada a negociação privada entre ambas as partes de forma a atingirem os seus objetivos. Este tipo de contratos costuma envolver uma negociação de grandes quantidades de energia por grandes períodos de tempo, de forma a compensar os altos custos de negociação dos mesmos.
2. Negociação "em balcão" – Contrariamente ao tipo de transação anterior, as quantidades de energia negociadas são pequenas e seguem um perfil standard, onde está definido a quantidade de energia que deve ser negociada em diferentes alturas do dia e da semana. Desta forma, este tipo de transação tem as grandes vantagens de permitir aos *players* efetuar transações de baixo custo e facilitar-lhes a gestão das suas necessidades quando têm datas de entrega próximas.
3. Negociação eletrónica – O tipo de transação eletrónica permite aos *players* recorrerem a um mercado virtual para divulgarem as suas ofertas de forma anónima. As suas ofertas estarão disponíveis no mercado até que as mesmas sejam satisfeitas por uma oferta compatível a um preço igual ou melhor do que o inicialmente estabelecido. As ofertas podem ser retiradas pelo seu autor ou quando o mercado encerra para esse período. Os minutos e segundos próximos ao encerramento do mercado são caracterizados por uma grande atividade de negociação dada a necessidade de geradores e retalhistas ajustarem a sua posição antes do período de entrega.

No que diz respeito ao contrato, existem quatro tipos de contratos bilaterais (Algarvio e Fernando Lopes 2014):

1. Contratos a Prazo – contratos de troca de energia entre um comprador e um vendedor em que se comprometem a trocar uma determinada quantia, numa data futura, pelo preço negociado no momento. Este tipo de negociação tem uma grande incerteza

envolvida atendendo a que no momento acordado para troca, o preço acordado poderá ser inferior ou superior ao valor atual da energia. Por exemplo, um vendedor poderá ter um lucro superior ao previsto ou efetuar uma venda com um preço abaixo do pretendido. No entanto, como este tipo de contratos são privados, só dizem respeito às duas entidades envolvidas, os mesmos podem cancelar o contrato por mútuo acordo.

2. Contratos Futuros – contratos com o mesmo funcionamento dos contratos a prazo com a exceção de serem geridos por uma terceira entidade responsável por garantir o cumprimento do acordo. Desta forma, contrariamente aos contratos a prazo, é muito improvável conseguir o cancelamento de um acordo. Este tipo de contratos também são caracterizados por permitirem que no prazo de troca acordado, a troca seja realizada de forma inversa. Isto é, a troca é realizada na direção oposta.
3. Contratos de Opção – A definição do contrato é igual aos contratos a prazo e futuros com a diferença que as duas entidades apenas garantem uma opção de compra/venda. A troca é realizada se no prazo estipulado os dois lados pretenderem exercer a sua opção de troca. Assim como os contratos futuros, as duas entidades podem trocar de papéis, invertendo o sentido da troca.
4. Contratos de Diferença – contratos que permitem às duas entidades envolvidas protegerem-se da alteração de preço da energia entre a data de estabelecimento do acordo e a data acordada de troca. Ou seja, se na data de troca o preço for superior ao acordado, o vendedor paga ao comprador a diferença enquanto que se o preço for inferior acontece o inverso, o comprador compensa o vendedor com a diferença.

Este tipo de negociação permite aos *players* dos MEE controlar o preço pelo qual irão transacionar energia (à exceção dos Contratos de Diferença), contrariamente ao que acontece nos mercados spot, onde o preço de energia é muito variável conforme as propostas de todos os *players* envolvidos. Por outro lado, ao estabelecerem um Contrato a Prazo ou Contrato Futuro, os *players* estão a comprometer-se em transacionar energia por um determinado preço num momento futuro e, no momento da troca, o preço inicialmente proposto poderá favorecer uma das partes e consequentemente desfavorecer a outra, quando comparado com o preço praticado nos outros tipos de mercado. Ao efetuar uma transação a um preço inferior ao praticado pelos seus concorrentes, um *player*, para além do prejuízo que obtém, perde poder competitivo para os seus concorrentes. Uma forma de evitar esse risco passa por estabelecer Contratos de Opção ou Contratos de Diferença conforme visto anteriormente. O primeiro permite ao *player* não exercer a opção de troca e o segundo permite garantir que a transação é realizada ao preço de mercado. No entanto a primeira opção também tem o risco de não dar garantias ao *player* que a outra parte irá exercer a sua opção de troca e a segunda opção não permite obter melhores preços que os de mercado. Desta forma é possível perceber o risco associado à negociação de contratos bilaterais e a necessidade que os *players* têm de ferramentas que lhes ajudem a reduzir esse risco e até permitir otimizar os seus lucros.

Após a análise dos MEE, com especial atenção ao modelo de mercado baseado em contratos bilaterais, é possível realizar uma análise de valor de negócio do produto a desenvolver na presente dissertação.

2.2 Análise de Valor de Negócio

O processo de inovação pode ser dividido em três áreas: *Fuzzy Front End (FFE)* (Linha da Frente de Inovação), o processo *New Product Development (NPD)* (Desenvolvimento de Novo Produto) e a comercialização (Koen et al. 2002). A primeira área é geralmente considerada como uma das grandes oportunidades de melhoria do processo geral de inovação. Isso deve-se, em grande parte, à falta de exploração desta área na literatura, quando comparado com as restantes áreas. Para além disso, não é possível adaptar a investigação realizada na área de NPD uma vez que esta área segue um processo formal e estruturado, sendo o oposto do processo de FFE. Para além disso, a área de FFE tem o potencial de aumentar o valor, quantidade e probabilidade de se iniciar a área de NPD com conceitos altamente rentáveis.

Perante a dificuldade de identificar as melhores práticas de FFE e comparar diferentes práticas da mesma, Koen et al. 2002 criaram o modelo *New Concept Development (NCD)* com o intuito de aumentar o conhecimento sobre FFE e fornecer uma terminologia comum. A Figura 2.3 apresenta o modelo de relacionamento de construção de NCD.

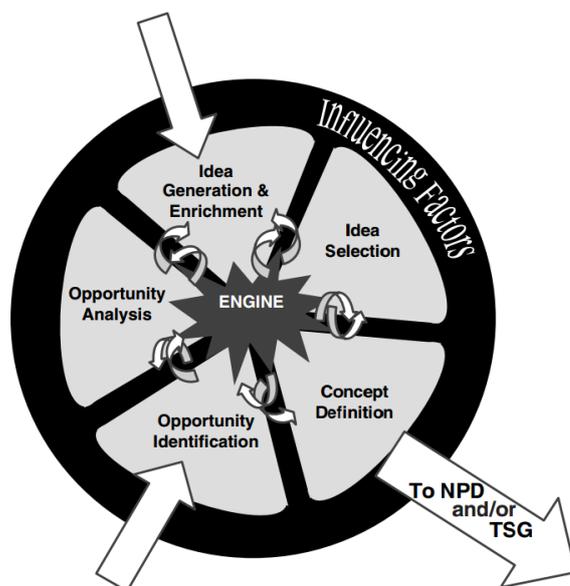


Figura 2.3: Modelo de relacionamento de construção de NCD (Koen et al. 2002).

Conforme se pode observar na Figura 2.3, o modelo NCD é composto por três componentes principais:

- Motor – condutor dos cinco elementos chave controláveis pela organização, resultante da capacidade de liderança, cultura e estratégia de negócio da organização;
- Área interna – define os cinco elementos chave do FFE controláveis pela organização:
 - Identificação da oportunidade;
 - Análise da oportunidade;
 - Geração e enriquecimento de ideias;

- Seleção de ideia;
- Definição de conceito.
- Fatores de influência – capacidades organizacionais; mundo exterior (canais de distribuição, lei, políticas governamentais, clientes, concorrentes, clima político e económico), e o avanço científico (interno e externo) que podem estar envolvidos.

O conceito proposto na presente dissertação é resultante da aplicação do modelo NCD, ao seguir os cinco elementos chave do FFE, analisados em detalhe nas secções seguintes.

2.2.1 Identificação e Análise de Oportunidade

Os MEE estão em constante evolução, sofrendo várias alterações, tornando-se cada vez mais complexos e imprevisíveis (Kaur et al. 2014). As entidades que neles participam necessitam cada vez mais de ferramentas que lhes permitam estudar os mercados, compreendendo-os e procurando melhorar a sua participação nos mesmos (Sioshansi 2013). Ao longo do tempo foram surgindo várias soluções para esse efeito. No entanto, foi verificada uma fraqueza nas mesmas, a sub-exploração do modelo de contratos bilaterais. Enquanto que nos restantes modelos, as entidades envolvidas podem obter um apoio à decisão bastante alargado, no caso das negociações bilaterais, as entidades apenas encontram abordagens simplificadas, continuando a necessitar de um apoio à decisão apropriado. A fraqueza identificada não afeta apenas o estudo do modelo de contratos bilaterais mas também o estudo dos MEE no geral, uma vez que este modelo tem um grande impacto no seu normal funcionamento. Perante esta realidade foi identificada uma oportunidade de inovação.

Numa análise posterior à oportunidade identificada, foram analisadas em detalhe a tendência dos MEE, as soluções existentes, a tecnologia utilizada, o funcionamento do modelo de contratos bilaterais e as técnicas e tecnologia necessária para desenvolver uma solução. Os MEE para além de se terem tornado bastante complexos ao longo dos anos, devido às constantes alterações no seu funcionamento, continuam a apresentar a mesma tendência no presente e para o futuro. O uso de energia de fontes renováveis tem crescido muito nos últimos anos e promete continuar a crescer, tendo em conta as políticas atuais de redução de emissão de gases com efeito de estufa (Commission 2018c). Desta forma, os MEE continuam e vão continuar a precisar de se adaptar de forma a dar resposta a essa tendência. As entidades que neles participam vão continuar a necessitar de ferramentas que lhes permitam estudar o meio e acompanhar as suas mudanças (Sioshansi 2013).

As principais soluções para o estudo de MEE revelam a grande aplicabilidade da simulação para esse fim. Para além disso é também comumente aplicado o conceito de SMA, que aliado ao conceito de simulação permite a modelação das diversas entidades participantes nos MEE e as suas interações (Rouchier 2017; Zhou, Chan e Chow 2007). A capacidade de aprendizagem dos agentes torna-se também um fator muito importante na tentativa de aproximar, o máximo possível, as simulações de uma realidade onde as entidades estão sempre a aprender e a adaptar-se. Esta característica também é fulcral nos sistemas de apoio à decisão para os *players* participantes nos MEE, uma vez que pretendem maximizar os seus ganhos e, para esse fim, necessitam de uma ferramenta capaz de ir mais além na extração de conhecimento acerca do funcionamento dos MEE. Para esse efeito o conceito de *Machine Learning* revela-se especialmente adequado (Foruzan, Scott e J. Lin 2015; Tiago Pinto, Vale, T. M. Sousa et al. 2014; G. Santos, I. Praça et al. 2013).

Para o apoio aos negociadores de contratos bilaterais surge também a necessidade de compreensão do funcionamento do processo de negociação no geral, de forma a perceber o contributo que pode ser fornecido pela solução a desenvolver. Neste âmbito é identificado o processo de negociação automática, especialmente adequado à implementação de agentes de *software* capazes de negociar entre si. Através do acesso a uma revisão do estado de arte dos principais modelos de negociação automática, é possível verificar quais as principais fases de uma negociação (Fernando Lopes, Wooldridge e Novais 2008): Preliminares, Pré-negociação, Negociação e Renegociação. Para cada fase são ainda identificados os seus principais componentes, e quais as lacunas atuais do estado de arte. A análise de oponentes revela-se muito importante em todo o processo de negociação e é verificada uma sub-exploração da mesma na literatura.

Após a análise da oportunidade, são geradas e enriquecidas ideias de como abordar a mesma.

2.2.2 Geração e Enriquecimento de Ideias

Inicialmente é idealizado a criação de um sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais. O objetivo traçado para o sistema consiste no apoio aos *players* que negociam contratos bilaterais, permitindo-lhes otimizar os seus ganhos. Para esse efeito pretende-se apoiar o *player* nas fases de pré-negociação e negociação através da extração de conhecimento sobre os seus oponentes, ao realizar uma análise detalhada dos mesmos.

Apoio à Decisão na Fase de Pré-Negociação

Na fase de pré-negociação, pretende-se apoiar o *player* na seleção dos melhores oponentes com quem negociar, tendo em conta os seus objetivos. Para essa seleção, é importante tentar prever o comportamento de cada oponente possível, estimando os preços esperados para diferentes quantidades de energia, cobrindo as necessidades do *player* apoiado. Essa estimativa poderá ser realizada através de uma técnica de previsão (Gupta e Chitkara 2017). Ao conjunto de preços esperados para cada oponente para cada quantidade de energia é atribuído o nome de cenário. Através do cenário gerado, com a aplicação do conceito de teoria de jogos (Aumann 2017), é possível determinar todas as ações possíveis que o *player* suportado poderia tomar e tentar perceber qual a melhor. Nesse caso, cada ação é uma distribuição possível da quantidade que o *player* pretende transacionar pela lista de oponentes possíveis. Para avaliar as ações é necessário ter em conta a sua utilidade, que pode ser obtida ao quantificar o benefício que o *player* tem ao transacionar as quantidades associadas a cada oponente, pelo seu preço esperado. Ao obter a utilidade de cada ação é possível recomendar ao *player* a ação com o maior valor de utilidade.

No entanto surge a ideia de gerar mais do que um cenário, uma vez que os oponentes poderão ter comportamentos diferentes e, sendo assim, o *player* estará melhor preparado. Para esse efeito pode-se considerar várias técnicas de previsão, cada uma gerando um cenário diferente. Ao considerar vários cenários, surge a necessidade de melhores métodos de decisão do que apenas selecionar a ação com maior utilidade. O *player* poderá pretender tentar obter o melhor negócio possível como também poderá querer preparar-se para o pior e evitar surpresas. Seguindo esse raciocínio seria também interessante conseguir determinar o cenário mais provável, ou seja, a técnica de previsão que se aproxima mais da realidade. O

pior cenário pode ser obtido aplicando o método minimax, ao selecionar a melhor ação do cenário com menor utilidade global (soma da utilidade das suas ações). O melhor cenário possível já está considerado ao selecionar a ação com maior utilidade entre todas as ações de todos os cenários. Em relação ao cenário mais provável surge a ideia de aplicar um Algoritmo de Aprendizagem por Reforço (AAR) (Sutton e Barto 1998), que avalia o desempenho de cada técnica de previsão ao comparar os cenários previstos com os cenários reais. Assim como no caso das técnicas de previsão, a utilização de diferentes AAR também se pode revelar vantajoso, percebendo qual o método que faz uma avaliação mais adequada ao problema em questão. Para esse efeito seria necessário a utilização de um AAR que avalie os AAR utilizados.

Neste ponto da geração de ideias começa-se a ter uma boa versão de apoio à fase de pré-negociação. No entanto, numa segunda análise surge a seguinte questão: *Este tipo de abordagem permite o suporte de diferentes contextos? Os cenários alternativos permitem apoiar o player em diferentes contextos?* As negociações podem ocorrer em diferentes contextos e em cada contexto os oponentes podem ter comportamentos muito distintos. A geração de cenários tem em conta sempre a mesma fonte de dados, sem qualquer noção de contexto. Ou seja, os cenários vão ser sempre gerados tendo em conta todos os contextos presentes na fonte de dados. Neste caso surge a necessidade de identificar o contexto da negociação e filtrar os dados utilizados, considerando apenas dados do mesmo contexto. Desta forma, a aplicação gera cenários alternativos dentro de um determinado contexto. Com esta alteração surge também a necessidade de atualizar o método de avaliação das técnicas de previsão, uma vez que as técnicas podem ter melhores ou piores resultados consoante o tipo de contexto. Assim sendo, interessa mudar a avaliação do AAR para uma avaliação da melhor técnica de previsão para cada contexto.

A ideia principal para o apoio na fase de pré-negociação é bastante enriquecida pela consideração do contexto da negociação. No entanto, numa terceira análise, surge uma nova questão: *Será suficiente selecionar oponentes tendo em conta apenas o lucro esperado? Será que as melhores ofertas possíveis são de confiança?* Desta forma surge a ideia de avaliar a reputação de cada oponente e juntar esse dado no cálculo da utilidade de cada ação, confrontando o benefício económico com a reputação dos oponentes. Perante esta alteração, interessa dar ao utilizar a opção de escolher o risco que está disposto a correr. O risco mínimo apenas consideraria a reputação dos oponentes envolvidos em cada ação, e o risco máximo apenas consideraria o benefício económico. Ao mesmo tempo que se considera o aumento de complexidade do cálculo da utilidade de cada ação, surge uma nova questão: *Quão complexo o sistema se pode tornar ao gerar todas as ações possíveis de diferentes cenários? Será sempre necessário considerar todas as possibilidades?* Perante estas questões, surge a ideia de aplicar um algoritmo de otimização neste problema, procurando obter boas soluções sem percorrer todas as hipóteses (Rustagi 2014). Esse algoritmo de otimização poderia ser de um único objetivo (a otimização do benefício económico) ou de múltiplos objetivos (otimizando tanto o benefício económico como o risco associado). Desta forma, o *player* apoiado teria a hipótese de escolher entre o método de teoria de jogos (que analisa todas as hipóteses) ou um dos métodos de otimização, dependendo do risco desejado. Ainda no tema do desempenho surge a ideia da criação de um componente responsável por medir o tempo de execução de cada AAR e de cada técnica de previsão, permitindo depois ao *player* apoiado fazer um balanço entre desempenho e qualidade de resultados. Ao dar prioridade ao desempenho, o sistema seleciona as técnicas que costumam demorar menos tempo a executar, em troca de um possível sacrifício da qualidade dos resultados.

Ao atingir uma versão enriquecida e sólida da ideia de apoio à decisão na fase de pré-negociação, surge a necessidade de identificar a melhor abordagem à fase que a sucede, a negociação em si.

Apoio à Decisão na Fase de Negociação

Nesta fase de negociação, é identificada a necessidade de apoiar o *player* apoiado na escolha das melhores ofertas e contra-ofertas a apresentar ao seu oponente. Para esse efeito podem ser adicionadas várias estratégias ao sistema e, através de dados históricos do oponente em questão, determinar qual a melhor estratégia a seguir a cada oferta/contra-oferta. Neste momento surgem algumas questões: *Que informação é importante registar? O que acontece quando o player nunca negociou com o player em questão?* Em resposta, é identificada a necessidade de avaliar a qualidade dos resultados de cada estratégia, quando as mesmas são utilizadas, para cada oponente. Desta forma é possível saber num dado momento qual a melhor estratégia a seguir com um determinado oponente, sendo essa a recomendada. Em caso de ser a primeira negociação que o *player* apoiado tem com um determinado oponente, o sistema recomenda uma estratégia aleatória. Para além disso, surge a ideia de também considerar o histórico de negociações com *players* semelhantes ao oponente em questão, assim como todo o histórico de negociações do *player* apoiado. Para esse efeito, cada uma das três fontes identificadas teria de ter um peso associado. Para esse peso surge a ideia de iniciar o sistema atribuindo o mesmo valor a cada fonte e atualizar o seu peso consoante os resultados obtidos, ao utilizar as estratégias recomendadas pelas mesmas. A atribuição de pesos e respetiva atualização pode resultar da aplicação de diferentes técnicas. Numa primeira versão, surge a ideia de aplicar um média ponderada ou uma abordagem de fatores de certeza (Hussain, Bui e H.-M. Kim 2016; Walley 1996). Os diferentes métodos considerados podem ser avaliados, em semelhança ao sucedido na fase de pré-negociação, através da utilização de um AAR.

Apesar dos avanços alcançados, permanece a questão relativa à falta de informação. O *player* apoiado está muito restrito às suas próprias negociações do passado, levando algum tempo para obter um histórico que lhe dê boas garantias. Neste sentido, surge a necessidade de também utilizar informação partilhada por outros *players*. Essa informação pode ter a mesma divisão aplicada à informação do *player* apoiado: histórico de negociações com o oponente em questão, com *players* semelhantes e com todos os *players* no geral. Desta forma é necessária a aplicação do mesmo método de avaliação de cada tipo de fonte. Assim sendo é atribuído um peso a cada tipo de fonte: a informação pessoal e a informação recolhida. Dentro de cada uma dessas fontes, existem as três fontes já identificadas, também elas alvo de uma atribuição de peso e respetiva avaliação.

Por último, surgem ainda duas melhorias à ideia atual, baseadas na experiência adquirida na determinação da melhor ideia para o apoio à pré-negociação: a importância da reputação e dos contextos de negociação. Neste caso, é importante avaliar a credibilidade da informação partilhada por outros *players* (Weng et al. 2010). Esse valor de credibilidade deverá ser atualizado tendo em conta os resultados obtidos ao utilizar as estratégias sugeridas. Em relação aos contextos de negociação, é importante separar a informação disponível pelos diferentes contextos, permitindo identificar a melhor estratégia a utilizar com determinado *player* em determinado contexto.

Após o processo de geração de ideias e respetivo enriquecimento surge a seleção da ideia a seguir e conseqüente definição de conceito.

2.2.3 Seleção de Ideia e Definição de Conceito

O processo de geração de ideias conduzido no âmbito desta dissertação consistiu num processo iterativo de enriquecimento da ideia inicial. Durante o seu enriquecimento surgiram várias alternativas, sendo todas elas consideradas, uma vez que todas podem dar o seu contributo. Através da utilização de algoritmos de AAR, é possível testar diferentes abordagens, aproveitando os contributos de cada uma e permitindo identificar, a todo o momento, qual a mais apropriada. A utilização de várias abordagens é também justificada pela necessidade de balanço entre qualidade dos resultados e tempo de execução.

Da aplicação do modelo NCD, surge o conceito de sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais em MEE, identificando os melhores oponentes com quem negociar e a melhor estratégia a seguir ao longo da negociação com cada um deles.

Uma vez definido o conceito do produto a desenvolver, é analisado o seu valor para o cliente.

2.2.4 Valor para o cliente

O conceito de valor não tem uma definição universalmente aceite. Pelo contrário, ao longo do tempo foram-lhe atribuídas várias definições, tendo em conta a subjetividade do mesmo. O conceito de valor permite identificar a qualidade/benefício de algo segundo determinado ponto de vista ou conjunto de critérios. A grande indefinição em relação ao conceito de valor, advém principalmente da tentativa de especificação de quais os critérios de avaliação de algo, de forma a determinar o seu valor. Por exemplo, um determinado objeto pode ser considerado como tendo um elevado valor num determinado contexto, mas num contexto diferente, o mesmo pode ser visto como algo sem valor. O valor de algo pode ser apresentado de duas formas distintas: um conjunto de benefícios proporcionados pelo mesmo; ou um número que permite comparar o seu valor com o valor de outras coisas, segundo os mesmos critérios.

Segundo Tony Woodall, o valor para o cliente é “qualquer perceção (pessoal e do lado da procura) de vantagem resultante da associação do cliente com uma oferta de uma organização e pode ocorrer como uma redução de sacrifício; presença de benefício (percebido como atributos ou resultados); o resultado de qualquer combinação ponderada de sacrifício e benefícios (determinado e expressado racionalmente ou intuitivamente); ou uma agregação, ao longo do tempo, de qualquer uma ou todas as mencionadas” (Woodall 2003) (tradução livre do autor). Tendo em conta esta definição, é possível compreender que o valor para o cliente consiste na ponderação dos benefícios e sacrifícios que uma determinada oferta tem para o cliente.

O conceito de valor percebido representa a noção que o cliente tem do valor de uma oferta. Como normalmente o cliente não tem conhecimento do custo de produção de um determinado produto, o mesmo faz uma estimativa tendo em conta as características por ele identificadas. Desta forma, não é suficiente a criação de uma oferta que, em teoria, tem muito valor para o cliente, se o mesmo não o conseguir reconhecer.

A proposta de valor, no âmbito desta dissertação, consiste no desenvolvimento de um sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais em MEE, identificando os melhores oponentes com quem negociar e a melhor estratégia a seguir ao longo da negociação com cada um deles.

Na Tabela 2.1 é apresentada a proposta longitudinal de valor do produto a desenvolver.

Tabela 2.1: Proposta longitudinal de valor

	Benefícios	Sacrifícios
Pré Compra	Facilitar seleção de oponentes Considerar vários cenários Adaptar a diferentes contextos Maximizar lucro Prevenir pior cenário Gestão de risco Assistência às negociações Aumentar aprendizagem	Tempo
Compra	Qualidade Flexibilidade Credibilidade Performance Constante Evolução	Preço
Pós Compra	Fácil seleção de oponentes Consideração de vários cenários Adaptação a diferentes contextos Maximização de lucro Prevenção do pior cenário Controlo de risco Negociações assistidas Aprendizagem automática	Introdução de informação
Após Utilização	Satisfação Maior capacidade de negociação e controlo de objetivos	

Conforme se pode verificar na Tabela 2.1, na fase de pré compra, o produto oferece ao cliente os seguintes benefícios: facilitar a seleção de oponentes, determinando automaticamente o(s) oponente(s) com quem o cliente deve negociar e quanta energia transacionar com cada um, de forma a otimizar os seus ganhos; considerar vários cenários, reduzindo o fator surpresa; adaptar a diferentes contextos, utilizando apenas informação relevante para o contexto em que a negociação irá decorrer; maximizar o lucro, através da identificação do(s) oponente(s) que podem maximizar os ganhos do cliente; prevenir o pior cenário, identificando o(s) oponente(s) com quem negociar no caso de ocorrer o pior cenário previsto; gestão de risco, permitindo ao cliente definir o impacto da reputação de cada oponente nas recomendações do sistema; assistência às negociações, apoiando o cliente durante a fase de negociação com cada oponente selecionado, através da recomendação da melhor estratégia a seguir ao longo da negociação; e aumentar aprendizagem, apresentando ao cliente recomendações, num curto espaço de tempo, resultantes de um processo de aprendizagem complexo. Nesta fase o cliente tem o sacrifício do tempo necessário para análise do produto, e tomar a decisão de o adquirir ou não, de acordo com o valor percebido.

Na fase de compra, os benefícios para o cliente são os seguintes: qualidade do produto; flexibilidade de configuração do produto; credibilidade das recomendações, resultantes de

um processo de aprendizagem complexo; performance do produto, dada a sua otimização e possibilidade de balanceamento entre qualidade de resultados e tempo de execução; e constante evolução, uma vez que o produto está constantemente a aprender e a melhorar as suas recomendações. O sacrifício do cliente nesta fase é o preço de aquisição do produto.

Na fase seguinte, após a compra do produto, o cliente começa a usufruir dos benefícios identificados na fase de pré compra: fácil seleção de oponentes; consideração de vários cenários; adaptação a diferentes contextos; maximização de lucro; prevenção do pior cenário; controlo de risco; negociações assistidas; e aprendizagem automática. O único custo inerente a esta fase é a necessidade de introdução de informação no sistema: informação pessoal e informação partilhada por outros *players* acerca da melhor estratégia a seguir com determinado oponente em determinado contexto; opinião pessoal acerca de cada oponente possível, necessária ao cálculo da sua reputação; e cenários de negociação reais. No entanto, à exceção da opinião pessoal acerca de cada oponente, a introdução da restante informação é opcional, uma vez que o produto recolhe informação ao longo da sua utilização, para além da informação que lhe é possível inferir. Contudo, a qualidade do produto assenta na qualidade da informação que o sustenta, sendo necessária uma quantidade mínima de informação para a assegurar.

Por último, após a utilização do produto, o cliente tem o benefício de se sentir satisfeito com a sua utilização assim como o aumento da sua capacidade de negociação e controlo de objetivos.

A análise do valor do produto, para o cliente, é sucedida de uma análise do modelo de negócio do mesmo.

2.2.5 Modelo de Negócio

A Figura 2.4 apresenta o modelo de negócio para o produto proposto nesta dissertação. Os segmentos identificados são os participantes em negociações bilaterais, que tem interesse em melhorar os seus resultados, e os investigadores deste tipo de negociação (Centros de Investigação e Desenvolvimento (I&D), faculdades, e todas as entidades interessadas nesta área de investigação). A relação com os clientes será garantida pela equipa de suporte das empresas que se tornem parceiras deste projeto. Os canais de distribuição serão: publicações e apresentações em conferências, congressos e *workshops*, assim como publicações em revistas científicas (divulgando o produto aos principais investigadores da área); parcerias com empresas de software (aproveitando a sua experiência de distribuição); feiras industriais (com o mesmo intuito das publicações científicas); e redes sociais e meios de comunicação tradicionais (que permitem uma maior divulgação do produto ao público em geral).

A proposta de valor do produto proposto surge sobre a forma de um sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais. O sistema oferece ao cliente a possibilidade de gestão de risco das suas negociações; maximização de lucro; preparação de pior cenário; aprendizagem automática; adaptação a diferentes contextos; fácil seleção de oponentes; negociações assistidas; e consideração de múltiplos cenários (benefícios detalhados na Secção 2.2.4).

Para a concretização da proposta de valor do produto proposto, é necessária a realização de várias atividades chave: apuramento de estado de arte de soluções e tecnologia, de forma a identificar as soluções existentes, as tecnologias mais utilizadas e novas tecnologias apropriadas ao produto em questão; reuniões com entidades envolvidas em MEE, com o

intuito de obter informação adicional, necessária para o design de um produto de qualidade; design da solução, tendo em conta as necessidades dos clientes que não estão a ser atendidas pelas soluções atuais, utilizando as tecnologias mais apropriadas, entre as mais utilizadas e as emergentes; desenvolvimento da solução, seguindo o design concebido fielmente de forma a garantir a qualidade do produto; avaliação da solução, verificando se a mesma cumpre todos os objetivos estabelecidos; e por último, divulgação da solução, dando-a a conhecer aos potenciais clientes. Para a realização destas atividades, são identificados como recursos chave a equipa de I&D, responsável pelas atividades chave; parcerias com empresas de software, especializadas na comercialização e divulgação do produto; e participação em novos projetos de I&D relacionados com o produto proposto. Como parceiros chave, foram identificadas as conferências, importantes para a divulgação do produto proposto; centros de I&D, que assim como as empresas de software são possíveis parceiros de novos projetos de I&D relacionados com o produto proposto e experiência a ele inerente; empresas de software, que para além da parceria em novos projetos, são importantes para a comercialização e divulgação do produto proposto.

No modelo de negócio foram identificados os custos associados à participação em conferências (preço de submissão de artigo, deslocação e participação); custos associados à publicação de artigos científicos; remuneração da equipa de I&D; software e hardware necessários para o desenvolvimento do produto; e por último os custos associados a deslocações para reuniões com entidades envolvidas em MEE. Por outro lado, foram identificadas as seguintes fontes de receita: financiamento de projetos de I&D; citações, trazendo reconhecimento académico para o produto e conseqüente aumento de visibilidade; e a comercialização do produto, através de parcerias com empresas de software.

Parceiros Chave <ul style="list-style-type: none"> • Conferências • Centros de I&D • Empresas de Software • Entidades envolvidas em MEE 	Atividades Chave <ul style="list-style-type: none"> • Apuramento de estado de arte de soluções e tecnologia • Reuniões com entidades envolvidas em MEE • Design da solução • Desenvolvimento da solução • Avaliação da solução • Divulgação da solução 	Proposta de Valor <ul style="list-style-type: none"> • Sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais • Gestão de risco • Maximização de lucro • Preparação de pior cenário • Aprendizagem automática • Adaptação a diferentes contextos • Fácil seleção de oponentes • Negociações assistidas • Consideração de múltiplos cenários 	Relação com o Cliente <ul style="list-style-type: none"> • Equipe de suporte das empresas 	Segmentação de Clientes <ul style="list-style-type: none"> • Participantes em negociações bilaterais • Investigadores de negociações bilaterais
Recursos Chave <ul style="list-style-type: none"> • Equipa I&D • Projetos I&D • Parcerias com empresas de software 		Canais de Distribuição <ul style="list-style-type: none"> • Publicações e apresentações em conferências, congressos e <i>workshops</i> • Publicações em revistas científicas • Parcerias com empresas de software • Feiras industriais • Redes sociais • Meios de comunicação tradicionais 		
Estrutura de Custos <ul style="list-style-type: none"> • Participação em conferências • Publicações de artigos científicos • Equipa de I&D • Software e hardware • Reuniões com entidades envolvidas em MEE 		Fontes de Receita <ul style="list-style-type: none"> • Projetos de investigação • Citações (Reconhecimento científico) • Comercialização do produto 		

Figura 2.4: Modelo canvas.

Após a especificação do modelo de negócio do produto a desenvolver, é analisada em detalhe a rede de valor do mesmo, tendo em conta a sua proposta de valor, os segmentos de clientes envolvidos, os parceiros-chave e as contribuições do produto.

2.2.6 Rede de Valor

Ao estar integrado num ramo de um centro de investigação dedicado ao estudo de sistemas de energia, o sistema proposto adiciona valor nas duas principais áreas de investigação: MEE e redes elétricas inteligentes. Para esse efeito o centro conta com simuladores dessas áreas, cuja adição de um sistema de apoio à decisão para a negociação de contratos bilaterais pode trazer grandes benefícios, expandindo a sua cobertura e aumentando o seu realismo. Para além disso também é verificado valor, no sentido inverso, em que o sistema proposto pode ser testado em diferentes contextos, verificando a sua aplicabilidade aos demais, resultando num maior enriquecimento do mesmo.

Num perspetiva mais alargada, o sistema proposto adiciona valor aos participantes em negociações de contratos bilaterais em MEE, permitindo-lhes otimizar os seus resultados. Para além das entidades participantes, outras entidades interessadas no estudo dos MEE, podem contar com o sistema proposto de forma a aumentar a cobertura e realidade da sua análise às negociações de contratos bilaterais. O sistema proposto pode ser uma mais valia para as ferramentas de simulação de MEE já existentes, uma vez que as mesmas apresentam uma cobertura simplificada desde modelo de negociação.

A ferramenta a desenvolver pode também acrescentar valor à comunidade científica através do conhecimento gerado através do seu uso, criando novas perspetivas de investigação.

No ponto de vista dos conceitos aplicados, o sistema pode acrescentar valor ao apresentar a sua aplicação dos conceitos de SMA, negociação automática e aprendizagem automática, entre outros conceitos matemáticos, à área de negociação de contratos bilaterais em MEE.

Após a análise da rede de valor do produto, é apresentado o algoritmo com um papel importante na análise final do produto desenvolvido, tendo em conta múltiplos critérios.

2.2.7 AHP

O método AHP (Processo de Análise Hierárquica) (Saaty 1990), uma abordagem ao processo de decisão multi-critério em que os seus fatores estão organizados de forma hierárquica e é possível atribuir diferentes graus de importância aos vários critérios.

No âmbito desta dissertação pretende-se aplicar este algoritmo, durante a fase de experimentação e avaliação do sistema proposto, na avaliação do desempenho de cada algoritmo de previsão e estimação que o mesmo disponibiliza. A avaliação será realizada em diferentes níveis de granularidade: qualidade de previsão/estimação para cada contexto, e qualidade de previsão/estimação para cada oponente em cada contexto. Para esse fim são considerados os seguintes critérios: média e desvio padrão do tempo de pré-processamento, média e desvio padrão do tempo de execução, quantidade de dados de treino, e média e desvio padrão do erro de previsão/estimação. Desta forma é possível avaliar os vários algoritmos de previsão e estimação, tendo em conta diferentes perspetivas (rapidez, qualidade de resultados, quantidade de dados de treino ou equilíbrio entre todos critérios).

Após a análise de valor do produto a desenvolver, são analisados os principais conceitos essenciais à sua implementação.

2.3 Aprendizagem e Negociação em Sistemas Multi-Agente

Nesta secção, são apresentados os principais conceitos relacionados com a aplicação de SMA à negociação de contratos bilaterais. Para esse efeito, é realizada uma apresentação do conceito de SMA, seguido de uma análise ao conceito de Negociação Automática (essencial para fornecer um apoio apropriado a este tipo de interação entre agentes), e por último o conceito de *Machine Learning* (em que a sua aplicação aos SMA permite dota-los com a capacidade de aprendizagem).

2.3.1 Sistemas Multi-Agente

Nos anos 80 surgiu um novo ramo de Inteligência Artificial (IA), a Inteligência Artificial Distribuída (IAD). Este ramo surgiu com o propósito de melhorar a resolução de problemas complexos de aprendizagem, planeamento e de tomada de decisão. Para esse feito a IAD conta com vários agentes distribuídos, capazes de processar informação autonomamente, que permite separar o problema em partes inferiores e aproveitar toda a capacidade computacional disponível. O termo agente tem muitas definições associadas atendendo à sua utilização em diversas áreas com diferentes propósitos. Na área de IAD, uma das definições mais populares é a definição básica de agente, apresentada por Wooldridge e Jennings 1995, que define um agente como sendo um *hardware* ou, mais frequentemente, um *software* que usufrui das seguintes propriedades:

- Autonomia – operação sem intervenção externa e controlo do seu estado interno;
- Habilidade social – comunicação com outros agentes ou humanos através de alguma linguagem de agentes;
- Pro-atividade – capacidade de tomar iniciativas de acordo com os seus objetivos individuais, não se limitando a reagir às mudanças no seu ambiente;
- Reatividade – capacidade de reconhecer o ambiente que os rodeia e responder a mudanças que nele ocorrem.

No entanto, ao longo do tempo foram sendo atribuídas mais propriedades (Weiss 1999):

- Agilidade – tirando partido de oportunidades imprevistas;
- Aprendizagem – capacidade de adequar o seu comportamento conforme as experiências do passado;
- Capacidade sensorial – utilização de sensores para recolher informação do seu ambiente envolvente;
- Carácter – comportamento credível e emocional;
- Flexibilidade – capacidade de realizar tarefas que não foram predefinidas;
- Inteligência – capacidade de raciocinar autonomamente, aprender com a sua experiência, e adequar as suas ações conforme os seus objetivos;

- Mobilidade – capacidade de se mover entre computadores;
- Persistência – existência durante grandes períodos de tempo.

A IAD divide-se em duas áreas: SMA e Resolução Distribuída de Problemas (RDP). Os SMA são mais focados nos agentes e na forma como coordenam o seu conhecimento e as suas atividades enquanto os RDP se focam em como o problema é resolvido. No caso dos SMA os agentes já existem à partida, independentemente do problema específico que possa surgir, enquanto que os RDP só concebem os seus agentes após análise do problema a resolver (Yeoh e Yokoo 2012). Ambas as áreas utilizam um conjunto de agentes que interagem entre si de forma a resolver um problema que um único agente não conseguiria.

No âmbito dos MEE, são desenvolvidas soluções que aplicam o conceito de SMA, uma vez que é pretendido resolver um problema em que é essencial a mais fiel representação das diversas entidades envolvidas, com interações complexas entre elas. Os SMA permitem uma boa representação deste meio, dotando as diversas entidades envolvidas com as propriedades acima identificadas. Para o desenvolvimento de SMA, é possível encontrar várias *frameworks*, conforme identificado na secção seguinte.

Frameworks

Em relação às *frameworks* para implementação de SMA, Kravari e Bassiliades 2015 apresentam uma revisão das 24 soluções existentes até à data. Para a avaliação de cada *framework*, os autores consideram os seguintes critérios: propriedades da plataforma (criador, domínio primário, última versão, licença e código aberto), usabilidade (simplicidade, capacidade de aprendizagem, escalabilidade, compatibilidade com padrões e comunicação), capacidade operacional (performance, estabilidade, robustez, linguagens de programação e sistemas operativos), pragmatismo (instalação, suporte ao utilizador, popularidade, maturidade da tecnológica e custo) e gestão de segurança (segurança de ponto a ponto, equidade de recursos e segurança da plataforma).

Ao analisar as várias *framework* identificadas, Kravari e Bassiliades 2015 chegam à conclusão que a *framework* JADE (Bellifemine, Caire e Greenwood 2007) continua a ser a mais popular, ficando muito bem classificada em todos os critérios analisados, com exceção do seu baixo suporte de tecnologias de web semântica. Em suma, a *framework* apresenta as seguinte características:

- Código aberto, não tendo qualquer custo associado;
- Licença LGPLv2, permitindo a adoção da *framework* sem restringir a sua utilização em soluções de código aberto;
- Última versão lançada a 8 de Junho de 2017 (JADE 4.5);
- Intuitiva e com uma interface gráfica muito útil;
- Aprendizagem facilitada com documentação apropriada;
- Elevada escalabilidade;
- Compatibilidade com os protocolos FIPA e CORBA;
- Vários protocolos de comunicação: ACL (Assíncrono), MTPs, RMI, IIOP, HTTP e WAP;

- Elevada performance, garantindo comunicações rápidas entre agentes;
- Elevada estabilidade e robustez;
- Linguagem de programação Java, o que a torna independente do sistema operativo;
- Elevado apoio ao cliente através de respostas a perguntas frequentes, lista de contactos e documentação adequada;
- *Framework* mais popular permitindo um maior apoio da comunidade;
- Versão estável e madura resultante de vários anos de desenvolvimento;
- Segurança elevada.

A implementação de um SMA permite facilitar o estudo de processos com elevadas interações, como por exemplo a negociação automática.

2.3.2 Negociação Automática

A questão da negociação bilateral está longe de ser uma temática trivial, sendo assim um tema recorrente na literatura de várias áreas, como é o caso da psicologia social (Thompson 2000), ciências de economia e gestão (Snyder e Diesing 1977), relações internacionais (Jennings et al. 2001) e IA (Rahwan et al. 2003). Em relação a este tema, foi realizada uma revisão muito relevante (Fernando Lopes, Wooldridge e Novais 2008), onde são apresentadas as principais fases de negociação automática, resultantes da análise das várias áreas identificadas (ver Tabela 2.2).

Tabela 2.2: Principais fases de negociação automática, adaptado de (Fernando Lopes, Wooldridge e Novais 2008) (tradução livre do autor).

Fase	Componentes
Preliminares	1. Conflitos sociais (deteção e exploração) 2. Partes negociadoras (número de partes)
Pré-negociação	3. Estruturação de informação pessoal (definição e execução de tarefas chave de pré-negociação) 4. Análise dos oponentes (recolha e uso de informação chave) 5. Definição do protocolo e seleção da estratégia inicial
Negociação	6. Troca de ofertas e comentários 7. Argumentação (troca de ameaças, promessas, etc.) 8. Aprendizagem (em negociação) 9. Escolha dinâmica de estratégias (seleção de novas estratégias) 10. Resolução de impasses
Renegociação	11. Análise e melhoria do acordo final

De seguida é apresentada um resumo dos principais componentes identificados, para cada fase de negociação, explicando o seu funcionamento e o seu estado de arte, começando pela fase dos Preliminares.

Preliminares

A primeira fase de negociação identificada é a fase de Preliminares. Esta fase é frequentemente considerada pelos principais modelos de negociação como sendo pertencente à fase de Pré-negociação. Nos Preliminares, são considerados os seguintes componentes:

1. Conflitos sociais (deteção e exploração) – componente focado em resolver os conflitos que possam surgir entre as partes, quando os mesmos têm interesses diferentes, tornando as suas aspirações incompatíveis (Rubin, Pruitt e S. H. Kim 1994).

Na literatura são comumente identificados três níveis de conflitos sociais (LEWICKI et al. 2003):

- (a) Conflito interpessoal (por exemplo conflitos entre chefes e subordinados);
- (b) Conflito intra-grupo (por exemplo conflitos entre membros da equipa e do comité);
- (c) Conflito inter-grupo (por exemplo conflito entre nações).

Este componente da fase preliminar das negociações começou por ser desvalorizado, dando mais importância ao processo de chegar a acordo. No entanto, este componente começou a ganhar importância com a evolução dos SMA, que se tornaram cada vez mais complexos. Desde então que têm sido feitos muitos progressos em torno deste tema. Contudo, continua a faltar resposta na literatura para duas questões importantes (Fernando Lopes, Wooldridge e Novais 2008):

- (a) Como desenvolver métodos efetivos para a deteção de conflitos?
 - (b) Como reconhecer e explorar o papel do conflito como força condutora da negociação?
2. Partes negociadoras (número de partes) – as negociações, dependendo do número de partes, podem ser bilaterais (envolvendo duas partes) ou multilaterais (envolvendo mais de duas partes) e, dependendo do número de recursos a negociar, pode ser uma negociação de um único recurso ou negociação de múltiplos recursos. As partes são agentes, ou grupos de agentes com interesses em comum que participam em negociação e os recursos são o alvo da negociação (Thompson 2000).

As negociações multilaterais podem ser de um-para-muitos, quando uma única entidade negocia com mais do que uma entidade, e muitos-para-muitos, quando múltiplas entidades negociam com múltiplas entidades adversárias. As negociações um-para-muitos são normalmente consideradas como um conjunto de negociações bilaterais concorrentes.

As negociações multilaterais são muito mais complexas que as negociações bilaterais. Quando três ou mais entidades negociam, a complexidade dessa negociação pode aumentar de cinco formas distintas (LEWICKI et al. 2003):

- Aumento de número de entidades envolvidas e respetiva necessidade de tempo para discussão;
- Aumento de recursos e posições em discussão;
- Aumento da complexidade social resultando numa maior pressão para os intervenientes;

- Aumento da complexidade do processo de negociação;
- Aumento da complexidade estratégica de negociação ao ser necessário acompanhar atentamente um maior número de entidades.

Na literatura é possível verificar que as negociações bilaterais têm sido o alvo de maior foco dos investigadores enquanto que as negociações multilaterais têm sido pouco abordadas. Neste tipo de negociações, apenas as negociações um-para-muitos tem tido alguma atenção.

A fase de Preliminares é sucedida pela fase de Pré-Negociação.

Pré-Negociação

A Pré-Negociação é a segunda fase de negociação identificada. Esta fase, assim como a fase anterior (frequentemente integrada nesta fase), são maioritariamente desvalorizadas nos modelos de negociação, apesar do grande benefício que os mesmos podem trazer à negociação. Esses benefícios podem ser reconhecidos ao analisar os seus componentes:

3. Estruturação de informação pessoal (definição e execução de tarefas chave de pré-negociação) – Segundo Bazerman e Neale 1993; LEWICKI et al. 2003; Raiffa 1982, no planeamento das suas negociações, os negociadores bem sucedidos procuram sempre fazer várias atividades, incluindo as seguintes quatro:
 - (a) Definir os recursos – lista de recursos a negociar;
 - (b) Estabelecer a agenda da negociação – confronto das listas de recursos de cada parte de forma a determinar a lista final de recursos a negociar;
 - (c) Priorizar os recursos – ordenar os recursos pela sua importância e determinar quais os recursos que estão relacionados.
 - (d) Definir limites e metas – definição do limite e meta para cada recurso a negociar. O limite (também conhecido como ponto de resistência, preço de reserva ou ponto de desistência (LEWICKI et al. 2003)) dita o ponto onde o negociador desiste da negociação e a meta (também conhecida como ponto de aspiração (Rubin, Pruitt e S. H. Kim 1994)) indica o ponto que o negociador acredita ser possível atingir, de forma realista.

Na literatura é possível verificar que os investigadores de IA têm dado pouca atenção a várias atividades de pré-negociação importantes (Fernando Lopes, Wooldridge e Novais 2008), nomeadamente a identificação dos recursos e definição da agenda da negociação.

4. Análise dos oponentes (recolha e uso de informação chave) – Segundo LEWICKI et al. 2003; Raiffa 1982; Roloff 1992, os seguintes tipos de dados, acerca do(s) oponente(s), são muito importantes:
 - (a) Os limites e metas dos oponentes. O negociador pode assumir que os oponentes pensam como ele e têm limites semelhantes. As metas dos oponentes podem ser especuladas ou então, o negociador pode tentar obter essa informação diretamente dos oponentes. Essa informação poderá ser obtida num diálogo antes da negociação ou então, caso não seja possível, o negociador tenta recolher essa informação nos momentos iniciais da negociação.

- (b) O histórico de negociação dos oponentes – a forma como os oponentes negociaram no passado pode dizer muito sobre como negociam no presente. Para esse efeito, o negociador pode obter informação de outros negociadores que conheçam ou tenham negociado com os oponentes em questão. No entanto essa informação deve ser analisada cautelosamente uma vez que não é garantido que os oponentes tenham um comportamento igual no presente, especialmente em diferentes períodos de tempo e circunstâncias.
- (c) As estratégias que os oponentes pretendem utilizar – Apesar de ser pouco provável que os oponentes disponibilizem as suas estratégias, as mesmas podem ser inferidas através da informação que consigam recolher (especialmente os seus interesses e reputação).

Quanto maior a informação que o negociador tiver acerca dos seus oponentes, melhor preparado estará para iniciar a negociação e tentar obter o melhor resultado possível. No entanto, o negociador poderá ter uma grande dificuldade para obter dessa informação, uma vez que fica dependente da contribuição dos oponentes e de outras entidades. Em caso de falta de informação auxiliar, o negociador pode tentar colocar-se no lugar do oponente e pensar o que faria nessa situação.

Na literatura tem-se verificado uma grande desvalorização, por parte dos investigadores de IA, em relação à recolha de informação acerca dos oponentes, na fase de pré-negociação. No entanto este componente pode ter um grande impacto na negociação em si, o que justifica uma maior aposta no mesmo.

5. Definição do protocolo e seleção da estratégia inicial – definição das regras que governam a interação entre os negociadores (Jennings et al. 2001). Em específico o protocolo define:

- Estados da negociação (por exemplo se estão a aceitar propostas);
- Ações válidas para cada estado (quais as mensagens que podem ser enviadas por quem, para quem e em que fase);
- Eventos que mudam estado da negociação (por exemplo quando a proposta é aceite);

O protocolo define as ações que podem ser tomadas pelos negociadores mas não especifica nenhuma ação em particular. A sofisticação dos protocolos depende da quantidade de informação que os negociadores podem trocar. Uma versão mais simples apenas permite a troca de ofertas enquanto que uma abordagem mais sofisticada pode incluir:

- Troca de comentários sobre as ofertas recebidas – críticas sobre que partes da negociação são aceitáveis ou não;
- Troca de argumentos para suportar a posição dos negociadores – justificação da sua posição ou persuasão dos outros negociadores para mudarem a sua.

Apesar das estratégias de negociação poderem representar uma grande variedade de comportamentos, com resultados muito diferentes, foram identificados os três principais grupos de estratégias mais adotados pelos negociadores (Rubin, Pruitt e S. H. Kim 1994; Van de Vliert 1997). Segundo Fernando Lopes, Wooldridge e Novais 2008,

os grupos de estratégias identificados podem ser aplicados tanto em negociações bilaterais como multilaterais. No entanto, os mesmos ressaltam a existência de várias táticas, pertencentes a cada estratégia. Essas táticas são movimentos a curto prazo que permitem, num nível superior, atingir uma determinada estratégia.

Os principais grupos de estratégias são os seguintes:

- *Contending* (Contendendo), *Competing* (Competindo) ou *Dominating* (Dominando) – os negociadores mantêm as suas aspirações e procuram persuadir/forçar os seus oponentes a cederem. Este tipo de estratégias podem tomar uma das seguintes formas (Pruitt 2013; Pruitt e Carnevale 1993):
 - Mostrando firmeza – apresentando exigências altas no início da negociação, cedendo lentamente e fazendo afirmações/ações demonstrativas da sua convicção;
 - Reduzindo a resistência dos oponentes à concessão – argumentos persuasivos, ameaças e promessas;
 - Impondo pressão de tempo – apresentação de prazo para o fim da negociação; ameaça de negociação com outras entidades; imposição de custos acrescidos ao longo do tempo; ou desistência da negociação.
- *Concession making* (Concedendo), *Yielding* (Cedendo), *Accommodating* (Acomodando) ou *Obliging* (Prestando) – os negociadores reduzem as suas aspirações parcialmente ou totalmente para ir ao encontro das aspirações dos seus oponentes, tentando chegar a um ponto intermédio entre ambas.
- *Problem solving* (Resolução de problemas), *Collaborating* (Colaborando) ou *Integrating* (Integrando) – os negociadores mantêm as suas aspirações, tentando reconcilia-las com as aspirações dos seus oponentes, procurando o maior benefício possível para ambas as partes. As principais estratégias deste grupo são (Fisher, Ury e Patton 2011; Pruitt 2013):
 - *Expanding the "pie"* (Expandindo a "torta") – aumento dos recursos disponíveis para a negociação de forma a que todas as partes consigam atingir os seus objetivos;
 - *Nonspecific compensation* (Compensação inespecífica) – uma das partes atinge os seus objetivos e recompensa os oponentes pela sua cedência;
 - *Logrolling* (Troca de favores) – as partes cedem nos recursos menos prioritários para eles mas mais prioritários para os seus oponentes;
 - *Cost cutting* (Redução de custos) – uma das partes atinge os seus objetivos e os custos impostos nos oponentes são parcialmente ou totalmente eliminados;
 - *Bridging* (Ponte) – os negociadores procuram alternativas que satisfaçam os interesses de ambas as partes.

Após a fase de preparação da negociação, surge a negociação em si.

Negociação

Após a preparação da negociação na fase de Pré-Negociação, surge a fase da Negociação em si. Esta fase é caracterizada pelos seguintes componentes:

6. Troca de ofertas e comentários – No processo de negociação, é normalmente assumido, que as partes envolvidas estão dispostas a fazer algum tipo de cedência, mostrando-se com boas intenções. Caso contrário, são reconhecidas más intenções nos negociadores ao apenas se focarem nos seus interesses e serem inflexíveis às necessidades das restantes partes envolvidas.

Em relação à troca de informação, os negociadores enfrentam dois dilemas (Kelley 1996):

- Honestidade – definição da percentagem de verdade a partilhar com os oponentes. Excesso de partilha pode levar a uma posição desvantajosa enquanto que falta de partilha pode inviabilizar a negociação.
 - Confiança – definição da credibilidade das informações obtidas; A confiança depende da experiência passada com o negociador em questão, a sua reputação atual e as circunstâncias atuais.
7. Argumentação (troca de ameaças, promessas, etc.) – a apresentação de argumentos e contra-argumentos efetivos tem um grande impacto na negociação. Um dos tipos de argumentos mais utilizados pelos negociadores são do tipo persuasivo, tentando convencer os seus oponentes a aceitarem a sua proposta. O tipo de argumentos persuasivos mais comumente reconhecidos pelo seu impacto são os seguintes (Kraus, NIRKE e K. Sycara 1993; E. P. Sycara 1987):

- Apelar a precedentes como contra-exemplos – identificar contradições nas exigências dos seus oponentes e as suas ações no passado;
- Apelar à prática predominante – dar garantias aos seus oponentes que a proposta irá permitir-lhes atingirem os seus objetivos, uma vez que a mesma já o permitiu a outras entidades;
- Apelar ao interesse próprio – convencer os seus oponentes que a proposta lhes permite atingir objetivos muito importantes.

Para além dos argumentos persuasivos, é possível verificar uma grande utilização de outros tipos de argumentação em negociações da vida real (Kraus, NIRKE e K. Sycara 1993):

- Ameaças – argumentos com o intuito de castigar o oponente caso o mesmo não atenda às condições que lhe são propostas. Este tipo de argumento depende muito da credibilidade da entidade em cumprir as suas ameaças e na dimensão do castigo.
 - Promessas – contrariamente às ameaças, o negociador promete compensar o seu oponente pela sua cooperação. A credibilidade do negociador e das suas promessas também é um fator chave neste tipo de argumento.
8. Aprendizagem (em negociação) – capacidade dos negociadores em aprender antes, durante e após as negociações de forma a melhorar as suas habilidades de negociação e confiança nas mesmas, potenciando melhores resultados. Nadler, Thompson e Boven

2003; Thompson 2000 apontam os quatro métodos de aprendizagem mais utilizados pelos negociadores:

- Aprendizagem didática (baseada em princípios) – os negociadores seguem determinados princípios para resolver problemas;
- Aprendizagem por revelação de informação – os negociadores aprendem com o seu próprio comportamento;
- Aprendizagem analógica – adaptação de soluções para problemas do passado para o problema atual;
- Aprendizagem observacional (imitação) – aprendizagem através da imitação de outros negociadores.

Apesar de existir alguns estudos na literatura sobre agentes negociadores autônomos, com capacidade de aprendizagem, existem algumas questões por abordar (Fernando Lopes, Wooldridge e Novais 2008):

- Como combinar diferentes métodos de aprendizagem?
- Em que condições é que a aprendizagem melhora eficazmente a performance da negociação?
- Quais são os métodos mais eficazes de aprendizagem? Como avaliar a eficácia dos diferentes métodos de aprendizagem?

9. Escolha dinâmica de estratégias (seleção de novas estratégias) – Os negociadores iniciam o processo de negociação seguindo uma determinada estratégia. No entanto, no decorrer da negociação, perante toda a nova informação disponível, a estratégia inicialmente selecionada poderá deixar de ser a mais eficaz face a outras estratégias que entretanto se tornaram mais apropriadas. As possibilidades de sequências de estratégias são inúmeras mas é possível encontrar na literatura algumas sugestões (Fernando Lopes, Wooldridge e Novais 2008):

- Sequência de duas fases – Na primeira fase são aplicadas estratégias de Contenda e Cedência e na segunda fase estratégias de Resolução de Problemas (Pruitt e Carnevale 1993);
- Sequência de três fases – Na primeira fase são aplicadas estratégias de Contenda, seguidas de estratégias de Resolução de Problemas e por último são aplicadas novamente estratégias de Contenda. No entanto a reutilização de estratégias de Contenda no final da negociação não reúne um consenso na literatura. Alguns investigadores sugerem que as estratégias de Contenda surgem no final da negociação, quando os negociadores afirmam os seus ganhos, outros sugerem um continuo aumento da utilização de estratégias de Resolução de Problemas (Putnam 1990).

10. Resolução de impasses – As negociações nem sempre terminam em acordo. Por vezes os negociadores chegam a um ponto da negociação em que não encontram forma de chegar a consenso, e deixam de ter uma interação produtiva. LEWICKI et al. 2003 sugeriu o seguinte procedimento para a resolução de impasses altamente polarizados:

- (a) Sincronização da redução de hostilidade e melhoria da eficácia da comunicação;

- (b) Controlo do número de recursos em negociação, dividindo os recursos muito abrangentes em recursos de menor escala e especial atenção ao adicionar novos recursos;
- (c) Estabelecimento de um ponto comum;
- (d) Criar propostas mais atrativas para o oponente, tendo em conta as necessidades do mesmo.

No entanto, é frequente ocorrer impasses em que os negociadores não consigam resolver por si mesmos, necessitando do envolvimento de uma terceira entidade. A solução mais habitual para este tipo de necessidade é a utilização de um mediador.

Com o término da fase de negociação, existe a possibilidade de ocorrência da fase de renegociação.

Renegociação

A última fase de negociação surge após a negociação em si, onde por vezes surge a necessidade de renegociação. Assim como as fases Preliminares e Pré-Negociação, esta fase também é pouco explorada na literatura, focando-se em acordos inalteráveis. Esta fase é caracterizada por um único componente:

11. Análise e melhoria do acordo final – Normalmente, no final da negociação, as partes envolvidas estão satisfeitas com o acordo alcançado. No entanto, após uma análise mais detalhada, os mesmos podem-se aperceber de erros que cometeram na negociação, ou ocorrer alguma mudança nas circunstâncias da negociação. Nestes casos, surge a necessidade de reabrir a negociação.

Na literatura sobre negociação, são frequentemente identificados três tipos diferentes de acordo (Fernando Lopes, Wooldridge e Novais 2008):

- (a) Acordo de compromisso – acordo estabelecido quando as partes concedem para uma posição intermédia em um ou mais pontos do seu acordo inicial;
- (b) Acordo integrante – acordo que integra o interesse de ambas as partes e permite obter um maior benefício conjunto;
- (c) Acordo ótimo de Pareto – acordo que se obtém ao aplicar a fronteira ótima de Pareto (Raiffa 1982). Este tipo de acordo é o que permite obter o maior benefício conjunto comparativamente com os restantes. No entanto, os negociadores tendem a adotar uma grande desconfiança em situações de conflitos, adotando uma postura de ganhar ou perder, não conseguindo obter acordos integrantes ou acordos ótimos de Pareto.

Conforme identificado na análise ao processo de negociação automática, a capacidade de aprendizagem do negociador pode ter um grande impacto nos seus resultados. Desta forma, na Secção 2.3.3 é abordado o conceito de aprendizagem automática.

2.3.3 Aprendizagem Automática

Aprendizagem Automática é um campo da IA que tem o propósito de dotar os computadores de capacidade de aprendizagem sem ter de ser explicitamente programado (Nasrabadi 2007). Este campo é por vezes confundido com o campo de Prospecção de Dados (Hand 2007). No entanto, não representam o mesmo apesar de ter aspetos em comum. O campo de Aprendizagem Automática é focado na aprendizagem de máquinas enquanto que Prospecção de Dados é voltado para a aprendizagem do ser humano. Esta última tem o principal objetivo de extrair conhecimento através de análises exploratórias de dados.

Hoje em dia, as tarefas de Aprendizagem Automática são habitualmente classificadas em duas categorias principais: Aprendizagem Supervisionada (Kotsiantis, Zaharakis e Pintelas 2007) e Aprendizagem Não Supervisionada (Hastie, Tibshirani e Friedman 2009). A diferença entre ambas reside no auxílio que obtêm no seu processo de aprendizagem. Na Aprendizagem Supervisionada são fornecidos exemplos de dados de entrada e de saída e a tarefa consiste em compreender a relação entre eles. Por outro lado, na Aprendizagem Não Supervisionada, não são fornecidos exemplos, deixando os algoritmos perceberem por si mesmos qual a relação dos dados e quais os seus padrões.

Na categoria de Aprendizagem Supervisionada, existem três casos particulares: Aprendizagem Semi-Supervisionada (Chapelle, Scholkopf e Zien 2009), Aprendizagem Ativa (Settles 2012) e Aprendizagem por Reforço (Sutton e Barto 1998). Na primeira, são fornecidos dados de entrada ao algoritmo mas nem todos têm um dado de saída associado. Na Aprendizagem Ativa, só é possível obter os dados de saída para alguns dos dados de entrada (normalmente há um orçamento associado). O algoritmo tem de selecionar os dados de entrada que podem adicionar maior valor ao modelo, ao descobrir-se os seus dados de saída. Por último, a Aprendizagem por Reforço, é uma área inspirada em psicologia comportamental, que permite a um agente de *software* avaliar o resultado da tomada de diferentes ações, consoante os resultados obtidos. Cada ação obtém uma recompensa de acordo com a qualidade do resultado obtido. Cada atualização da pontuação de uma ação pode ter maior ou menor impacto consoante o peso atribuído à nova informação.

Para o processo de aprendizagem automática podem ser utilizadas várias *frameworks*, conforme identificado na secção seguinte.

Frameworks

Ao longo dos anos têm surgido várias *frameworks* de aprendizagem automática, de forma a dar resposta à sua crescente utilização assim como as novos desafios emergentes. Um exemplo desses desafios é o conceito de *Big Data*, relativo aos grandes conjuntos de dados que hoje em dia são possíveis de obter, devido à maior capacidade de geração e armazenamento garantidos pela tecnologia atual. Desta forma surge a necessidade de novas técnicas para tornar possível a leitura e análise dessa quantidade de dados, tentando também reduzir o tempo necessário. Devido à grande quantidade de dados disponíveis, a aprendizagem profunda tem recebido cada vez mais atenção, uma vez que a mesma é capaz de os processar e extrair conhecimento que até então não era possível obter. Para esse efeito surgem várias *frameworks*: Apache MXNet, Apache Singa, Caffe, Microsoft Cognitive Toolkit (CNTK), TensorFlow e VELES.

Para além das *frameworks* focadas em aprendizagem profunda, surgem também várias soluções para uma aprendizagem automática generalizada, distribuída e escalável: Amazon Machine Learning (Amazon ML), Apache Mahout, Azure ML Studio, H2O, Oryx e Spark MLlib.

No entanto, as *frameworks* apresentadas têm uma abordagem de alto nível, permitindo aos seus utilizadores gerirem os seus processos de aprendizagem automática, sem necessitar de ter um conhecimento aprofundado dos algoritmos utilizados. A maioria destas *frameworks* comunica, ou suporta a utilização de código de *frameworks* de menor escala, focadas no desenvolvimento e disponibilização de algoritmos de aprendizagem automática. As principais soluções são as seguintes: Accord.NET, Massive Online Analysis (MOA), mlpack, Python, R, Shogun, Torch e Weka.

A *framework* Accord.NET, de código aberto, desenvolvida na linguagem de programação C Sharp (C#), fornece vários algoritmos para as diversas tarefas de aprendizagem automática. A *framework* não oferece meios de ligação com outras ferramentas ou linguagens de programação.

A Massive Online Analysis (MOA) é uma *framework* de código aberto dedicada à prospeção de fluxos de dados, disponibilizando vários algoritmos para esse efeito. A ferramenta é desenvolvida na linguagem Java e não oferece interface com outras ferramentas/linguagens.

A *framework* mlpack, de código aberto, é desenvolvida na linguagem de programação C++. Os seus algoritmos de aprendizagem automática podem ser utilizados através de uma biblioteca em C++, de forma mais sofisticada, ou então através de comandos que podem ser executados na linha de comandos, sem acesso ao código fonte dos algoritmos.

O Python é uma linguagem de programação e surge nesta lista devido à sua grande aplicabilidade a tarefas de aprendizagem automática, sendo cada vez mais utilizada. Para esse efeito existem algumas bibliotecas para facilitar o processo de aprendizagem automática, sendo as principais: Pattern, um módulo para prospeção de dados na Internet; scikit-learn, a principal e mais popular *framework* para tarefas de aprendizagem automática em Python; e Theano, focada na definição, otimização e avaliação de expressões matemáticas complexas no menor tempo possível, ao nível das bibliotecas mais rápidas. Estas ferramentas são de código aberto mas não possuem interfaces com outras linguagens de programação.

O R é uma linguagem de programação e também um software de código aberto, para computação estatística e gráfica. Assim como o Python, esta linguagem tem sido muito adotada para o processo de aprendizagem automática. O software é expansível, através de novos pacotes que podem ser desenvolvidos pela comunidade em geral. Dessa forma, o repositório de pacotes do R contém uma grande variedade de soluções para as várias tarefas de aprendizagem automática. Atendendo à sua crescente adoção, foram surgindo várias interfaces que permitem executar o R a partir de outras linguagens de programação, sendo a principal solução o pacote Rserve.

A *framework* Shogun, de código aberto e desenvolvida em C++, é uma das mais antigas ferramentas para aprendizagem automática. Para além de poder ser utilizada pela linguagem de programação C++, a mesma também pode ser utilizada em várias outras linguagens incluindo Python, R e Java.

Torch é uma *framework* de aprendizagem automática, de código aberto e desenvolvida na linguagem de programação Lua. A ferramenta é focada no aumento do seu desempenho sem tornar o processo de desenvolvimento de algoritmos mais complexo.

Por último, o WEKA é uma *framework*, desenvolvida na linguagem de programação Java, que está relacionada com o projeto da *framework* MOA, mas dedicada a problemas de menor dimensão, em termos de processamento de dados.

Após a análise dos principais conceitos necessários para a implementação do conceito definido, é necessário analisar os sistemas de apoio à decisão para mercados de energia elétrica. Desta forma é possível identificar as suas capacidades assim como as suas limitações, de forma a garantir o maior contributo possível do produto a desenvolver, para os seus segmentos de clientes.

2.4 Sistemas de Apoio à Decisão para Mercados de Energia Elétrica

Ao longo do tempo foram surgindo várias soluções para o estudo dos MEE. Esta secção apresenta as principais ferramentas para o estudo dos MEE no geral (Secção 2.4.1) e do modelo de contratos bilaterais em particular (Secção 2.4.2).

2.4.1 Simulação de Mercados de Energia Elétrica

Na literatura é possível verificar que as principais soluções existentes para o estudo de MEE, resultam da aplicação dos conceitos de simulação e SMA. As principais ferramentas identificadas são: Simulator for Electric Power Industry Agents (SEPIA) (Harp et al. 2000), EMCAS (Koritarov 2004), Power Web (Zimmerman e Thomas 2004), Short-Medium Run Electricity Market Simulator (SREMS) (Migliavacca 2007), AMES (Li e Tesfatsion 2009), MASCEM (Isabel Praça et al. 2003; Gabriel Santos et al. 2016) e ALBidS (Tiago Pinto, Vale, T. M. Sousa et al. 2014).

O SEPIA (Harp et al. 2000) é um simulador de MEE que permite distribuir os seus agentes por vários computadores não sendo obrigatório executar todos no mesmo. A ferramenta permite indicar o número de agentes participantes assim como os seus comportamentos, interações e alterações ao longo da simulação.

O simulador multi-agente EMCAS (Koritarov 2004), permite representar os diversos tipos de agente envolvidos nos MEE como as empresas de geração, consumo, transmissão e distribuição, os operadores de sistema independentes, e reguladores. Os agentes são capazes de adequar as suas estratégias consoante a experiência que vão adquirindo no mercado. O simulador suporta vários modelos de bolsa e negociação de contratos bilaterais. A simulação pode considerar o espaço de tempo necessário para o estudo em questão, uma vez que o tempo simulado pode ir até várias décadas.

O Power Web (Zimmerman e Thomas 2004) é um simulador de MEE com a particularidade de ser desenvolvido em web e permitir a livre participação de qualquer utilizador com acesso à Internet. A ferramenta suporta simulações com um grande número de cenários e regras. O simulador permite aos utilizadores competir em mercado aberto contra produtores de energia elétrica, que podem ser outros utilizadores ou algoritmos computacionais.

O SREMS (Migliavacca 2007) é um simulador de MEE, baseado no mercado italiano, que é focado na análise de cenários de curto a médio prazo (duração de 1 ou mais meses), através

da aplicação do conceito de teoria de jogos. A ferramenta inclui as seguintes características: cálculo das ofertas horárias ótimas; consumo inalterável com a variação do preço, definido para cada hora de cada zona; rede baseada em árvore com limites de trânsito entre zonas; agendamento mensal de reservatórios hídricos e estações de bombeamento; representações muito realistas de centrais térmicas; possibilidade de definição de quota associada aos contratos bilaterais, dependendo da quantidade de produtores e a sua atitude face ao risco.

O AMES (Li e Tesfatsion 2009) é software de código aberto, baseado em agentes, para o estudo do mercado de energia elétrica grossista reestruturado, seguindo o modelo de mercado da Comissão Federal de Regulamentação de Energia dos Estados Unidos (FERC). A ferramenta modela os agentes negociadores (consumidores e geradores de energia elétrica), um operador de sistema independente e a respetiva rede de transporte. O AMES tem o principal objetivo de verificar a adaptabilidade das medidas comuns de venda de energia elétrica e de garantia da qualidade do sistema ao mercado reestruturado. Para esse fim, os agentes geradores possuem a capacidade de aprender através do uso de aprendizagem por reforço estocástico para a seleção das ofertas do seu interesse.

O MASCEM (Isabel Praça et al. 2003; Gabriel Santos et al. 2016) surgiu em 2003 com o propósito de colmatar as falhas identificadas nos simuladores de MEE desenvolvidos até ao momento. Desde a sua criação que o simulador procura atingir uma cobertura o mais completa possível dos MEE, modelando todas as entidades envolvidas, as suas diversas interações e o maior número de modelos de mercado possíveis. Para esse efeito, a ferramenta tem vindo a ser atualizada ao longo dos anos para dar resposta às frequentes mudanças no meio simulado (Vale et al. 2011). O próprio sistema sofreu uma profunda reestruturação de forma a otimizar a sua performance (Gabriel Santos et al. 2016). Atualmente, o MASCEM é um simulador desenvolvido na linguagem JAVA, que implementa um SMA através da *framework* Java Agent Development Framework (JADE). A ferramenta permite modelar cinco tipos de agentes: Agente Principal, que é o agente principal do simulador, responsável por permitir a interação do utilizador e controlar a execução do mesmo; Agente MIB, responsável por analisar os computadores disponíveis na rede e enviar um relatório para o Agente Principal, que assim pode decidir para onde enviar cada agente; Operador de Mercado, que gere as negociações em mercados de bolsa e respetivo despacho económico enviado para o Operador de Sistema; Operador de Sistema Independente, responsável por gerir a rede de transmissão; e o Player, que pode ser comprador, vendedor ou agregador. Os modelos de mercado suportados pelo MASCEM são: modelo de bolsa (simétrico e assimétrico), modelo de ajustes, modelo de mercado a prazo e contratos bilaterais.

O ALBidS (Tiago Pinto, Vale, T. M. Sousa et al. 2014) é um sistema de apoio à decisão multi-agente para a participação em MEE baseados em leilão. A ferramenta surge com o propósito de permitir aos simuladores de MEE dotarem os seus *players* de capacidade de aprendizagem e adaptação aos diferentes contextos de negociação, diferentes comportamentos dos outros *players* e alterações aplicadas ao meio envolvente. O sistema apresenta uma grande contribuição científica para o estudo de MEE, uma vez que permite aumentar o realismo das modelações das ferramentas atuais, ao permitir uma representação dos *players* mais inteligente e conseqüentemente mais próximo da realidade. Para além das ferramentas, também os próprios *players* reais podem tirar partido do ALBidS para otimizar a sua participação nos MEE, de forma a aumentar os seus ganhos.

Após a análise dos sistemas de apoio à decisão para MEE no geral, são analisadas em específico, as soluções para a negociação de contratos de energia.

2.4.2 Sistemas de Negociação de Contratos de Energia

Na literatura é possível verificar a existência de algumas ferramentas que suportam a negociação de contratos bilaterais. Nesta secção são apresentadas as soluções com maior exploração deste modelo de mercado. Essas soluções são: EMCAS (Koritarov 2004), General Environment for Negotiation with Intelligent Multi-Purpose Usage Simulation (GENIUS) (R. Lin et al. 2014), Multi-Agent Negotiation and Risk Management in Electricity Markets (MAN-REM) (Lopes, Rodrigues e J. Sousa 2012) e MASCEM (Isabel Praça et al. 2003; Gabriel Santos et al. 2016).

EMCAS

O simulador EMCAS (Koritarov 2004) permite simular a negociação de contratos bilaterais, entre outros modelos de mercado. Este simulador é um SMA que permite a definição de objetivos para vários agentes, em vez de se focar apenas na perspectiva de um agente e obter a melhor oferta para os seus interesses. A Figura 2.5 apresenta a forma como as negociações bilaterais são modeladas.



Figura 2.5: Interação entre os agentes do simulador EMCAS para a negociação de contratos bilaterais.

A simulação de contratos bilaterais no EMCAS é baseada em Pedidos de Propostas (PDP) estabelecidos entre os agentes consumidores e os agentes de empresas geradoras, numa abordagem de três passos. O primeiro passo consiste no envio de um PDP por parte dos consumidores para as empresas geradoras, antecipando as suas necessidades energéticas. No segundo passo, as empresas geradoras avaliam os PDP recebidos e respondem com um preço para o total ou parte da quantidade de energia proposta. Quando os consumidores recebem essas respostas, os mesmos podem aceitar ou rejeitar. No último passo, os dois tipos de agente analisam as suas interações com as outras entidades e os resultados obtidos, de forma a ajustar as suas estratégias para as próximas rondas de PDP, através de um processo de exploração. Os agentes são capazes de se aperceber de mudanças significantes no mercado, quando os seus resultados começam a piorar consideravelmente. Contudo, os mesmos são capazes de se adaptar a essas condições através do seu dinamismo e adaptabilidade.

GENIUS

O GENIUS (R. Lin et al. 2014) é um ambiente integrado que suporta a conceção de negociadores automáticos genéricos. O projeto surgiu com o intuito de lidar com os obstáculos em criar agentes generalizados que consigam negociar em vários domínios assim como contra agentes humanos. Para esse fim, a ferramenta permite a criação de estratégias de negociadores automáticos e validação das mesmas através da simulação do processo de negociação.

A ferramenta disponibiliza um ambiente flexível e de fácil utilização para a implementação de agentes, criação de estratégias e análise de agentes. O cerne do sistema pode ser incorporado em sistemas de negociação mais complexos, dando o seu contributo em todo o processo de negociação. A Figura 2.6 apresenta a arquitetura do GENIUS.



Figura 2.6: Arquitetura do GENIUS.

A arquitetura do GENIUS, apresentada na Figura 2.6, demonstra que a ferramenta é composta por quatro módulos principais: Análise, Repositório, Controlo de Simulação e Registo.

O módulo de Análise permite analisar os resultados através de diferentes medidas de avaliação. Em relação ao módulo Repositório, o mesmo é composto por três sub-módulos: Definição da Negociação, Agente e Protocolo de Negociação. O primeiro sub-módulo permite a definição do domínio da negociação e respetivo perfil de preferências (um para cada agente em que o mínimo é de dois). Com a definição do cenário, torna-se possível realizar uma Análise do Espaço de Resultados (sub-módulo de Análise). O segundo sub-módulo do Repositório é relacionado com a criação dos agentes e configuração dos seus parâmetros. Após a criação do agente, é possível analisar o ambiente da negociação através da Introspeção de Agente, sub-módulo de Análise. O último sub-módulo do Repositório é a definição do protocolo de negociação (um para um, um para muitos ou muitos para muitos). Assim como nos restantes sub-módulos do Repositório, também existe um sub-módulo de Análise de apoio à definição do protocolo de negociação, denominado Análise da Dança da Negociação. Esta análise consiste na avaliação de características da negociação como a equidade e bem-estar social.

O módulo Controlo de Simulação, como o nome indica, é responsável pelo controlo da simulação, estando ligado ao módulo Repositório, onde se encontram os principais componentes. Por último, o módulo Registo permite fazer a depuração do sistema e obter informação detalhada acerca do processo de negociação, estando ligado ao sub-módulo Protocolo de Negociação.

Na ferramenta GENIUS, o processo de negociação segue três fases:

1. Preparação – Preparação da negociação que envolve a configuração de três componentes:
 - (a) Definição dos agentes envolvidos – Os agentes envolvidos podem ser humanos ou automáticos. Os agentes automáticos podem ser definidos através da criação de um novo agente ou integração de um agente existente através de adaptadores. Para a criação de agentes, pode ser utilizado classes esqueleto que simplificam o processo. Em relação à comunicação e aos protocolos de negociação, os mesmos já se encontram implementados.
 - (b) Domínio – Na definição do domínio é considerado o número de entidade envolvidas na negociação, a espaço temporal da negociação, os recursos a ser negociados e um conjunto de objetivos. O domínio da negociação permite incluir agentes cooperativos e não cooperativos. Os agentes cooperativos tentam maximizar a combinação das suas utilidades enquanto os não cooperativos apenas se focam na sua utilidade individual.
 - (c) Protocolo de Negociação – Especificação do número de negociações e como as mesmas são conduzidas. O protocolo também permite definir negociações obrigatórias e se têm um limite associado.
2. Negociação – Fase onde ocorre a negociação em si. Se existirem negociadores humanos, os mesmos interagem através de uma interface gráfica da aplicação. Desta forma, os negociadores humanos podem trocar ofertas com os seus oponentes, ver as ofertas e definir o seu perfil de preferências.
3. Pós-Negociação – Análise da performance dos negociadores através de um conjunto de ferramentas de análise que permite avaliar as estratégias de negociação. As ferramentas permitem calcular soluções ótimas ao usar fronteira eficiente de Pareto, produto Nash e técnicas Kalai-Smorodinsky. Os resultados são apresentados ao utilizador, permitindo observar a distância entre os resultados das negociações decorridas e as soluções ótimas.

MAN-REM

O MAN-REM (Lopes, Rodrigues e J. Sousa 2012) é uma *framework* que resulta da junção de pequenos simuladores multi-agente, e propõe o uso de agentes de software para o estudo de MEE, em específico o modelo de Contratos Bilaterais. A ferramenta foi desenvolvida na linguagem de programação JAVA e utiliza a *framework* JADE para o desenvolvimento dos seus agentes. O MAN-REM possui uma interface gráfica que permite a definição de cenários assim como a configuração da ferramenta.

Nas suas simulações, a ferramenta considera os seguintes agentes: os produtores de energia; os consumidores (residenciais, comerciais, industriais, entre outros); os distribuidores de energia; e o operador de mercado, responsável por validar a viabilidade dos contratos.

As negociações entre os produtores e os consumidores seguem uma abordagem de três fases: pré-negociação, negociação e pós-negociação. Na primeira fase é realizado o planejamento da negociação, definindo as preferências da entidade para o seu contrato, incluindo como lidar com contra-ofertas. A próxima fase consiste na negociação em si, ou seja, troca de ofertas e contra-ofertas, de acordo com as estratégias dos agentes. Para além disso, os agentes são capazes de conceder, abdicando da sua posição inicial de forma a conseguir obter um acordo. Por último, a fase de Pós-negociação quando os agentes fecham negócio ao chegar a acordo.

O MAN-REM cobre dois tipos de estratégias possíveis: Estratégias para promover flexibilidade e estratégias para gestão de risco. Para a promoção de flexibilidade, os agentes têm a possibilidade de formular as suas propostas tendo em conta a variação de preços ao longo do dia, permitindo a mudança da transação de energia para um período de menor custo. Para esse fim, os consumidores têm a estratégia Gestão de Preço e os produtores têm a estratégia Gestão de Volume. A estratégia de Gestão de Preço procura maximizar o benefício do produtor ao tentar vender o maior volume possível nos períodos de menor custo de produção. Por outro lado, a estratégia dos consumidores procura minimizar os seus custos ao gerir o seu consumo consoante os diferentes preços ao longo do dia.

Na estratégia de gestão de risco, o agente avalia o risco a cada concessão, considerando as seguintes variáveis: tempo passado desde o início da negociação, quantidade de recursos disponível, o comportamento anterior do oponente, e a concessão total realizada em cada recurso da negociação. As preferências de risco do agente são amplamente classificadas em: aversão ao risco ($\lambda < 0$), risco neutro ($\lambda = 0$) e à procura do risco ($\lambda > 0$). Para esse efeito, os agentes contam com dois tipos de funções de utilidade multi-objetivo: função de utilidade marginal de gestão de risco e função de utilidade esperada de Von Neumann-Morgenstern.

MASCEM

O simulador MASCEM (Isabel Praça et al. 2003; Gabriel Santos et al. 2016), apresentado na Secção 2.4.1, inclui o suporte de negociações bilaterais, entre outros modelos dos MEE. Para esse efeito, os consumidores que pretendem negociar contratos bilaterais, enviam um Pedido de Propostas (PDP) com a quantidade que desejam transacionar e o preço esperado, para todos os produtores no mercado simulado. Ao receber os PDP, os produtores analisam a sua capacidade, disponibilidade atual, experiência do passado e a viabilidade de entrega da energia elétrica no local do consumidor (através da comunicação com o operador de sistema). Após a validação do PDP, caso o produtor tenha a possibilidade de fazer uma oferta segundo os requisitos do produtor, o mesmo formula a oferta e envia-a para o produtor. Por último, os consumidores validam as ofertas dos produtores e decidem se as aceitam ou rejeitam. No final de um período de negociação, os *players* analisam as suas estratégias conforme os resultados obtidos.

Para a definição das suas ofertas, tanto nos contratos bilaterais como nos restantes modelos de mercado, os *players* contam com as seguintes estratégias:

- Estratégias dependentes do tempo – Estratégias de alteração de preço dentro de um período de negociação.

- *Determined* (Determinado) – O agente mantém o seu preço ao longo da negociação.
- *Anxious* (Ansioso) – O agente começa a fazer pequenas modificações no seu preço no início da negociação.
- *Moderate* (Moderado) – O agente começa a modificar um pouco o seu preço a meio da negociação.
- *Gluttonous* (Guloso) – O agente apenas começa a alterar o seu preço no final da negociação.
- Estratégias dependentes do comportamento – Estratégias de ajustamento de preço entre períodos de negociação.
 - *Composed Goal Directed* (Direcionado a um Objetivo Composto) – O agente tem dois objetivos consecutivos. O primeiro é vender/comprar toda a quantidade de energia necessária e o segundo é aumentar o lucro da negociação.
 - *Adapted Derivative Following* (Acompanhamento Derivado Adaptativo) – Baseada na estratégia *Derivative Following* (Acompanhamento Derivado) de Greenwald. O agente efetua alterações ao seu preço consoante os resultados obtidos nos últimos dois períodos, tendo em conta a diferença de preço por ele praticada. Em caso de aumento de lucro, a estratégia aumenta o preço de acordo e caso contrário diminui.
 - *Market Price Directed* (Direcionado ao Preço de Mercado) – A estratégia consiste em seguir o preço de mercado do período anterior, aplicando uma pequena alteração baseado nos resultados dos últimos períodos.

Após a análise dos sistemas de apoio à decisão para MEE, o presente capítulo termina com o levantamento das conclusões finais do estudo realizado.

2.5 Conclusões

Os MEE aumentaram muito a sua complexidade e imprevisibilidade ao longo dos últimos anos. O estudo deste meio torna-se cada vez mais importante, especialmente para as entidades envolvidas, que pretendem otimizar a sua participação no mesmo. Na literatura tem surgido várias soluções que suportam esse estudo. No entanto, um análise detalhada das mesmas revela a falta de suporte ao modelo de mercado baseado em contratos bilaterais, estando principalmente focados nos modelos baseados em leilão.

As soluções atuais demonstram a aplicabilidade da simulação multi-agente para o estudo de MEE, uma vez que torna possível uma representação dos mesmos, muito próxima da realidade, através da modelação das diversas entidades e respetivas interações entre elas. A capacidade de aprendizagem dos agentes tem também um contributo muito importante para a qualidade da simulação, dando um maior realismo aos seus comportamentos. Para este efeito, *Machine Learning* revela-se um conceito essencial. A aplicação deste conceito no estudo dos MEE permite também uma muito superior extração de conhecimento e consequente apoio à decisão das entidades envolvidas.

No caso do apoio à decisão aos *players* que negociam contratos bilaterais em MEE, surge outro conceito muito importante: a negociação automática. Uma revisão muito

relevante identifica as principais fases de negociação e os principais componentes de cada uma. Nos modelos de negociação atuais, é verificada uma grande desvalorização da fase de pré-negociação que, quando incluída, é abordada de forma simples. O foco principal está voltado na negociação em si. No entanto, a fase de pré-negociação pode revolucionar por completo o decorrer da negociação, uma vez que permite ao negociador enfrentar a negociação com uma preparação muito superior. Em específico, a análise dos oponentes pode revelar informação vital para o sucesso da negociação.

A análise às soluções existentes de apoio à negociação de contratos bilaterais, demonstra a falta de exploração da fase de pré-negociação, especialmente relativamente à recolha de informação acerca dos oponentes. A falta de informação, acerca dos seus possíveis oponentes, impede o *player* de fazer uma seleção de oponentes adequada aos seus interesses. Para além disso, na fase de negociação, o *player* não tem conhecimento acerca de qual a melhor estratégia a seguir com determinado oponente, existindo uma falta de capacidades de combinação dinâmica de estratégias; de adaptação ao longo do processo de negociação, permitindo a mudança de abordagem estratégica; e adaptação a diferentes contextos de negociação e a diferentes perfis de negociação.

De forma a dar resposta às necessidades identificadas, esta dissertação propõe o desenvolvimento de um sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais em MEE. O sistema tem dois objetivos principais: identificar o(s) melhor(es) oponentes com quem o *player* apoiado pode negociar, de forma a ir ao encontro dos seus objetivos pessoais; auxiliar o *player* durante o processo de negociação com um determinado oponente, recomendando a melhor estratégia a seguir, ao longo da negociação. Esta solução é apresentada em detalhe no Capítulo 3.

Capítulo 3

Solução Proposta

Neste capítulo é apresentada a solução proposta desta dissertação, um sistema de apoio à decisão multi-agente para a negociação de contratos bilaterais em MEE.

Para o desenvolvimento do SMA, é selecionada a *framework* JADE, uma vez que a mesma continua a ser a mais popular e melhor classificada na revisão analisada na Secção 2.3.1, indo ao encontro dos objetivos do sistema proposto nesta dissertação. O sistema proposto será desenvolvido na linguagem de programação Java de forma a suportar a utilização do JADE e ao mesmo tempo garantir uma maior compatibilidade com diferentes sistemas operativos.

Para a implementação da base de dados, que tem um papel essencial no sistema proposto, foi selecionado o Sistema de Gestão de Base de Dados (SGBD) PostgreSQL. Esta seleção deve-se ao facto deste PostgreSQL ser um dos principais SGBD de código aberto, ficando apenas atrás do MySQL, em termos de popularidade (DB-Engines 2018a). No entanto ambas as SGBD têm uma oferta muito semelhante, apresentando todos os requisitos do sistema proposto nesta dissertação. Contudo, o MySQL é preterido pelo PostgreSQL, uma vez que o mesmo não é totalmente um SGBD de código livre, uma vez que as versões mais completas são comerciais. O PostgreSQL tem apresentado o maior crescimento de popularidade, entre os dois (DB-Engines 2018b) e é totalmente livre.

Em relação ao processo de aprendizagem automática, tendo em conta as diferentes características das *frameworks* analisadas na Secção 2.3.3, pretende-se utilizar o software R (R Core Team 2016). A escolha resulta da necessidade de adotar uma solução compatível com a linguagem Java (linguagem necessária à implementação da *framework* JADE) e que ao mesmo tempo ofereça estabilidade e crescimento no presente e no futuro. Para além do R, as *frameworks* WEKA, Shogun e mlpack também podem ser utilizadas a partir da linguagem Java. No entanto, entre elas, apenas o WEKA e o Shogun oferece um maior controlo dos algoritmos que disponibiliza, contrariamente ao mlpack que apenas permite a execução dos seus algoritmos (quando utilizada a partir do Java). O que favorece o R, comparativamente ao WEKA e o Shogun, é o critério da adoção pela comunidade de aprendizagem automática e perspectiva de crescimento, uma vez que os seus pacotes são frequentemente atualizados e estão constantemente a surgir novos pacotes. Contudo, o sistema a desenvolver não deve estar restrito a uma única ferramenta, permitindo a fácil inclusão de ferramentas alternativas como o WEKA e o Shogun, que podem acrescentar valor ao sistema.

Nas secções iniciais deste capítulo, são apresentados os modelos de apoio à decisão para cada fase de negociação considerada: Pré-Negociação (Secção 3.1) e Negociação (Secção 3.2). O modelo de dados da base de dados onde será armazenada toda a informação do sistema, é apresentado na Secção 3.3. Por último, na Secção 3.4, são apresentados os agentes que constituem o SMA, assim como as suas interações.

3.1 Modelo de Apoio à Decisão para Pré-Negociação

A Figura 3.1 apresenta o processo de seleção de oponente(s) na fase de pré-negociação. Inicialmente, o processo é descrito na perspectiva da abordagem de teoria de jogos (Aumann 2017) e, posteriormente, é apresentada a abordagem alternativa de otimização (Rustagi 2014).

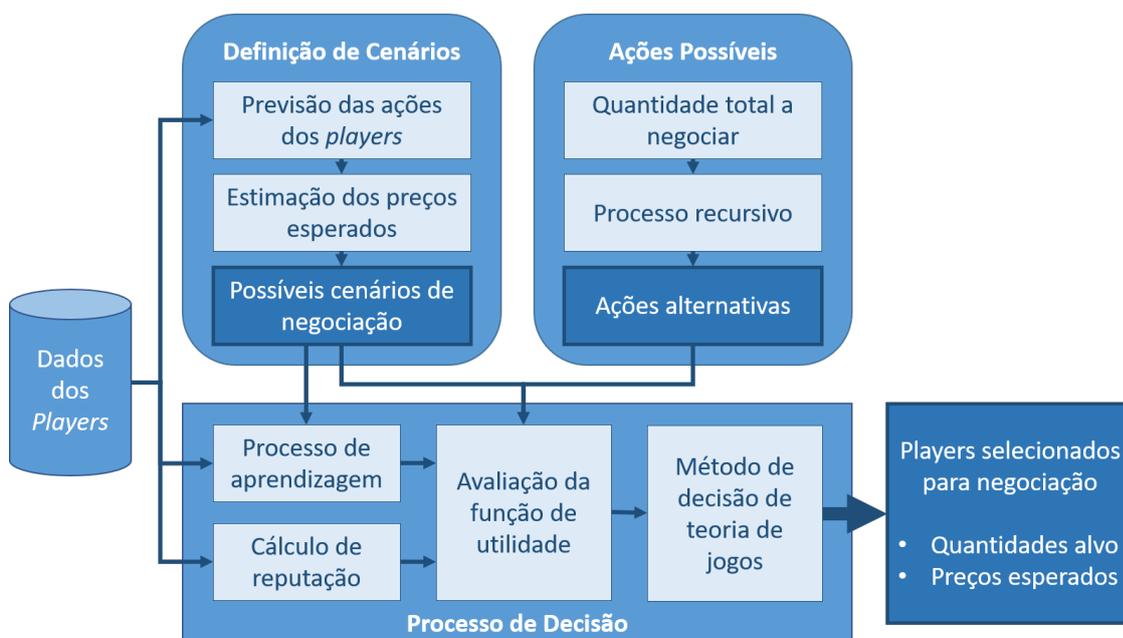


Figura 3.1: Processo de decisão na fase de pré-negociação, baseado em teoria de jogos.

O processo apresentado na Figura 3.1 é iniciado após a especificação dos seguintes dados de entrada, por parte do *player* apoiado:

- Lista de possíveis oponentes;
- Quantidade de energia a transacionar;
- Tipo de transação (compra ou venda);
- Data da negociação;
- Pesos relacionados com o cálculo de reputação;
- Percentagem de risco;
- Método de decisão.

Após a especificação dos dados de entrada, são apresentados os módulos de identificação de contexto (Secção 3.1.1) e de avaliação de reputação (Secção 3.1.2). De seguida são apresentados os três sub-processos identificados na Figura 3.1: Definição de Cenários (Secção 3.1.3), Ações Possíveis (Secção 3.1.4) e Processo de Decisão (Secção 3.1.5). Por último, é apresentado uma abordagem alternativa à teoria de jogos, através da aplicação de métodos de otimização (Secção 3.1.6).

3.1.1 Módulo de Identificação de Contexto

O módulo de identificação de contexto é responsável por analisar os dados históricos de contratos estabelecidos, presentes no sistema, de forma a identificar os diferentes contextos em que as negociações ocorreram. Para esse efeito, são utilizadas as seguintes técnicas:

1. *Clustering* (Agrupamento automático) – Através desta técnica é possível agrupar os períodos de negociação, num determinado número de grupos, de acordo com as suas semelhanças.
 - K-means (MacQueen 1967; Xiaoman et al. 2017)
2. Classificação – Técnica usada para atribuir um contexto a uma nova negociação, tendo em conta os resultados obtidos pelo processo de *Clustering*.
 - C5.0 (Ojha et al. 2017)

Para ser possível identificar o contexto de negociação atual, este módulo começa por gerar todos os diferentes contextos de negociação que ocorrem ao longo de uma semana. Para esse efeito são seguidos os seguintes passos:

1. Recolha de dados históricos das últimas x semanas (parâmetro configurável) do preço de energia do mercado diário.
2. Agregação dos dados das diferentes semanas de forma a criar uma única semana que as represente. O valor de cada período da semana gerada é equivalente à média ponderada dos valores do mesmo período em cada uma das semanas analisadas. A média ponderada permite atribuir diferentes pesos às várias semanas de forma a valorizar mais as semanas mais recentes. Desta forma, este módulo é capaz de se adaptar rapidamente a alterações de comportamento nos mercados de energia.
3. Execução do algoritmo de *clustering* de forma a agregar os valores ao longo da semana num determinado número de grupos. O número de grupos mais apropriado é determinado através do método da silhueta. Este método permite avaliar o grau de similaridade de um objeto em relação ao seu grupo, comparativamente com o seu grau de semelhança com os restantes grupos. Ao testar a agregação com diferentes números de grupos, é possível verificar qual o número de grupos com maior média do valor da silhueta.
4. Gravação na base de dados dos diferentes contextos e os períodos a que os mesmos correspondem.
5. Execução do algoritmo de classificação, treinado pelos diferentes contextos presentes na base de dados, de forma a identificar qual o contexto correspondente ao período da semana atual.

Os passos 1 a 4 são repetidos diariamente de forma a capturar novos contextos de negociação que possam surgir após um novo dia de negociação.

Após a deteção dos diferentes contextos, também é calculado o grau de similaridade entre contextos ao aplicar a Equação 3.1.

$$S_{c_a, c_b} = 1 - \left(\frac{|P_{c_a} - P_{c_b}|}{\max(P_{c_a}, P_{c_b})} \right) \quad (3.1)$$

Em que S_{c_1, c_2} é o grau de similaridade entre os contextos c_1 e c_2 . P_{c_a} e P_{c_b} representam o preço médio do contexto a e b , respetivamente.

A metodologia de identificação de contexto apresentada foi desenvolvida com um elevado nível de abstração, de forma a permitir gerar contextos temporais em diferentes domínios. Para além dos diferentes contextos de negociação, esta metodologia também já foi aplicada à geração dos diferentes contextos de utilização de vários recursos de um edifício (consumo das luzes, intensidade das luzes, porta aberta/fechada, consumo de uma divisão/zona, consumo do sistema de ar condicionado, etc.) (Silva, Gabriel Santos et al. 2018). Desta forma é possível compreender os diferentes padrões de utilização assim como identificar situações de alarme (consumos inesperados, avarias, etc.).

Para além do módulo de identificação de contexto, também o módulo de avaliação de reputação tem um papel importante no processo de apoio à decisão na fase de pré-negociação.

3.1.2 Módulo de Avaliação de Reputação

A reputação de cada oponente é calculada tendo em conta os seguintes componentes (baseado no sistema REGRET (Bidgoly e Ladani 2016; Sabater e Sierra 2001)) e especificado em (Tiago Pinto, Vale, Isabel Praça et al. 2015).

A reputação R_p do player p é avaliada da perspetiva do player apoiado sp . Para esse efeito são considerados dois componentes: o componente individual $R_{sp,p}$, que representa as observações diretas e experiência do player apoiado com o player alvo; e o componente social R_s , considerando a perspetiva do grupo em que cada player está inserido, assim como o preconceito em relação ao tipo de player. Todos os componentes de reputação variam entre 0 e 1. R_p é definido na Equação 3.2.

$$R_p = w_i R_{sp,p} + w_s R_s \quad (3.2)$$

Em que w_i e w_s são os pesos atribuídos aos componentes individual e social, respetivamente. A soma de ambos os pesos é igual a 1 e deve refletir a confiança que o player apoiado tem an sua própria experiência e na experiência dos outros *players*.

$R_{sp,p}$ é atualizado sempre que uma nova observação está disponível. O valor de $R_{sp,p}$ é afetado por cada experiência positiva ou negativa do player apoiado com o player alvo conforme definido na Equação 3.3.

$$R_{sp,p} = \frac{NPE}{TNE} \quad (3.3)$$

em que NPE representa o número de experiências positivas e TNE o número total de experiências que o player apoiado teve com o player alvo.

O componente social R_s é definido através da Equação 3.4.

$$R_s = w_{gp} R_{sp, Gp} + w_{gsp} R_{Gsp, p} + w_g R_{Gsp, Gp} + w_p P_s \quad (3.4)$$

Em que $R_{sp, Gp}$ representa a reputação do grupo do player alvo da perspetiva do player apoiado; $R_{Gsp, p}$ representa a reputação do player alvo da perspetiva do grupo do player

apoiado; $R_{Gsp,Gp}$ representa a reputação do grupo do player alvo do ponto de vista do grupo do player apoiado; e P_s é o componente de preconceito.

$R_{sp,Gp}$ é definido ao considerar a reputação individual de todos os membros que fazem parte do grupo do player alvo, conforme definido na Equação 3.5.

$$R_{sp,Gp} = \sum_{p_i \in Gp} (w_{sp,p_i} R_{sp,p_i}) \quad (3.5)$$

Em que $\sum_{p_i \in Gp} w_{sp,p_i} = 1$. R_{sp,p_i} é a reputação do membro i do grupo do player alvo do ponto de vista do player apoiado sp ; e w_{sp,p_i} representa o peso que é dado a cada reputação individual dos membros do grupo. Esses pesos podem ser definidos de acordo com a similaridade de cada membro do grupo com o player alvo.

$R_{Gsp,p}$ é definido ao ter em conta a opinião de cada player que pertence ao grupo do player apoiado, em relação à reputação do player alvo, conforme definido na Equação 3.6.

$$R_{Gsp,p} = \sum_{gsp_i \in Gsp} (w_{gsp_i,p} R_{gsp_i,p}) \quad (3.6)$$

Em que $\sum_{gsp_i \in Gsp} w_{gsp_i,p} = 1$. $R_{gsp_i,p}$ é a reputação do player alvo da perspectiva de cada membro i do grupo do player apoiado; e $w_{gsp_i,p}$ representa o peso que é dado a cada uma das reputações individuais dos membros do grupo. $R_{Gsp,Gp}$ é definido ao ter em conta a opinião de cada membro do grupo do player apoiado em relação à reputação de cada membro do grupo do player alvo, conforme definido na Equação 3.7.

$$R_{Gsp,Gp} = \sum_{gsp_i \in Gsp} (w_{gsp_i,Gp} R_{gsp_i,Gp}) \quad (3.7)$$

Em que $\sum_{gsp_i \in Gsp} w_{gsp_i,Gp} = 1$. $R_{gsp_i,Gp}$ é a reputação do grupo do player apoiado do ponto de vista de cada membro i do grupo do player apoiado; este valor é obtido ao aplicar a Equação 3.5 da perspectiva de cada membro do grupo do player apoiado. $w_{gsp_i,Gp}$ representa o peso que é dado a cada uma das reputações individuais dos membros do grupo.

Após a análise do módulo de avaliação de reputação, a secção 3.1.3 apresenta o primeiro sub-processo de apoio à fase de pré-negociação.

3.1.3 Definição de Cenários

Na Definição de Cenários são analisados os dados históricos (contratos previamente estabelecidos) de cada oponente na lista previamente selecionada pelo *player* apoiado. No entanto, para essa análise, é necessária a identificação prévia do contexto de negociação. O comportamento de cada oponente pode variar muito consoante o contexto em que o mesmo está inserido. A deteção do contexto de negociação permite limitar a análise de dados históricos dos oponentes aos contratos estabelecidos no mesmo contexto.

A partir dos dados históricos de cada oponente para o mesmo contexto de negociação, são gerados vários cenários. A denominação de cenário está associada ao conjunto de

preços esperados para cada oponente para as várias quantidades de energia possíveis (entre o valor mínimo negociável e a energia total que o *player* apoiado deseja transacionar), num determinado contexto. Os preços esperados são determinados ao aplicar um algoritmo de previsão. Numa fase inicial são considerados os seguintes algoritmos:

- Média simples
- Máquinas de Suporte Vetorial (MSV) (Suthaharan 2016)
- Redes Neurais Artificiais (RNA) (Da Silva et al. 2017)

Cada cenário é gerado por um algoritmo diferente. No entanto, o mesmo algoritmo pode ser utilizado para gerar mais do que um cenário, ao aplicar uma utilização diferenciada do mesmo. A diferença pode estar relacionada com os parâmetros do algoritmo, quantidade de dados de treino ou tipo de dados de treino considerados. Uma vez que o sistema deve permitir a fácil adição de novos algoritmos de previsão, o sistema permite a geração de uma infinidade de cenários.

Após a previsão dos preços esperados, é realizada uma estimativa de preços para as quantidades de energia que não puderam ser previstas. Isto acontece quando não há um mínimo de dados históricos relativos a essas quantidades de energia. Nesses caso é aplicada uma metodologia de estimação baseada em lógica difusa, que determina os preços em falta, tendo em conta os preços previstos para as restantes quantidades de energia.

No fim deste processo são obtidos vários cenários para o contexto em que a negociação irá decorrer. Em simultâneo com este processo, é executado o processo de determinação das ações possíveis.

3.1.4 Ações Possíveis

Neste sub-processo, são geradas todas as ações que o *player* apoiado pode tomar em cada cenário. Uma ação é uma distribuição possível da quantidade total a transacionar pelos vários oponentes possíveis. Para cada cenário, são geradas todas as distribuições possíveis, desde transacionar a quantidade total com apenas um dos oponentes, até dividir a quantidade total por todos os oponentes. A Tabela 3.1 apresenta um exemplo de geração de todas as ações possíveis para um cenário em que o *player* apoiado pretende negociar 3 MWh e selecionou 2 possíveis oponentes.

Tabela 3.1: Exemplo de ações possíveis.

Ação	Oponente 1	Oponente 2
1	3 MWh	0 MWh
2	2 MWh	1 MWh
3	1 MWh	2 MWh
4	0 MWh	3 MWh

Após os processos de Definição de Cenários e determinação das Ações Possíveis, é iniciado o processo de Decisão.

3.1.5 Processo de Decisão

O Processo de Decisão é iniciado pela avaliação da função de utilidade, onde é determinada a utilidade de cada ação em cada cenário, segundo formulação especificada em (Tiago Pinto, Vale, Isabel Praça et al. 2015). Este sub-processo é iniciado após o processo de aprendizagem (resultante da Definição de Cenários), e a avaliação de reputação de cada oponente (ver Secção 3.1.2). A utilidade de cada ação é determinada através da Equação 3.8.

$$U_{as} = rE'_{as} + (1 - r)R_a \quad (3.8)$$

Em que r é o nível de risco que o player apoiado está disposto a correr, entre 0 e 1. E'_{as} é o ganho económico normalizado (lucro no caso de venda e custo no caso de compra, assumindo valores entre 0 e 1) de realizar a ação a no cenário s , e R_a é o componente da reputação que resulta ao negociar as quantidades definidas em a com cada um dos oponentes (também entre 0 e 1).

Ambos os componentes de reputação e economia variam entre 0 e 1, de forma a terem o mesmo impacto no valor de utilidade final, dependendo apenas do risco. O componente de reputação R_a é definido na Equação 3.9.

$$R_a = \sum_{p=1}^{np} R_p \frac{A_{ap}}{TP} \quad (3.9)$$

Em que p representa cada oponente entre a lista de oponentes possíveis np . R_p é a reputação do player p , entre 0 e 1. A_{ap} é o volume de energia alocado pela ação a para ser negociado com o player p (entre 0 e TP), e TP é o volume total de energia que o player apoiado pretende negociar.

O componente económico E'_{as} define o nível de lucro ou custo, numa escala entre 0 e 1, ao normalizar os valores atuais de lucro/custo E_{as} , conforme apresentado na Equação 3.10.

$$E'_{as} = \begin{cases} \frac{E_{as} - E_{min}}{E_{max} - E_{min}}, & \text{quando o player apoiado está a vender} \\ \frac{E_{max} - E_{as}}{E_{max} - E_{min}}, & \text{quando o player apoiado está a comprar} \end{cases} \quad (3.10)$$

Em que E_{min} é o valor mínimo de E_{as} que resulta de todas as combinações ação-cenário, e E_{max} é o valor máximo de E_{as} entre todas as combinações.

E_{as} representa o valor absoluto de lucro/custo que resulta de transacionar os volume de energia com os oponentes definidos na ação a , com os preços esperados para cada player, resultantes do cenário s , conforme definido na Equação 3.11.

$$E_{as} = \sum_{p=1}^{np} A_{ap} EP_{spA_{ap}} \quad (3.11)$$

Em que $EP_{spA_{ap}}$ é o preço esperado do player p no cenário s , para a quantidade de energia A_{ap} . $EP_{spA_{ap}}$ varia entre 0 e ∞ , dependendo das previsões do preço do contrato.

Em suma, a utilidade de uma ação resulta da média ponderada entre o componente económico e o de reputação. O componente económico representa o benefício económico da

ação enquanto que, o componente de reputação, representa a reputação média dos oponentes envolvidos. O contributo de cada componente é determinado pela percentagem de risco que o *player* apoiado está disposto a correr. Quanto maior o risco, maior o contributo do componente económico face ao componente de reputação. O risco mínimo (0%) apenas considera o componente de reputação enquanto que o risco máximo (100%) considera apenas o componente económico.

Uma vez determinada a utilidade de cada ação de cada cenário, é efetuada a decisão de qual ação recomendar ao *player* apoiado. Para esse fim, o sistema conta com três métodos de decisão:

- Mais Provável – Método de decisão que permite selecionar a ação com maior valor de utilidade, resultante da combinação do cenário mais provável de acontecer na realidade de cada oponente. Para esse fim, todos os cenários gerados são confrontados com os cenários reais, sempre que a informação acerca dos mesmos seja disponibilizada, avaliando o desempenho de cada método de previsão para cada oponente. A avaliação é realizada recorrendo a vários AAR que atualizam a pontuação de cada método de previsão para cada oponente, cada vez que são conhecidos os cenários reais. Os próprios AAR também são avaliados de forma a perceber, ao longo do tempo, qual o AAR mais apropriado. Essa avaliação é realizada através da aplicação de um AAR simples. A ação selecionada é a ação que reúne a maior utilidade ao combinar o cenário mais provável do AAR melhor avaliado de cada oponente.

Numa primeira abordagem, serão considerados os seguintes AAR:

- AAR Simples;
- Q-Learning (B. G. Kim et al. 2016; Watkins e Dayan 1992);
- Roth-Erev (Erev e Roth 1998; Nallur et al. 2016);
- Otimista – A ação selecionada por este método de decisão é a ação com maior utilidade entre todas as ações possíveis de todos os cenários.
- Pessimista – Método de decisão baseado no método minimax de teoria de jogos, em que é selecionada a ação com maior utilidade do cenário com menor utilidade global (soma da utilidade de todas as ações desse cenário).

Uma vez determinada a ação a recomendar, a mesma é enviada ao *player* apoiado, especificando a quantidade a negociar com cada oponente e o preço esperado para cada um.

Após a análise do processo de apoio à decisão na fase de pré-negociação, sob a perspetiva da abordagem de teoria de jogos, a secção 3.1.6 apresenta a abordagem alternativa de otimização.

3.1.6 Otimização

A presente secção (3.1) apresenta o processo de seleção de oponente(s) na fase de pré-negociação, utilizando uma abordagem de teoria de jogos, em que são analisadas todas as ações possíveis. No entanto, tal tarefa pode revelar-se muito complexa e muito demorada, dependendo da quantidade de energia total a transacionar e o número de possíveis

oponentes. Em alternativa o sistema oferece abordagens que utilizam métodos de otimização que procuram obter os melhores resultados possíveis, sem necessitar de testar todas as possibilidades. A abordagem considerada é a seguinte:

- Otimização de um único objetivo – Otimização do benefício económico quando o *player* estiver disposto a correr o risco máximo (100%), ignorando a reputação dos seus oponentes. Para este fim é considerado o método *Particle Swarm Optimization (PSO)* (Otimização baseada em Enxames de Partículas) (Eberhart e Kennedy 1995; Silva, Faia et al. 2018).

Introduzido por Kennedy e Eberhart em 1995 Eberhart e Kennedy 1995, o algoritmo PSO foi inspirado no movimento de organismos em grandes enxames, como é o caso dos bandos de pássaros ou cardumes de peixes. O algoritmo otimiza um problema ao iniciar com um número inicial de partículas, posicionadas aleatoriamente no espaço de procura, e move-las em direção à melhor solução, ao melhorar a sua posição ao longo do tempo. Como resultado, o método é capaz de apresentar bons resultados mas não garante a solução ótima. O algoritmo aplica as equações 3.12 e 3.13 em cada iteração.

$$v_{id}^{k+1} = w \cdot v_{id}^k + c_1 \cdot r_1^k \cdot (Pbest_{id}^k - x_{id}^k) + c_2 \cdot r_2^k \cdot (Gbest_{id}^k - x_{id}^k) \quad (3.12)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (3.13)$$

Em que,

- *Pbest* - melhor posição encontrada por cada partícula,
- *Gbest* - melhor posição de todas as partículas,
- *v* - velocidade da partícula,
- *x* - posição da partícula,
- *k* - iteração,
- *d* - parâmetro,
- *i* - partícula,
- *w* - termo de inércia,
- *c₁* - termo de atração local,
- *c₂* - termo de atração global,
- *r₁*, *r₂* - número aleatório entre [0, 1].

O algoritmo 3.1 apresenta o processo principal do PSO.

Algorithm 3.1 Processo PSO

inicialização das partículas com posições e velocidades aleatórias

```

repeat
  for all partículas do
    calcular nova posição                                ▷ (equações 3.12 e 3.13)
    avaliar a nova posição                              ▷ (equação 3.14)
    if posição atual > Pbest then
      Pbest = posição atual
    end if
    if Pbest > Gbest then
      Gbest = Pbest
    end if
  end for
until critério de paragem                               ▷ Gbest é a solução final

```

Conforme especificado no algoritmo 3.1, o processo do PSO começa com a atribuição de uma posição e uma velocidade aleatória a cada partícula. A cada iteração, a sua posição é atualizada, ao aplicar as equações 3.12 e 3.13, e avaliadas pela função objetivo (equação 3.14). De seguida, se for encontrada uma posição melhor, a mesma torna-se a melhor local e também global se for maior que o valor atual. Quando o critério de paragem é atingido, o processo termina e a solução final é a melhor posição global.

O processo do método PSO depende dos seguintes parâmetros:

- **Tamanho do enxame** - número de partículas do enxame. Quanto maior o tamanho do enxame, maior a área coberta do espaço de procura, a cada iteração; Os grandes enxames reduzem o número de iterações mas aumenta a complexidade e, consequentemente, o tempo de execução para encontrar uma solução boa.
- **Número máximo de iterações** - Este parâmetro deve ser adaptado a cada problema uma vez que o melhor valor é o mínimo que garanta uma boa solução. O valor pode ser demasiado baixo se terminar a procura sem encontrar uma solução boa e demasiado alto se apenas aumentar o tempo de execução sem melhorar a solução final.
- **Termos de atração local e global** - a confiança que uma partícula tem nas suas pesquisas anteriores e nas dos seus vizinhos, respetivamente.
- **Peso de inércia** - o limite para o movimento das partículas que controla o quanto elas podem mover em cada iteração.

A equação 3.14 apresenta a formulação do problema de otimização.

$$f = \begin{cases} \min \left(\sum_{i=1}^{Ni} (A_i \times EP_{i,A}) \right), & \text{se tipo negociação} = 1 \\ \max \left(\sum_{i=1}^{Ni} (A_i \times EP_{i,A}) \right), & \text{se tipo negociação} = 2 \end{cases} \quad (3.14)$$

Em que,

- *i* - player,
- *Ni* - número de *players*,

- A_i - volume de energia a transacionar com o player i ,
- $EP_{i,A}$ - preço esperado do player P para o volume de energia A ,
- Tipo de negociação - 1 quando o player apoiado quer comprar energia e 2 quando quer vender.

Os preços esperados resultam das previsões realizadas pelo sistema e, para cada volume de energia que não foi possível prever, é realizado o processo de estimação. Este processo combina um mecanismo de agregação com uma abordagem difusa (Faia, Tiago Pinto e Vale 2016).

A principal restrição aplicada a este problema é representada pela equação 3.15. Assim é garantido que a soma dos volumes a transacionar com cada player não ultrapassem o total de energia TA que o player apoiado pretende negociar.

$$\sum_{i=1}^{Ni} (A_i) = TA \quad (3.15)$$

Ao utilizar este tipo de abordagem, o sub-processo de determinação das Ações Possíveis, e respetivo cálculo de utilidade são ignorados, uma vez que este tipo de tarefas passam a ser realizadas pelo algoritmo de otimização. No entanto os métodos de decisão são mantidos, mas com menos implicações no resultado final. O método de decisão passa a permitir apenas a seleção dos cenários a enviar para o algoritmo de otimização.

Após a análise do modelo de apoio à decisão para a pré-negociação, é realizada a análise do modelo de apoio à decisão da fase seguinte, a negociação em si.

3.2 Modelo de Apoio à Decisão para Negociação

Para o apoio à decisão na fase de negociação, o sistema recorre à rede de aprendizagem apresentada na Figura 3.2, para identificar a melhor estratégia de negociação que o *player* apoiado deve seguir.

A rede de aprendizagem é inspirada no funcionamento dos métodos de RNA. A rede contém quatro nós na camada de entrada, três camadas ocultas e um nó na camada de saída.

Na primeira camada, estão presentes quatro nós de entrada:

- 1.1 - Base de Conhecimento dos *players* – informação que o *player* apoiado recolhe de outros *players* acerca da melhor estratégia a utilizar durante a negociação com determinado oponente. O contributo da informação partilhada por cada *player* depende da reputação do mesmo. O cálculo da reputação, apresentado na Secção 3.1.2, combina a opinião pessoal do *player* apoiado com a opinião social acerca do mesmo. A opinião pessoal do *player* apoiado acerca de determinado oponente depende da sua credibilidade (Weng et al. 2010), ou seja, a qualidade da informação partilhada pelo mesmo. A credibilidade de cada *player* é atualizada de acordo com os resultados obtidos ao seguir a sua recomendação.

- 1.2 - Base de Conhecimento do sistema – semelhante ao nó 1.1 mas do ponto de vista do *player* apoiado. Avaliação de cada estratégia para cada oponente tendo em conta a sua experiência de negociação com o mesmo, utilizando os AAR.
- 1.3 - Contexto – contexto de negociação identificado pelo módulo de deteção de contexto apresentado na Secção 3.1.1.
- 1.4 - Oponente – identificação do oponente em questão.

De seguida, na primeira camada oculta são executados dois nós:

- 2.1 - Contextos semelhantes – neste nó é determinado o grau de semelhança de cada contexto presente no sistema, em relação ao contexto de negociação identificado no nó 1.3. O contributo de cada contexto, na recomendação final, é medido pelo seu grau de semelhança.
- 2.2 - Perfis semelhantes – num raciocínio semelhante ao verificado no nó 2.1, este nó determina o grau de semelhança do perfil de negociação do oponente em questão, em relação aos restantes perfis de negociação considerados no sistema. O perfil do oponente é determinado pelo módulo de identificação de perfis (apresentado na secção seguinte). Assim como no nó 2.1, o contributo de cada perfil é medido pelo seu grau de semelhança ao perfil do oponente em questão.

A segunda camada oculta está separada em dois nós que combinam a informação obtida nas duas camadas anteriores:

- 3.1 - Outros – Neste nó é considerada toda a informação partilhada por outros *players*:
 - 3.1.1 - Informação Geral – relativa a todos os *players* no geral;
 - 3.1.2 - Informação Perfil – relativa aos *players* com perfis semelhantes, conforme identificado no nó 2.2;
 - 3.1.3 - Informação Oponente – relativa ao oponente em questão.

Esse processo é repetido para cada contexto semelhante, identificado no nó 2.1.

- 3.2 - Sistema – Este nó apresenta o mesmo funcionamento do nó 3.1, com a diferença de considerar apenas a informação pessoal do *player* apoiado.

Por último, na quinta camada, é obtido o resultado final que consiste no grau de recomendação de cada estratégia para ser utilizada numa negociação com um determinado oponente. Para esse fim, a contribuição de cada nó da segunda e terceira camadas é medida por um peso que representa a qualidade das recomendações obtidas através de cada um. Ao longo do tempo o sistema vai ajustando os pesos de forma a dar maior importância aos nós com melhor impacto no resultado final da negociação. Numa primeira fase são considerados dois métodos alternativos de atribuição de pesos e propagação:

- Média ponderada;
- Fatores de certeza (Hussain, Bui e H.-M. Kim 2016; Walley 1996).

De forma a determinar o método mais apropriado, é utilizado um AAR para esse efeito, responsável por avaliar o desempenho de cada método ao longo do tempo, de acordo com os resultados da negociação.

A avaliação de cada estratégia é realizada pelos vários AAR presentes no sistema, também aplicados na fase de pré-negociação, em também eles são avaliados por um AAR simples de forma a determinar o AAR a considerar em cada momento.

A rede de aprendizagem é executada a cada oferta/contra-oferta do oponente, atualizando o perfil de negociação do oponente, e conseqüentemente reavaliando o valor de confiança nas estratégias recomendadas.

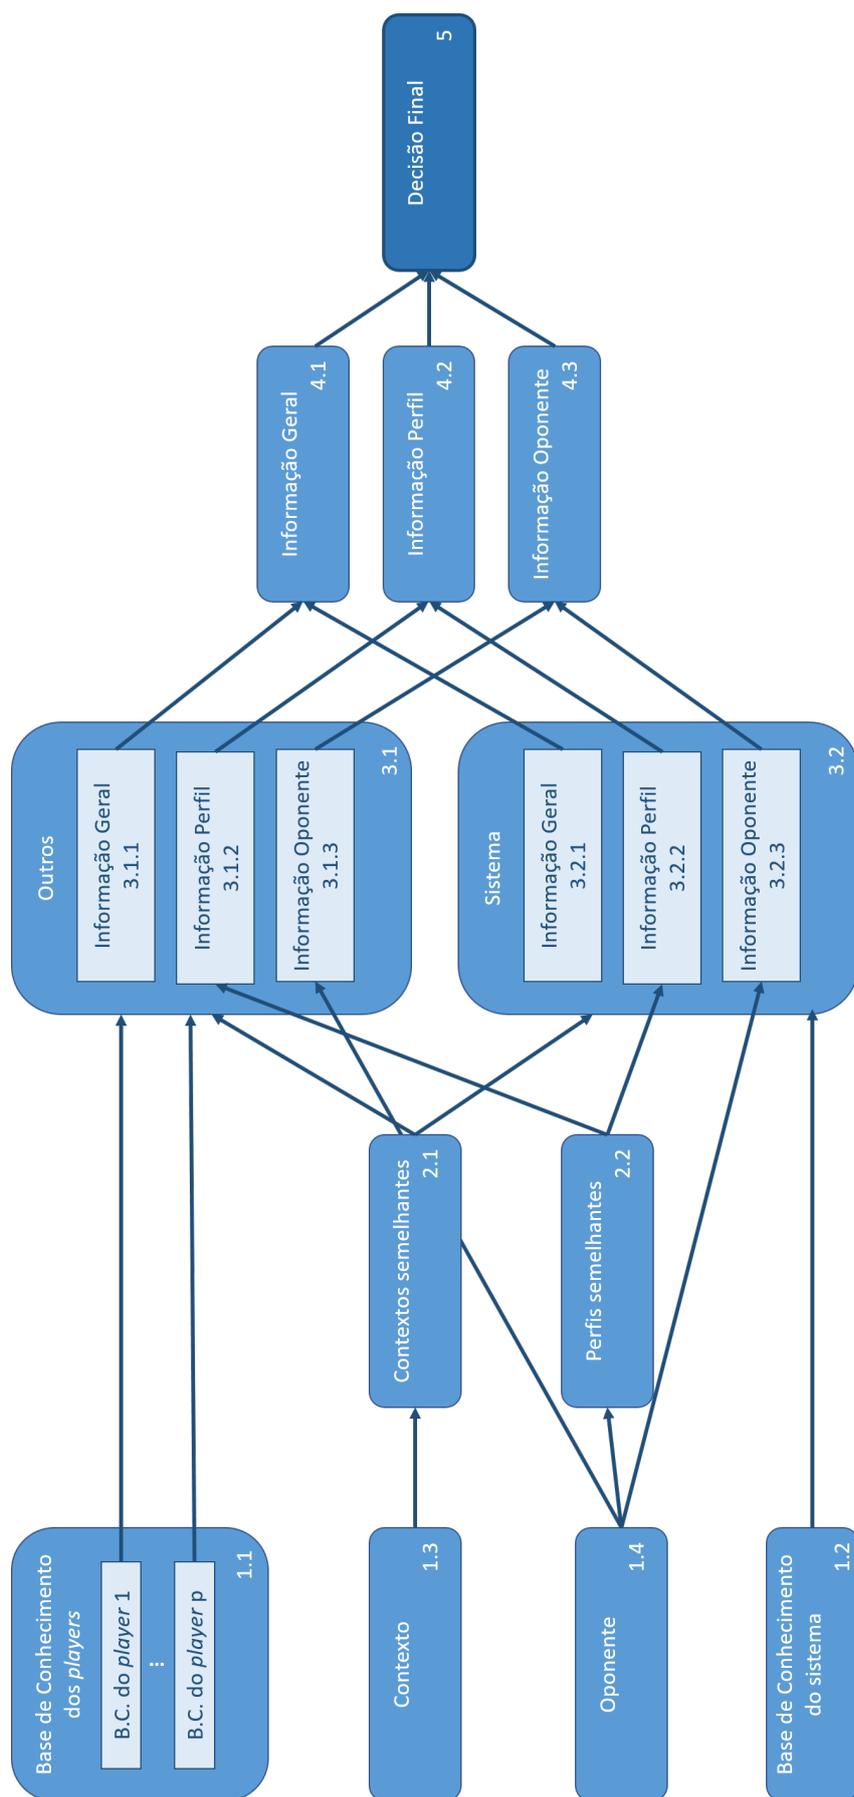


Figura 3.2: Rede de aprendizagem.

Conforme analisado na presente secção, o módulo de identificação de perfis tem um grande impacto no processo de apoio à decisão na fase de negociação.

3.2.1 Módulo de Identificação de Perfis

O módulo de identificação de perfis é responsável por analisar as ofertas/contra-ofertas de determinado *player*, confronta-las com os perfis de negociação presentes no sistema e identificar qual o que melhor representa o comportamento do *player*.

A identificação de perfis é realizada através da aplicação das mesmas técnicas usadas no módulo de identificação de contexto (apresentadas na Secção 3.1.1).

Numa fase inicial são consideradas as seguintes estratégias:

- Estratégias dependentes do tempo – evolução da estratégia do *player* a cada oferta/contra-oferta. As estratégias são aplicáveis tanto no caso de compra como venda, apenas invertendo a tendência das ofertas (subida/descida de preço).
 - Determinado – o *player* mantém sempre o mesmo preço;
 - Moderado – o preço altera-se de forma constante;
 - Guloso – no início o preço sofre pequenas alterações mas numa fase posterior, o *player* faz grandes alterações ao preço apresentado;
 - Ansioso – contrariamente ao perfil Guloso, este perfil apresenta grandes alterações no início e pequenas no fim;
 - Descida percentual – semelhante ao perfil Moderado, com a diferença de se alterar consoante uma determinada percentagem em vez de um valor fixo.
- Estratégias dependentes do comportamento – estratégias que variam consoante o comportamento apresentado pelo oponente. O preço altera-se ao longo das ofertas/contra-ofertas seguindo uma percentagem relativa à variação percentual do preço apresentado pelo oponente.
- Estratégias combinadas – combinação de duas ou mais estratégias ao longo da negociação. O *player* segue cada uma dessas estratégias durante um determinado número de ofertas.
 - Guloso+Ansioso
 - Guloso+Ansioso+Guloso
 - Ansioso+Guloso+Ansioso
 - Guloso+Ansioso+Guloso+Ansioso+Guloso

Assim como no módulo de identificação de contextos, neste módulo também é determinado o grau de similaridade entre as diferentes estratégias, aplicando a Equação 3.16.

$$S_{s_a, s_b} = 1 - \left(\frac{D_{s_a, s_b}}{D_{max}} \right) \quad (3.16)$$

Em que S_{s_a, s_b} é a similaridade entre as estratégias s_a e s_b . D_{s_a, s_b} é a distância euclidiana entre as duas estratégias definida pela Equação 3.17 e D_{max} é a distância máxima entre duas estratégias após comparar todas as estratégias.

$$D_{s_a, s_b} = \sqrt{\sum_{i=1}^n (P_{s_a, i} - P_{s_b, i})^2} \quad (3.17)$$

Em que i é a iteração da estratégia e n é o número total iterações das estratégias. $P_{s_a, i}$ representa o preço P da estratégia s_a na iteração i , enquanto que $P_{s_b, i}$ é relativo à estratégia s_b .

Após a análise dos modelos de apoio à decisão nas fases de negociação suportadas, surge na secção 3.3 a análise do modelo de dados essencial à implementação dos mesmos.

3.3 Modelo de Dados

O modelo de dados do sistema proposto está dividido em várias figuras de forma a facilitar a sua interpretação e distinguir os diferentes conceitos de cada fase de negociação. As Figuras 3.3, 3.4 e 3.5 são relativas à fase de pré-negociação enquanto que as Figuras 3.6 e 3.7 correspondem à fase de negociação.

A Figura 3.3 apresenta o modelo de dados para registo do *Player*, Contexto, Contrato e Reputação.

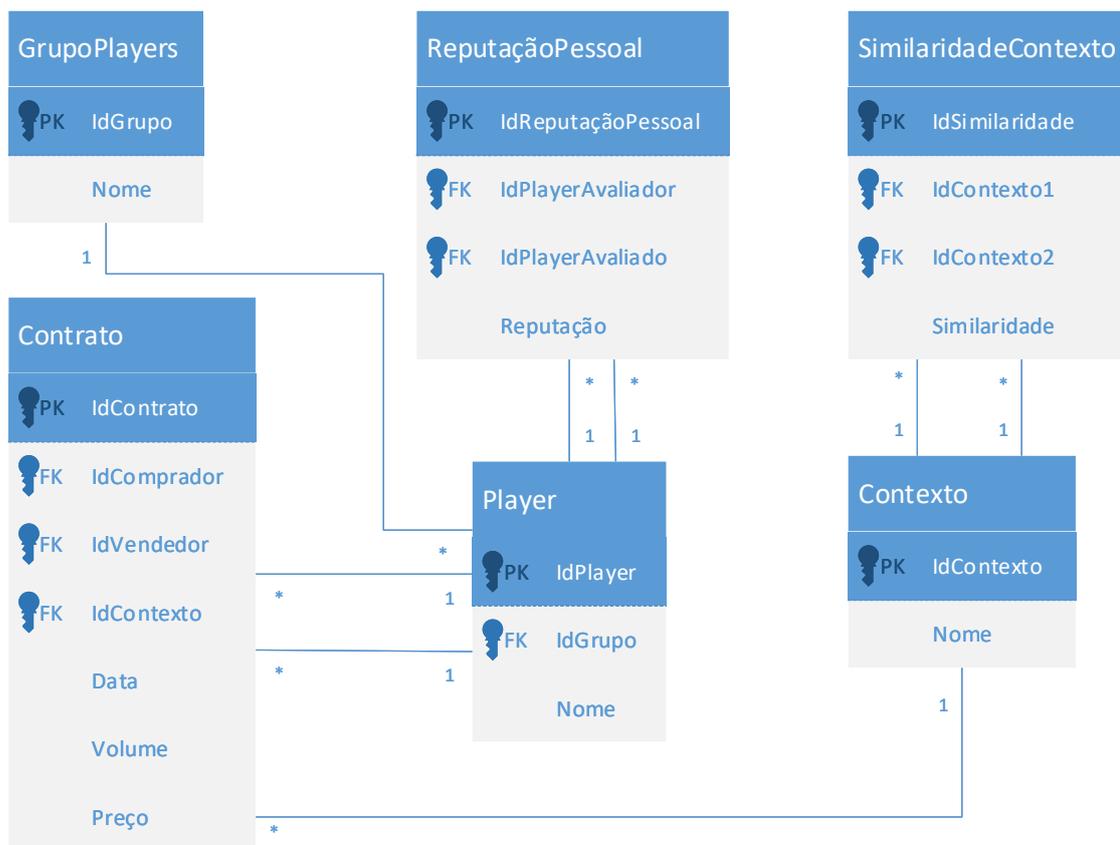


Figura 3.3: Modelo de dados [UML] relativo ao *Player*, *Contexto*, *Contrato* e *Reputação*.

Na Figura 3.3 é possível verificar que cada *player* pertence a um grupo de *players*, tem um histórico de contratos estabelecidos como comprador ou vendedor, e tem uma opinião acerca da reputação dos outros *players*, assim como os outros *players* podem ter sobre si. Os contratos são estabelecidos num determinado contexto e cada contexto tem um grau de similaridade com os restantes contextos (valor entre 0 e 1 em que quanto maior o valor maior o grau de similaridade).

A Figura 3.4 apresenta o modelo de dados relativo ao processo de previsão e aprendizagem por reforço.

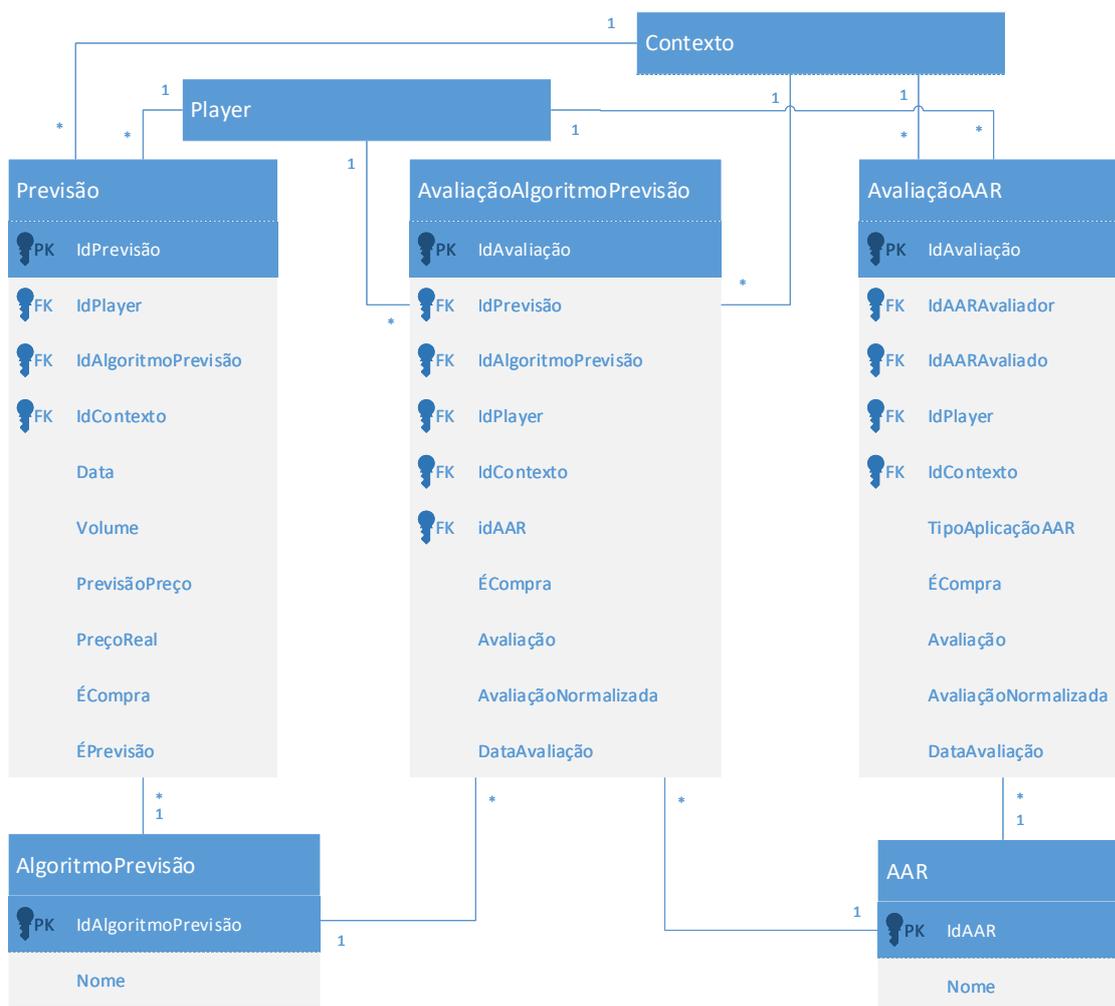


Figura 3.4: Modelo de dados [UML] relativo ao processo de previsão e aprendizagem por reforço.

Conforme se pode observar na Figura 3.4, cada previsão de preço, para um determinado volume de energia, realizada pelo sistema é registada na tabela *Previsão*, ficando associada ao *player* alvo, algoritmo de previsão utilizado, e contexto de negociação, com o intuito de permitir uma futura avaliação do desempenho desse algoritmo. O campo *ÉPrevisão* permite saber se o valor foi gerado por um algoritmo de previsão ou por um algoritmo de estimação. A avaliação dos algoritmos de previsão é registada na tabela *AvaliaçãoAlgoritmoPrevisão*, estando associada ao AAR avaliador; ao algoritmo de previsão; o *player* alvo da previsão; e o contexto da negociação. O próprio AAR também é alvo de uma avaliação que é registada na tabela *AvaliaçãoAAR*, estando associada ao AAR avaliador e ao AAR avaliado. Esta tabela contém um campo denominado *TipoAplicaçãoAAR* com o intuito de especificar se a avaliação do AAR é relativa à sua utilização na fase de pré-negociação (avaliação dos algoritmos de previsão) ou na fase de negociação (avaliação das estratégias).

A Figura 3.5 apresenta o modelo de dados relativo ao processo de geração de todas as ações possíveis e avaliação da sua utilidade.

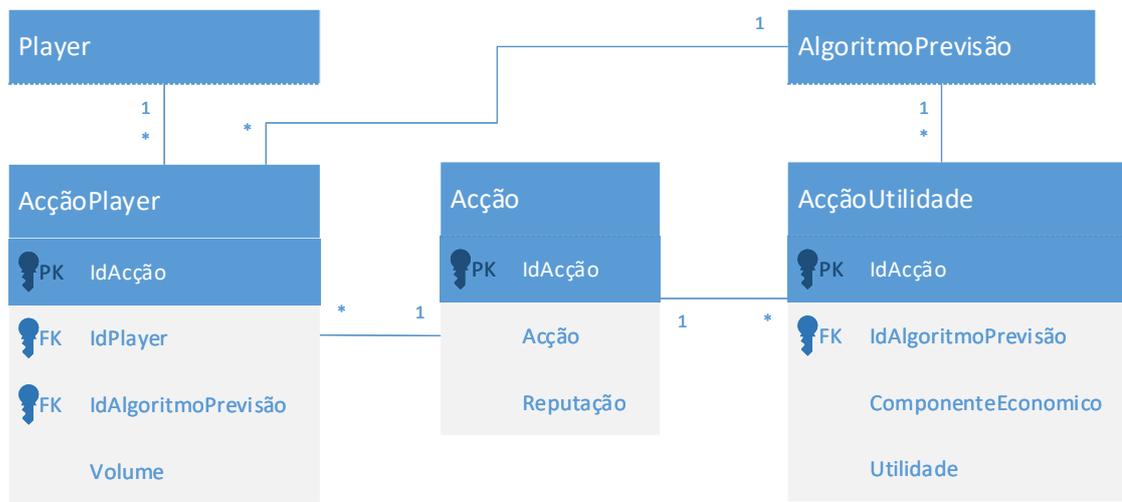


Figura 3.5: Modelo de dados [UML] relativo ao processo de geração de todas as ações possíveis e avaliação da sua utilidade.

O processo de geração de todas as ações possíveis pode tornar-se muito complexo e pesado quando se considera volumes de energia e número de oponentes maiores. Para contornar essa questão, as ações são temporariamente gravadas em tabelas de forma a serem facilmente manipuladas durante o processo de avaliação da sua utilidade e seleção da melhor ação. Conforme apresentado na Figura 3.5, a tabela *Acção* contém cada distribuição possível do volume de energia a transacionar pelos possíveis oponentes assim como o valor do componente reputação para o cálculo da utilidade da ação. Cada *player* participante na ação e o volume de energia a transacionar é especificado na tabela *AcçãoPlayer*, para cada algoritmo de previsão existente. O segundo componente para o cálculo da utilidade de cada ação, o componente económico, e o valor final da utilidade são registados na tabela *AcçãoUtilidade*.

A Figura 3.6 apresenta o modelo de dados para registo das estratégias de negociação.

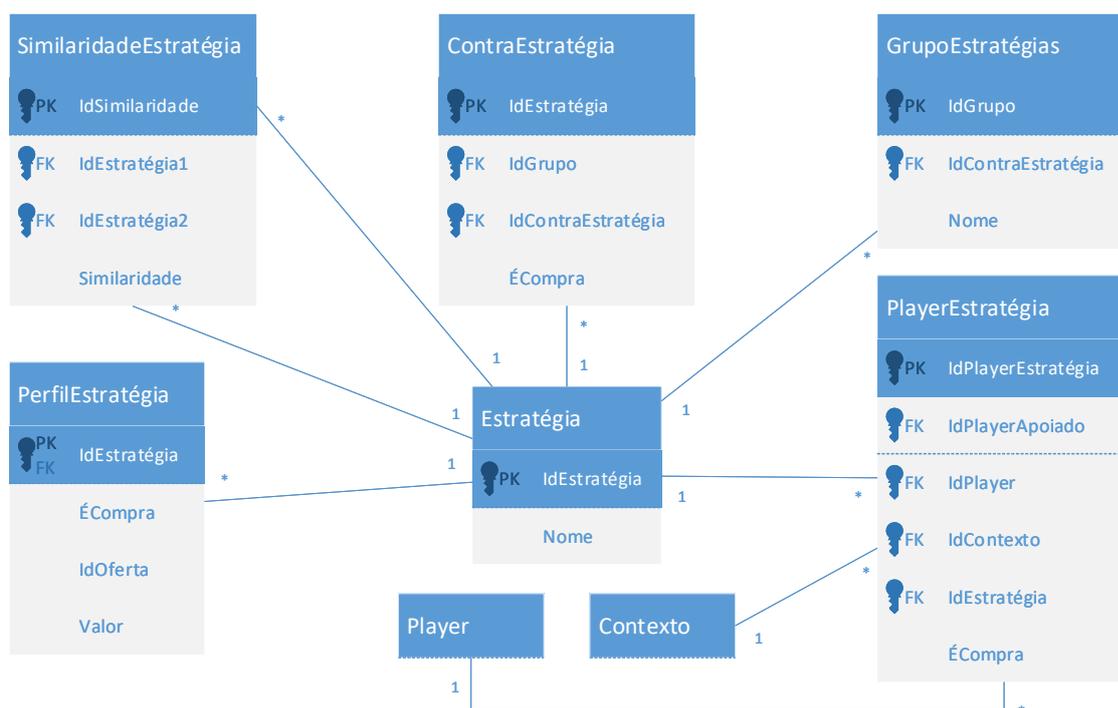


Figura 3.6: Modelo de dados [UML] para registo das estratégias de negociação.

As tabelas apresentadas na Figura 3.6 permitem o registo das diferentes estratégias de negociação assim como o grupo a que cada uma pertence; as suas contra estratégias individuais e enquanto grupo de estratégias; a similaridade entre as diferentes estratégias (valor entre 0 e 1 em que quanto maior o valor maior o grau de similaridade); o perfil de negociação de cada estratégia tanto no momento de compra como de venda de energia. Por último, é também registada a estratégia de negociação de cada oponente de acordo com a experiência do *player* apoiado.

A Figura 3.7 apresenta o modelo de dados para registo e avaliação das estratégias, fontes de informação e métodos de pesagem.

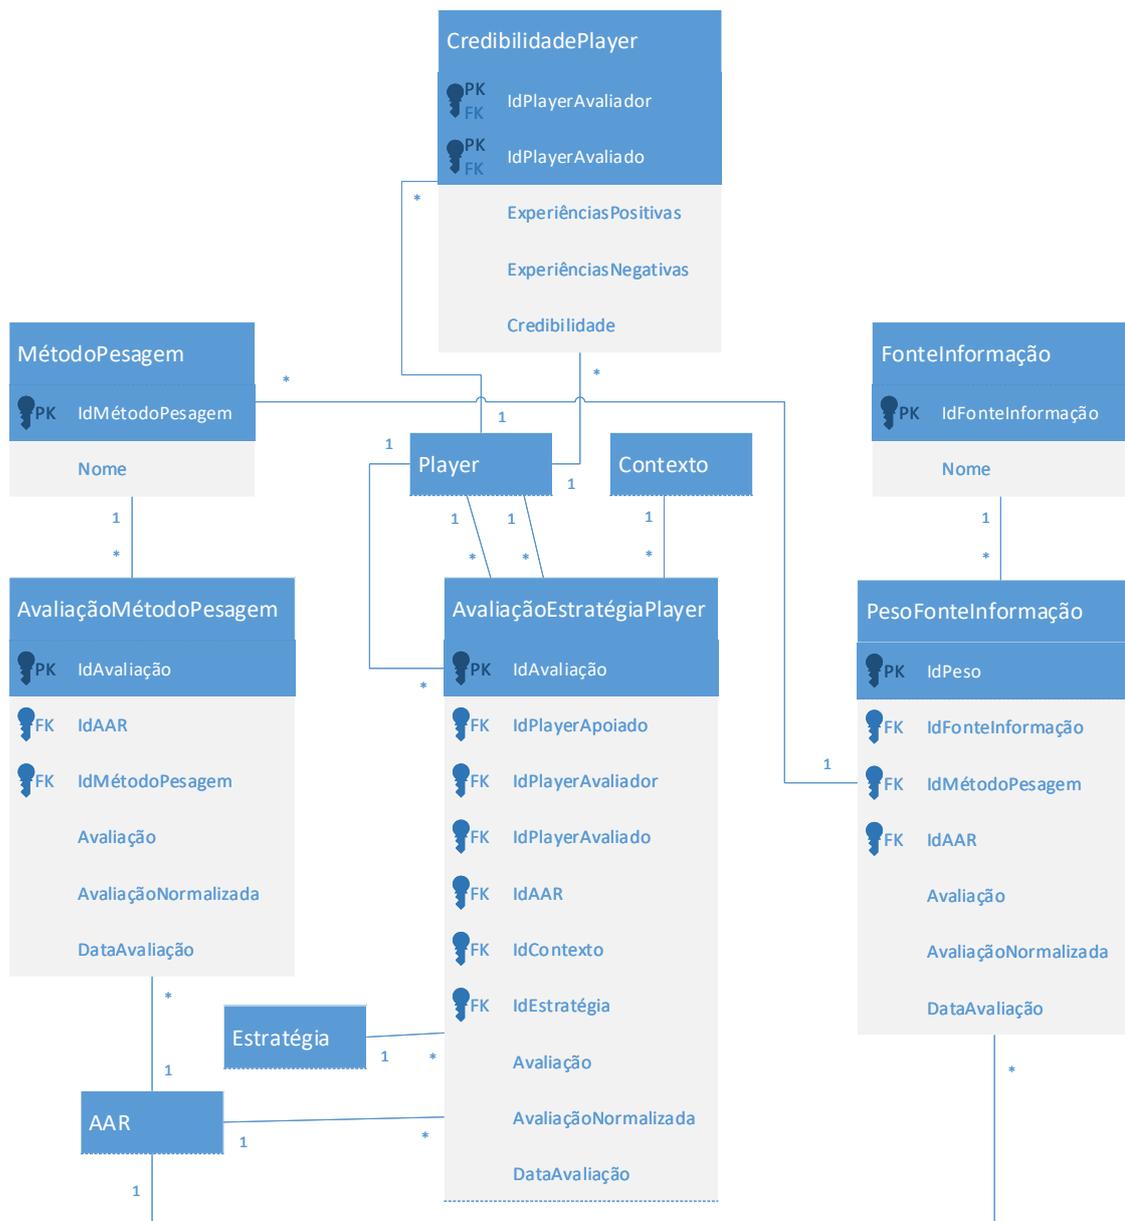


Figura 3.7: Modelo de dados [UML] para registo e avaliação das estratégias, fontes de informação e métodos de pesagem.

Conforme se pode observar na Figura 3.7, as diferentes fontes de informação são registadas na tabela *FonteInformação* enquanto que o peso que cada uma tem na rede de aprendizagem é atualizado na tabela *PesoFonteInformação*, através do AAR superior. O peso é atribuído por um dos métodos de pesagem presentes em *MétodoPesagem*, que também são avaliados pelo AAR superior, na tabela *AvaliaçãoMétodoPesagem*. Na tabela *AvaliaçãoEstratégia-Player* é registada a opinião partilhada ao *player* apoiado por um *player* acerca da melhor estratégia a usar numa negociação com outro *player*, num determinado contexto. A opinião própria do *player* apoiado é registada ao considerá-lo o *player* avaliador. De forma a validar a opinião partilhada pelos outros *players*, o *player* apoiado tem na tabela *CredibilidadePlayer* a credibilidade de cada um resultante do número de experiências positivas e negativas ao seguir as suas opiniões.

Para além do modelo de dados do produto a desenvolver, é também importante analisar o modelo multi-agente do mesmo.

3.4 Modelo Multi-Agente

A Figura 3.8 apresenta o modelo do SMA proposto, identificando os seus agentes e principais interações entre eles.

Conforme pode ser observado na Figura 3.8, o *player* apoiado pode comunicar com três agentes do SMA: agente principal, agente de pré-negociação e agente de negociação. Inicialmente o *player* apoiado solicita apoio à decisão ao agente principal, cuja função é criar e indicar-lhe o agente apropriado à fase de negociação em causa. A partir desse momento o *player* apoiado deve comunicar com o agente indicado. Na Figura 3.8, os agentes estão representados por uma cor representativa da fase à qual prestam apoio: azul no caso da pré-negociação, verde no caso da negociação e cinzento quando prestam apoio a ambas.

Para o apoio à fase de pré-negociação, intervêm em exclusivo os seguintes agentes:

- Agente de Pré-Negociação – agente responsável por gerir o processo de apoio à decisão na fase de pré-negociação, comunicando com os agentes necessários, reunindo informação, fazendo tarefas adicionais necessárias e apresentando a recomendação final ao *player* apoiado;
- Agente de Geração de Cenários – agente responsável pelo processo de geração de cenários. Para esse efeito, o agente solicita a todos os agentes de previsão necessários, a geração de um cenário de negociação. No caso do *player* apoiado solicitar o método de decisão Mais Provável, o agente de geração de cenários comunica com o agente AAR Superior, com o intuito de identificar o agente de previsão que tem apresentado o maior realismo nos seus cenários gerados.
- Agentes de Previsão – cada agente de previsão representa um método diferente de previsão.
- Agentes de Pesquisa de Ações – Este tipo de agentes representam as alternativas de pesquisa de ações possíveis. No caso da abordagem de teoria de jogos, são pesquisadas todas as ações possíveis enquanto que nas restantes alternativas é seguida uma abordagem de otimização, procurando identificar as melhores (ou próximas das melhores) ações num curto tempo de pesquisa.

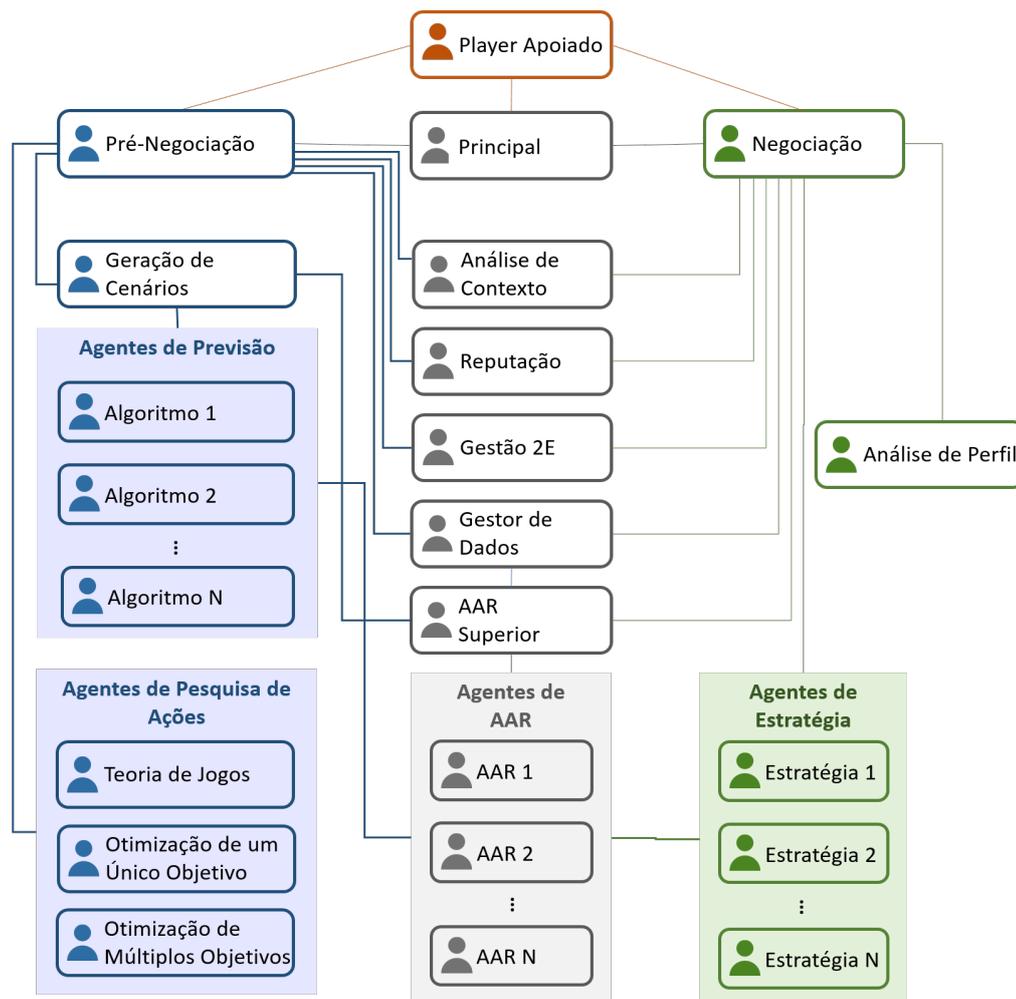


Figura 3.8: Modelo do SMA proposto.

O apoio à fase de negociação é garantido pela intervenção exclusiva dos seguintes agentes:

- Agente de Negociação – agente responsável por liderar o processo de apoio à decisão na fase de negociação, comunicando com os agentes necessários, reunindo informação, fazendo tarefas adicionais necessárias e apresentando a recomendação final ao *player* apoiado;
- Agente de Análise de Perfil – agente responsável por determinar os perfis de negociação dos *players*;
- Agentes de Estratégia – cada agente representa uma estratégia de negociação diferente e quando solicitados, determinam a próxima oferta que o *player* apoiado deve apresentar.

Por último, os agentes que intervêm em ambas as fases de negociação:

- Agente de Análise de Contexto – agente responsável por identificar os diferentes contextos de negociação presentes nos dados históricos, assim como identificar o contexto de negociação em qual o *player* apoiado pretende negociar;
- Agente de Gestão de Dados – agente responsável por fazer a gestão de dados, adicionando novos dados partilhados pelo *player* apoiado e monitorizando o estado da

base de dados de forma a detetar atualizações de dados. Este agente partilha com os agentes de aprendizagem toda a nova informação relevante para o seu processo de aprendizagem;

- Agente de Gestão 2E (Eficiência e Eficácia) – A identificação das alternativas a usar, de forma a dar resposta à qualidade e tempo de execução desejado pelo *player* apoiado, é realizada por este agente. Para esse efeito este agente deve registar o tempo de execução das várias alternativas presentes no sistema (algoritmos de previsão, métodos de pesquisa de ações, estratégias, variações de parâmetros, entre outros);
- Agente de Reputação – agente responsável pelo cálculo da reputação e credibilidade de cada *player*, atualizando-as sempre que surja nova informação;
- Agente AAR Superior – agente que utiliza um AAR para avaliar o desempenho dos AAR presentes no sistema. Para esse efeito, este agente efetua duas avaliações distintas: avaliação do melhor método de AAR para a determinação do algoritmo de previsão mais próximo da realidade e avaliação do melhor método de AAR para a identificação da melhor estratégia a seguir na negociação com cada oponente em cada contexto possível;
- Agentes AAR – agentes correspondentes a cada AAR presente no sistema. Cada agente é responsável por duas avaliações: avaliação do desempenho de cada algoritmo de previsão e avaliação da aplicação de cada estratégia de negociação a cada oponente em cada contexto.

Os processos de apoio a ambas as fases de negociação, incluindo as comunicações necessárias entre os agentes, são apresentados nas secções 3.4.1 (Pré-Negociação) e 3.4.2 (Negociação).

3.4.1 Processo de Apoio à Fase de Pré-negociação

O processo de apoio à fase de pré-negociação é apresentado através de um diagrama de sequência, onde é possível identificar os diferentes passos do processo assim como o contributo de cada interveniente e as comunicações estabelecidas. O diagrama é dividido em várias figuras de forma a facilitar a sua interpretação, mas mantendo a sequência correta das comunicações.

A Figura 3.9 apresenta o início do processo.

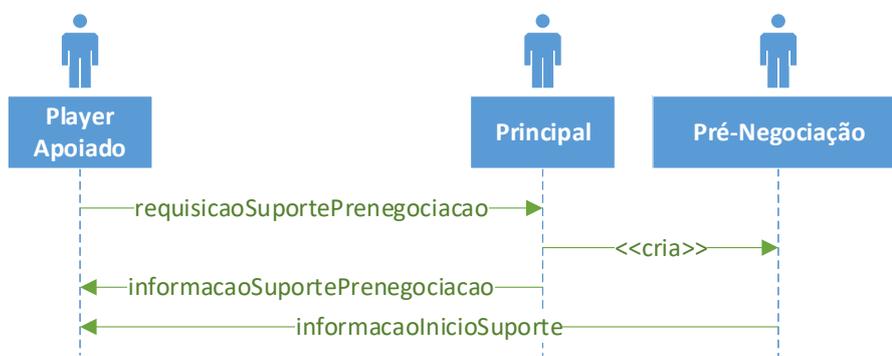


Figura 3.9: Comunicações no início do processo de apoio à fase de pré-negociação.

Conforme se pode observar na Figura 3.9, o processo é iniciado com a recepção de uma requisição do *player* apoiado para obter apoio na fase de pré-negociação. Ao receber a solicitação, o Agente Principal é responsável por criar e atribuir um Agente de Pré-Negociação ao *player* apoiado. A intervenção do Agente Principal termina ao informar o *player* apoiado acerca do nome do Agente de Pré-negociação que lhe irá prestar assistência. Assim que o Agente de Pré-negociação é iniciado e está disponível, o mesmo envia uma mensagem ao *player* apoiado, apresentado-se e garantindo que o processo decorre como esperado. De seguida, o Agente de Pré-negociação procede com a identificação do contexto e cenário mais provável conforme apresentado na Figura 3.10.

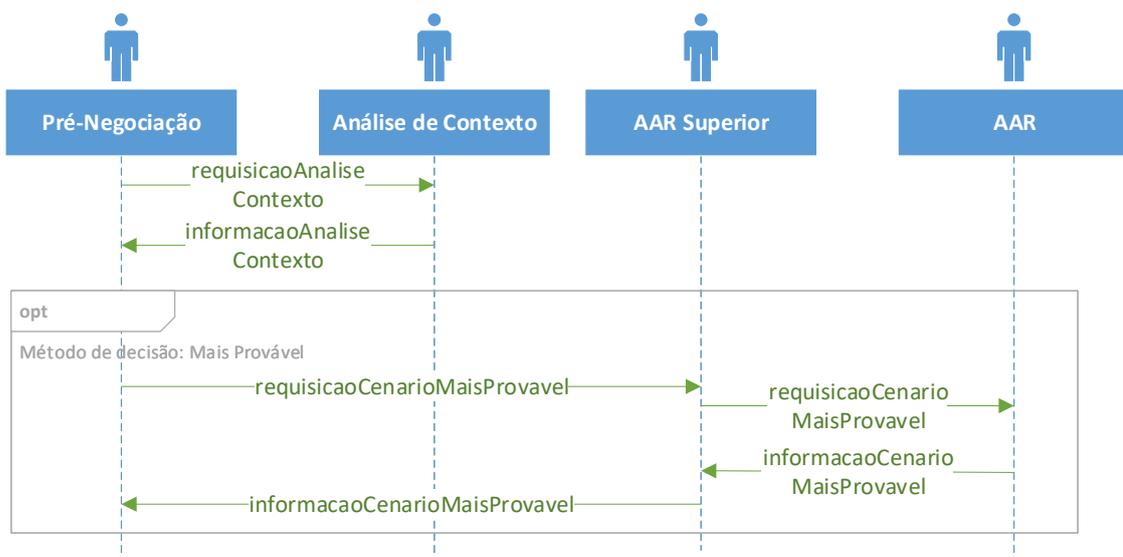


Figura 3.10: Diagrama de sequência [UML] de comunicações para a identificação do contexto e cenário mais provável.

Na Figura 3.10 é possível verificar que o primeiro passo do Agente de Pré-negociação é a identificação do contexto de negociação atual. Para esse efeito, o mesmo comunica com o Agente de Análise de Contexto, o qual, através da metodologia apresentada em 3.1.1, classifica o contexto atual. Após este passo, caso o *player* apoiado tenha indicado o método de decisão Mais Provável, o Agente de Pré-negociação comunica com o Agente AAR Superior de forma a saber qual o cenário mais provável. O Agente AAR Superior por sua vez comunica com o Agente AAR que representa o AAR melhor avaliado (método que tem apresentado maior capacidade de identificar o cenário mais provável). O Agente AAR comunica ao Agente AAR Superior qual o cenário mais provável e este reencaminha a mensagem para o Agente de Pré-negociação. Após serem conhecidos o contexto atual e o cenário mais provável (caso seja necessário), é possível proceder à fase de geração de cenários, apresentada na Figura 3.11.

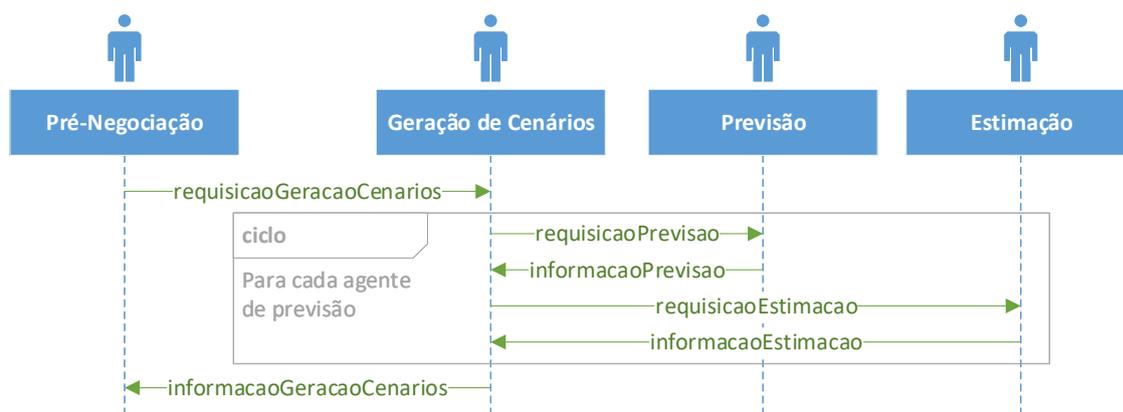


Figura 3.11: Diagrama de sequência [UML] de comunicações para geração de cenários.

Conforme se pode observar na Figura 3.11, o processo de geração de cenários é iniciado por uma requisição do Agente de Pré-negociação ao Agente de Geração de Cenários. Por sua vez, o Agente de Geração de Cenários solicita a todos os Agentes de Previsão existentes no SMA a geração de um cenário. Ao receber os resultados enviados pelos Agentes de Previsão, o Agente de Geração de Cenários solicita ao Agente de Estimação a estimativa dos preços em falta, quando o Agente de Previsão não conseguiu prever o preço para todas as quantidades de energia necessárias. O Agente de Geração de Cenários comunica sempre com todos os Agentes de Previsão mesmo quando o *player* apoiado apenas pretende obter o cenário mais provável. Desta forma o sistema registra os outros cenários gerados e pode continuar a avaliar a capacidade desses algoritmos em representar a realidade. Por fim, o Agente de Geração de Cenários comunica os cenários gerados ao Agente de Pré-negociação. A última fase do processo principal de apoio à Pré-negociação é apresentada na Figura 3.12.

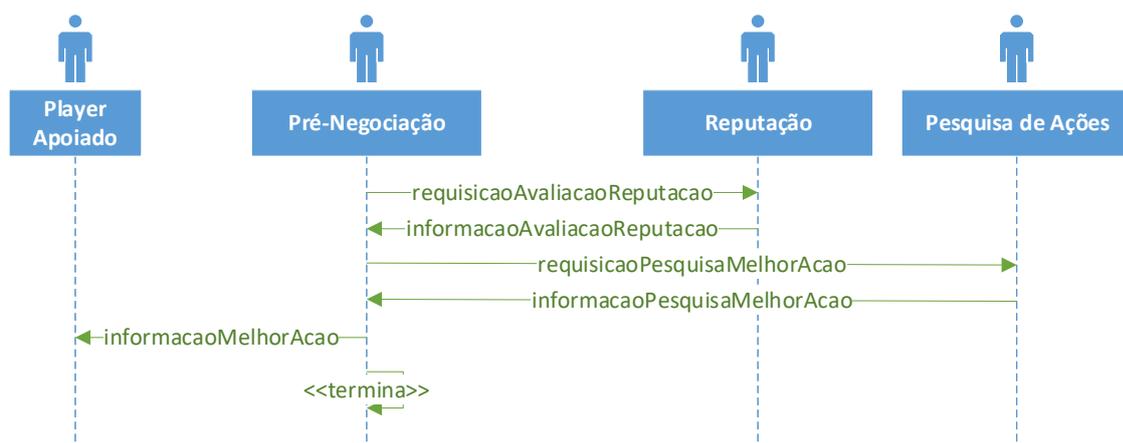


Figura 3.12: Diagrama de sequência [UML] de comunicações para avaliação de reputação e pesquisa melhor ação.

Na última fase do processo, apresentada na Figura 3.12, o Agente de Pré-negociação solicita ao Agente de Reputação a avaliação da reputação dos oponentes indicados pelo *player* apoiado. Após receber a reputação de cada oponente, o Agente de Pré-negociação tem toda a informação necessária para solicitar a pesquisa da melhor ação. Para esse efeito é

enviada uma requisição ao Agente de Pesquisa de Ações mais apropriado às preferências do *player* apoiado (Agente de Teoria de Jogos ou Agente de Otimização). Ao obter a melhor ação, o Agente de Pré-negociação envia essa informação ao *Player* Apoiado e termina a sua execução.

Para este processo também é importante considerar o processo de atualização das avaliações dos cenários e dos próprios AAR, apresentado na Figura 3.13.



Figura 3.13: Diagrama de sequência [UML] de comunicações para atualização das avaliações dos AAR.

Conforme se pode observar na Figura 3.13, o Agente Gestor de Dados está sempre alerta para o surgimento de novos contratos reais na base de dados. O agente compara os cenários gerados para a mesma data dos contratos e solicita ao Agente AAR Superior que atualize a avaliação dos diferentes cenários. Para além disso, o Gestor de Dados também solicita ao AAR Superior a avaliação de todos os AAR pela sua capacidade de identificar o cenário mais provável.

O processo de apoio à fase de negociação é apresentado na secção 3.4.2.

3.4.2 Processo de Apoio à Fase de Negociação

Assim como no processo de apoio à fase de pré-negociação, apresentado na secção 3.4.1, este processo é apresentado através de um diagrama de sequência dividido em várias figuras, sem perder a sequência correta das comunicações.

A Figura 3.14 apresenta o início do processo de apoio à negociação.

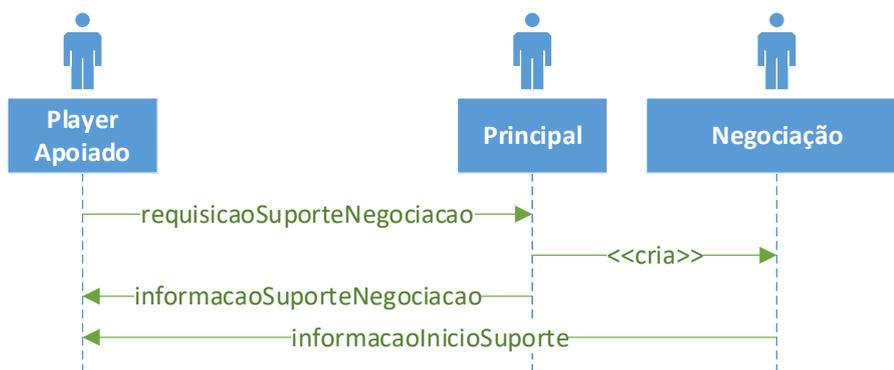


Figura 3.14: Diagrama de sequência [UML] de comunicações no início do processo de apoio à fase de negociação.

Conforme apresentado na Figura 3.14, este processo é iniciado de forma idêntica ao início do processo de apoio à fase de pré-negociação. O *Player Apoiado* solicita suporte à fase de negociação e o Agente Principal atribui-lhe um Agente de Negociação dedicado a esse fim. O Agente Principal comunica o nome do Agente de Negociação ao *Player Apoiado* e o Agente de Negociação apresenta-se ao *Player Apoiado* assim que estiver disponível. De seguida, o Agente de Negociação procede com a identificação do contexto, análise do perfil do oponente e obtenção da credibilidade dos *players*.

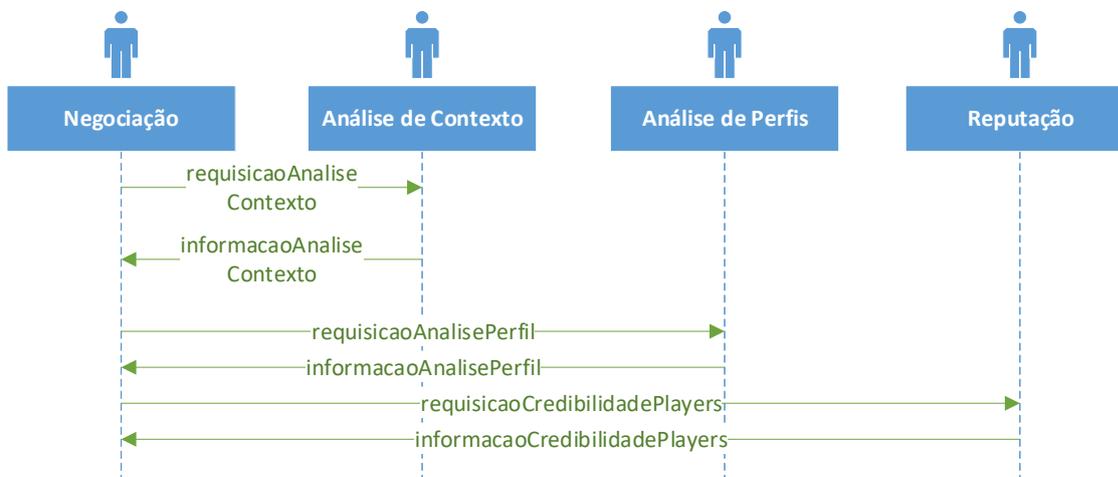


Figura 3.15: Diagrama de sequência [UML] de comunicações para identificação do contexto, análise do perfil e obtenção de credibilidade.

Conforme se pode observar na Figura 3.15, o Agente de Negociação procede com a requisição da identificação do contexto atual ao Agente de Análise de Contexto e requisição da análise do perfil do oponente ao Agente de Análise de Perfis. Após receber a informação requisitada, o Agente de Negociação solicita ao Agente de Reputação os valores de credibilidade de todos os *players* que partilharam a sua opinião. Posteriormente, o Agente de Negociação realiza os passos em falta para a obtenção da melhor estratégia a recomendar ao *Player Apoiado*, conforme apresentado na Figura 3.16.

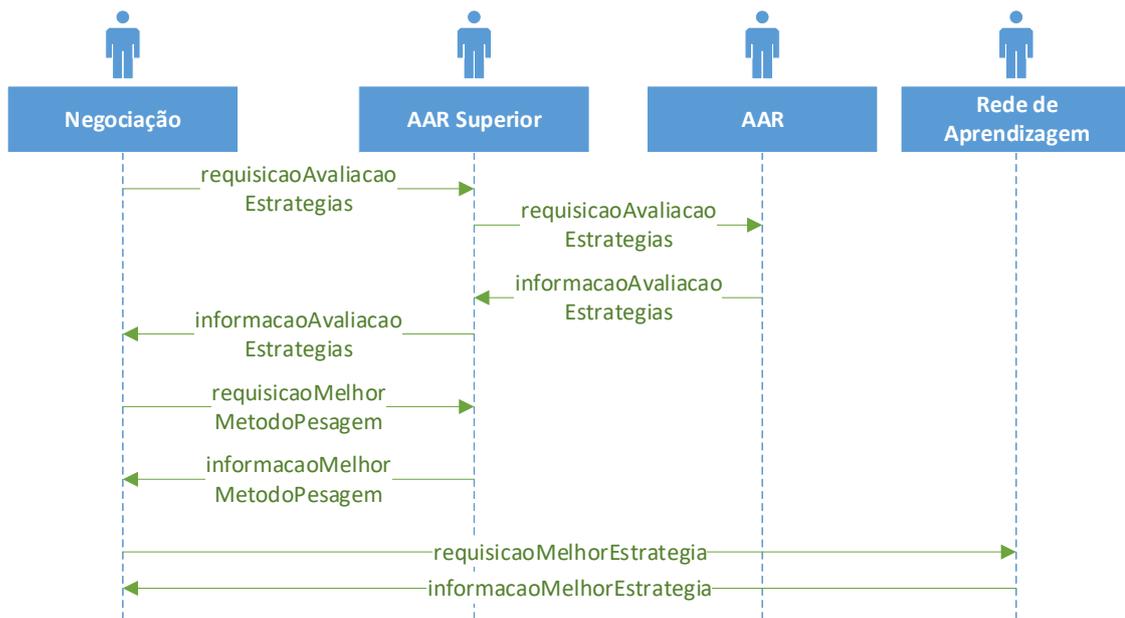


Figura 3.16: Diagrama de sequência [UML] de comunicações para obtenção da melhor estratégia a recomendar.

A Figura 3.16 demonstra que o Agente de Negociação solicita ao Agente AAR Superior a avaliação das várias estratégias integradas no SMA. Por sua vez, o Agente AAR Superior solicita ao Agente AAR, representante do AAR com melhor pontuação a avaliar estratégias, a avaliação das várias estratégias. Esta informação contém a opinião do *Player* Apoiado assim como as opiniões partilhadas por outros *players*. Após obter a avaliação das estratégias, o Agente de Negociação solicita ao Agente AAR Superior o método de pesagem com melhor pontuação. Após reunidos todos os pré-requisitos, o Agente de Negociação solicita ao Agente da Rede de Aprendizagem a determinação da melhor estratégia a recomendar ao *Player* Apoiado. Na Figura 3.17 é apresentada a fase final da primeira interação do *Player* Apoiado com o Agente de Negociação.

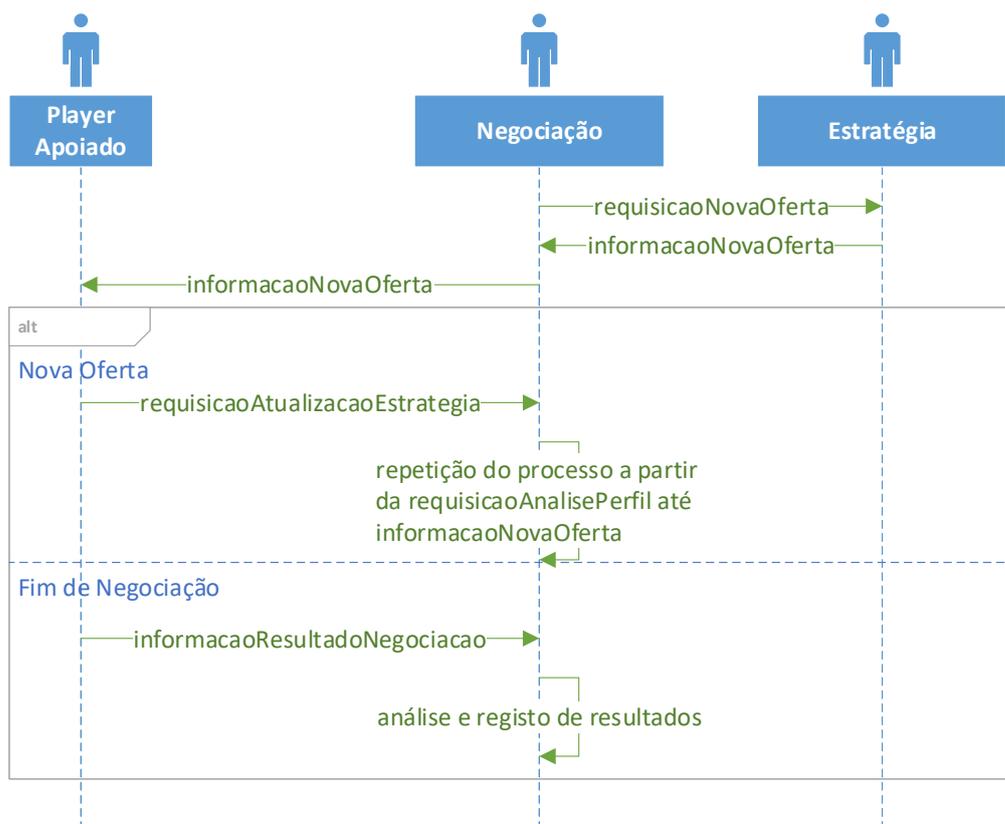


Figura 3.17: Diagrama de sequência [UML] de comunicações para obtenção da oferta a licitar e futuras interações.

Conforme se pode observar na Figura 3.17, o Agente de Negociação solicita ao Agente de Estratégia, que representa a estratégia recomendada, a próxima oferta que o *Player Apoiado* deve oferecer de forma a seguir a estratégia recomendada. Após informar o *Player Apoiado* do valor a licitar, o Agente de Negociação aguarda nova requisição para atualizar a estratégia a seguir ou então, caso a negociação já tenha sido concluída, se chegaram a acordo e qual o valor acordado. No caso do *Player Apoiado* requisitar a atualização da estratégia a seguir, o Agente de Negociação volta a repetir os passos do processo principal desde a requisição da análise do perfil do oponente até informar o *Player Apoiado* acerca da nova oferta a licitar. No caso contrário, quando o *Player Apoiado* informa o resultado da negociação, o *Player* de Negociação procede com a análise e registo dos resultados conforme apresentado na Figura 3.18.

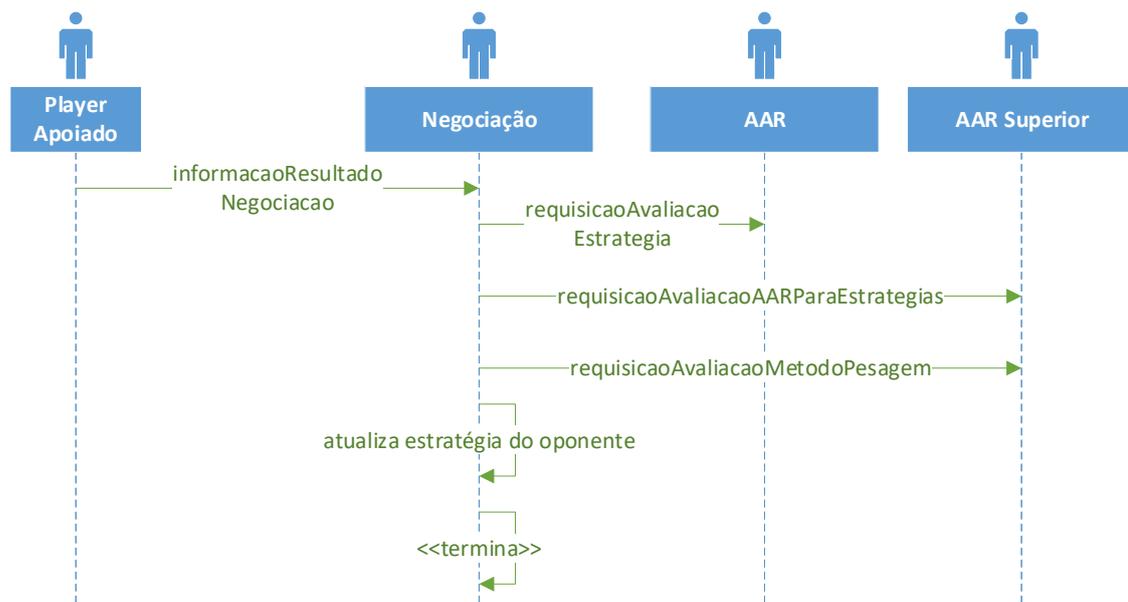


Figura 3.18: Diagrama de sequência [UML] de comunicações para atualização das avaliações de acordo com resultado da negociação.

Na última fase do processo de apoio à fase de negociação, quando o *Player Apoiado* informa o resultado da negociação, o Agente de Negociação procede ao registo da informação e atualização de todas as pontuações relacionadas. Primeiro solicita ao AAR, que avaliou as estratégias ao longo deste processo, que atualize a sua avaliação da estratégia recomendada de acordo com o resultado final. De seguida o próprio AAR é avaliado consoante a sua capacidade de identificar a melhor estratégia. O pontuação do método de pesagem também é atualizado pelo agente AAR Superior. Por último, o Agente de Negociação atualiza a estratégia do oponente antes de terminar a sua execução.

Após a análise do modelo multi-agente, é apresentado na secção 3.5 o modelo de classes do sistema proposto.

3.5 Modelo de Classes

O modelo de classes está dividido em seis figuras de forma a apresentar diferentes níveis de detalhe das principais especificações do sistema proposto.

A Figura 3.19 apresenta a visão geral do modelo de classes do SMA.

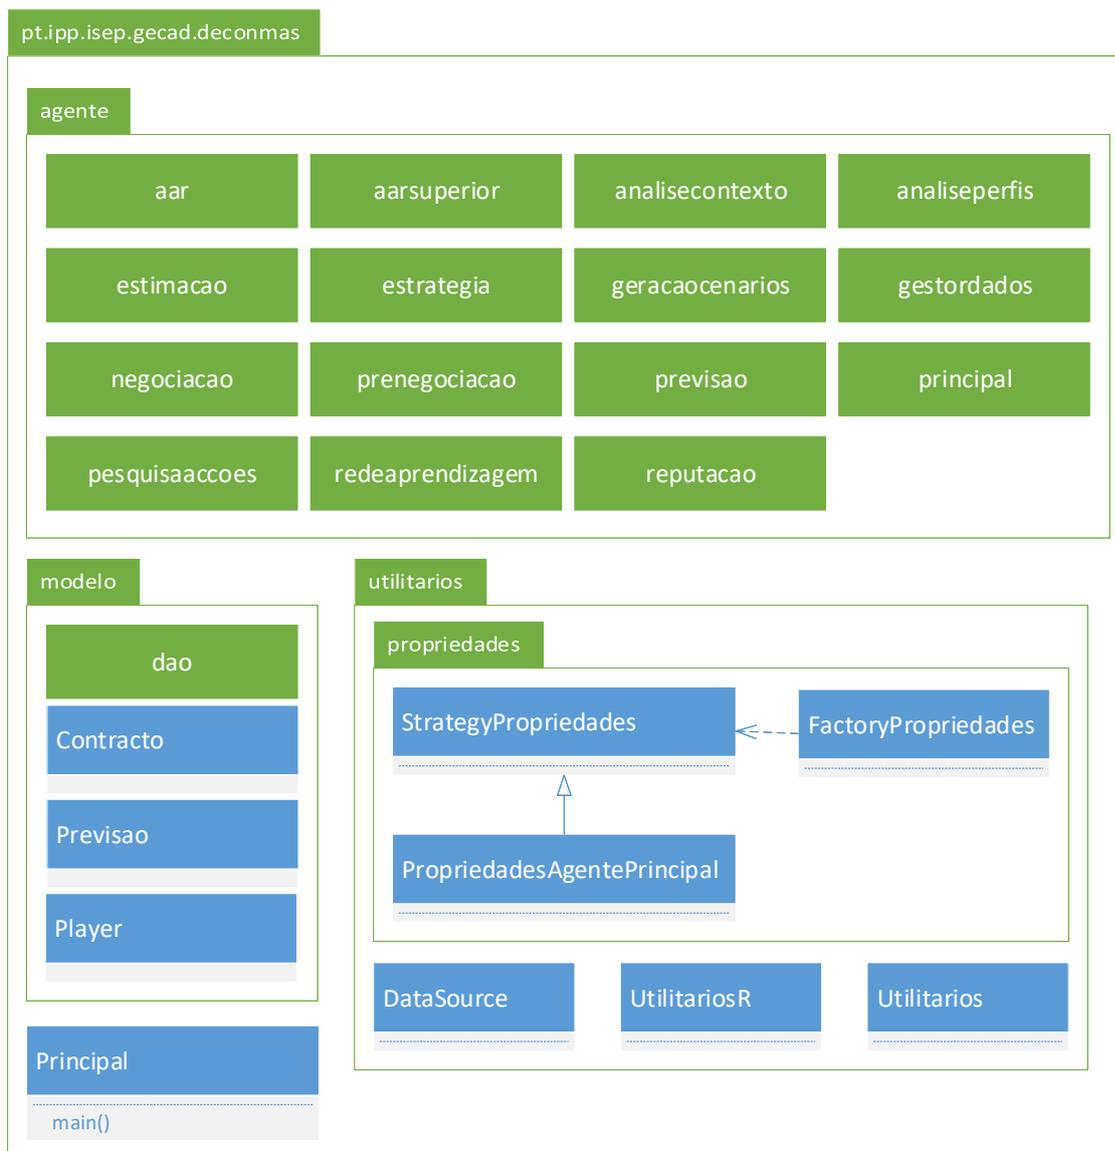


Figura 3.19: Diagrama de classes [UML] do SMA (visão geral).

Conforme se pode observar na Figura 3.19, o pacote principal (deconmas) está dividido em três pacotes: agente, modelo, e utilitários. O pacote agente contém a implementação de cada agente integrado no SMA dentro do seu próprio pacote (ver Figura 3.20).

No caso do pacote modelo, são modelados os conceitos de contracto, previsão e *player*. Apenas são modelados estes conceitos uma vez que o conteúdo das mensagens entre os agentes estão no formato *json*, não sendo necessária a modelação de todos os conceitos envolvidos. A informação é extraída e adicionada diretamente nos objetos *json*. Este pacote contém ainda o pacote dao responsável por agregar as classes que implementam os métodos de leitura e escrita em base de dados. Cada tabela apresentada no modelo de dados contém uma classe Data Access Object (DAO) correspondente (por exemplo, a tabela *Player* tem a classe *PlayerDAO* para manipulação da mesma). Esta abordagem segue o padrão DAO que permite a separação das regras de negócio das regras de acesso à base de dados.

O pacote utilitários contém as classes não relacionadas com as regras de negócio mas que auxiliam a sua implementação. A classe *DataSource* permite estabelecer a ligação com a base de dados assim como garantir uma *pool* de conexões (múltiplas conexões em simultâneo), através da API *c3p0*. Desta forma é possível aumentar a performance do sistema ao garantir o menor tempo possível de leitura e escrita na base de dados (especialmente no caso da geração de todas as ações possíveis em cada cenário e cálculo da respetiva utilidade). A classe *UtilitariosR* permite fazer operações de conversão de matrizes e vectores no formato Java para o texto de criação das mesmas em R. Por último, a classe *Utilitarios* contém métodos auxiliares gerais como é o caso de métodos para saber se uma porta está disponível (necessário para criação do servidor R), determinação do elemento mais frequente de uma lista, entre outros. Este pacote contém ainda o pacote propriedades onde é implementado o padrão *factory* para gestão dos ficheiros de propriedades. O SMA contém um ficheiro de configuração onde são definidos os principais parâmetros para a inicialização do sistema (portas, nome da plataforma multi-agente, nomes dos contentores de agentes, nomes dos serviços disponibilizados pelos vários agentes, entre outros). Desta forma é possível alterar facilmente configurações chave do sistema sem alterar o seu código. O padrão *factory* permite a fácil adição de novos ficheiros de propriedades que possam ser necessários para a configuração do sistema, sendo apenas necessário a criação de uma nova classe e uma pequena configuração na *factory*.

Por último, a classe Principal é responsável pela inicialização do SMA. Após a visão geral do modelo de classes, é possível observar na Figura 3.20 o tipo de estrutura dos pacotes dos agentes.

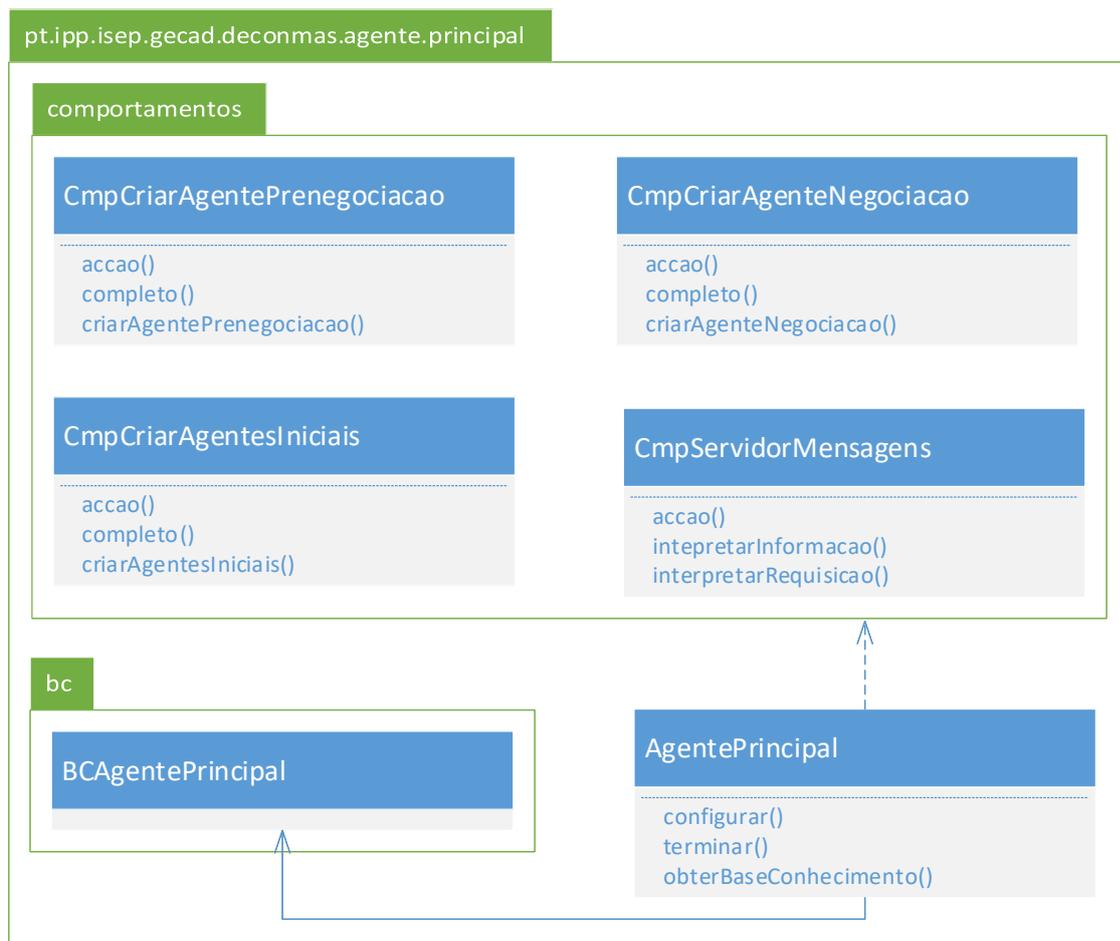


Figura 3.20: Diagrama de classes [UML] do pacote de um agente.

Na Figura 3.20 é apresentado o conteúdo do pacote do agente principal, a título de exemplo da estrutura adotada por todos os agentes. Na figura é possível identificar dois pacotes: *comportamentos* e *bc* (base de conhecimento). O pacote *comportamentos*, como o seu nome indica, contém os diferentes comportamentos que um agente pode ter ao longo da sua execução. O comportamento comum a todos os agentes é o *CmpServidorMensagens* que é responsável por analisar e filtrar todas as mensagens recebidas. Neste comportamento são identificadas as mensagens de requisição ou informação que interessam ao agente, o que o leva a tomar um determinado comportamento. Por exemplo, quando o agente principal recebe uma requisição do *player* apoiado para receber apoio à fase de pré-negociação, é iniciado o comportamento *CmpCriarAgentePrenegociacao* responsável por criar um agente de pré-negociação dedicado ao *player* apoiado.

O segundo pacote, *bc*, contém a base de conhecimento do agente. Neste pacote são gravados todos os dados que o agente necessita de aceder, mais do que uma vez, ao longo da sua execução. Assim, ao longo do tempo o agente vai atualizando o seu conhecimento acerca dos agentes com quem comunica assim como o estado dos processos que possam estar a decorrer. No caso do agente principal apenas é necessário registar o contacto dos agentes por ele criados, de forma a ser possível contactá-los e saber se foram todos inicializados corretamente. As Figuras 3.21 a 3.24 apresentam outros exemplos de bases de

conhecimento. Por último, a classe *AgentePrincipal* é responsável pelo processo de criação do agente, a criação da base de conhecimento e o término da sua execução.

As Figuras 3.21 a 3.24 apresentam as bases de conhecimento dos agentes *GeracaoCenarios*, *AnalisePerfis*, *AARSuperior* e *RedeAprendizagem*, respetivamente, responsáveis por gerir os algoritmos de previsão, estratégias, AARs e métodos de pesagem, respetivamente. A forma como estes componentes são implementados é muito importante para garantir a expansibilidade do sistema, ou seja, a fácil adição, remoção e manutenção das técnicas utilizadas. A Figura 3.21 apresenta a base de conhecimento do agente *GeracaoCenarios*.

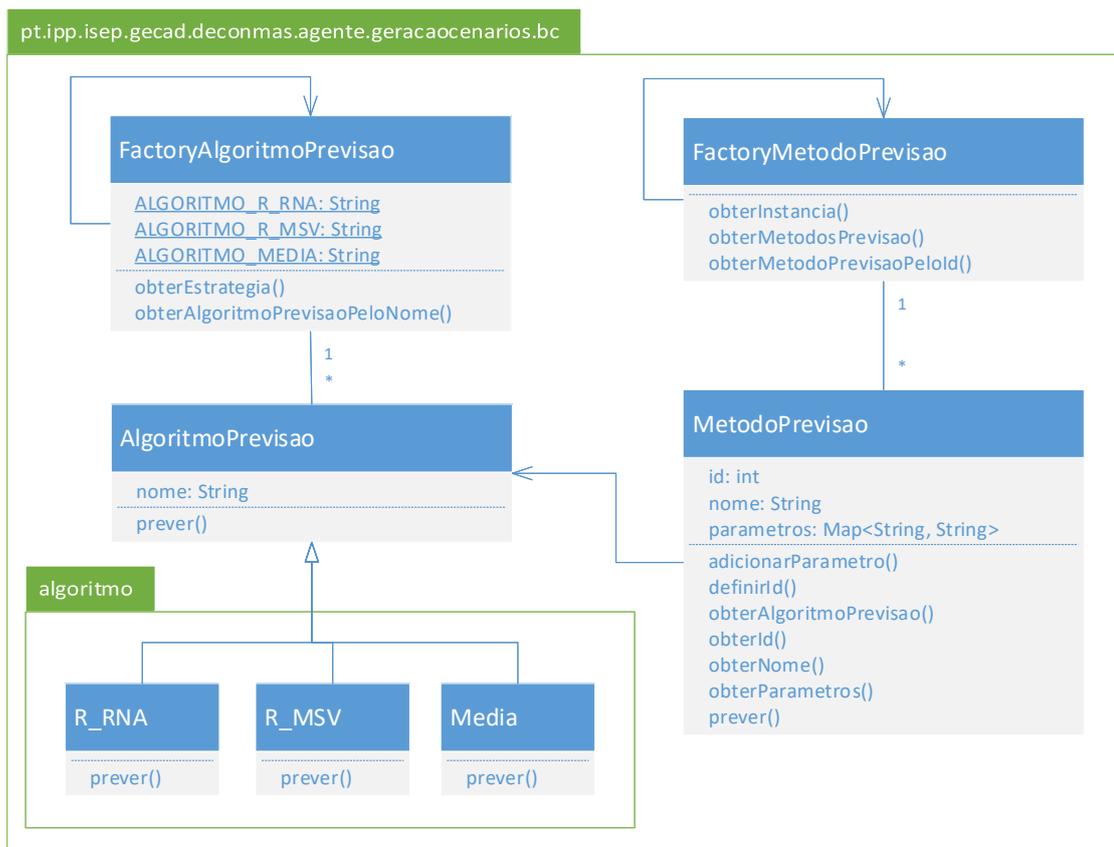


Figura 3.21: Diagrama de classes [UML] da base de conhecimento do agente *GeracaoCenarios*.

Na Figura 3.21 são apresentados os diferentes algoritmos de previsão e a estrutura de classes para a sua manutenção. Conforme se pode observar, por defeito o sistema contém os algoritmos RNA, MSV e Media, todos subclasses de *AlgoritmoPrevisao*. À imagem da implementação dos ficheiros de propriedades, a gestão destes algoritmos também é realizada através do padrão *factory*. A *factory* *FactoryAlgoritmoPrevisao* permite obter um dos algoritmos inseridos no sistema que são enumerados em variáveis do tipo *String*, estáticas e finais (ex.: *ALGORITMO_R_RNA*). Contudo o sistema não se limita a considerar um cenário por algoritmo. Uma vez que um algoritmo pode ser configurado de diferentes formas e obter resultados muito distintos, foi também adicionada a *factory* *FactoryMetodoPrevisao*. Esta *factory* permite obter um *MetodoPrevisao* que é uma variação de um algoritmo de previsão com um ou mais parâmetros diferentes. Por exemplo, um dos parâmetros pode ser a quantidade de dados de treino, considerando um RNA com poucos dados (dados mais

recentes) e outra com um maior número de dados (maior histórico de dados). Os próprios parâmetros dos algoritmos também podem ser modificados como por exemplo o número de camadas na RNA.

Desta forma é possível adicionar novos algoritmos sem grandes alterações ao sistema. Para esse efeito basta criar uma nova subclasse de *AlgoritmoPrevisao* e adicionar a sua instância à *FactoryAlgoritmoPrevisao*. Posteriormente, os métodos de previsão também são facilmente adicionados na *FactoryMetodoPrevisao* ao especificar o algoritmo de previsão correspondente e quais os parâmetros a utilizar (se não forem especificados, são usados os parâmetros por defeito).

A Figura 3.22 apresenta a base de conhecimento do agente *AnalisePerfis*.

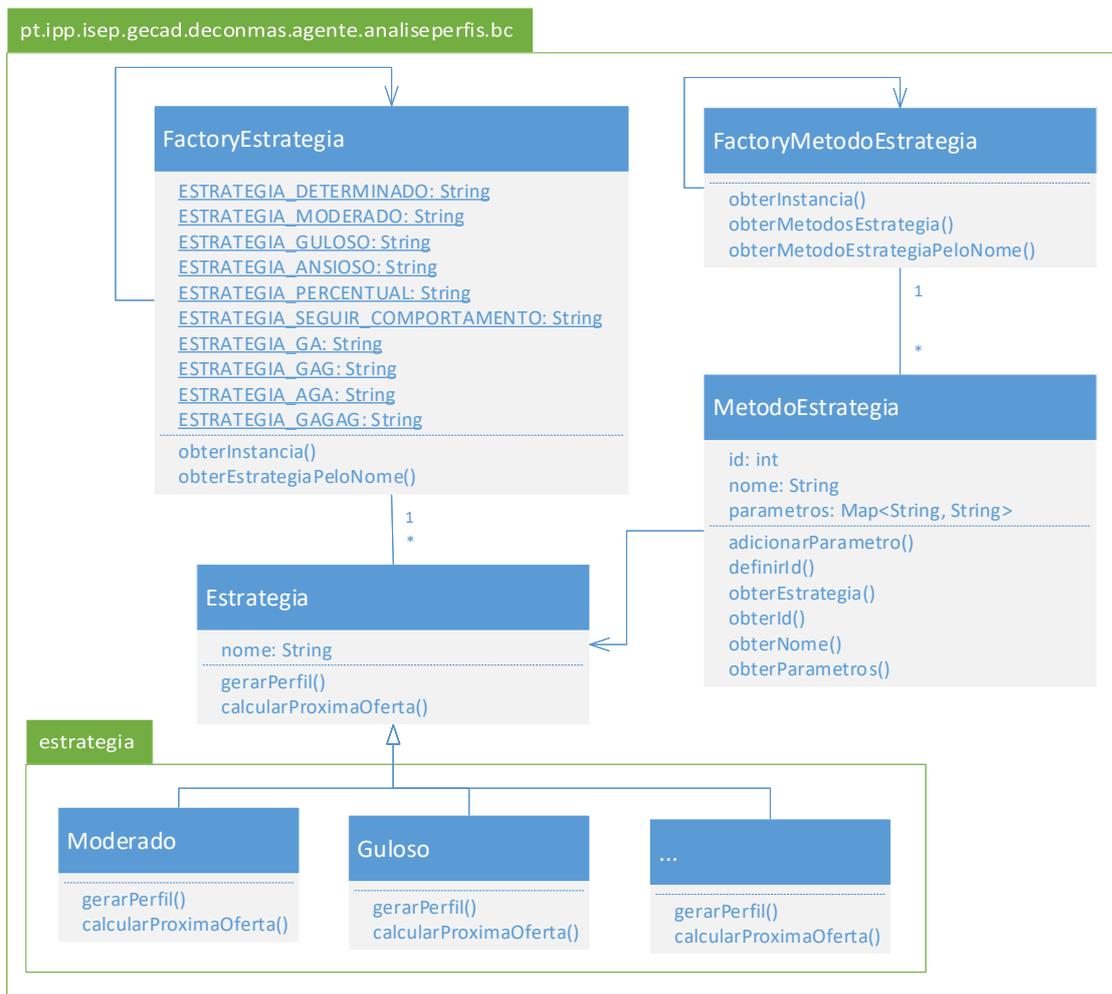


Figura 3.22: Diagrama de classes [UML] da base de conhecimento do agente *AnalisePerfis*.

A implementação das estratégias de negociação segue a mesma abordagem utilizada nos algoritmos de previsão. Neste caso também existe as estratégias e os métodos de estratégias em que se pode variar os seus parâmetros. Por exemplo, a estratégia *Percentagem* tem o parâmetro percentagem que tanto pode ser um valor alto e as ofertas alteram de preço drasticamente ou então assumir um valor baixo e variar pouco ao longo do tempo. Cada

classe de estratégia permite gerar o perfil da estratégia (ofertas entre o valor inicial e o limite do *player* apoiado, respeitando o número de licitações máximo) e calcular a próxima oferta que o *player* apoiado deve licitar para seguir essa estratégia.

A Figura 3.23 apresenta a base de conhecimento do agente *AARSuperior*.

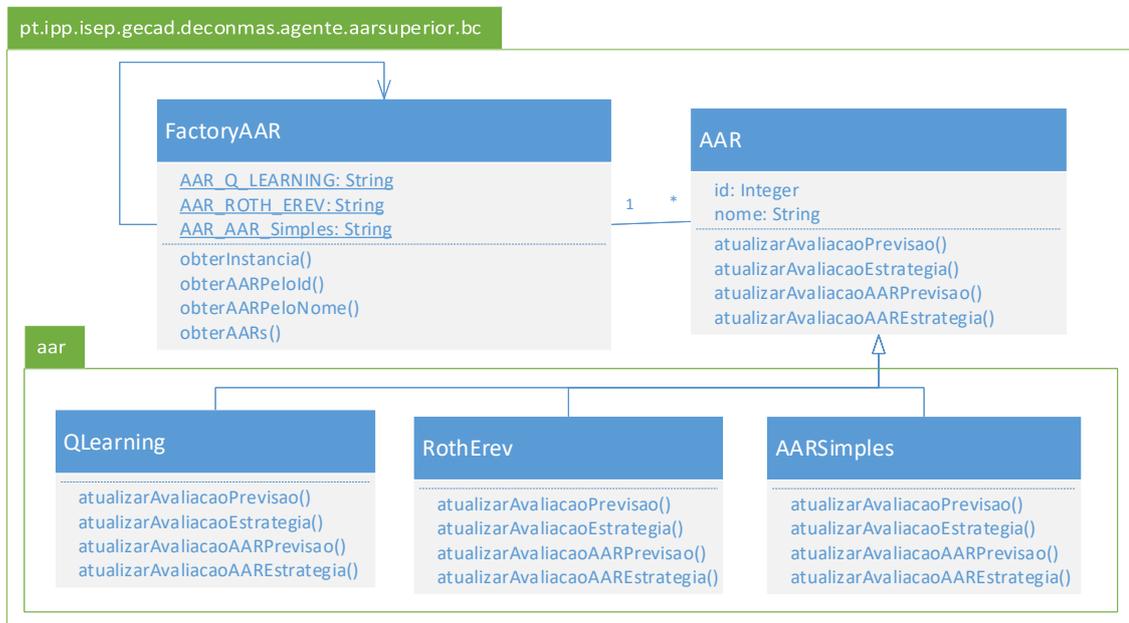


Figura 3.23: Diagrama de classes [UML] da base de conhecimento do agente *AARSuperior*.

A gestão dos diferentes AAR segue uma abordagem semelhante à gestão dos algoritmos de previsão e estratégias, apenas com a diferença de não ter uma segunda *factory* responsável pela variação das técnicas principais. Neste caso existe apenas a *FactoryAAR* que permite selecionar o AAR desejado. Os AAR permitem avaliar os diferentes algoritmos de previsão assim como as estratégias de negociação. Para além disso todos os AAR permitem avaliar todos os AAR envolvidos no processo de avaliação de algoritmos de previsão e estratégias de negociação de forma a determinar qual o melhor AAR. Apenas um desses AAR será responsável por essa avaliação ao ser nomeado AAR Superior. Por defeito o AAR Superior é o *QLearning*.

A Figura 3.24 apresenta a base de conhecimento do agente *RedeAprendizagem*.

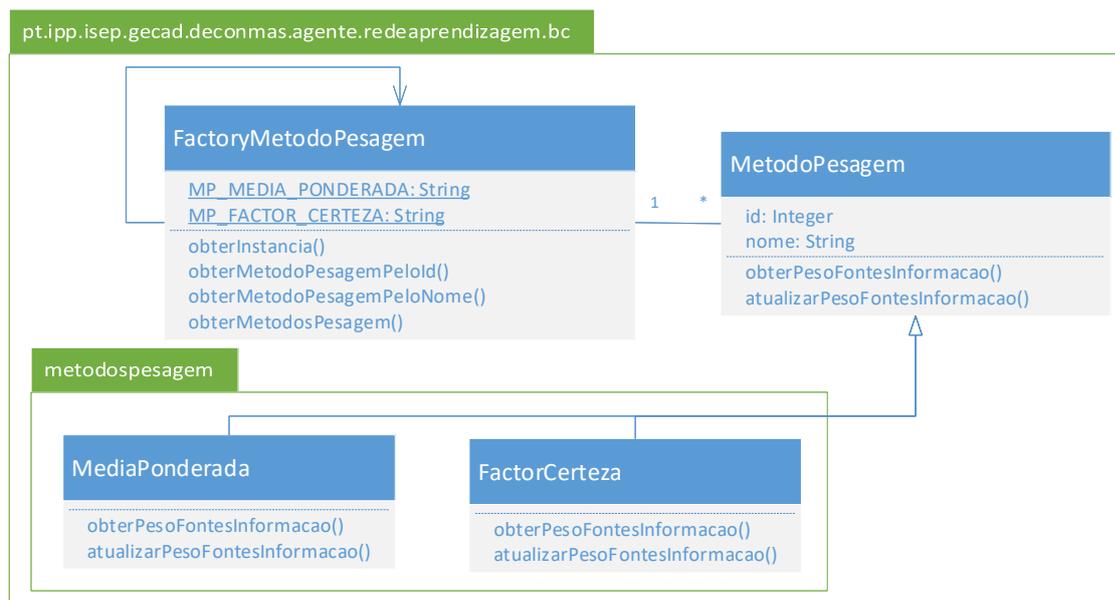


Figura 3.24: Diagrama de classes [UML] da base de conhecimento do agente *RedeAprendizagem*.

Através da Figura 3.24 é possível verificar que a abordagem de gestão dos diferentes métodos de pesagem é idêntica à gestão dos AAR. Apenas é usada uma *factory*. Os métodos de pesagem permitem obter e atualizar os pesos das fontes de informação.

Após a análise da solução proposta, no Capítulo 4 é apresentado o processo de experimentação e avaliação da solução.

Capítulo 4

Casos de Estudo

O presente capítulo apresenta os casos de estudo realizados para a avaliação do funcionamento do sistema proposto, de forma a identificar se foram cumpridos os objetivos propostos. Para esse fim são realizados dois casos de estudo, um focado no apoio à fase de pré-negociação (Secção 4.1) e outro dedicado à fase de negociação (Secção 4.2).

4.1 Caso de Estudo de Apoio à Fase de Pré-negociação

O presente caso de estudo tem o intuito de validar a capacidade do SMA desenvolvido em apoiar a decisão de um *player* apoiado na fase de pré-negociação. Para esse efeito, pretende-se avaliar a capacidade do SMA em identificar o(s) melhor(es) oponente(s) com quem o *player* apoiado pode negociar, e o volume de energia a negociar com cada um, de forma a aumentar o resultado da sua negociação.

Para além do objetivo principal indicado, é também importante analisar o contributo das diferentes técnicas utilizadas. Desta forma, na Secção 4.1.1 é apresentado o pré-processamento de dados necessário para a realização deste caso de estudo. Na Secção 4.1.2 são apresentados os contextos de negociação gerados a partir dos dados selecionados. De seguida, na Secção 4.1.4 é apresentado o resultado de apoio à decisão ao utilizar o método de pesquisa de ações baseado em teoria de jogos, enquanto que na Secção 3.1.6 é apresentado o método alternativo de otimização. Por último é apresentado o processo de aprendizagem por reforço responsável por identificar o cenário de negociação mais provável.

4.1.1 Pré-processamento de Dados

De forma a tornar o caso de estudo o mais próximo da realidade possível, foi considerado um *dataset* com contractos bilaterais de energia reais. O *dataset* pode ser consultado em (OMIE 2019a) e é composto pelos contratos bilaterais físicos executados que foram declarados no Operador de Sistema espanhol, no período entre 1 de Julho de 2007 e 31 de Outubro de 2008 (16 meses). Cada dia de negociação é composto por 24 períodos (um por hora), num total de 11 712 períodos. As negociações foram realizadas por 132 *players* diferentes (88 compradores e 44 vendedores) num total de 1 797 996 contratos estabelecidos. A Tabela 4.1 apresenta uma visão geral do *dataset*.

Tabela 4.1: Visão geral do *dataset*.

	Min.	Média	Desvio Padrão	Max.
Contratos / Período	128	157	17,78	180
Contratos / Dia	147	3 753	485,78	4 287
Contratos / Player	2	27 244	58 653,22	288 160
Contratos / Player / Período	1	5	6,83	29
Volume / Período / Contrato	1	69,04	6,25	3 575
Volume / Player / Contrato	1	89,05	223,17	3 575
Volume / Período	7 718	10 813	1 346,38	14 128
Volume / Dia	8 210	258 405,89	34 317,46	316 801
Volume / Player	30	1 875 400,33	4 503 101,94	26 081 833

Conforme pode ser observado na Tabela 4.1, o *dataset* é muito completo e tem um número mais do que suficiente de *players* e contractos estabelecidos, tendo em conta os requisitos deste estudo. No entanto, o *dataset* não contém a seguinte informação necessária:

- Preço dos contractos – uma informação muito importante para determinar os preços esperados para diferentes quantidades de energia para cada *player*;
- Reputação dos *players* – a reputação de cada *player* do ponto de vista dos outros *players*. Informação necessária para o processo de avaliação de reputação.
- Grupos de *players* – também necessário para o processo de avaliação de reputação.

Apesar da informação em falta, o *dataset* selecionado continua a ser uma opção muito boa, uma vez que a informação relativa aos preços dos contractos é muito sensível e é raramente partilhada. A informação disponível permite obter uma base realista para este caso de estudo e, através de uma geração cuidada dos dados em falta, é possível manter os dados muito próximos da realidade.

Os preços dos contractos foram gerados com base no preço real do mercado do dia seguinte espanhol (OMIE 2019b), no mesmo período em que os contractos foram estabelecidos. Contudo, não é normal que os contractos estabelecidos no mesmo período tenham o mesmo preço. Para combater essa situação, foi gerada uma informação adicional acerca dos *players*: o seu perfil de negociação. Desta forma foram considerados cinco perfis de negociação distintos conforme apresentado na Figura 4.1.

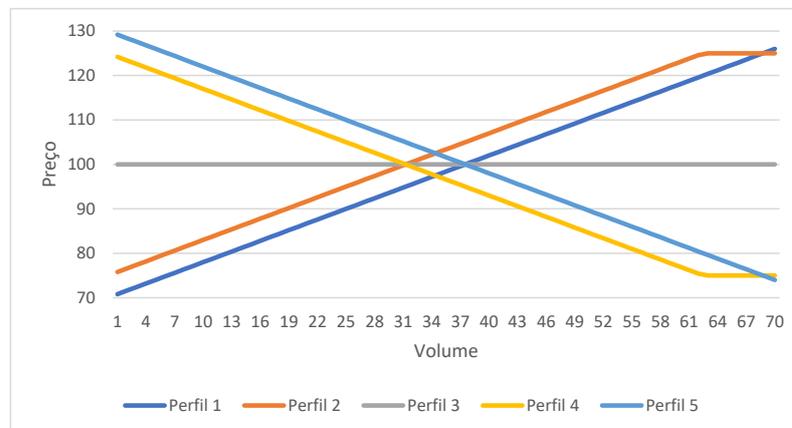


Figura 4.1: Perfis de negociação para geração de preços dos contractos.

A Figura 4.1 apresenta a percentagem do preço de mercado para cada perfil para cada volume de energia, desde 1 até ao volume de energia a considerar neste estudo (55). Conforme pode ser observado, o Perfil 1 varia entre 70% e 130% do preço de mercado, apresentado preços superiores para volumes de energia superiores. O Perfil 2 é semelhante ao Perfil 1 apenas com um aumento de 5%, tanto na percentagem mínima como na máxima. Por outro lado os Perfis 4 e 5 apresenta um comportamento oposto aos anteriores e também com uma diferença de 5% entre eles. Por último, o Perfil 3 segue o preço de mercado para todos os volumes de energia.

Em relação à reputação dos *players*, a opinião pessoal de cada *player*, acerca dos outros *players*, foi gerada através da média ponderada de três componentes:

- Experiência pessoal com o *player* a avaliar (50%).
- Número de *players* que negociaram com o *player* a avaliar (25%).
- Número total de contractos estabelecidos pelo *player* a avaliar (25%).

Por último, o grupo de cada *player* foi definido ao agregar os *players* de acordo com os seguintes atributos:

- Número de dias em que estabeleceu contractos;
- Variação no volume de energia contratado;
- Número de contractos estabelecidos;
- Volume de energia médio contratado.

A Figura 4.2 apresenta o valor médio de silhueta ao tentar agrupar os *players* em diferentes números de grupos.

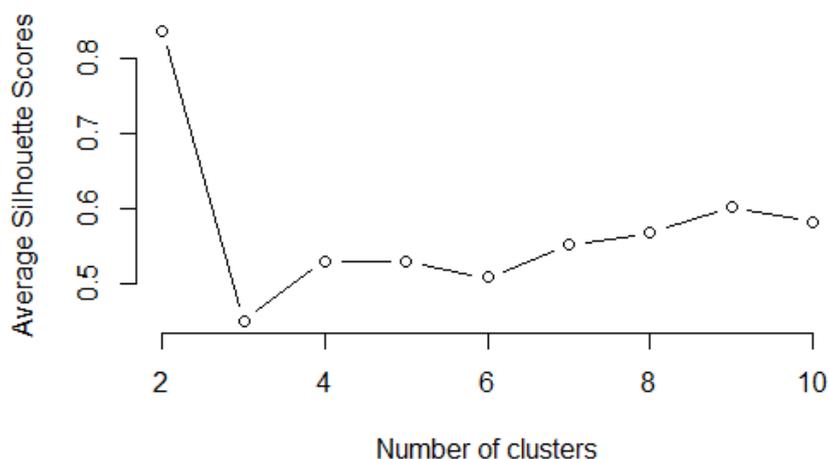


Figura 4.2: Valor médio da silhueta para diferentes números de grupos de *players*.

Ao analisar a Figura 4.2 é possível observar que o maior valor médio de silhueta é atingido ao considerar 2 grupos. A Tabela 4.2 apresenta os centroides dos grupos gerados, assim como o número de *players* em cada grupo.

Tabela 4.2: Grupos dos *players*.

Grupo	Players	Nr. Dias	Variação Volume	Total Contractos	Volume Médio
1	65	459,58	132,66	52737,63	137,59
2	66	139,89	15,20	3634,58	42,80

Na Tabela 4.2, é possível verificar que os grupos gerados ficaram equilibrados em número de *players*, o que permite a separação dos *players* mais ativos dos menos ativos. Os centroides evidenciam uma grande diferença entre cada grupo, justificando assim os valores de silhueta observados.

4.1.2 Geração de Contextos

Ao aplicar a metodologia de geração de contextos, apresentada em 3.1.1, ao *dataset* selecionado, foi gerado o perfil semanal de preços de mercado apresentado na Figura 4.3.

	Segunda	Terça	Quarta	Quinta	Sexta	Sábado	Domingo
1	68,87	62,64	61,19	60,15	59,75	69,14	66,52
2	63,57	58,96	58,56	56,98	56,72	64,73	63,16
3	59,64	56,28	52,51	48,69	53,84	61,43	59,32
4	58,73	55,14	53,26	49,14	53,55	58,91	56,29
5	57,68	54,56	52,45	49,07	54,03	57,21	54,47
6	59,80	58,70	56,08	52,32	57,69	57,14	55,34
7	69,08	67,78	63,97	62,41	65,61	59,57	58,23
8	76,60	77,84	76,82	74,89	77,31	65,60	59,84
9	76,93	78,78	78,67	77,60	80,41	65,89	60,38
10	76,76	77,34	77,98	76,40	80,06	71,39	64,84
11	77,78	77,66	79,17	75,97	80,72	77,53	67,44
12	78,53	77,35	79,07	75,11	79,82	77,35	69,48
13	78,42	80,49	79,90	77,72	79,70	77,74	70,89
14	76,17	78,01	76,78	74,13	77,81	78,02	69,33
15	71,25	71,44	68,81	69,38	69,32	72,63	67,05
16	69,63	70,98	67,75	68,95	66,30	65,94	62,52
17	72,20	72,00	69,94	70,63	67,92	63,50	60,10
18	74,83	75,35	73,03	74,03	69,90	64,35	61,97
19	74,95	75,41	74,09	76,11	72,26	67,18	65,91
20	78,28	78,30	78,60	80,16	77,91	76,80	75,31
21	89,51	88,44	87,33	91,29	87,61	86,77	91,43
22	86,53	85,23	84,81	87,66	84,63	86,41	93,42
23	76,49	72,96	74,56	77,30	75,00	80,47	86,86
24	70,18	67,05	65,57	67,96	67,48	74,58	78,11

Figura 4.3: Perfis semanal de preços de mercado das últimas semanas.

Na Figura 4.3 é apresentado o preço de mercado de cada período de cada dia que representa o perfil desse período nas últimas semanas. A cor de fundo varia entre o preço mais barato (verde escuro) e o mais caro (vermelho escuro). Através deste efeito visual é possível identificar alguns grupos de períodos. No entanto, de forma a ser mais exato é determinado o número de grupos através do método da silhueta conforme apresentado na Figura 4.4.

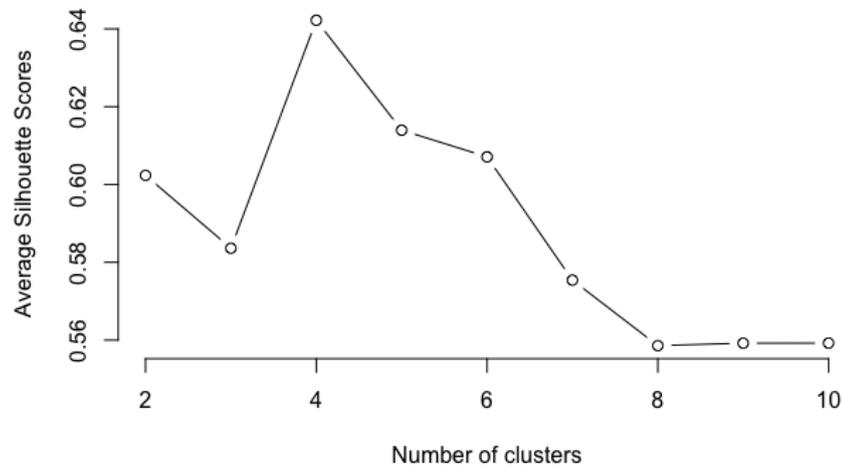


Figura 4.4: Valor médio da silhueta para diferentes números de grupos.

Conforme se pode analisar na Figura 4.4, o número de grupos com maior valor médio de silhueta é o número quatro. A Figura 4.5 apresenta a distribuição dos *players* pelos quatro grupos após execução do algoritmo de *clustering*.

	Segunda	Terça	Quarta	Quinta	Sexta	Sábado	Domingo
1	2	2	1	1	1	2	2
2	2	1	1	1	1	2	2
3	1	1	1	1	1	1	1
4	1	1	1	1	1	1	1
5	1	1	1	1	1	1	1
6	1	1	1	1	1	1	1
7	2	2	2	2	2	1	1
8	3	3	3	3	3	2	1
9	3	3	3	3	3	2	1
10	3	3	3	3	3	2	2
11	3	3	3	3	3	3	2
12	3	3	3	3	3	3	2
13	3	3	3	3	3	3	2
14	3	3	3	3	3	3	2
15	2	2	2	2	2	3	2
16	2	2	2	2	2	2	2
17	2	2	2	2	2	2	1
18	3	3	3	3	2	2	1
19	3	3	3	3	2	2	2
20	3	3	3	3	3	3	3
21	4	4	4	4	4	4	4
22	4	4	4	4	4	4	4
23	3	3	3	3	3	3	4
24	2	2	2	2	2	3	3

Figura 4.5: Contextos de negociação.

Os contextos apresentados na Figura 4.5 estão ordenados pelo seu preço médio, do mais baixo (1) para o mais alto (4), conforme especificado na Tabela 4.3.

Tabela 4.3: Preço médio por contexto.

1	2	3	4
56,72	67,67	77,15	87,86

Conforme se pode observar na Figura 4.5, o contexto 1 ocorre majoritariamente nas primeiras horas do dia, enquanto que o contexto 3 ocorre de manhã e no final do dia (a partir das 18h), com exceção dos períodos 21 e 22 onde ocorre o contexto 4. Por último, o contexto 2 ocorre em diferentes períodos do dia, ao longo da semana, principalmente em fases de transição entre contextos como é o caso dos períodos 1-2, 7, 15-17 e 24. Através desta análise é possível perceber o impacto que tem o período de negociação no resultado da mesma e a importância de se considerar o contexto de negociação. Por exemplo, os preços praticados no contexto 1 são muito distintos dos preços praticados no contexto 4. No entanto, os contextos possuem sempre um grau de semelhança, especialmente os contextos mais próximos como é o caso do 1 e 2, 2 e 3, e 3 e 4. Dessa forma é também calculado o grau

de semelhança de cada contexto com os restantes contextos, através do método apresentado na Secção 3.1.1. A Tabela 4.4 apresenta o grau de semelhança entre contextos.

Tabela 4.4: Similaridade entre contextos.

	1	2	3	4
1	1	0,838	0,735	0,646
2	0,838	1	0,877	0,770
3	0,735	0,877	1	0,878
4	0,646	0,770	0,878	1

Na Tabela 4.4 são apresentados os graus de semelhança entre os diferentes contextos, desde 0, quando são totalmente diferentes, até 1, quando são iguais. Conforme se pode observar, mesmo no caso dos contextos mais distantes, o grau de semelhança não é muito baixo (0,646). Estes valores demonstram que a consideração dos dados de todos os contextos é importante desde que sejam devidamente pesados os seus graus de similaridade. A informação proveniente dos contextos mais semelhantes tem um contributo superior para a recomendação final.

4.1.3 Cenário

Para a determinação do cenário a considerar neste caso de estudo, é importante analisar o número de ações possíveis para diferentes volumes de energia e números de oponentes (Tabela 4.5), assim como o tempo de execução necessário para determinar a melhor ação (Figura 4.6).

Tabela 4.5: Número de ações possíveis ao negociar diferentes volumes de energia com diferentes números de oponentes.

Volume	Oponentes			
	2	3	4	5
10	11	66	286	1 001
20	21	231	1 771	10 626
30	31	496	5 456	46 376
40	41	861	12 341	135 751
50	51	1 326	23 426	316 251
60	61	1 891	39 711	635 376
70	71	2 556	62 196	1 150 626

Conforme se pode observar na Tabela 4.5, o número de ações possíveis evolui muito rápido, principalmente com o aumento do número de oponentes. Ao tentar negociar um volume de energia de 70 com 5 oponentes, o *player* apoiado pode tomar mais de um milhão de ações distintas. Na Figura 4.6 é apresentado o tempo de execução necessário para determinar a melhor ação ao tentar negociar diferentes volumes de energia com 5 oponentes.

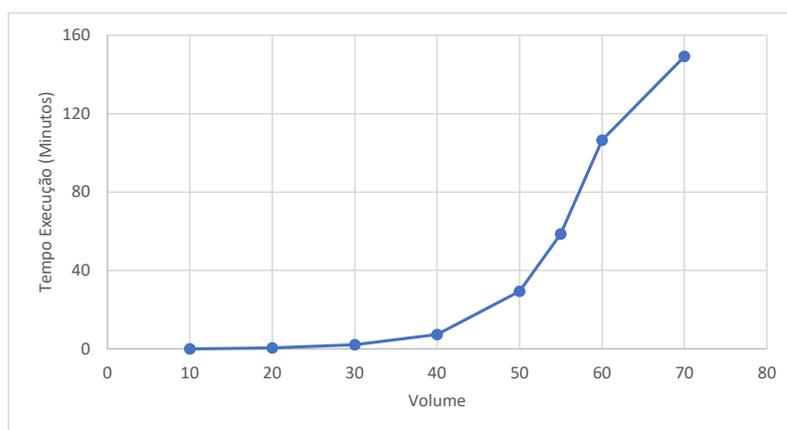


Figura 4.6: Tempo de execução do método de decisão baseado em teoria de jogos.

Devida à complexidade evidenciada na Tabela 4.5, é natural que os tempos apresentados na Figura 4.6 evoluam de forma exponencial. O método de pesquisa de ações baseado em teoria de jogos demora 149,15 minutos (aproximadamente 2 horas e meia).

Após a análise do grau de complexidade que o caso de estudo pode assumir, é especificado na Tabela 4.6, um cenário apropriado.

Tabela 4.6: Cenário do caso de estudo.

Volume de Energia	70
Nr. Oponentes	5
Tipo de Transação	Venda
Período de Negociação	Período 12 de 31 de Outubro de 2008
Contexto	3
Cálculo da Reputação	50% Opinião Pessoal e 50% Opinião Social
Risco	0%, 25%, 50%, 75% e 100%
Método de Decisão	Pessimista, Otimista e Mais Provável
Nr. Ações Possíveis	1 150 626
Método Pesquisa de Ações	Teoria de Jogos e Otimização

O volume de energia considerado é de 70 e o número de oponentes é 5, uma vez que esta combinação é responsável pela geração de 1 150 626 ações diferentes, conforme analisado anteriormente. Para além disso, o sistema vai gerar todas as ações para cada cenário (método de previsão) inserido no sistema, o que aumenta consideravelmente a complexidade do problema a resolver. Usando estes parâmetros é possível obter um cenário com um grau de complexidade adequado aos objetivos deste estudo.

O *player* apoiado foi selecionado ao identificar um dos principais *players* vendedores que tenha vários contractos estabelecidos para os volumes de energia entre 1 e 70 (volume máximo a transacionar). Em relação aos 5 possíveis oponentes, os mesmos foram selecionados ao identificar os *players* compradores de energia com maior número de contractos com diferentes volumes de energia entre 1 e 70; elevado número de contractos; e diferentes níveis de reputação (opinião pessoal do *player* apoiado). Perante estes critérios foram selecionados os *players* apresentados na Tabela 4.7.

Tabela 4.7: Possíveis oponentes.

Nome	Perfil Negociação	Reputação	Grupo
<i>Player 1</i>	1	0.03	2
<i>Player 2</i>	2	0.46	2
<i>Player 3</i>	3	0.50	2
<i>Player 4</i>	4	0.60	2
<i>Player 5</i>	5	0.60	2

A Tabela 4.7 apresenta 5 *players*, em que cada um tem um perfil de negociação diferente, entre os perfis apresentados na Figura 4.1, de forma a potenciar diferentes comportamentos.

O *player* apoiado irá tentar negociar com os possíveis oponentes no período 12 do dia 31 de Outubro de 2008, que corresponde ao último dia do *dataset* considerado. Desta forma é aproveitado o máximo do *dataset* para o processo de aprendizagem. A este período de negociação corresponde o contexto 3, o segundo contexto onde há maior procura de energia e que ocorre tanto no período da manhã como no final do dia.

No que diz respeito ao risco que o *player* apoiado está disposto a correr, serão testados 5 valores diferentes, de 0% a 100% de risco com incrementos de 25%. Em relação ao método de decisão, serão testados os três métodos implementados de forma a ser possível comparar os seus resultados.

Para além das configurações apresentadas, também é necessário definir os cenários a serem gerados pelo sistema. Para este propósito foram selecionados os 9 cenários apresentados na Tabela 4.8.

Tabela 4.8: Cenários / Métodos de previsão.

Nome	Algoritmo	Nr. Contractos
RNA_500	Rede Neuronal Artificial	500
RNA_1000	Rede Neuronal Artificial	1000
MSV_500	Máquinas de Suporte Vectorial	500
MSV_1000	Máquinas de Suporte Vectorial	1000
AD	Árvore de Decisão	1000
FA	Floresta Aleatória	1000
KVMP	K Vizinhos Mais Próximos	1000
RL	Regressão Linear	500
Média	Média	1000

Os cenários são gerados através de 7 algoritmos de previsão distintos: RNA, MSV, AD, FA, KVMP, RL e Média. De forma a serem utilizados diferentes métodos de previsão e não apenas algoritmos de previsão, são considerados 2 cenários que usam RNA mas com um número de contractos diferente. O mesmo acontece com o algoritmo MSV. Este número é relativo ao total de contractos considerados na fase de treino do algoritmo.

4.1.4 Teoria de Jogos

Conforme apresentado nos diagramas de sequência do processo de apoio à fase de pré-negociação, o Agente de Pré-negociação começa por solicitar a análise do contexto de negociação atual. Neste caso trata-se de uma negociação no período 12 de uma segunda-feira, o que corresponde ao contexto 3. Após a determinação do contexto, é executado o processo de geração de cenários. As Figuras 4.7 a 4.15 apresentam todos os cenários gerados.

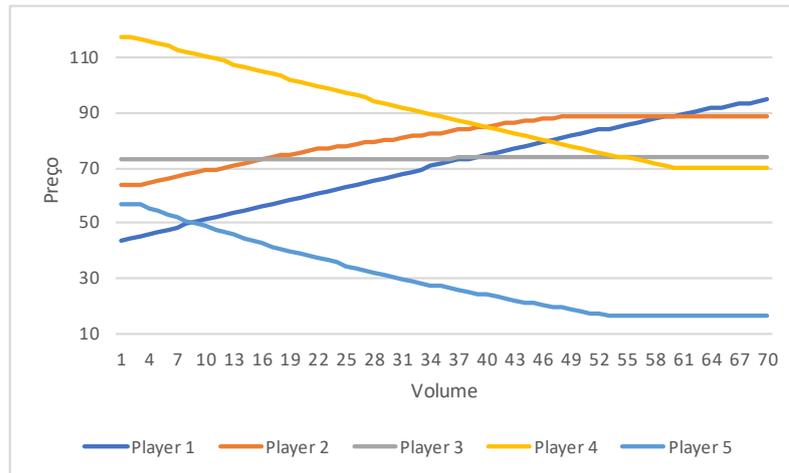


Figura 4.7: Cenário RNA_500.

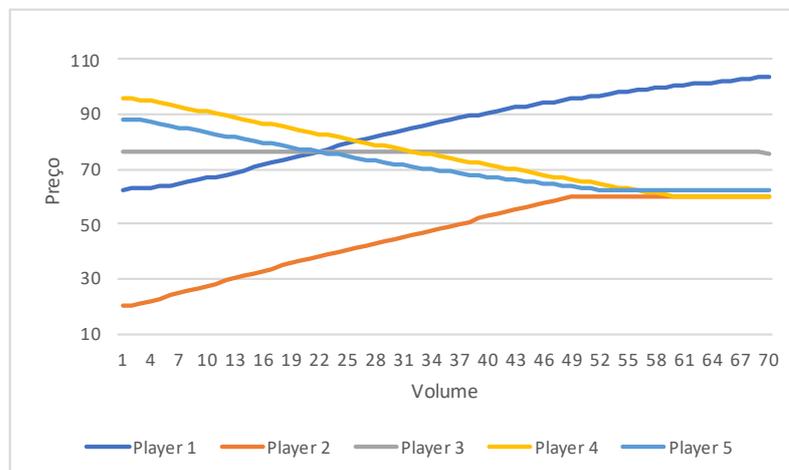


Figura 4.8: Cenário RNA_1000.

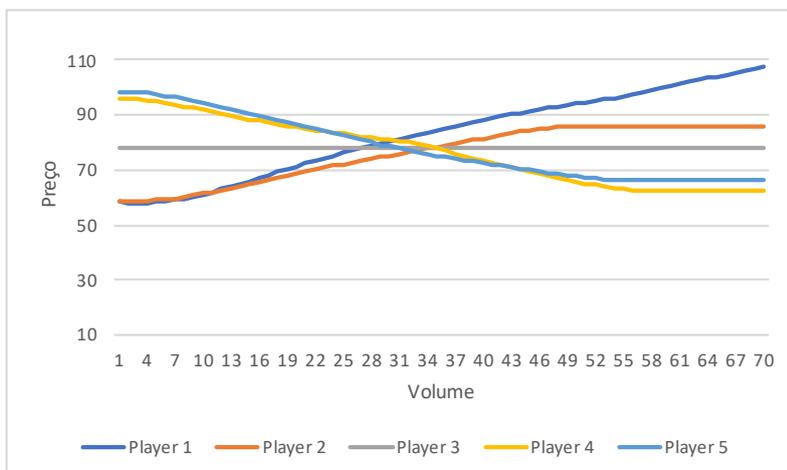


Figura 4.9: Cenário MSV_500.

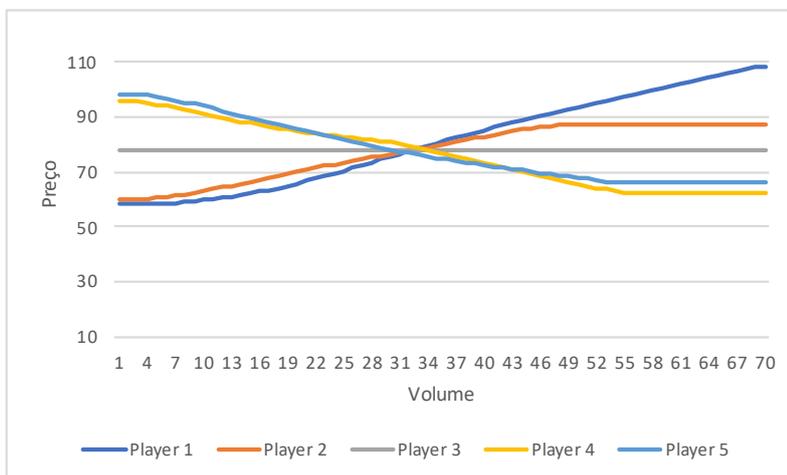


Figura 4.10: Cenário MSV_1000.

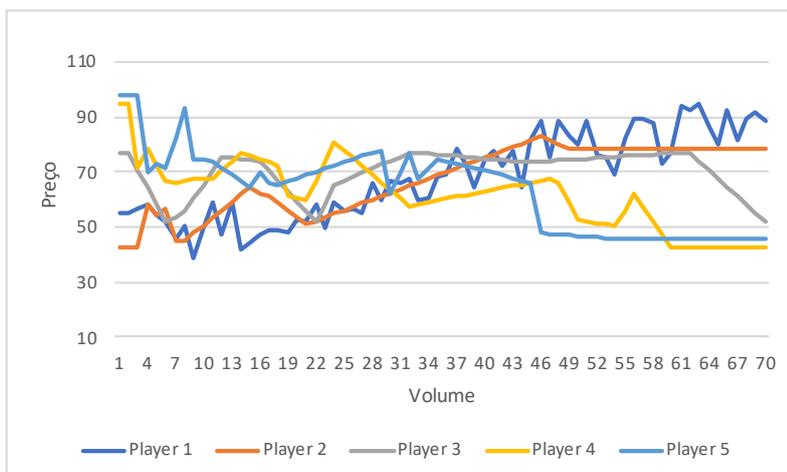


Figura 4.11: Cenário Média.

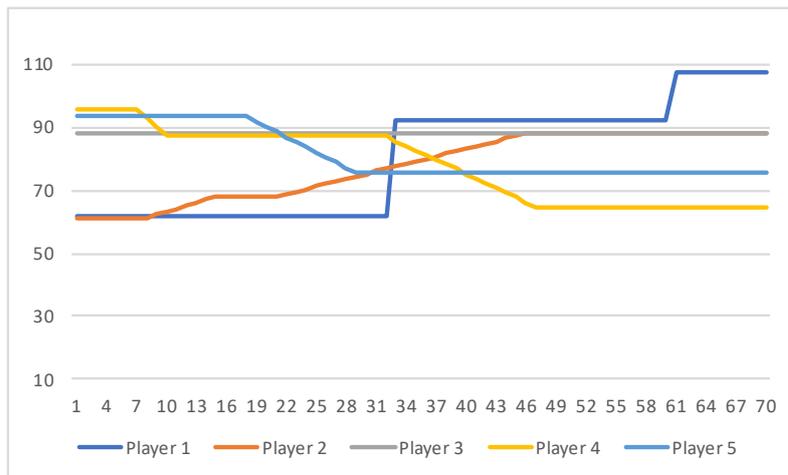


Figura 4.12: Cenário AD.

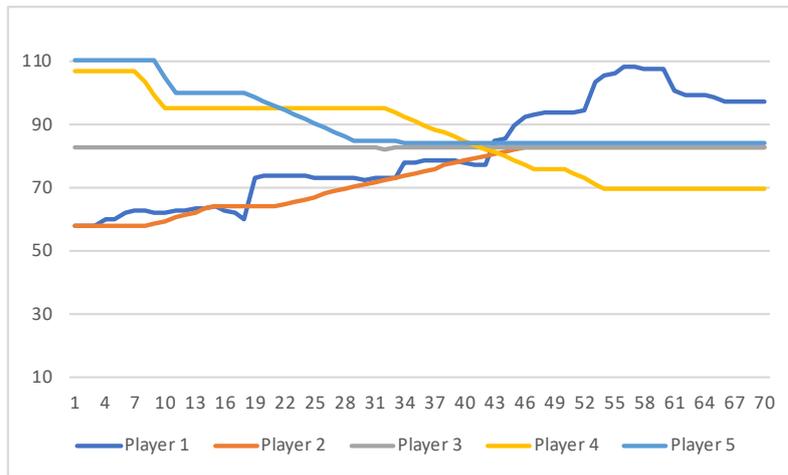


Figura 4.13: Cenário FA.

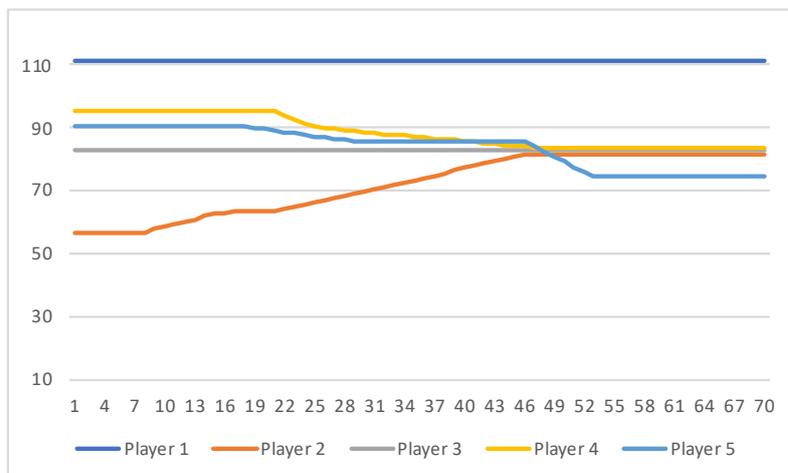


Figura 4.14: Cenário KVMP.

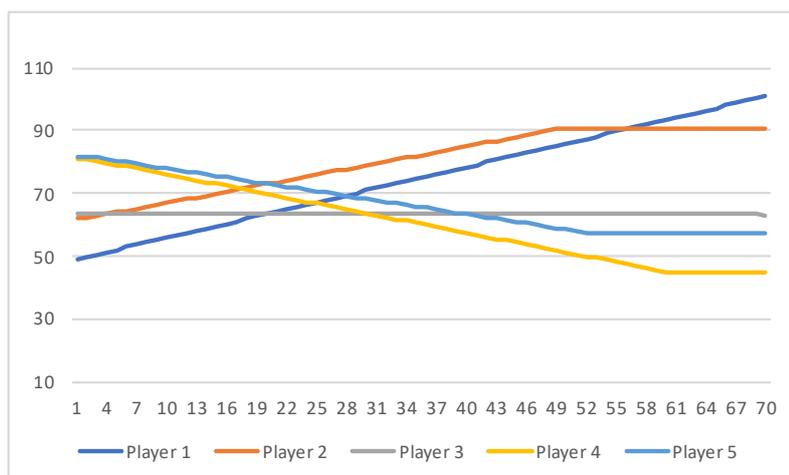


Figura 4.15: Cenário RL.

Conforme se pode observar nos cenários gerados, é previsto um comportamento de cada *player* próximo do esperado, ao seguir os perfis de negociação apresentados anteriormente. Os cenários variam principalmente nos preços máximos e mínimos previstos para cada *player*. Uma vez que só são previstos os volumes de energia que os *players* tenham transacionado anteriormente, o processo de estimação mantém a tendência entre os volumes previstos, o que resulta em variações mais constantes.

Contudo, alguns cenários fogem um pouco à regra e apresentam um padrão um pouco diferente do esperado, como é o caso dos cenários *RNA_500*, *RNA_1000* e *KVMP*. Considerando os diferentes perfis de negociação apresentados na Figura 4.1, esperaria-se cenários com maior interseção dos preços dos diferentes *players*, especialmente para volumes de energia intermédios. No caso dos cenários *RNA_500* e *RNA_1000*, surge um *player* com uma interseção muito prematura ou muito tardia, respetivamente. Quanto ao cenário *KVMP*, o mesmo revelou dificuldades em identificar o comportamento do *Player 1*. Estas diferenças demonstram as diferentes capacidades dos diferentes métodos de previsão de prever os preços praticados pelos diferentes *players* em diferentes períodos de negociação, em diferentes contextos. Um método de previsão pode revelar-se mais adequado a um determinado tipo de *player* ou a um determinado contexto. O método de decisão Mais Provável surgiu com esse intuito: identificar o cenário mais provável para cada *player* em cada contexto.

Considerando o interesse do *player* apoiado em estabelecer um contracto de venda com um volume de 70, o *Player 1* surge como o melhor oponente ao ter o preço mais alto para esse volume (à exceção do cenário *RNA_500*, onde a melhor oferta é do *Player 5*). Contudo, esta análise só é garantidamente válida se não se considerar a reputação de cada *player*. Dependendo do nível de risco que o *player* apoiado está disposto a correr, podem surgir melhores ofertas na relação reputação-preço. O processo de avaliação de reputação é solicitado pelo Agente de Pré-negociação após a geração de cenários. Neste caso de estudo, o Agente de Reputação responde com a informação apresentada na Tabela 4.9.

Tabela 4.9: Reputação final dos possíveis oponentes.

Nome	Opinião Pessoal	Opinião Social	Reputação Final
Player 1	0.03	0.35	0.19
Player 2	0.46	0.38	0.42
Player 3	0.50	0.38	0.44
Player 4	0.60	0.38	0.49
Player 5	0.60	0.38	0.49

O valor final da reputação de cada *player* apresentado na Tabela 4.9 é semelhante à opinião pessoal do *player* apoiado, apesar do *Player 1* apresentar um grande benefício com a inclusão da opinião social. No que diz respeito à componente social, os oponentes apresentam uma reputação muito próxima. Desta forma, torna-se difícil saber exatamente qual a melhor ação que o *player* apoiado pode tomar em diferentes níveis de risco. Uma vez conhecidos os cenários possíveis e a reputação de cada *player*, o Agente de Pré-negociação solicita ao Agente de Pesquisa de Ações a identificação da melhor ação possível. As secções seguintes, 4.1.4 e 4.1.4, apresentam os resultados obtidos para os métodos de decisão Pessimista e Otimista, respetivamente.

Método de Decisão Pessimista

Uma vez que o método de decisão Pessimista consiste na seleção da melhor ação do cenário com menor valor de utilidade global, é importante considerar os valores apresentados na Figura 4.16.

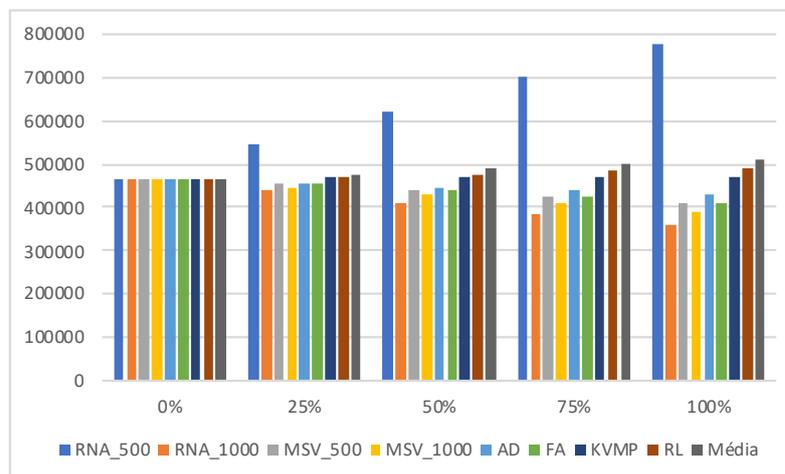


Figura 4.16: Valor global de utilidade de cada cenário para diferentes níveis de risco.

Ao analisar a Figura 4.16, é possível verificar o impacto dos diferentes níveis de risco na utilidade global dos cenários. Quanto maior o risco, maior o contributo do componente económico, o que aumenta consideravelmente a diferença entre os vários cenários. Quando o *player* apoiado não pretende correr qualquer risco, os cenários são apenas avaliados pela reputação dos oponentes, o que vai resultar no mesmo valor para todos os cenários. Nesta análise, torna-se evidente o grande valor de utilidade global apresentado pelo cenário *RNA_500*,

que se deve ao facto deste apresentar as previsões de preços mais elevados entre todos os cenários. Os restantes cenários estão mais próximos e o cenário *RNA_1000* apresenta a menor utilidade global sempre que é considerado algum nível de risco. Desta forma, será este o cenário considerado pelo método de decisão Pessimista para seleção da ação com maior utilidade. No entanto, para 0% de risco, este critério não é aplicável e nesse caso é necessário selecionar a ação com maior utilidade mas menor componente económico. A Tabela 4.10 apresenta a ação recomendada pelo método de decisão Pessimista, para diferentes níveis de risco.

Tabela 4.10: Ação recomendada ao aplicar teoria de jogos e método de decisão Pessimista, para diferentes níveis de risco.

Risco	Cenário	Player 1	Player 2	Player 3	Player 4	Player 5	Total
0%	RNA_500				22 99,68	48 19,00	70 2 906, 96
25%	RNA_1000			30 76,44	22 82,94	18 78,57	70 5 532, 14
50%	RNA_1000	70 103,59					70 7 251, 30
75%	RNA_1000	70 103,59					70 7 251, 30
100%	RNA_1000	70 103,59					70 7 251, 30

Na Tabela 4.10, é apresentado para cada nível de risco, o cenário com menor utilidade global, o volume e respetivo preço a transacionar com cada *player*, e por último o volume e preço total.

Os resultados demonstram que os cenários selecionados pelo método de decisão Pessimista foram os cenários esperados. No caso de 0% de risco, foi selecionado o cenário *ANN_500*, uma vez que este apresentou a ação com menor componente económico, entre as ações com maior utilidade. Para este nível de risco, é recomendado ao *player* apoiado negociar com os *players* que têm o maior valor de reputação (*Players 4 e 5*). Contudo, o preço total esperado fica muito aquém dos outros níveis de risco. Isto deve-se ao desvio do cenário *RNA_500* para o *Player 5*, conforme analisado anteriormente. Assim, o *player* apoiado está preparado para o pior cenário possível mas com grande probabilidade de obter melhores resultados.

Ao aumentar o risco para 25%, o cenário selecionado passa a ser o *ANN_1000*. Perante este aumento, a ação com maior utilidade passa a englobar o *Player 3*, com uma reputação próxima dos *players* melhor reputados. A maior parte do volume é transacionado com o *Player 3* que, entre os 3, apresenta o melhor preço para volumes elevados de energia. O volume restante é transacionado com os *Players 4 e 5* que apresentam melhores preços de energia para volumes inferiores.

No caso de se considerar 50% de risco, ambas as componentes de reputação e economia têm o mesmo peso, o que favorece o *Player 1*, uma vez que este apresenta o melhor preço para a totalidade de energia a transacionar. O componente económico supera a reputação

do *player*, que não é distante o suficiente dos restantes *players*, para desvalorizar essa ação. Esta recomendação mantém-se para níveis de risco superiores uma vez que já foi identificada a ação com o maior componente económico.

A subsecção 4.1.4 permite efetuar a mesma análise mas para o método de decisão Otimista.

Método de Decisão Otimista

No caso do método de decisão Otimista, pretende-se selecionar a ação com maior utilidade entre todos os cenários gerados. A Tabela 4.11 apresenta a ação selecionada para diferentes níveis de risco.

Tabela 4.11: Ação recomendada ao aplicar teoria de jogos e método de decisão Otimista, para diferentes níveis de risco.

Risco	Cenário	Player 1	Player 2	Player 3	Player 4	Player 5	Total
0%	FA				28 94,85	42 83,89	70 6 179, 18
25%	RNA_500		49 88,85		21 100,56		70 6 465, 41
50%	RNA_500		50 88,85		20 101,44		70 6 471, 30
75%	RNA_500		52 88,85		18 103,22		70 6 478, 16
100%	KVMP	70 111,331					70 7 793, 10

Conforme se pode observar na Tabela 4.11, os cenários selecionados pelo método Otimista são diferentes dos selecionados pelo método Pessimista. Para o nível de risco de 0%, o método selecionado é o *FA*, pois é o cenário onde os *players* com maior reputação apresentam melhores preços.

Com o aumento do risco para 25%, a ação com maior utilidade pertence ao cenário *RNA_500*, em que *Player 5* é substituído pelo *Player 2*, dado que este último apresenta um preço superior e uma reputação próxima. O *Player 4* mantém-se mas apresenta um preço ainda mais vantajoso do que no caso anterior. O cenário e os *players* recomendados mantêm-se ao considerar riscos de 50% e 75%. A única alteração nestes níveis de risco é o contributo do *Player 2*, que é cada vez superior, uma vez que a reputação tem cada vez menos peso e o *player* tem melhores preços para maiores volumes de energia.

No caso de 100% de risco, o cenário selecionado é o *KVMP*, onde o *Player 1*, o menos reputado, apresenta a oferta mais alta de todas para o volume de energia que o *player* apoiado pretende transacionar. Os resultados apresentados demonstram que o método Otimista permite selecionar os contratos com possibilidade de serem os mais lucrativos para o *player* apoiado.

A Secção 4.1.5 apresenta os resultados obtidos ao executar o cenário proposto com o método de pesquisa de ações de otimização.

4.1.5 Otimização

O método de pesquisa de ações baseado em otimização é uma alternativa ao método baseado em teoria de jogos. Ambos os métodos recebem como dados de entrada os cenários gerados e o cálculo da reputação de cada oponente. Para a análise deste método são utilizados os mesmos dados, apresentados na Secção 4.1.4, de forma a ser possível comparar os resultados obtidos por ambos os métodos.

Para a realização desta análise, o método de otimização PSO é executado com os parâmetros identificados na Tabela 4.12.

Tabela 4.12: Configuração do método de otimização.

Parâmetro	Valor
Execuções	100
Iterações	150
Partículas	10
Intervalo de Inércia	[0.4, 0.9]
Termo de Atração Local	1
Termo de Atração Global	1

De seguida, são analisados os resultados obtidos ao aplicar este método em conjunto com os métodos de decisão Pessimista e Otimista. Por último, é analisado o tempo de execução deste método e comparado com o método baseado em teoria de jogos.

Método de Decisão Pessimista

A aplicação do método de decisão Pessimista com o método de otimização é um pouco diferente do método de teoria de jogos, uma vez que não são analisadas todas as ações de cada cenário. Desta forma, o algoritmo de otimização pré-seleciona a ação com maior utilidade de cada cenário e, de seguida, é o método de decisão Pessimista seleciona a ação com menor utilidade.

A Tabela 4.13 apresenta a ação recomendada pelo método Pessimista, para diferentes níveis de risco.

Tabela 4.13: Ação recomendada ao aplicar otimização e método de decisão Pessimista, para diferentes níveis de risco.

Risco	Cenário	Player 1	Player 2	Player 3	Player 4	Player 5	Total
0%	RNA_500	3 45,32	5 65,45	7 73,01	17 104,12	38 24,94	70 3 692, 16
25%	RL			27 63,73	30 63,75	13 76,61	70 4 629, 34
50%	AD	16 61,63	1 61,18	8 88,06	20 87,12	25 82,09	70 5 546, 31
75%	Média	28 66,07	1 42,53		38 61,54	3 98,00	70 4 525, 00
100%	RNA_500				70 70,21		70 4 914, 73

Ao analisar a Tabela 4.13, é possível observar que foram selecionados diferentes cenários nos diferentes níveis de risco, com exceção para o risco de 0%, quando comparado com os resultados obtidos pelo método baseado em teoria de jogos. No caso do risco de 0%, é interessante verificar que foram selecionados todos os *players* apesar de apenas os *Players* 4 e 5 terem o nível de reputação máximo. Isto deve-se ao facto do algoritmo de otimização não ter encontrado a solução ótima, apesar de ficar próximo da mesma. Contudo, o impacto dos *players* com menor reputação é baixo, uma vez que a maior parte da energia é transacionada com os *players* de maior reputação.

No caso do risco de 25%, o cenário selecionado foi o *RL*, onde o método de otimização encontrou uma ação com melhor reputação do que a anterior, apesar da sua importância ser menor. Neste caso, ao dar algum peso ao componente económico, os *Players* 3 e 4 ganham maior destaque ao apresentar melhores preços para volumes de energia altos do que o *Player* 5.

Ao aumentar o risco para 50%, a ação com menor utilidade entre as melhores de cada cenário, pertence ao cenário *AD*, onde o *Player* 1, o menos reputado, começa a ganhar algum destaque. O mesmo sucede quando o risco é de 75% e o cenário selecionado é o da *Média*. Contudo, esta ação apresenta um preço total inferior à ação recomendada para risco de 50%. Por último, em caso de risco máximo, foi selecionado o cenário *RNA_500*, onde a melhor ação corresponde a estabelecer um contrato com a totalidade de energia com o *Player* 4. No entanto, é possível verificar na Figura 4.7, que a melhor ação deste cenário seria transacionar toda a energia com o *Player* 1.

A Figura 4.17 apresenta a comparação do preço total das ações recomendadas por ambos os métodos de pesquisa de ações.

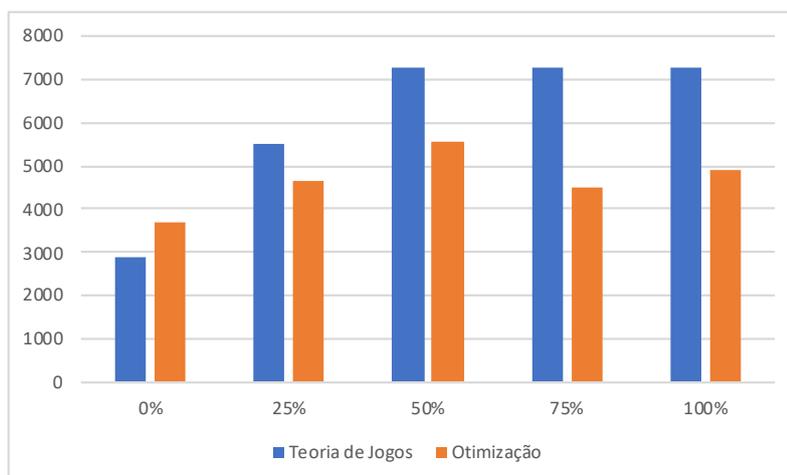


Figura 4.17: Comparação do preço total das ações recomendadas para o método de decisão Pessimista.

Conforme se pode observar na Figura 4.17, o método de otimização apresenta resultados com uma distância significativa face aos valores apresentados pelo método de teoria de jogos, com exceção dos níveis de risco de 0% e 25%. Esta diferença entre ambos os métodos também se deve à diferente aplicação do método Pessimista. Ao aplicar o método de teoria de jogos, apesar do cenário selecionado ter a menor utilidade global, a ação selecionada tem um valor de utilidade superior a algumas das melhores ações de outros cenários. Por outro lado, no caso da otimização, o método Pessimista seleciona sempre a pior das melhores ações.

No caso do método de decisão Pessimista, os resultados apresentados ajustam-se à necessidade do *player* apoiado de se preparar para o pior cenário, ao apresentar-lhe cenários ainda mais desafiantes. Contudo, no caso do método de decisão otimista, pretende-se obter recomendações o mais próximo possível da solução ótima, de forma a maximizar o potencial lucro do *player* apoiado.

Método de Decisão Otimista

Para a aplicação do método de decisão otimista, o método de otimização procura a melhor ação de cada cenário e no fim seleciona a ação com maior valor de utilidade. A Tabela 4.14 apresenta os resultados obtidos para cada nível de risco.

Tabela 4.14: Ação recomendada ao aplicar otimização e método de decisão Otimista, para diferentes níveis de risco.

Risco	Cenário	Player 1	Player 2	Player 3	Player 4	Player 5	Total
0%	AD				66 64,75	4 93,42	70 4 647, 11
25%	KVMP				70 83,70		70 5 858, 99
50%	KVMP				42 85,14	28 86,03	70 5 984, 97
75%	KVMP	43 111,33			12 95,48	15 90,48	70 7 290, 26
100%	KVMP	39 111,33		10 82,74	19 95,48	2 90,48	70 7 164, 42

Na Tabela 4.14, é possível verificar que o cenário *KVMP* foi selecionado em todos os casos com risco associado. Apenas no caso de 0% de risco que o cenário selecionado foi o *AD*. Com o método de decisão Otimista, o algoritmo de otimização foi capaz de identificar ações próximas das esperadas para os diferentes níveis de risco. Os valores totais são bastante superiores aos valores apresentados pelo método de decisão Pessimista. Contudo, ainda é possível observar alguma distância das soluções ótimas (apresentadas pelo método de decisão baseado em teoria de jogos). A diferença entre ambas é evidenciada na Figura 4.18.

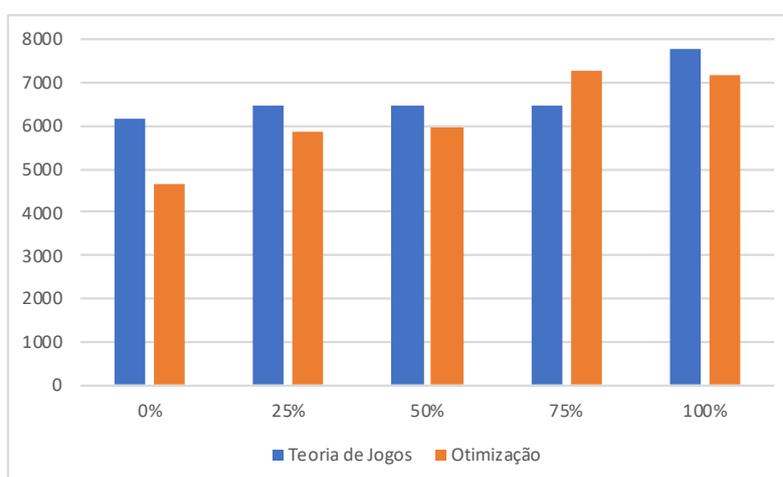


Figura 4.18: Comparação do preço total das ações recomendadas para o método de decisão Otimista.

Ao analisar a Figura 4.18, é possível comprovar que os resultados obtidos pelo método de otimização estão bastante próximos dos resultados do método de teoria de jogos. Desta forma, o método de otimização revela-se uma boa opção para o *player* apoiado de forma a obter boas soluções num espaço de tempo reduzido. O método de otimização permite adicionar flexibilidade ao sistema em relação ao tempo necessário para determinar a melhor solução. Consoante o desempenho desejado pelo *player* apoiado, o sistema pode analisar todas as opções e demorar o tempo que for necessário ou, por outro lado, utilizar o método

de otimização e adequar os seus parâmetros ao tempo de execução desejado. O número de partículas, iterações e execuções podem ser alterados de acordo com o desempenho esperado.

Avaliação de Tempo de Execução

A Figura 4.19 apresenta o tempo de execução do método de decisão baseado em otimização.

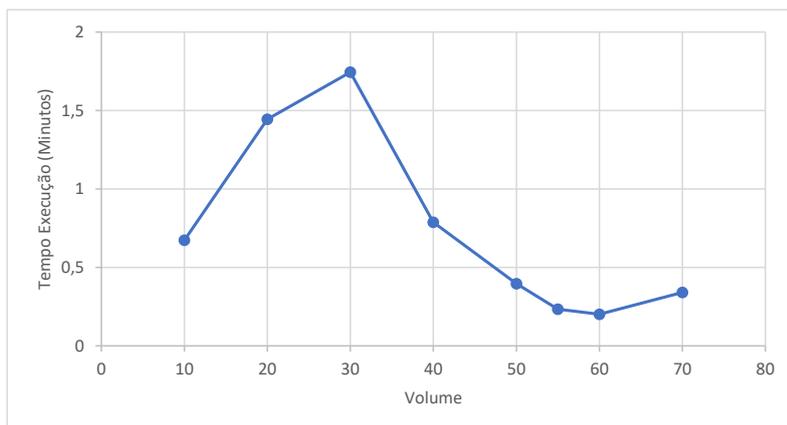


Figura 4.19: Tempo de execução do método de decisão baseado em otimização.

O tempo de execução apresentado na Figura 4.19, demonstra o grande contributo do método de otimização: uma enorme redução no tempo de execução. Este método é capaz de determinar a melhor ação no cenário analisado neste caso de estudo em cerca de 20 segundos (apenas 0,23% do tempo necessário pelo método baseado em teoria de jogos). Contudo, a qualidade dos resultados não é a mesma e, dessa forma, quanto mais tempo o algoritmo de otimização tiver disponível, mais a sua recomendação estará próxima da solução ótima. Ainda assim, a relação qualidade-tempo é muito vantajosa.

4.1.6 Aprendizagem por reforço

A componente de aprendizagem por reforço é uma componente muito importante da fase de apoio à pré-negociação, uma vez que permite identificar quais os cenários mais prováveis para cada *player* em cada um dos contextos considerados. Para além de contar com diferentes AAR para esse fim, existe um AAR Superior responsável por determinar o AAR com maior capacidade de determinar o melhor cenário para cada *player* em cada contexto.

De forma a ser possível analisar o processo de aprendizagem, o sistema irá gerar os diferentes cenários para cada contexto de cada um dos cinco possíveis oponentes, para todos os períodos dos dias 29 e 30 de Outubro de 2008 (os dois dias anteriores ao dia considerado no cenário deste caso de estudo). A geração de cenários para estes dias será realizada através do treino dos diferentes métodos de previsão com os contratos estabelecidos até ao dia 28 de Outubro de 2008. Com esta análise será possível observar a capacidade de aprendizagem dos diferentes AAR, do ARR Superior, e posteriormente, analisar a recomendação do método de decisão Mais Provável (alternativa aos métodos Pessimista e Otimista).

O AAR Superior avaliou os diferentes AARs recorrendo à percentagem de acerto do cenário que eles recomendaram face ao cenário real, a cada contrato analisado. A Tabela 4.15 apresenta os resultados de aprendizagem do AAR Superior para cada contexto de cada *player*. As avaliações estão normalizadas entre 0 e 1 de forma a permitir identificar facilmente qual o melhor AAR em cada momento (valor 1). Para além desta informação, também são apresentados os contractos analisados durante o processo de avaliação. A tabela apresenta ainda diferentes graus de granularidade, permitindo observar o melhor AAR por *player*-contexto, *player*, e geral.

Tabela 4.15: Resultados de aprendizagem do AAR Superior para cada contexto de cada *player*.

Player	Contexto	Q-Learning	Roth-Erev	AAR Simples	Contractos
1	1	0,980	1	0,985	12
	2	1	0,958	0,884	10
	3	1	0,922	0,910	22
	4	1	1	1	4
	Total	1	0,975	0,949	48
2	1	0,964	1	0,947	12
	2	1	0,984	0,947	10
	3	1	0,981	0,954	22
	4	1	0,965	0,977	4
	Total	1	0,991	0,965	48
3	1	0,941	1	0,920	72
	2	1	0,999	0,970	60
	3	0,982	1	0,982	132
	4	1	0,948	0,998	24
	Total	0,994	1	0,980	288
4	1	1	0,970	0,957	72
	2	0,981	1	0,966	60
	3	0,978	1	0,975	132
	4	1	0,967	0,967	24
	Total	1	0,994	0,976	288
5	1	0,936	1	0,926	72
	2	1	0,977	0,966	60
	3	0,992	1	0,949	132
	4	1	0,943	0,943	24
	Total	1	0,998	0,963	288
Total Global		1	0,993	0,968	960

Ao analisar a Tabela 4.15 é possível verificar que o *Q-Learning* é o AAR que domina a maior parte dos contextos de cada *player*, e conseqüentemente obteve a melhor pontuação global. A sua superioridade foi verificada em todos os *players*, com exceção do *Player 3* onde o AAR *Roth-Erev* apresentou melhores resultados. O AAR Simples não superou os restantes

AAR em nenhuma das avaliações realizadas, o que comprova a importância de utilizar AAR capazes de aprender ao longo do tempo.

A Tabela 4.16 apresenta os resultados de aprendizagem do AAR Superior para cada contexto no geral.

Tabela 4.16: Resultados de aprendizagem do AAR Superior para cada contexto.

Contexto	Q-Learning	Roth-Erev	AAR Simples	Contractos
1	0,970	1	0,953	240
2	1	0,987	0,950	200
3	1	0,990	0,963	440
4	1	0,965	0,977	80

Conforme se pode verificar na Tabela 4.16, o *Q-Learning* apresentou o melhor resultado em todos os contextos menos no contexto 1 onde foi superado pelo AAR *Roth-Erev*. Ao analisar o conjunto de resultados de aprendizagem do AAR Superior, é possível verificar a importância de contar com diferentes algoritmos de AAR, uma vez que não existe um AAR que seja o melhor a detetar o cenário mais provável em todas as circunstâncias. Ao contar com vários AAR, o sistema está preparado para dar a melhor recomendação consoante o *player* e contexto em causa.

Na Figura 4.20 é apresentado o processo de aprendizagem do AAR Superior para o contexto 3 do *Player 4*. A seleção deste exemplo do processo de aprendizagem teve como critério o número de contratos analisados e a variação do perfil de negociação do *player*.

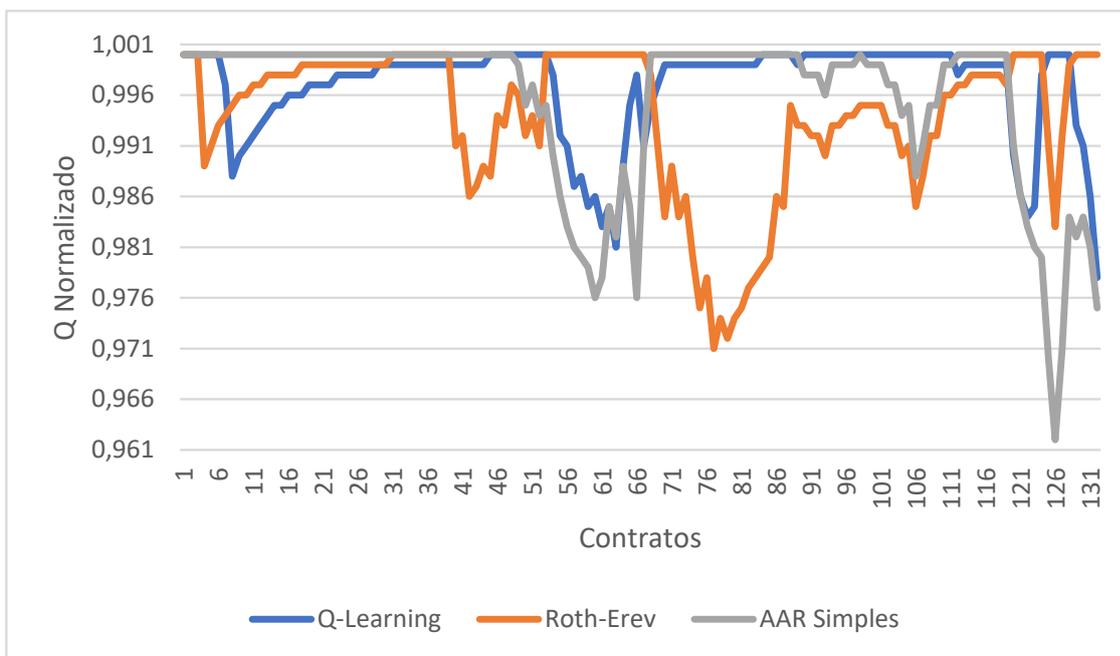


Figura 4.20: Processo de aprendizagem do AAR Superior para o contexto 3 do *Player 4*.

A Figura 4.20 demonstra que o melhor AAR para o contexto 3 do *Player 4*, o Roth-Erev, não foi sempre o melhor AAR ao longo do processo de aprendizagem. Muito pelo contrário, em alguns momentos teve o pior desempenho como foi o caso do período entre os contratos 70 e 120. No entanto, o Roth-Erev recuperou e tornou-se no mais capaz de identificar o cenário mais provável. Os AAR Q-Learning e AAR Simples foram melhores durante mais tempo mas acabaram por perder pontos durante a avaliação dos últimos contratos.

As Tabelas 4.17 e 4.18 apresentam os resultados de aprendizagem do AAR melhor pontuado, o Q-Learning para cada contexto de cada *player*, sobre o cenário mais provável. Os resultados gerais de cada contexto são apresentados na Tabela 4.19.

Tabela 4.17: Resultados de aprendizagem do AAR Q-Learning para cada contexto de cada player.

Player	Contexto	RNA_500	RNA_1000	MSV_500	MSV_1000	AD	FA	KVMP	RL	Média
1	1	0,930	1	0,783	0,879	0,863	0,755	0,973	0,855	0,983
	2	0,937	0,843	0,964	0,940	0,987	0,927	0,716	0,942	1
	3	0,981	0,969	0,957	0,965	0,959	0,970	0,861	0,993	1
	4	0,797	0,854	1	0,930	0,708	0,952	0,810	0,558	0,938
	Total	0,930	0,935	0,945	0,947	0,897	0,919	0,857	0,854	1
2	1	0,965	0,958	0,905	0,914	0,910	0,878	0,940	0,964	1
	2	0,941	0,957	0,990	0,985	1	0,970	0,906	0,978	0,981
	3	0,947	0,968	0,974	0,974	0,973	1	0,953	0,860	0,971
	4	0,926	0,845	1	0,980	0,915	0,877	0,828	0,840	0,927
	Total	0,974	0,960	0,997	0,993	0,979	0,960	0,935	0,939	1
3	1	0,967	0,960	0,950	0,930	0,923	0,932	0,932	1	0,960
	2	0,989	0,986	0,999	1	0,998	0,970	0,970	0,994	0,963
	3	0,939	0,965	0,980	0,978	0,981	1	1	0,817	0,950
	4	1	0,781	0,993	0,993	0,994	0,820	0,819	0,992	0,891
	Total	0,993	0,941	1	0,995	0,993	0,949	0,949	0,970	0,960
4	1	0,972	0,915	0,946	0,925	0,925	0,913	0,931	1	0,980
	2	0,958	0,997	0,999	1	0,996	0,989	0,972	0,992	0,986
	3	0,923	0,990	0,983	0,980	0,977	1	0,993	0,819	0,981
	4	0,957	0,812	1	0,999	0,973	0,864	0,833	0,922	0,914
	Total	0,970	0,946	1	0,994	0,985	0,959	0,949	0,950	0,983

Tabela 4.18: Continuação: Resultados de aprendizagem do AAR Q-Learning para cada contexto de cada player.

Player	Contexto	RNA_500	RNA_1000	MSV_500	MSV_1000	AD	FA	KVMP	RL	Média
5	1	0,990	0,956	0,942	0,921	0,929	0,910	0,923	1	0,938
	2	0,879	1	0,999	1	0,997	0,994	0,966	0,985	0,976
	3	0,943	0,946	0,976	0,974	0,973	1	0,957	0,810	0,953
	4	0,949	0,931	1	0,999	0,986	0,870	0,851	0,888	0,966
	Total	0,960	0,979	1	0,994	0,992	0,963	0,944	0,940	0,979
	Total Global	0,977	0,963	1	0,996	0,981	0,961	0,938	0,941	0,996

Tabela 4.19: Resultados de aprendizagem do AAR Q-Learning para cada contexto.

Contexto	RNA_500	RNA_1000	MSV_500	MSV_1000	AD	FA	KVMP	RL	Média
1	0,992	0,985	0,931	0,940	0,936	0,903	0,967	0,991	1
2	0,945	0,961	0,995	0,989	1	0,974	0,910	0,983	0,986
3	0,952	0,973	0,980	0,980	0,978	1	0,959	0,865	0,977
4	0,927	0,846	1	0,982	0,917	0,878	0,829	0,841	0,929

Os resultados apresentados nas Tabelas 4.17 e 4.18, permitem verificar que o cenário *MSV_500* é o cenário mais provável na maior parte dos casos. No entanto, os cenários *MSV_1000* e *Média* ficaram muito próximos. O cenário *MSV_500* apresentou os melhores resultados para os *players* 3, 4 e 5 enquanto que nos restantes, o melhor foi o cenário *Média*. Contudo, estes não são sempre os melhores cenários em todos os contextos. Todos os algoritmos tiveram pelo menos um contexto de um *player* em que foram mais capazes de identificar o cenário mais provável. Ainda assim, ao analisar as avaliações em cada contexto, sem individualizar os *players*, apresentadas na Tabela 4.19, é possível verificar que os cenários mais prováveis de cada contexto são sempre diferentes. Os cenários mais prováveis dos contextos 1 e 4 são os esperados enquanto que os cenários AD e FA surpreendem nos contextos 2 e 3, respetivamente, ao superar os restantes cenários.

Através desta avaliação, confirma-se a importância de incluir no sistema vários métodos de previsão, de forma a ser possível gerar cenários próximos da realidade para os diferentes contextos e para os diferentes *players*. Os pontos fracos de uns métodos de previsão são colmatados por outros métodos, garantindo uma capacidade de previsão superior à soma da capacidade de cada método individualmente.

A Figura 4.21 apresenta o processo de aprendizagem do AAR Q-Learning para o contexto 3 do *Player 4* (mantendo o caso analisado na Figura 4.20).

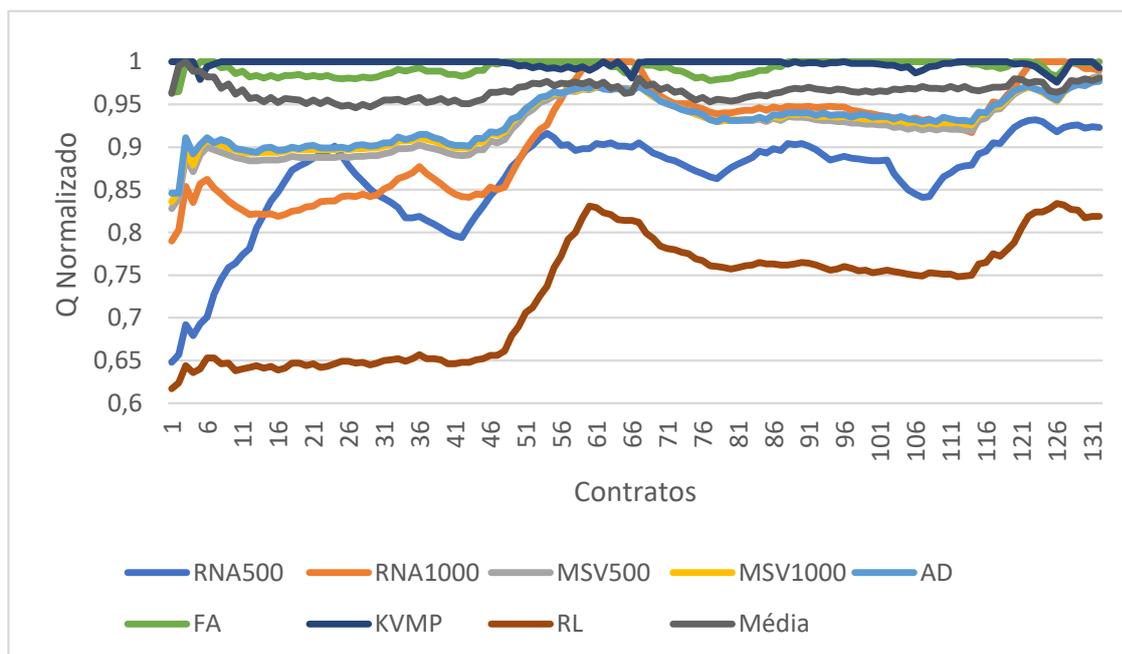


Figura 4.21: Processo de aprendizagem do AAR Q-Learning para o contexto 3 do *Player 4*, sobre o cenário mais provável.

Atendendo aos resultados apresentados na Tabela 4.17, o cenário mais provável para o *Player 4* no contexto 3 é o FA, seguido do KVMP e RNA_1000. Ao analisar a Figura 4.21 é possível comprovar esse resultado, uma vez que são esses os 3 algoritmos que terminam com maior pontuação. O cenário RNA_1000 foi o cenário mais próximo da realidade durante a maior parte do processo de aprendizagem, sendo seguido de perto, e alternando em alguns momentos, pelo FA (que acabou por terminar o processo em primeiro). O cenário RNA_1000 começou distante do melhor cenário mas acabou por recuperar a meio

do processo de avaliação, tornando-se no cenário mais provável durante alguns contratos, e voltando a surgir no topo no final do processo. Os cenários *RNA_500* e *RL* foram praticamente sempre os cenários mais distantes da realidade.

Método de Decisão Mais Provável

Através do processo de aprendizagem por reforço, é possível determinar o cenário mais provável que o *player* apoiado irá encontrar ao negociar com os oponentes selecionados. A Tabela 4.20 apresenta o cenário mais provável de cada *player* para o contexto 3, determinado pelo AAR melhor pontuado para o *player* e contexto em questão.

Tabela 4.20: Cenário mais provável para cada *player* para o contexto 3.

Player	AAR	Cenário
1	Q-Learning	Média
2	Q-Learning	FA
3	Roth-Erev	FA
4	Roth-Erev	KVMP
5	Roth-Erev	MSV_1000

A Tabela 4.20 apresenta para os *Players* 1 e 2, os cenários já identificados na Tabela 4.19, durante a análise do processo de aprendizagem do AAR *Q-Learning* sobre o cenário mais provável. No entanto, no caso dos *Players* 3, 4 e 5, o AAR mais provável é o *Roth-Erev*, que identificou os cenários *FA*, *KVMP* e *MSV_1000*, respectivamente, como os mais prováveis.

Através da junção dos cenários mais prováveis de cada *player* para o contexto 3, é possível obter o cenário geral mais provável conforme apresentado na Figura 4.22.

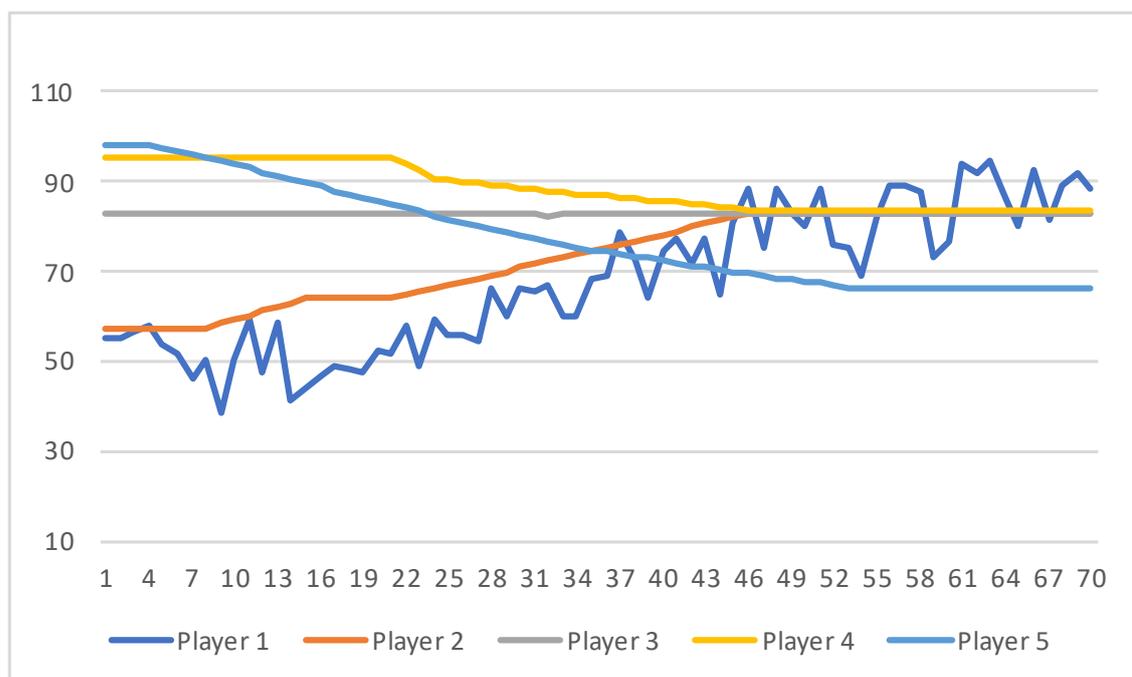


Figura 4.22: Cenário Mais Provável

A Figura 4.22 apresenta um cenário mais próximo da realidade ao considerar apenas as melhores previsões, eliminando o ruído gerado por alguns métodos de previsão. Por exemplo, o intervalo de preços está mais de acordo com o esperado, ficando entre 38,80 e 98,50. Desta forma foi possível ignorar casos como a previsão do cenário *KVMP* para o *Player 5* de um preço de 110 para todos os volumes considerados. Para além deste caso mais evidente, também as previsões do *Player 5* e do *Player 2* nos cenários *RNA_500* e *RNA_1000*, respetivamente, puderam ser descredibilizadas através do processo de aprendizagem.

A Tabela 4.21 apresenta a ação recomendada pelo método de decisão mais provável ao utilizar o método de pesquisa de ações baseado em teoria de jogos.

Tabela 4.21: Ação recomendada ao aplicar teoria de jogos e método de decisão Mais Provável, para diferentes níveis de risco.

Risco	Player 1	Player 2	Player 3	Player 4	Player 5	Total
0%				52 83,70	18 87,28	70 5 923, 44
25%			34 82,80	21 95,48	15 89,83	70 6 167, 73
50%			36 82,81	21 95,48	13 91,48	70 6 175, 48
75%	63 94,48			3 95,48	4 97,96	70 6 630, 52
100%	63 94,48			3 95,48	4 97,96	70 6 630, 52

Ao analisar as ações recomendadas na Tabela 4.21, é possível verificar, uma vez mais, a tendência de negociar com os *players* mais reputados nos níveis de risco inferiores e a inclusão de *players* menos reputados com o aumento do risco. No entanto, comparativamente aos resultados apresentados pelos métodos de decisão pessimista e otimista, o *Player 3* tem mais impacto e as ações recomendadas para os níveis de risco de 75% e 100% não incluem apenas o *Player 1*. Apesar de apenas considerar o cenário mais provável de cada *player*, este método de decisão identificou ações com preços totais muito próximos do cenário otimista, mas com valores de reputação superiores.

O método de decisão Mais Provável permite assim ao *player* apoiado preparar-se para o cenário que irá encontrar no período de negociação, sem correr o risco de apresentar um excesso de confiança ou de cautela.

4.2 Caso de Estudo de Apoio à Fase de Negociação

O presente caso de estudo tem o intuito de validar a capacidade do SMA desenvolvido em apoiar a decisão de um *player* apoiado na fase de negociação. Para esse efeito, pretende-se avaliar a capacidade do SMA em identificar as melhores ofertas a apresentar ao oponente em questão, de forma a obter o melhor resultado possível. Para esse fim, este estudo pretende dar continuidade ao estudo realizado à fase de pré-negociação, apresentando os resultados

do apoio à negociação recomendada pelo método de decisão Mais provável (Tabela 4.21), para 100% de risco.

Para além do objetivo principal indicado, é também importante analisar o contributo das diferentes técnicas utilizadas. Desta forma, na Secção 4.2.1 é apresentado o pré-processamento de dados necessário para a realização deste caso de estudo. Na Secção 4.2.2 é apresentado o cenário considerado neste estudo, com base no cenário já apresentado no caso de estudo anterior. Por último, na Secção 4.2.3 é apresentado o resultado de apoio à decisão ao utilizar a rede de aprendizagem para determinar as melhores ofertas.

4.2.1 Pré-processamento de Dados

Apesar deste estudo ser baseado no cenário do caso de estudo anterior, a fase de apoio à negociação requer informação extra: as opiniões do *player* apoiado, e as partilhadas pelos outros *players*, sobre a melhor estratégia a adotar contra um determinado oponente; e a credibilidade dos *players* que partilharam a sua opinião.

A geração das opiniões dos diferentes *players*, teve por base a determinação da estratégia de cada *player* em cada contexto. Para esse efeito foi gerada uma estratégia aleatória para cada *player* para o contexto 1. Aos restantes contextos de cada *player* foram atribuídas estratégias tão semelhantes com a estratégia do contexto 1 como a semelhança entre o contexto em questão e o contexto 1. Desta forma é possível garantir uma grande variedade de estratégias na base de dados assim como uma coerência de um mesmo *player* em diferentes contextos.

Após a determinação das estratégias de cada *player*, em cada contexto, essa informação é atribuída a todos os *players*. No entanto, cada *player* só recebe informação acerca dos *players* com quem tenham negociado anteriormente. No entanto, nem todos os *players* estarão dispostos a partilhar as suas opiniões exatamente como elas são. De forma a ser possível avaliar a credibilidade de cada *player*, foi gerado um valor aleatório de credibilidade, entre 0 e 1 para cada *player*. As opiniões de cada *player* são invertidas de acordo com o seu valor de credibilidade. Caso o valor seja 0, as suas opiniões são o inverso das originais, enquanto que no valor máximo de credibilidade, as opiniões mantêm-se. No entanto, o valor de credibilidade de cada *player* é ocultado após o pré-processamento dos dados, obrigando a rede de aprendizagem a determiná-la automaticamente, baseado na qualidade das recomendações.

4.2.2 Cenário

A Tabela 4.22 apresenta o cenário considerado neste estudo.

Tabela 4.22: Cenário do caso de estudo.

Volume de Energia	61
Tipo de Transação	Venda
Oponente	<i>Player 1</i>
Período de Negociação	Período 12 de 31 de Outubro de 2008
Contexto	3
Preço Esperado	94,48
Preço Ótimo	104,48
Preço Limite	84,48

Assim como recomendado pelo método de decisão Mais Provável, para 100% de risco, o *player* apoiado irá tentar negociar com o *Player 1*, um volume de 61 de energia a um preço esperado de 94,48. Para o *player* apoiado, o valor ótimo seria estabelecer um contrato a um preço de 104,48 e não aceitará propostas abaixo dos 84,48.

A Tabela 4.23 apresenta as estratégias consideradas no SMA para a realização deste estudo.

Tabela 4.23: Estratégias de negociação.

#	Estratégia	Parâmetros	Grupo	Contra-Estratégia
1	Determinado	-	2	1
2	Moderado	$m = 2,5$	3	8
3	Percentagem_0.05	$p = 0.05$	3	8
4	Percentagem_0.10	$p = 0.10$	3	8
5	Seguir Comportamento	-	-	-
6	Ansioso_0.6	fator = 0.6	4	8
7	Ansioso_0.9	fator = 0.9	4	8
8	Guloso_0.9	fator = 0.9	1	1
9	AGA_0.6	fator = 0.6	4	3
10	AGA_0.9	fator = 0.9	4	2
11	GA_0.6	fator = 0.6	3	8
12	GA_0.9	fator = 0.9	3	8
13	GAG_0.6	fator = 0.6	4	8
14	GAG_0.9	fator = 0.9	4	8
15	GAGAG_0.6	fator = 0.6	4	8
16	GAGAG_0.9	fator = 0.9	4	8

Assim como no caso dos métodos de previsão, é possível verificar na Tabela 4.23 que existem algumas variações de estratégias, ao alterar-se a configuração das mesmas. As estratégias base são 10 (apresentadas na Secção 3.2.1) com a adição de 6 variações, num total de 16 estratégias distintas.

As estratégias foram agrupadas de forma a ser possível identificar os diferentes tipos de estratégias. Após a análise do melhor número de grupos, foi determinado que existem quatro tipos de estratégias principais: variação constante, lenta a rápida, rápida a lenta e sem variação. As variações da estratégia Guloso ficaram no grupo 1, ao apresentar um perfil de negociação que começa lento e termina rápido. Por sua vez, a estratégia Determinado ficou no grupo 2 ao apresentar um perfil sem variação. No grupo 3 ficaram as estratégias

constantes que são as Moderado, Percentagem e GA. Por último, no grupo 4 ficaram as restantes estratégias, com um perfil de negociação que começa rápido e termina lento.

Na Tabela 4.23 são ainda apresentadas a melhor contra-estratégia para cada estratégia. Conforme se pode observar, a estratégia Guloso_0.9 é a selecionada para a maioria das estratégias. Esta estratégia pode ser usada como contra-estratégia em caso de dúvida, uma vez que tem grande probabilidade de sucesso. Por outro lado, a estratégia Determinado é a melhor contra-estratégia dela própria e as variações de Guloso. Por último, as estratégias AGA_0.6 e AGA_0.9 têm como contra estratégias a Percentagem_0.05 e Moderado, respetivamente.

Para além das contra-estratégias individuais, também foram determinadas as contra-estratégias de cada grupo, apresentadas na Tabela 4.24.

Tabela 4.24: Contra-estratégias dos grupos de estratégias.

Grupo	Contra-Estratégia
1	1
2	1
3	8
4	8

A contra-estratégia de cada grupo foi selecionada ao procurar a contra-estratégia mais frequente entre os membros do grupo. Neste caso, os membros dos grupos 1 e 2 têm como contra-estratégia a estratégia Determinado. Por outro lado, o membro do grupo 3 tem como contra-estratégia a estratégia Guloso_0.9, assim como a maioria dos membros do grupo 4.

A Tabela 4.25 e a Figura 4.24 apresentam os perfis de negociação de cada estratégia quando usadas numa compra.

Tabela 4.25: Perfil de negociação das estratégias na compra de energia.

Estratégia	Iterações							
	1	2	3	4	5	6	7	8
Determinado	0,500	0,500	0,500	0,500	0,500	0,500	0,500	0,500
Moderado	0,000	0,143	0,286	0,429	0,571	0,714	0,857	1,000
Ansioso_0.6	0,000	0,464	0,675	0,796	0,874	0,929	0,969	1,000
Ansioso_0.9	0,000	0,549	0,745	0,846	0,907	0,948	0,978	1,000
Guloso_0.9	0,000	0,020	0,048	0,086	0,143	0,238	0,429	1,000
Percentagem_0.05	0,000	0,123	0,252	0,387	0,529	0,679	0,835	1,000
Percentagem_0.10	0,000	0,105	0,221	0,349	0,489	0,644	0,813	1,000
Seguir Comportamento	-	-	-	-	-	-	-	-
GA_0.6	0,000	0,015	0,035	0,063	0,561	0,787	0,916	1,000
GA_0.9	0,000	0,020	0,047	0,085	0,639	0,837	0,938	1,000
GAG_0.6	0,000	0,016	0,038	0,591	0,843	0,987	0,992	1,000
GAG_0.9	0,000	0,021	0,050	0,658	0,875	0,987	0,993	1,000
GAGAG_0.6	0,000	0,015	0,524	0,755	0,762	0,770	0,996	1,000
GAGAG_0.9	0,000	0,019	0,585	0,786	0,793	0,802	0,997	1,000
AGA_0.6	0,000	0,467	0,680	0,686	0,694	0,705	0,908	1,000
AGA_0.9	0,000	0,538	0,730	0,736	0,745	0,757	0,936	1,000

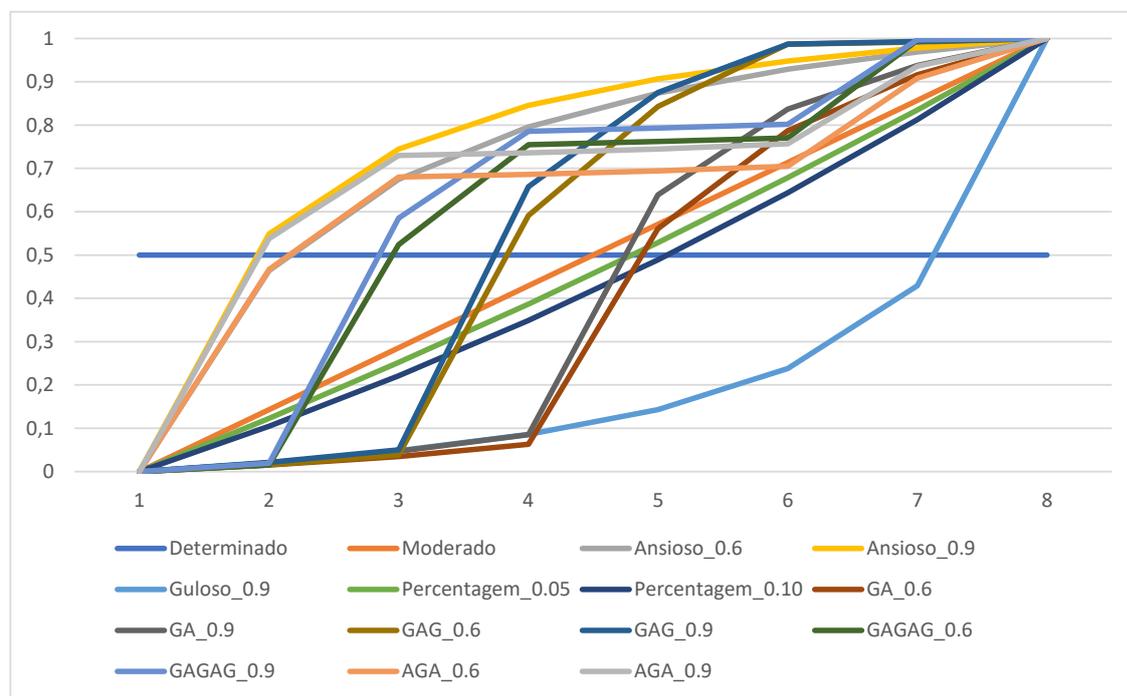


Figura 4.23: Perfil de negociação das estratégias na compra de energia.

Com o auxílio dos perfis de negociação de cada estratégia, é possível compreender melhor as diferenças entre cada estratégia. Na Figura 4.23, é possível identificar os quatro grupos gerados: a estratégia Determinado com um preço sem variação no centro do gráfico; a estratégia Guloso no arco inferior; as estratégias constantes na diagonal do gráfico; e as

estratégias com grande impacto da estratégia Ansioso, a dominar o lado superior à diagonal do gráfico.

A Figura 4.24 apresenta o grau de semelhança entre as estratégias de negociação.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1	0,44	0,44	0,43	-	0,35	0,32	0,31	0,45	0,42	0,28	0,28	0,25	0,24	0,34	0,33
2	0,44	1	0,95	0,90	-	0,56	0,48	0,46	0,65	0,58	0,71	0,72	0,69	0,66	0,70	0,66
3	0,44	0,95	1	0,95	-	0,51	0,44	0,51	0,61	0,54	0,74	0,74	0,66	0,64	0,66	0,62
4	0,43	0,90	0,95	1	-	0,46	0,39	0,56	0,57	0,50	0,76	0,74	0,63	0,60	0,62	0,58
5	-	-	-	-	1	-	-	-	-	-	-	-	-	-	-	-
6	0,35	0,56	0,51	0,46	-	1	0,92	0,06	0,85	0,85	0,32	0,35	0,51	0,53	0,69	0,71
7	0,32	0,48	0,44	0,39	-	0,92	1	0,00	0,83	0,83	0,25	0,28	0,44	0,46	0,62	0,65
8	0,31	0,46	0,51	0,56	-	0,06	0,00	1	0,21	0,13	0,49	0,44	0,23	0,20	0,22	0,18
9	0,45	0,65	0,61	0,57	-	0,85	0,83	0,21	1	0,92	0,40	0,40	0,48	0,49	0,70	0,70
10	0,42	0,58	0,54	0,50	-	0,85	0,83	0,13	0,92	1	0,34	0,34	0,45	0,46	0,66	0,67
11	0,28	0,71	0,74	0,76	-	0,32	0,25	0,49	0,40	0,34	1	0,94	0,61	0,57	0,47	0,43
12	0,28	0,72	0,74	0,74	-	0,35	0,28	0,44	0,40	0,34	0,94	1	0,66	0,61	0,49	0,46
13	0,25	0,69	0,66	0,63	-	0,51	0,44	0,23	0,48	0,45	0,61	0,66	1	0,95	0,66	0,63
14	0,24	0,66	0,64	0,60	-	0,53	0,46	0,20	0,49	0,46	0,57	0,61	0,95	1	0,67	0,65
15	0,34	0,70	0,66	0,62	-	0,69	0,62	0,22	0,70	0,66	0,47	0,49	0,66	0,67	1	0,95
16	0,33	0,66	0,62	0,58	-	0,71	0,65	0,18	0,70	0,67	0,43	0,46	0,63	0,65	0,95	1

Figura 4.24: Similaridade entre as estratégias de negociação.

Conforme se pode analisar na Figura 4.24, a estratégia 1 (Determinado) é a que apresenta menor grau de semelhança médio com as restantes estratégias, justificando assim a sua presença isolada num grupo. A estratégia 8 (Guloso) apresenta uma situação semelhante, com graus de semelhança baixos, especialmente no caso das estratégias baseadas na estratégia Ansioso. Contrariamente, as restantes estratégias são mais facilmente agrupáveis, como é o caso das estratégias 2-4; 6,7,9 e 10; 11 e 12; 13 e 14; e 15 e 16.

Por último, é importante considerar as estratégias de negociação do oponente em questão para os diferentes contextos, apresentadas na Tabela 4.26.

Tabela 4.26: Estratégias do oponente nos diferentes contextos.

Contexto 1	Guloso_0.9
Contexto 2	Moderado
Contexto 3	Ansioso_0.6
Contexto 4	Ansioso_0.9
Preço Ótimo	84,48
Preço Limite	104,48

As estratégias do oponente foram especificamente atribuídas após a fase de pré-processamento, de forma a contar com alguma diversidade. Para este estudo é considerado que o *Player 1* terá os mesmos objetivos de preço nos diferentes contextos, baseado na recomendação para o contexto 3. O oponente tem um preço ótimo equivalente ao preço limite do *player* apoiado e vice-versa.

A Secção 4.2.3 apresenta os resultados obtidos ao executar a rede de aprendizagem para o cenário identificado.

4.2.3 Negociação

A Tabela 4.27 apresenta o resultado da negociação do *player* apoiado com o *Player 1*, nos diferentes contextos, seguindo as recomendações da rede de aprendizagem. Na tabela são apresentadas as estratégias recomendadas ao *player* apoiado em cada iteração da negociação, assim como a classificação da estratégia do oponente. Cada iteração contém ainda o preço apresentado por cada *player* até ambos chegarem a um acordo. Por último é apresentada a recompensa resultante da negociação, utilizada para treinar a rede de aprendizagem.

Tabela 4.27: Resultados de negociação com *Player 1* nos diferentes contextos.

Contexto		Iterações								Recompensa	
		1	2	3	4	5	6	7	8		
1	Estratégia	8	8	8	1	1	1	1	1	1	0,50
	Player Apoiado	104,48	104,16	103,73	94,48	94,48	94,48	94,48	94,48	94,48	
	Player 1	84,48	84,80	85,23	85,83	86,73	88,23	91,23	91,23	91,23	
	Estratégia	3	3	3	14	8	8	8	8	8	
2	Estratégia	8	8	8	8	8	8	8	8	8	0,66
	Player Apoiado	104,48	104,16	103,73	103,13	102,23	100,73	97,73	97,73	97,73	
	Player 1	84,48	86,98	89,48	91,98	94,48	96,98	96,98	96,98	96,98	
	Estratégia	4	4	4	2	2	2	2	2	2	
3	Estratégia	8	8	8	8	8	8	8	8	8	0,66
	Player Apoiado	104,48	104,16	103,73	103,13	102,23	100,73	97,73	97,73	97,73	
	Player 1	84,48	91,98	95,39	97,34	98,60	99,48	99,48	99,48	99,48	
	Estratégia	2	2	2	6	6	6	6	6	6	
4	Estratégia	8	8	8	8	8	8	8	8	8	0,81
	Player Apoiado	104,48	104,16	103,73	103,13	102,23	100,73	97,73	97,73	97,73	
	Player 1	84,48	93,95	97,34	99,07	100,13	100,13	100,13	100,13	100,13	
	Estratégia	6	6	6	7	7	7	7	7	7	

Conforme se pode observar na Tabela 4.27, o *player* apoiado conseguiu estabelecer contratos com um preço igual ou superior ao previsto pelo cenário Mais Provável do caso de estudo anterior. Primeiramente, interessa analisar os resultados do contexto 3, o contexto analisado no estudo da pré-negociação. No início da negociação, o sistema assumiu que a estratégia do *Player 1* neste contexto seria a 2 (Moderado), uma vez que, ao nunca ter negociado com o *Player 1* anteriormente, foi selecionada a estratégia mais comum entre os oponentes conhecidos no mesmo contexto. Consequentemente, a estratégia recomendada ao *player* apoiado é a estratégia 8 (Guloso_0.9), a contra-estratégia da estratégia 2. Ambos os *players* iniciam a negociação no seu preço ótimo e vão movendo as ofertas em direção ao seu preço limite. Ao fim de três iterações, o sistema já é capaz de aplicar o algoritmo de classificação com maior eficiência e dessa forma foi capaz de identificar corretamente a estratégia do *Player 1* (estratégia 6: Ansioso_0.6). A Figura 4.25 apresenta o resultado do algoritmo de classificação ao analisar as três iterações. O algoritmo recebe como dados de entrada, os valores normalizados das estratégias conhecidas, nas suas três primeiras iterações, com o objetivo de classificar as ofertas normalizadas do *Player 1*, numa dessas estratégias.

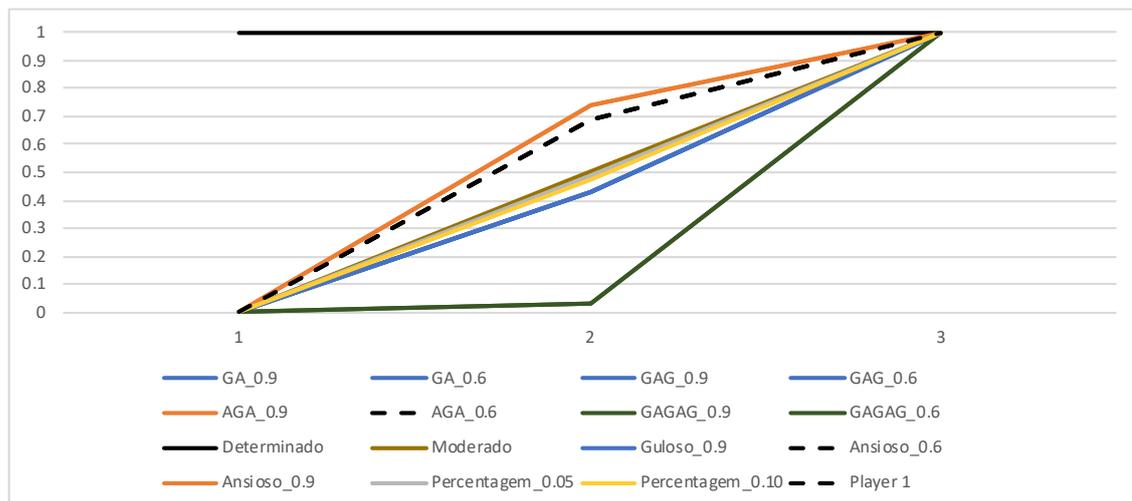


Figura 4.25: Classificação da estratégia do *Player 1* ao fim de três iterações.

A Figura 4.25 permite compreender o quão próximas as estratégias são nas suas primeiras iterações. Nesta figura é possível identificar claramente os quatro tipos de estratégias principais. Apesar da dificuldade nesta fase, o algoritmo de classificação foi capaz de identificar corretamente a estratégia do *Player 1*. No entanto, também poderia ter sido selecionada a estratégia *AGA_0.6*, que apresenta exatamente os mesmos valores. A qualidade dos resultados obtidos pelo processo de classificação aumenta consideravelmente com o aumentar do número de iterações. A Figura 4.26 apresenta o resultado do algoritmo de classificação ao analisar as seis iterações de ofertas do *Player 1*.

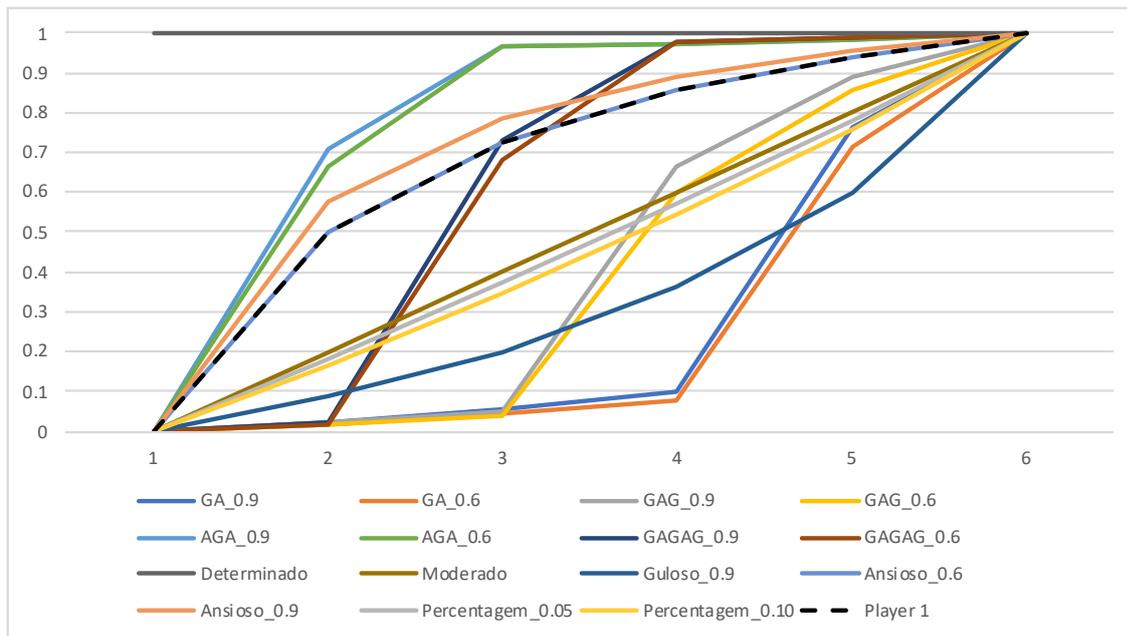


Figura 4.26: Classificação da estratégia do *Player 1* ao fim de seis iterações.

Ao comparar os resultados das Figura 4.25 e 4.26, é possível observar o grande impacto do número de iterações na classificação da estratégia do oponente. Nesta fase da negociação, a estratégia *Ansioso_0.6* está isolada e foi corretamente identificada.

Retomando a análise do resultado para o contexto 3, a alteração na classificação da estratégia do *Player 1* não alterou o rumo da negociação uma vez que tanto a estratégia 2 (*Moderado*) como a estratégia 6 (*Ansioso_0.6*) têm a mesma contra-estratégia (8: *Guloso_0.9*). Ao fim de 7 iterações, o *player* apoiado apresentou um preço inferior ao preço que o oponente estaria disposto a apresentar na sua próxima oferta, fechando o acordo com um preço de 97,73.

Em relação ao contexto 4, o oponente alterou a sua estratégia para a estratégia 7 (*Ansioso_0.9*), uma variação com uma ansiedade mais acentuada, quando comparada com a estratégia usada no contexto 3. Assim como no contexto anterior, nas primeiras três iterações, o sistema baseou-se na estratégia mais usada pelos oponentes conhecidos no mesmo contexto. Neste caso, a estratégia do *Player 1* foi classificada como sendo a estratégia 6 (*Ansioso_0.6*), que é próxima da correta. A estratégia 6 seria então identificada a partir da iteração 4 em que é utilizado o processo de classificação. Durante toda a negociação, foi recomendado ao *player* apoiado a utilização da estratégia 8 (*Guloso_0.9*) que é contra-estratégia das estratégias atribuídas ao *Player 1* ao longo da negociação. Neste contexto, o *player* apoiado conseguiu estabelecer o contrato mais cedo e a um preço superior (100,73), muito próximo do preço ótimo e muito acima do esperado.

No caso do contexto 1, o *Player 1* adotou a estratégia 8 (*Guloso*), a principal contra-estratégia das restantes estratégias. A estratégia mais comum entre os oponentes conhecidos deste contexto é a estratégia 3 (*Percentagem_0.05*). Assim sendo, a rede de aprendizagem recomendou a estratégia 8 nas primeiras três iterações. Na iteração 4, o sistema classifica a estratégia do oponente como sendo a estratégia 14 (*GAG_0.9*). Apesar de não ser exatamente a estratégia correta, ambas apresentam o mesmo perfil após 3 iterações. A partir da quinta iteração, o algoritmo de classificação já conseguiu separar as estratégias o

suficiente para classificar corretamente a estratégia do *Player 1*. Nesse momento, a rede de aprendizagem foi capaz de recomendar ao *player* apoiado, a prática da melhor contra-estratégia (estratégia 1: Determinado). A partir desta iteração, o *player* apoiado manteve o mesmo preço, aguardando a aceitação do *Player 1*. A negociação terminou ao fim de oito iterações, com um preço de 94,48, exatamente o preço esperado.

Por último, no contexto 2, a estratégia do *Player 1* foi inicialmente considerada como sendo a estratégia 4 (Porcentagem_0.10), a estratégia mais comum entre os oponentes conhecidos neste contexto. Ao fim de três iterações, o processo de classificação foi capaz de identificar corretamente a estratégia do *Player 1* como sendo a estratégia 2 (Moderado). Para a negociação contra esta estratégia, também é recomendada, pela rede de aprendizagem, a utilização da estratégia 8 (Guloso_0.9). A negociação no contexto 2 teve um desfecho idêntico ao do contexto 3, onde o preço acordado foi de 97,73.

Após a análise dos resultados obtidos, nos diferentes contextos, é apresentado na Seção 4.2.4, o funcionamento da rede de aprendizagem, internamente, para determinar a melhor estratégia a recomendar ao *player* apoiado.

4.2.4 Rede de Aprendizagem

Para a análise do funcionamento da rede de aprendizagem, serão consideradas as negociações do *player* apoiado com o *Player 1*, no contexto 3. Na Figura 4.27 são apresentadas as pontuações de cada estratégia, para cada componente da rede de aprendizagem, assim como os pesos respectivos, no momento da primeira negociação.

A figura começa por apresentar a avaliação de cada estratégia segundo o ponto de vista do sistema (resultado das negociações do *player* apoiado), sobre os oponentes em geral (Geral); oponentes com o mesmo perfil de negociação que o oponente em questão (Perfil) e o próprio oponente (Oponente). O mesmo tipo de categorias também são apresentadas para a informação partilhada por outros *players* (Outros). Após conhecidas as avaliações das componentes Sistema e Outros, as mesmas são somadas de forma ponderada, de acordo com os pesos de cada componente, resultando nas avaliações finais de cada componente (Geral, Perfil e Oponente). Por último são conhecidas as avaliações finais ao aplicar a média ponderada dos três componentes.

As avaliações apresentadas já incluem a informação de todos os contextos com o seu devido peso (grau de semelhança com o contexto atual); informação de todos os perfis com o seu devido peso (grau de semelhança com a estratégia do oponente); e credibilidade dos *players* que partilharam a sua opinião no componente Outros. O processo de avaliação recorreu ao AAR Superior para identificar o AAR com melhores resultados para o oponente e contexto em questão. Para além disso, o AAR Superior também determinou o método de pesagem mais adequado. Neste estudo, foram considerados o AAR Q-Learning e o método de pesagem Média Ponderada.

Estratégia	Sistema			Outros			Geral	Perfil	Oponente	Final
	Geral	Perfil	Oponente	Geral	Perfil	Oponente				
1	0,42	0,31	0,00	0,24	0,27	0,39	0,33	0,29	0,19	0,27
2	0,48	0,46	0,00	0,23	0,23	0,36	0,35	0,35	0,18	0,29
3	0,51	0,51	0,00	0,23	0,23	0,35	0,37	0,37	0,18	0,30
4	0,54	0,56	0,00	0,23	0,23	0,35	0,38	0,40	0,17	0,32
5	0,50	0,46	0,00	0,23	0,23	0,36	0,36	0,35	0,18	0,30
6	0,20	0,06	0,00	0,33	0,44	0,47	0,27	0,25	0,23	0,25
7	0,15	0,00	0,00	0,36	0,50	0,50	0,26	0,25	0,25	0,25
8	0,80	1,00	0,00	0,34	0,50	0,46	0,57	0,75	0,23	0,52
9	0,34	0,21	0,00	0,25	0,32	0,41	0,30	0,27	0,21	0,26
10	0,28	0,13	0,00	0,28	0,38	0,44	0,28	0,25	0,22	0,25
11	0,45	0,49	0,00	0,23	0,23	0,35	0,34	0,36	0,18	0,29
12	0,41	0,44	0,00	0,24	0,23	0,36	0,32	0,34	0,18	0,28
13	0,26	0,23	0,00	0,29	0,31	0,41	0,28	0,27	0,20	0,25
14	0,24	0,20	0,00	0,30	0,33	0,42	0,27	0,26	0,21	0,25
15	0,30	0,22	0,00	0,27	0,32	0,41	0,28	0,27	0,21	0,25
16	0,27	0,18	0,00	0,29	0,34	0,42	0,28	0,26	0,21	0,25
Peso	0,50	0,50	0,50	0,50	0,50	0,50	0,33	0,33	0,33	1,00

Figura 4.27: Pesos e avaliações da rede de aprendizagem no início da negociação com o *Player 1* no contexto 3.

Ao analisar a componente Sistema, apresentada na Figura 4.27, é possível confirmar que o sistema não tem qualquer informação acerca do próprio oponente, antes da primeira negociação com o mesmo. As avaliações do subcomponente Perfil estão de acordo com a contra-estratégia sugerida na Tabela 4.27, uma vez que as estratégias têm uma pontuação próxima do seu grau de semelhança com a estratégia 8 (Guloso_0.9). O histórico de negociações com *players* com o mesmo perfil de negociação do *Player 1*, garantiu ao *player* apoiado um conhecimento avançado da melhor contra-estratégia. No caso da subcomponente geral, onde consta a avaliação segundo as negociações com todos os *players* conhecidos, é mantida a recomendação da estratégia 8 (Guloso_0.9), apesar de apresentar algumas diferenças relativamente à subcomponente Perfil.

Contrariamente à componente Sistema, na componente Outros as avaliações não são tão esclarecedoras, apesar da estratégia 8 manter-se como uma das melhores avaliadas. Esta proximidade de todas as avaliações deve-se ao *player* apoiado / sistema desconhecem a credibilidade dos *players* que partilharam a sua opinião. Ao confrontar todas as opiniões, tanto as positivas como as negativas, o resultado torna-se algo confuso. A rede de aprendizagem deve conseguir avaliar a credibilidade de cada *player* consoante o resultado da negociação em análise. Neste subcomponente já existe informação acerca do oponente uma vez que parte dos *players* que partilharam a sua opinião, negociaram anteriormente com o *Player 1*.

Após a consideração das avaliações de cada estratégia nos componentes Sistema e Outros, é realizada a média ponderada dos seus subcomponentes. Nesta primeira negociação, todos componentes têm o mesmo peso. O resultado da média ponderada indica o componente Perfil como o mais próximo da realidade, apresentando uma avaliação de 0,75 para a estratégia 8 (Guloso_0.9).

Por último, no componente final, o resultado é o esperado, com a recomendação da estratégia 8 (Guloso_0.9), com uma grande vantagem face às restantes estratégias. Após a primeira negociação com o *Player 1* no contexto 3, a rede de aprendizagem é atualizada com a recompensa da negociação. A Figura 4.28 apresenta o resultado da atualização da rede de aprendizagem, ao prestar apoio à segunda negociação com o mesmo *player* e contexto.

Estratégia	Sistema			Outros			Geral Perfil Oponente			Final
	Geral	Perfil	Oponente	Geral	Perfil	Oponente	Geral	Perfil	Oponente	
1	0,42	0,31	0,00	0,24	0,24	0,31	0,33	0,28	0,16	0,26
2	0,48	0,46	0,00	0,25	0,24	0,33	0,37	0,36	0,17	0,30
3	0,51	0,51	0,00	0,26	0,26	0,34	0,39	0,39	0,18	0,32
4	0,54	0,56	0,00	0,27	0,28	0,35	0,41	0,43	0,18	0,34
5	0,50	0,46	0,00	0,25	0,24	0,33	0,38	0,36	0,17	0,31
6	0,20	0,06	0,00	0,26	0,31	0,33	0,23	0,18	0,17	0,19
7	0,15	0,00	0,00	0,27	0,34	0,34	0,21	0,16	0,18	0,18
8	0,80	1,00	1,00	0,46	0,66	0,55	0,63	0,84	0,76	0,75
9	0,34	0,21	0,00	0,24	0,26	0,32	0,29	0,23	0,17	0,23
10	0,28	0,13	0,00	0,25	0,27	0,32	0,26	0,20	0,17	0,21
11	0,45	0,49	0,00	0,24	0,25	0,33	0,35	0,38	0,17	0,30
12	0,41	0,44	0,00	0,24	0,24	0,32	0,33	0,35	0,17	0,29
13	0,26	0,23	0,00	0,25	0,25	0,32	0,26	0,24	0,17	0,22
14	0,24	0,20	0,00	0,25	0,26	0,32	0,25	0,23	0,17	0,21
15	0,30	0,22	0,00	0,24	0,26	0,32	0,27	0,24	0,17	0,23
16	0,27	0,18	0,00	0,25	0,26	0,32	0,26	0,22	0,17	0,22
Peso	0,52	0,52	0,48	0,48	0,48	0,52	0,34	0,35	0,31	1,00

Figura 4.28: Pesos e avaliações da rede de aprendizagem na segunda negociação com o *Player 1* no contexto 3

Na Figura 4.28, é possível verificar que o sistema passou a ter uma avaliação para a estratégia utilizada na negociação anterior. Uma vez que é a única estratégia e o resultado da negociação foi bom, a avaliação da estratégia é de 1,00. As subcomponentes Geral e Perfil mantêm-se inalteradas uma vez que não contêm informação associada ao oponente diretamente. Em relação à componente Outros, verificam-se várias alterações uma vez que a credibilidade dos *players* foi atualizada. Contudo, ainda estão distantes das avaliações verificadas no próprio Sistema. As classificações finais de cada subcomponente foram atualizadas de acordo com as alterações já verificadas e reforçam a posição da estratégia 8 (Guloso_0.9). Neste caso, a avaliação final desta estratégia segundo o componente Oponente já foi mais de acordo com os restantes componentes (Geral e Perfil). As avaliações finais aumentaram a distância da estratégia recomendada para as restantes estratégias, ficando mais próximas das semelhanças das estratégias com a estratégia 8 (Guloso_0.9).

Em relação aos pesos de cada subcomponente, verifica-se uma descida do peso do subcomponente Oponente do componente Sistema e dos subcomponentes Geral e Perfil do componente Outros. Isto deve-se ao baixo contributo dos mesmos para a recomendação da melhor estratégia, sendo penalizados de acordo. Nas componentes Geral, Perfil e Oponente finais, os pesos também foram atualizados de forma a penalizar a componente Oponente e favorecer a componente Perfil.

A Figura 4.29 apresenta o resultado da atualização da rede de aprendizagem, ao prestar apoio à quinta negociação com o mesmo *player* e contexto.

Estratégia	Sistema			Outros			Geral	Perfil	Oponente	Final
	Geral	Perfil	Oponente	Geral	Perfil	Oponente				
1	0,42	0,31	0,00	0,41	0,30	0,31	0,42	0,31	0,15	0,29
2	0,48	0,46	0,00	0,47	0,45	0,46	0,48	0,46	0,23	0,39
3	0,51	0,51	0,51	0,50	0,50	0,51	0,51	0,51	0,51	0,51
4	0,54	0,56	0,56	0,53	0,55	0,56	0,54	0,56	0,56	0,55
5	0,50	0,46	0,00	0,49	0,45	0,46	0,50	0,46	0,23	0,39
6	0,20	0,06	0,00	0,20	0,06	0,06	0,20	0,06	0,03	0,09
7	0,15	0,00	0,00	0,15	0,01	0,00	0,15	0,00	0,00	0,05
8	0,80	1,00	1,00	0,79	0,99	1,00	0,79	1,00	1,00	0,93
9	0,34	0,21	0,00	0,34	0,20	0,21	0,34	0,21	0,10	0,21
10	0,28	0,13	0,00	0,27	0,12	0,13	0,28	0,13	0,06	0,15
11	0,45	0,49	0,00	0,44	0,48	0,49	0,44	0,49	0,24	0,39
12	0,41	0,44	0,00	0,40	0,43	0,44	0,41	0,44	0,22	0,35
13	0,26	0,23	0,00	0,26	0,22	0,23	0,26	0,23	0,11	0,20
14	0,24	0,20	0,00	0,24	0,19	0,20	0,24	0,20	0,10	0,18
15	0,30	0,22	0,00	0,29	0,21	0,22	0,29	0,22	0,11	0,21
16	0,27	0,18	0,00	0,26	0,17	0,18	0,26	0,18	0,09	0,18
Peso	0,51	0,51	0,50	0,49	0,49	0,50	0,32	0,34	0,34	1,00

Figura 4.29: Pesos e avaliações da rede de aprendizagem na quinta negociação com o *Player* 1 no contexto 3

Após algumas negociações, é possível verificar na Figura 4.29, que a rede de aprendizagem foi capaz de atualizar corretamente a reputação dos *players* que partilharam a sua opinião. Isto verifica-se porque as avaliações da componente Outros já estão muito próximas das avaliações presentes no componente Sistema. Consequentemente, o resultado das avaliações finais de cada subcomponente também fica semelhante, resultando numa avaliação final semelhante à similaridade das estratégias com a estratégia 8 (Guloso_0.9). Os pesos de cada componente ficaram muito equilibrados com exceção de uma ligeira desvalorização do componente Geral face à informação acerca do oponente e dos *players* com o mesmo perfil.

Através da análise da rede de aprendizagem é possível perceber a importância de cada componente para a obtenção da melhor recomendação possível. Ao incluir diferentes fontes de informação, o *player* apoiado está protegido contra fontes menos credíveis ou simplesmente inadequadas a um determinado *player* ou contexto.

4.3 Conclusões

Os casos de estudo apresentados nesta secção permitem demonstrar as vantagens em utilizar o sistema desenvolvido para o apoio às fases de pré-negociação e negociação dos contratos bilaterais de energia.

No primeiro caso de estudo, foi demonstrado o enorme contributo do sistema ao ser capaz de analisar todas as ações possíveis que o *player* apoiado pode tomar, num cenário com mais

de um milhão de ações possíveis e vários cenários alternativos. O módulo de identificação de contextos tem um papel muito importante ao permitir ao *player* apoiado preparar-se para o contexto específico do momento de negociação, aumentando a probabilidade de sucesso. Para além da grande capacidade de análise, o sistema apresenta diferentes métodos de decisão, que permitem ao *player* apoiado ter diferentes abordagens à negociação. Os cenários pessimista e otimista permitem ao *player* apoiado preparar-se para o pior e melhor cenário, respetivamente. O método de decisão Mais Provável dota o sistema de um grande realismo ao ser capaz de aprender qual o cenário mais provável de cada oponente em cada contexto. A gestão de risco também tem um grande impacto conforme analisado no caso de estudo, permitindo ao *player* apoiado balançar as componentes económica e de reputação, de acordo com os seus objetivos. Por último, o sistema também permite ao *player* apoiado gerir o tempo de resposta com a introdução do método de otimização, onde é possível balancear a qualidade dos resultados com o tempo de execução.

No segundo caso de estudo foi possível dar continuidade ao primeiro e verificar o resultado da negociação anteriormente recomendada. Através deste caso de estudo foi possível verificar a capacidade da rede de aprendizagem de se adaptar às diferentes circunstâncias e conseguir apresentar boas recomendações ao *player* apoiado. Para esse fim, a capacidade de aprendizagem dos AAR, os métodos de pesagem, as diferentes fontes de informação e a gestão de credibilidade têm um enorme impacto. O módulo de identificação de perfis e de contextos também acrescentam muito valor ao sistema ao permitir identificar o perfil ou contexto em causa, filtrando a informação mais valiosa e comparar o mesmo com os restantes. O grau de semelhança dos contextos e perfis funciona como um peso que permite ao sistema considerar todas a informação sem perder o foco. Ao contar com diversas estratégias, o sistema tem maior capacidade de identificar corretamente a estratégia do oponente e identificar a melhor contra-estratégia. As recomendações permitiram obter um preço igual ou superior ao preço esperado.

Capítulo 5

Conclusão

Nos dias de hoje, os MEE estão constantemente a enfrentar novos desafios, o que resulta em constantes alterações e, conseqüentemente, um aumento da sua complexidade para as entidades envolvidas. Cada vez mais são necessárias ferramentas que permitam facilitar a experiência dessas entidades, ao permitir-lhes compreender melhor o modo de funcionamento dos MEE assim como apoiar-las nas suas decisões.

Para esse fim surgiram várias ferramentas na literatura mas o seu principal foco está nos mercados baseados em leilão. A negociação de contratos bilaterais continua a ser um modelo de mercado muito pouco explorado. No que diz respeito ao processo de negociação em si, também é identificado na literatura um baixo apoio à fase de pré-negociação e baixa ou nenhuma capacidade de aprendizagem durante uma negociação no geral.

Esta dissertação apresenta uma ferramenta que visa colmatar as lacunas identificadas, ao permitir o apoio aos *players* que pretendam estabelecer contratos bilaterais de energia, tanto na fase de pré-negociação como na negociação dos mesmos.

Na fase de pré-negociação, o *player* apoiado pode identificar qual o melhor(es) oponente(s) com quem negociar de forma a obter o melhor resultado possível, para a quantidade de energia desejada, no contexto de negociação associado ao período indicado. Para esse fim o *player* apoiado indica uma lista de possíveis oponentes com quem pretende negociar, o volume a transacionar, a data, a percentagem de risco que está disposto a correr, o método de decisão e a performance desejada (balanço entre qualidade dos resultados e tempo de execução). Em resposta, o sistema apresenta a melhor ação, segundo o método de decisão selecionado, especificando a quantidade de energia a transacionar com cada oponente e o preço esperado para cada um.

Na fase de negociação, o *player* apoiado pode contar com uma rede de aprendizagem capaz de identificar a melhor estratégia a seguir com um determinado oponente, num determinado contexto, de forma a obter o melhor resultado possível. Para esse fim, o *player* só precisa de indicar o seu preço ótimo, o preço limite e as ofertas que vai recebendo do oponente ao longo da negociação. Em troca, o sistema apresenta-lhe sempre a oferta a apresentar ao oponente, seguindo a melhor contra-estratégia da estratégia usada pelo oponente naquele momento. O *player* apoiado pode fornecer ao sistema informação partilhada por outros *players* e a rede de aprendizagem será responsável por gerir a credibilidade da mesma.

Em ambas as fases, o sistema é capaz de se adaptar às mudanças que possam ocorrer nos MEE, através dos seus mecanismos de aprendizagem (análise de contratos estabelecidos, contextos e perfis). Para além disso o sistema permite a fácil inclusão de novos métodos de previsão, estratégias de negociação, métodos de pesagem, AAR, o que lhe permite evoluir e acompanhar as necessidades emergentes.

Os casos de estudo apresentados permitem comprovar o cumprimento dos objetivos estabelecidos para a ferramenta, assumindo assim um papel importante no apoio à decisão na negociação de contratos bilaterais de energia. Para além disso, dada a abstração do sistema, o mesmo pode ser utilizado no apoio à negociação de outros recursos, não estando limitado à energia. Os avanços apresentados são relevantes para o processo de negociação em si.

Como trabalho futuro, pretende-se evoluir o apoio à fase de negociação da ferramenta, de forma a evoluir a modelação dos comportamentos dos *players* envolvidos, colmatando lacunas identificadas no estado de arte (apresentação de ameaças, promessas, pressão de tempo, número de iterações variável, entre outros). Para além disso, pretende-se integrar o sistema em simuladores de MEE, complementando o apoio a outros modelos de mercado e permitindo efetuar estudos com maior cobertura e impacto para a comunidade científica e entidades envolvidas.

Bibliografia

- Algarvio, Hugo e Fernando Lopes (2014). «Risk Management and Bilateral Contracts in Multi-agent Electricity Markets». Em: *Highlights of Practical Applications of Heterogeneous Multi-Agent Systems. The PAAMS Collection: PAAMS 2014 International Workshops, Salamanca, Spain, June 4-6, 2014. Proceedings*. Ed. por Juan M Corchado et al. Cham: Springer International Publishing, pp. 297–308. isbn: 978-3-319-07767-3. doi: 10.1007/978-3-319-07767-3_27. url: http://dx.doi.org/10.1007/978-3-319-07767-3%7B%5C_%7D27.
- Aumann, R.J. (2017). «Game Theory». Em: *The New Palgrave Dictionary of Economics*. London: Palgrave Macmillan UK, pp. 1–40. isbn: 978-1-349-95121-5. doi: 10.1057/978-1-349-95121-5_942-2. url: https://doi.org/10.1057/978-1-349-95121-5_942-2.
- Bazerman, Max H e Margaret Ann Neale (1993). *Negotiating rationally*. Simon e Schuster.
- Bellifemine, Fabio Luigi, Giovanni Caire e Dominic Greenwood (2007). *Developing multi-agent systems with JADE*. Vol. 7. John Wiley & Sons.
- Bidgoly, Amir Jalaly e Behrouz Tork Ladani (2016). «Benchmarking reputation systems: A quantitative verification approach». Em: *Computers in Human Behavior* 57, pp. 274–291. issn: 0747-5632. doi: <https://doi.org/10.1016/j.chb.2015.12.024>. url: <http://www.sciencedirect.com/science/article/pii/S0747563215302958>.
- Chapelle, Olivier, Bernhard Scholkopf e Alexander Zien (2009). «Semi-supervised learning (chapelle, o. et al., eds.; 2006)[book reviews]». Em: *IEEE Transactions on Neural Networks* 20.3, pp. 542–542.
- Commission, European (2018a). *2020 climate & energy package*. https://ec.europa.eu/clima/policies/strategies/2020_en. [Online; acedido em Fevereiro-2018].
- (2018b). *2030 climate & energy framework*. https://ec.europa.eu/clima/policies/strategies/2030_en. [Online; acedido em Fevereiro-2018].
- (2018c). *2050 low-carbon economy*. https://ec.europa.eu/clima/policies/strategies/2050_en. [Online; acedido em Fevereiro-2018].
- (2018d). *Renewable energy statistics*. http://ec.europa.eu/eurostat/statistics-explained/index.php/Renewable_energy_statistics. [Online; acedido em Fevereiro-2018].
- Da Silva, Ivan Nunes et al. (2017). *Artificial Neural Networks*. Springer.
- Eberhart, R. e J. Kennedy (1995). «A new optimizer using particle swarm theory». Em: *Micro Machine and Human Science, 1995. MHS '95., Proceedings of the Sixth International Symposium on*, pp. 39–43. doi: 10.1109/MHS.1995.494215.
- DB-Engines (2018a). *MySQL vs. PostgreSQL Comparison*. <https://db-engines.com/en/system/MySQL;PostgreSQL>. [Online; acedido em Fevereiro-2018].
- (2018b). *PostgreSQL is the DBMS of the Year 2017*. https://db-engines.com/en/blog_post/76. [Online; acedido em Fevereiro-2018].
- Erev, Ido e Alvin E Roth (1998). «Predicting how people play games: Reinforcement learning in experimental games with unique, mixed strategy equilibria». Em: *American economic review*, pp. 848–881.

- Faia, Ricardo, Tiago Pinto e Zita Vale (2016). «Dynamic Fuzzy Clustering Method for Decision Support in Electricity Markets Negotiation». Em: *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal* 5.1. issn: 2255-2863.
- Fisher, Roger, William L Ury e Bruce Patton (2011). *Getting to yes: Negotiating agreement without giving in*. Penguin.
- Foruzan, E., S. D. Scott e J. Lin (2015). «A comparative study of different machine learning methods for electricity prices forecasting of an electricity market». Em: *2015 North American Power Symposium (NAPS)*, pp. 1–6. doi: 10.1109/NAPS.2015.7335095.
- Gupta, S. e P. Chitkara (2017). «Day ahead price forecasting models in thin electricity market». Em: *2017 IEEE Power and Energy Conference at Illinois (PECI)*, pp. 1–6. doi: 10.1109/PECI.2017.7935757.
- Hand, David J. (2007). «Principles of Data Mining». Em: *Drug Safety* 30.7, pp. 621–622. issn: 1179-1942. doi: 10.2165/00002018-200730070-00010. url: <https://doi.org/10.2165/00002018-200730070-00010>.
- Harp, Steven A et al. (2000). «SEPIA. A simulator for electric power industry agents». Em: *IEEE Control Systems* 20.4, pp. 53–69.
- Hastie, Trevor, Robert Tibshirani e Jerome Friedman (2009). «Unsupervised Learning». Em: *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York, NY: Springer New York, pp. 485–585. isbn: 978-0-387-84858-7. doi: 10.1007/978-0-387-84858-7_14. url: https://doi.org/10.1007/978-0-387-84858-7_14.
- Hussain, Akhtar, Van-Hai Bui e Hak-Man Kim (2016). «Robust Optimization-Based Scheduling of Multi-Microgrids Considering Uncertainties». Em: *Energies* 9.4. issn: 1996-1073. doi: 10.3390/en9040278. url: <http://www.mdpi.com/1996-1073/9/4/278>.
- Ilic, Marija, Francisco Galiana e Lester Fink (2013). *Power systems restructuring: engineering and economics*. Springer Science & Business Media.
- Jennings, Nicholas R et al. (2001). «Automated negotiation : prospects, methods and challenges». Em: *Group Decision and Negotiation* 10.2, pp. 199–215.
- Jie, B., T. Tsuji e K. Uchida (2017). «An analysis of market mechanism and bidding strategy for power balancing market mixed by conventional and renewable energy». Em: *2017 14th International Conference on the European Energy Market (EEM)*, pp. 1–6. doi: 10.1109/EEM.2017.7981944.
- Kaur, H. et al. (2014). «Power system restructuring amp; competitive wholesale electricity markets in deregulated environment». Em: *2014 Innovative Applications of Computational Intelligence on Power, Energy and Controls with their impact on Humanity (CIPECH)*, pp. 233–237. doi: 10.1109/CIPECH.2014.7019096.
- Kelley, Harold H (1996). *A classroom study of the dilemmas in interpersonal negotiations*. Berkeley Institute of International Studies.
- Kim, B. G. et al. (2016). «Dynamic Pricing and Energy Consumption Scheduling With Reinforcement Learning». Em: *IEEE Transactions on Smart Grid* 7.5, pp. 2187–2198. issn: 1949-3053. doi: 10.1109/TSG.2015.2495145.
- Kirschen, Daniel Sadi. e Goran. Strbac (2004). *Fundamentals of power system economics*. John Wiley & Sons, p. 284. isbn: 9780470845721.
- Klemperer, Paul (1999). «Auction theory: A guide to the literature». Em: *Journal of economic surveys* 13.3, pp. 227–286.
- Koen, Peter A et al. (2002). *Fuzzy front end: effective methods, tools, and techniques*. Wiley, New York, NY.
- Koritarov, Vladimir S (2004). «Real-world market representation with agents». Em: *IEEE Power and Energy Magazine* 2.4, pp. 39–46.

- Kotsiantis, Sotiris B, I Zaharakis e P Pintelas (2007). «Supervised machine learning: A review of classification techniques». Em: *Emerging artificial intelligence applications in computer engineering* 160, pp. 3–24.
- Kraus, Sarit, N NIRKE e Katia Sycara (1993). «Reaching agreements through argumentation». Em: *Proceedings of the Twelfth International Workshop on Distributed Artificial Intelligence*, pp. 233–247.
- Kravari, Kalliopi e Nick Bassiliades (2015). «A Survey of Agent Platforms». Em: *Journal of Artificial Societies and Social Simulation* 18.1, p. 11. issn: 1460-7425. doi: 10.18564/jasss.2661. url: <http://jasss.soc.surrey.ac.uk/18/1/11.html>.
- Kubli, Merla, Moritz Loock e Rolf Wüstenhagen (2018). «The flexible prosumer: Measuring the willingness to co-create distributed flexibility». Em: *Energy Policy* 114, pp. 540–548.
- LEWICKI, Roy J et al. (2003). «Negotiation». Em: *MacGraw-Hill International Editions*.
- Li, Hongyan e Leigh Tesfatsion (2009). «Development of Open Source Software for Power Market Research: The AMES Test Bed». Em: *Journal of Energy Markets*. url: http://lib.dr.iastate.edu/econ%7B%5C_%7D1as%7B%5C_%7Dpubs/389.
- Lin, Raz et al. (2014). «GENIUS: An Integrated Environment for Supporting the Design of Generic Automated Negotiators». Em: *Computational Intelligence* 30.1, pp. 48–70. issn: 08247935. doi: 10.1111/j.1467-8640.2012.00463.x. url: <http://doi.wiley.com/10.1111/j.1467-8640.2012.00463.x>.
- Lopes, F, T Rodrigues e J Sousa (2012). «Negotiating Bilateral Contracts in a Multi-agent Electricity Market: A Case Study». Em: *2012 23rd International Workshop on Database and Expert Systems Applications*, pp. 326–330. doi: 10.1109/DEXA.2012.77.
- Lopes, Fernando e Helder Coelho (2018). *Electricity Markets with Increasing Levels of Renewable Generation: Structure, Operation, Agent-based Simulation and Emerging Designs*. Vol. 144. Springer.
- Lopes, Fernando, Michael Wooldridge e A Q Novais (2008). «Negotiation among autonomous computational agents: principles, analysis and challenges». Em: *Artificial Intelligence Review* 29.1, pp. 1–44. issn: 1573-7462. doi: 10.1007/s10462-009-9107-8. url: <http://dx.doi.org/10.1007/s10462-009-9107-8>.
- MacQueen, J. (1967). «Some methods for classification and analysis of multivariate observations». Em: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics*. Berkeley, Calif.: University of California Press, pp. 281–297. url: <https://projecteuclid.org/euclid.bsm/1200512992>.
- Migliavacca, G. (2007). «SREMS: a short-medium run electricity market simulator based on game theory and incorporating network constraints». Em: *2007 IEEE Lausanne Power Tech*, pp. 813–818. doi: 10.1109/PCT.2007.4538420.
- Nadler, Janice, Leigh Thompson e Leaf Van Boven (2003). «Learning negotiation skills: Four models of knowledge creation and transfer». Em: *Management Science* 49.4, pp. 529–540.
- Nallur, Vivek et al. (2016). «Algorithm Diversity: A Mechanism for Distributive Justice in a Socio-Technical MAS». Em: *Proceedings of the 2016 International Conference on Autonomous Agents & Multiagent Systems*. AAMAS '16. Singapore, Singapore: International Foundation for Autonomous Agents e Multiagent Systems, pp. 420–428. isbn: 978-1-4503-4239-1. url: <http://dl.acm.org/citation.cfm?id=2936924.2936986>.
- Nasrabadi, Nasser M. (2007). «Pattern Recognition and Machine Learning». Em: *Journal of Electronic Imaging* 16. doi: 10.1117/1.2819119. url: <https://doi.org/10.1117/1.2819119>.

- Ojha, U. et al. (2017). «Significance of important attributes for decision making using C5.0». Em: *2017 8th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, pp. 1–4. doi: 10.1109/ICCCNT.2017.8204031.
- OMEL (2018). *Operador del Mercado Ibérico de Energía*. <http://www.ome1.es>. [Online; acedido em Fevereiro-2018].
- OMIE (2019a). *ejecucioncbfom*. <http://www.omie.es/aplicaciones/datosftp/datosftp.jsp?path=/ejecucioncbfom/>. [Online; acedido em Outubro-2019].
- (2019b). *marginalpdbc*. <http://www.omie.es/aplicaciones/datosftp/datosftp.jsp?path=/marginalpdbc/>. [Online; acedido em Outubro-2019].
- Pinto, Tiago, Zita Vale, Isabel Praça et al. (2015). «Decision Support for Energy Contracts Negotiation with Game Theory and Adaptive Learning». Em: *Energies* 8.9, pp. 9817–9842. issn: 1996-1073. doi: 10.3390/en8099817. url: <https://www.mdpi.com/1996-1073/8/9/9817>.
- Pinto, Tiago, Zita Vale, Tiago M Sousa et al. (2014). «Adaptive learning in agents behaviour: A framework for electricity markets simulation». Em: *Integrated Computer-Aided Engineering* 21.4, pp. 399–415.
- Praça, Isabel et al. (2003). «MASCEM: a multiagent system that simulates competitive electricity markets». Em: *IEEE Intelligent Systems* 18.6, pp. 54–60. issn: 1541-1672. doi: 10.1109/MIS.2003.1249170. url: <http://ieeexplore.ieee.org/document/1249170/>.
- Pruitt, Dean G (2013). *Negotiation behavior*. Academic Press.
- Pruitt, Dean G e Peter J Carnevale (1993). *Negotiation in social conflict*. Thomson Brooks/Cole Publishing Co.
- Putnam, Linda L (1990). «Reframing integrative and distributive bargaining: A process perspective». Em: *Research on negotiation in organizations* 2.1, pp. 3–30.
- Quadri, Imran Ahmad, S. Bhowmick e D. Joshi (2018). «A comprehensive technique for optimal allocation of distributed energy resources in radial distribution systems». Em: *Applied Energy* 211, pp. 1245–1260. issn: 0306-2619. doi: <https://doi.org/10.1016/j.apenergy.2017.11.108>. url: <http://www.sciencedirect.com/science/article/pii/S0306261917317099>.
- R Core Team (2016). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria. url: <https://www.R-project.org/>.
- Rahwan, Iyad et al. (2003). «Argumentation-based Negotiation». Em: *Knowl. Eng. Rev.* 18.4, pp. 343–375. issn: 0269-8889. doi: DOI:10.1017/S0269888904000098. url: <http://dx.doi.org/DOI:10.1017/S0269888904000098>.
- Raiffa, Howard (1982). *The art and science of negotiation*. Harvard University Press.
- Roloff, Michael Elwood (1992). «Achieving Negotiation Goals: The 'Fruits and Foibles' of Planning Ahead». Em: *Communication and Negotiation*. Sage.
- Rouchier, Juliette (2017). «Agent-Based Simulation as a Useful Tool for the Study of Markets». Em: *Simulating Social Complexity: A Handbook*. Ed. por Bruce Edmonds e Ruth Meyer. Cham: Springer International Publishing, pp. 671–704. isbn: 978-3-319-66948-9. doi: 10.1007/978-3-319-66948-9_25. url: https://doi.org/10.1007/978-3-319-66948-9_25.
- Rubin, Jeffrey Z, Dean G Pruitt e Sung Hee Kim (1994). *Social conflict: Escalation, stalemate, and settlement*. McGraw-Hill Book Company.
- Rustagi, Jagdish S (2014). *Optimization techniques in statistics*. Elsevier.
- Saaty, Thomas L (1990). «How to make a decision: the analytic hierarchy process». Em: *European journal of operational research* 48.1, pp. 9–26.

- Sabater, Jordi e Carles Sierra (2001). «Regret: A reputation model for gregarious societies». Em: *Fourth workshop on deception fraud and trust in agent societies*. Vol. 70, pp. 61–69.
- Santos, G., T. Pinto et al. (2011). «Complex market integration in MASCEM electricity market simulator». Em: *2011 8th International Conference on the European Energy Market (EEM)*, pp. 256–261. doi: 10.1109/EEM.2011.5953019.
- Santos, G., I. Praça et al. (2013). «Scenarios generation for multi-agent simulation of electricity markets based on intelligent data analysis». Em: *2013 IEEE Symposium on Intelligent Agents (IA)*, pp. 5–12. doi: 10.1109/IA.2013.6595183.
- Santos, Gabriel et al. (2016). «MASCEM: Optimizing the performance of a multi-agent system». Em: *Energy* 111, pp. 513–524. issn: 0360-5442. doi: <https://doi.org/10.1016/j.energy.2016.05.127>. url: <http://www.sciencedirect.com/science/article/pii/S0360544216307654>.
- Settles, Burr (2012). «Active Learning». Em: *Synthesis Lectures on Artificial Intelligence and Machine Learning* 6.1, pp. 1–114. doi: 10.2200/S00429ED1V01Y201207AIM018. eprint: <https://doi.org/10.2200/S00429ED1V01Y201207AIM018>. url: <https://doi.org/10.2200/S00429ED1V01Y201207AIM018>.
- Silva, Francisco, Ricardo Faia et al. (2018). «Optimizing Opponents Selection in Bilateral Contracts Negotiation with Particle Swarm». Em: *Highlights of Practical Applications of Agents, Multi-Agent Systems, and Complexity: The PAAMS Collection*. Ed. por Javier Bajo et al. Cham: Springer International Publishing, pp. 116–124. isbn: 978-3-319-94779-2.
- Silva, Francisco, Gabriel Santos et al. (2018). «A context-based building security alarm through power and sensors analysis». Em: *Energy Informatics* 1.S1, p. 41. issn: 2520-8942. doi: 10.1186/s42162-018-0045-z.
- Sioshansi, Fereidoon P (2013). *Evolution of Global Electricity Markets: New paradigms, new challenges, new approaches*. Academic Press.
- Snyder, Glenn Herald e Paul Diesing (1977). *Conflict Among Nations: Bargaining, Decision Making, and System Structure in International Crises*. Princeton University Press. url: <http://www.jstor.org/stable/j.ctt13x0wmf>.
- Song, M. e M. Amelin (2018). «Price-Maker Bidding in Day-Ahead Electricity Market for a Retailer With Flexible Demands». Em: *IEEE Transactions on Power Systems* 33.2, pp. 1948–1958. issn: 0885-8950. doi: 10.1109/TPWRS.2017.2741000.
- Suthaharan, Shan (2016). «Support vector machine». Em: *Machine learning models and algorithms for big data classification*. Springer, pp. 207–235.
- Sutton, Richard S e Andrew G Barto (1998). *Reinforcement learning: An introduction*. Vol. 1. 1. MIT press Cambridge.
- Sycara, Ekaterini P (1987). «Resolving adversarial conflicts: an approach integration case-based and analytic methods». Em:
- Thompson, Leigh (2000). *Mind and Heart of the Negotiator, Second Edition, the*. Second. Upper Saddle River, NJ, USA: Prentice Hall Press. isbn: 0-13-017964-7.
- Vale, Zita et al. (2011). «MASCEM: Electricity Markets Simulation with Strategic Agents». Em: *IEEE Intelligent Systems* 26.2, pp. 9–17. issn: 1541-1672. doi: 10.1109/MIS.2011.3. url: <http://ieeexplore.ieee.org/document/5696716/>.
- Van de Vliert, Evert (1997). *Complex interpersonal conflict behaviour: Theoretical frontiers*. Psychology Press.
- Walley, Peter (1996). «Measures of uncertainty in expert systems». Em: *Artificial intelligence* 83.1, pp. 1–58.
- Watkins, Christopher JCH e Peter Dayan (1992). «Q-learning». Em: *Machine learning* 8.3-4, pp. 279–292.

- Weiss, Gerhard (1999). *Multiagent systems: a modern approach to distributed artificial intelligence*. MIT press.
- Weng, J. et al. (2010). «Credibility: How Agents Can Handle Unfair Third-Party Testimonies in Computational Trust Models». Em: *IEEE Transactions on Knowledge and Data Engineering* 22.9, pp. 1286–1298. issn: 1041-4347. doi: 10.1109/TKDE.2009.138.
- Woodall, Tony (2003). «Conceptualising 'value for the customer': An attributional, structural and dispositional analysis». Em: *Academy of marketing science review* 2003, p. 1.
- Wooldridge, Michael e Nicholas R Jennings (1995). «Intelligent agents: Theory and practice». Em: *The knowledge engineering review* 10.2, pp. 115–152.
- Xiaoman, W. et al. (2017). «Analysis of power large user segmentation based on affinity propagation and K-means algorithm». Em: *2017 IEEE Conference on Energy Internet and Energy System Integration (EI2)*, pp. 1–5. doi: 10.1109/EI2.2017.8245670.
- Yeoh, William e Makoto Yokoo (2012). «Distributed problem solving». Em: *AI Magazine* 33.3, p. 53.
- Zhou, Zhi, Wai Kin (Victor) Chan e Joe H. Chow (2007). «Agent-based simulation of electricity markets: a survey of tools». Em: *Artificial Intelligence Review* 28.4, pp. 305–342. issn: 1573-7462. doi: 10.1007/s10462-009-9105-x. url: <https://doi.org/10.1007/s10462-009-9105-x>.
- Zimmerman, R. D. e R. J. Thomas (2004). «PowerWeb: a tool for evaluating economic and reliability impacts of electric power market designs». Em: *IEEE PES Power Systems Conference and Exposition, 2004*. 1562–1567 vol.3. doi: 10.1109/PSCE.2004.1397612.