



Otimização de Portfólio de Participação em Mercados de Energia Elétrica

RICARDO FRANCISCO MARCOS FAIA

novembro de 2016

OTIMIZAÇÃO DE PORTFÓLIO DE PARTICIPAÇÃO EM MERCADOS DE ENERGIA ELÉTRICA

Ricardo Francisco Marcos Faia



Departamento de Engenharia Eletrotécnica

Mestrado em Engenharia Eletrotécnica – Sistemas Elétricos de Energia

2016

Relatório elaborado para satisfação parcial dos requisitos da Unidade Curricular de DSEE -
Dissertação do Mestrado em Engenharia Eletrotécnica – Sistemas Elétricos de Energia

Candidato: Ricardo Francisco Marcos Faia, Nº 1130266, 1130266@isep.ipp.pt

Orientação científica: Professora Doutora Zita Vale, zav@isep.ipp.pt

Coorientação: Doutor Tiago Pinto, tmcfp@isep.ipp.pt

Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e
Desenvolvimento (GECAD)



*Grupo de Investigação em Engenharia e Computação
Inteligente para a Inovação e o Desenvolvimento*

Departamento de Engenharia Eletrotécnica
Mestrado em Engenharia Eletrotécnica – Sistemas Elétricos de Energia

2016

Agradecimentos

Em primeiro lugar, agradeço aos meus pais pela educação, apoio e oportunidade que me deram para poder estudar. Sem o contributo deles nada disto teria sido concretizável.

Um agradecimento à minha irmã Joana e a toda a minha família pela motivação e constante preocupação demonstradas no decorrer deste ciclo de estudos.

À minha orientadora, Doutora Zita Vale, agradeço-lhe profundamente o voto de confiança prestado, as sugestões, o acompanhamento, a disponibilidade e também a oportunidade de integração no Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e Desenvolvimento (GECAD).

Ao meu Coorientador, Doutor Tiago Pinto, um agradecimento muito especial pela disponibilidade em todos os momentos, pelo auxílio prestado, pela paciência depositada, pelo companheirismo e por acreditar nas minhas capacidades para a elaboração desta dissertação.

Agradeço também ao grupo GECAD e a todas as pessoas que o integram, pela disponibilidade e colaboração demonstradas nos estudos que aí realizei, alguns dos quais se encontram plasmados neste estudo.

Finalmente, não posso deixar de agradecer a todos os meus colegas de curso, que me acompanharam nesta etapa da minha vida académica, com um profundo sentimento de amizade.

Resumo

Na atualidade são visíveis as mudanças ocorridas nos mercados de energia elétrica, em consequência da introdução maciça de energia proveniente de fontes renováveis. Pelo facto de serem renováveis são de grande interesse para a população, pois o custo de produção e as emissões de gases, que contribuem para o efeito de estufa durante o seu funcionamento, são nulas. Estas características são essenciais para as mais altas chefias das instituições europeias, que impuseram políticas para promover a utilização e instalação de tecnologia para o aproveitamento das fontes que facultam as energias renováveis.

Os estados membros europeus mostraram-se recetíveis a estas políticas e incentivaram o investimento nestas tecnologias. Deste modo, houve uma enorme introdução de energias de carácter intermitente e instável que condicionaram o normal funcionamento dos sistemas de energia elétrica, o que, por sua vez, conduziu a inúmeras mudanças no setor. Esta reestruturação teve impacto em todo o setor, como é o caso dos mercados de energia elétrica, onde surgiram novas formas de negociação e foram criadas novas entidades de mercado. Com estas alterações, a complexidade dos mercados de energia elétrica aumentou, assim como a imprevisibilidade dos mesmos. Por isso, tornou-se essencial a existência de formas de apoio que auxiliem a tomada de decisão por parte das entidades de mercado.

Com a emergência de todas estas exigências, tornou-se fundamental o desenvolvimento de ferramentas para auxílio na tomada de decisão. Estas ferramentas ajudam as diversas entidades a perceber o funcionamento dos mercados e prever as interações que ocorrerão entre as diferentes entidades existentes no mercado. A inteligência artificial teve um papel crucial no desenvolvimento destas ferramentas, nomeadamente os sistemas multiagente, que têm sido uma solução muito explorada pelos interessados no setor. Estes, utilizam várias técnicas da inteligência artificial, o que lhes permite serem adaptativos a diferentes situações, simular os diferentes agentes existentes no mercado, permitir diversos tipos de negociação, e ainda aprender ao longo da sua utilização. No entanto, apesar de estas ferramentas

atualmente estarem voltadas para o estudo do funcionamento do sistema elétrico, deixam de lado o contexto de negociação e descartam o apoio às decisões do vendedor/comprador de eletricidade.

O largo âmbito de aplicação da inteligência artificial fornece diversas experiências, nomeadamente ferramentas de otimização meta-heurísticas, que permitem a resolução de problemas num curto espaço de tempo, e com uma qualidade de resultados muito próxima daquela alcançada por técnicas determinísticas à custa de um elevado tempo de execução.

O trabalho desenvolvido nesta dissertação tem como objeto de estudo a falha supra referenciada. Sugere uma metodologia de negociação da energia elétrica que permite vender e comprar a mesma em diferentes mercados com regras específicas, e indica um portfólio de participação nos vários mercados em que cada interveniente pode negociar.

A metodologia apresentada permite gerar cenários realistas a partir do resultado da otimização do portfólio, que podem ser tomados em consideração na decisão dos intervenientes de mercado, e assim conseguirem retirar o máximo proveito das suas negociações.

Os resultados apresentados foram obtidos através da utilização de dados reais provenientes dos diferentes operadores de mercados. Estes dados são válidos para a formulação de diferentes cenários que possam ser considerados no ato da negociação.

Palavras-Chave

Ferramentas de Otimização, Inteligência Artificial, Mercados de Energia Elétrica, Otimização de Portfólio.

Abstract

Nowadays, there are several relevant changes in electricity markets, which are a consequence of the massive introduction of renewable energies. The fact that they are renewable is of great interest for all of us, because the cost of production of this energy is null and emissions of greenhouse gases are also zero during operation. This feature aroused great interest in the high European institutions that have imposed policies to promote the use and installation of technology for the use of sources that provide renewable energy.

European member states have shown receptiveness to these policies, potentiating the investment in these technologies and thus hearing a great introduction of intermittent and unstable energy that conditioned the normal operation of power systems and led to further inevitable changes in an already under-restructuring power and energy sector. This restructuring had an impact throughout the industry, as is the case of the electricity markets, where new forms of trading emerged and new market entities were created. With these changes the complexity of electricity markets increased as well as the associated unpredictability. This made it essential to have support tools to aid decision making by the market entities.

With the emergence of all these requirements it is fundamental to develop tools in order to assist the decision-making process, and to help understanding the functioning of markets and predict the interactions that occur between the existing market entities. Artificial intelligence has an important role in the development of these tools. Multi-agent systems, in particular, have been much explored by stakeholders in the sector as a valid solution. They use various techniques of artificial intelligence that allows them to be adaptive to any situation, to simulate the different existing players in the market, allowing any type of trading and enabling them to learn the logic of its use. However, these tools are directed to study of the proper functioning of the electrical system, leaving aside the negotiation context and the decision support for the seller / buyer of electricity.

The applicability of artificial intelligence is not limited to electricity markets. It is also applied in many other areas due to its optimization tools that enable solving problems in a short time and with very similar results to those achieved by deterministic techniques, at the cost of a high execution time.

The work in this dissertation addresses the above-mentioned gaps, and suggests an electricity trading decision support methodology to buy and sell electricity in different markets with specific rules. This is done by suggesting a portfolio of market participation that each party can perform. The presented methodology generates realistic scenarios from the portfolio optimization of the results that may be taken into account in the decision of market participants; and allow these players to take full advantage of it. The results were obtained through the use of real data stemmed from different market operators, which are valid for the generation of different scenarios that can be taken into account in the negotiation act.

Keywords

Artificial Intelligence, Energy Markets, Optimization Tools, Portfolio Optimization

Índice

AGRADECIMENTOS	I
RESUMO.....	III
ABSTRACT	V
ÍNDICE.....	VII
ÍNDICE DE FIGURAS	XI
ÍNDICE DE TABELAS	XV
ACRÓNIMOS.....	XVII
1. INTRODUÇÃO	1
1.1.MOTIVAÇÃO	1
1.2.OBJETIVOS	5
1.3.CONTRIBUIÇÕES.....	6
1.4.ESTRUTURA DO DOCUMENTO	9
2. ESTADO DA ARTE.....	11
2.1.MERCADOS DE ENERGIA ELÉTRICA	12
2.2.TIPOS DE MERCADO.....	15
2.3.UNIFICAÇÃO DO MERCADO EUROPEU	21
2.4.SMART GRID	26
2.5.SIMULAÇÃO DE MERCADOS.....	28
2.6.TEORIA DAS CARTEIRAS	33

2.7.SUMÁRIO	39
3. METODOLOGIA PROPOSTA	41
3.1.MAXIMIZAÇÃO DO LUCRO	43
3.2.FORMULAÇÃO MULTIOBJETIVO.....	45
3.3.MÉTODOS DE OTIMIZAÇÃO	47
3.4.HEURÍSTICA PARA SOLUÇÃO INICIAL COM BASE NO CONHECIMENTO.....	62
3.5.MÉTODO DE PREVISÃO.....	63
3.6.ESTIMATIVA DOS PREÇOS EM CONTRATOS BILATERAIS.....	64
3.7.SUMÁRIO	70
4. CASOS DE ESTUDO	73
4.1.ESTIMATIVA DE PREÇOS ATRAVÉS DO FUZZY DINÂMICO.....	74
4.2.OTIMIZAÇÃO DO LUCRO.....	78
4.3.OTIMIZAÇÃO MULTIOBJETIVO.....	102
4.4.SUMÁRIO	106
5. CONCLUSÕES	111
5.1.CONCLUSÕES.....	111
5.2.TRABALHO FUTURO	113
REFERÊNCIAS DOCUMENTAIS.....	115
ANEXO A. ESTIMAÇÃO DOS PREÇOS, EXEMPLO EXPLICATIVO.....	127
ANEXO B. DIAGRAMA DE EXTREMOS E QUARTIS PARA AS DIFERENTES VARIANTES DO PSO APLICADAS.....	131

ANEXO C. DIAGRAMA DE EXTREMOS E QUARTIS PARA AS DIFERENTES VARIANTES DO AG E SA APLICADAS.....	132
ANEXO D. ESCALONAMENTO DA QUANTIDADE DE COMPRA E VENDA DE ELETRICIDADE PARA OS DIFERENTES MERCADOS E CORRESPONDENTES VALORES DE EXPOSIÇÃO AO RISCO.....	133
ANEXO E. RESULTADOS PARA O PROBLEMA MULTIOBJETIVO	135

Índice de Figuras

Figura 1 – <i>Pool</i> Simétrico, (Praça et al., 2003)	17
Figura 2 – <i>Pool</i> Assimétrico, (Praça et al., 2003)	17
Figura 3 - Mercado intradiário, (MIBEL, 2007)	19
Figura 4 - Principais mudanças nos mercados de eletricidade, adaptado de (EMCC, 2016)	21
Figura 5 - Regiões abrangidas pelo MCR, (PCR, 2015)	22
Figura 6 -Principais mercados abrangentes do PCR, (PCR PXs, 2013)	23
Figura 7 - Ilustração de uma SG (Ramakrishnan and Ramakrishnan, 2013).	27
Figura 8 - Agentes em MASCEM, (Santos, 2015)	30
Figura 9 - Esquema de funcionamento do sistema AiD-EM, adaptado de (Pinto et al., 2015a)	32
Figura 10 – Frente de <i>Pareto</i> adaptado de (FinancialEdge.net, 2016).	34
Figura 11 - Diferentes tipos de risco, adaptado de (Bittencourt, 2011).	35
Figura 12 – Visão geral da metodologia Proposta	41
Figura 13- Fluxograma do PSO, (Faia et al., 2015b)	49
Figura 14 - Migração das partículas, (Coelho, 2008)	55
Figura 15 – Fluxograma AG	56
Figura 16 – Cruzamento de dois pontos	58
Figura 17 - Processo de mutação	58

Figura 18 - Fluxograma do SA, (Faia et al., 2016b)	60
Figura 19 - Topologia da RNA utilizada, (Pinto et al., 2015a)	66
Figura 20- Representação gráfica da lógica <i>fuzzy</i> , (Pinto et al., 2015a)	68
Figura 21 - Metodologia para a estimação de preços, (Faia et al., 2016a)	69
Figura 22 – Evolução dos indicadores $m1$ e $m2$	75
Figura 23 – Estimação dos preços no mercado Bilaterals	76
Figura 24 – Estimação dos preços no mercado SG	77
Figura 25 - Resultados do parâmetro função objetivo, para as diferentes estratégias de inércia	80
Figura 26- Resultados do parâmetro tempo, estratégias de inércia	81
Figura 27 - Resultados para o parâmetro iterações, estratégias de inércia	82
Figura 28 - Comparação dos valores para o parâmetro objetivo, das variantes PSO	84
Figura 29- Comparação dos valores para o parâmetro tempo, para as variantes PSO	85
Figura 30 -Comparação dos valores para o parâmetro iterações, variantes PSO	85
Figura 31 - Comparação dos valores para o parâmetro objetivo, variantes AG	87
Figura 32- Comparação dos valores para o parâmetro tempo de execução, das variantes AG	87
Figura 33 - Comparação dos valores para o parâmetro iterações, variantes AG	88
Figura 34 - Comparação dos valores para o parâmetro objetivo, variantes SA	90
Figura 35 - Comparação dos valores para o parâmetro tempo, variantes SA	90

Figura 36 - Comparação dos valores para o parâmetro iterações, variantes SA	91
Figura 37 - Diagrama de extremos e quartis para PSO - w6	92
Figura 38 - Intervalo de confiança para o valor esperado, PSO-w6	93
Figura 39 -Diagrama de extremos e quartis para NPSO – LRS	94
Figura 40 - Intervalo de confiança para o valor esperado, NPSO-LRS	94
Figura 41 - Diagrama de extremos e quartis para AG 2	95
Figura 42 -Intervalo de confiança para o valor esperado, AG 2	96
Figura 43 - Diagrama de extremos e quartis para SA 1	97
Figura 44 – Intervalo de confiança para o valor esperado, SA 1	97
Figura 45 - Preços para o 1º período	101
Figura 46 - Lucro em função da exposição ao risco	103
Figura 47 - Valor de lucro e risco dos diferentes algoritmos para os diferentes níveis de risco	104
Figura 48 - Ilustração da aplicação da lógica fuzzy	127
Figura 49 - Digrama de extremos e quartis das variantes do PSO	131
Figura 50- diagrama de extremos quartis das variantes do AG	132
Figura 51 - Diagrama de extremos e quartis das variantes do SA	132

Índice de Tabelas

Tabela 1 -Diferentes estratégias de inércias	50
Tabela 2 – Diferentes pesagens para diferentes números de <i>clusters</i> / erro de estimação	76
Tabela 3 - Número de <i>clusters</i>	78
Tabela 4 - Resolução determinística	79
Tabela 5 - Resultados das estratégias de cálculo de inércia	79
Tabela 6 -Comparação entre os parâmetros	82
Tabela 7- Resultados para as variantes do PSO	83
Tabela 8 - Resultados para AG	86
Tabela 9 - Resultados SA	89
Tabela 10 - Tabela de resumo da análise estatística dos vários métodos/variantes, atendendo ao valor da função objetivo (em €)	98
Tabela 11 - Resultados com a solução inicial baseada na heurística proposta	99
Tabela 12 - Escalonamento das Vendas	100
Tabela 13 - Escalonamento Compras	101
Tabela 14 - Valores médios e desvio padrão para o lucro nos diferentes níveis de risco	103
Tabela 15 - Valores de erro registados em cada mercado, em %	104
Tabela 16 – Resultados máximos obtidos para os diferentes níveis de pesagem	105

Tabela 17 - Comparação de valor da função objetivo	107
Tabela 18 - Coordenadas dos centros dos <i>clusters</i>	127
Tabela 19 - Declives e ordenadas na origem	128
Tabela 20 - Estimação dos preços	129
Tabela 21 – Resultados dos algoritmos/variantes aplicados para cada nível de risco	133
Tabela 22 - Resultados para o problema multiobjetivo	135

Acrónimos

AG	– Algoritmos genéticos
AiD-EM	– <i>Adaptive Decision Support for Electricity Markets Negotiations</i>
ALBiDS	– <i>Adaptive Learning strategic Bidding System</i>
AMES	– <i>Agent-based Modelling of Electricity Systems</i>
APX	– <i>Amsterdam Power Exchange</i>
CDI	– <i>Cluster's Dispersion Indicator</i>
ELIX	– Índice de Energia Elétrica Europeu
EMCAS	– <i>Electricity Market Complex Adaptive System</i>
EPEX	– <i>European Power Exchange Spot</i>
EPSO	– <i>Evolutionary Particle Swarm Optimization</i>
EQ.	– Equação
EU	– União Europeia
EUPHEMIA	– <i>Pan – European Hybrid Electricity Market integration Algorithm</i>
GECAD	– Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e Desenvolvimento
GME	– <i>Gestore Mercati Energetici</i>
h	– Horas
IA	– Inteligência artificial

IC	– Intervalo de confiança
IPEX	– <i>Italian Power Exchange</i>
MADP	– <i>Mean Absolute Deviation Percent</i>
MAPE	– <i>Mean Absolute Percentage Error</i>
MASCEM	– <i>Multi-Agent Simulator for Competitive Electricity Markets</i>
MIA	– <i>Mean Index Adequacy</i>
MIBEL	– Mercado Ibérico de Energia Elétrica
MILP	– <i>Mixed integer linear programming</i>
MINLP	– <i>Mixed integer nonlinear programming</i>
MIQP	– Problema quadrático inteiro misto
MPSO-TVAC	– <i>Migration Particle Swarm Optimization with Time Varying Acceleration coefficients</i>
MW	– <i>Megawatts</i>
NPSO-LRS	– <i>Non-Linear Particle Swarm Optimization with Local Random Search</i>
NSGA-II	– <i>Non-dominated sorting genetic algorithm</i>
OAA	– <i>Open Agent Architecture</i>
OMIE	– Operador de Mercado de Energia – Polo Espanhol
OMIP	– Operador de Mercado de Energia – Polo Português
PCR	– <i>Price Coupling of Regions</i>
PSO	– <i>Particle Swarm Optimization</i>

PUN	– <i>Prezzo Unico Nazionale</i>
QP	– Problema quadrático
QPSO	– <i>Quantum Particle Swarm Optimization</i>
REF.	– Referência
RNA	– Rede Neuronal Artificial
s	– Segundos
SA	– <i>Simulated Annealing</i>
SG	– <i>Smart-Grid</i>
ST	– <i>Solution Start</i>
VPPs	– <i>Virtual Power Players</i>

1. INTRODUÇÃO

1.1. MOTIVAÇÃO

O trabalho realizado nesta dissertação tem como motivação responder ao impacto das novas exigências a que os mercados de energia elétrica estão sujeitos. Incide particularmente no âmbito da linha de investigação de apoio a decisões para empresas, ou particulares que se dediquem à participação nos mercados de energia elétrica.

Atualmente, a sociedade em que vivemos tornou-se dependente do consumo de energia, nomeadamente da energia elétrica. Consumo este que não só proporciona mas também influencia o desenvolvimento económico. Olhando para o Homem como ser racional e com expectativas e ambições para o futuro, este vai procurar cada vez mais o desenvolvimento não só económico, mas também noutras vertentes, o que vai levar ao consumo de energia que, cada vez mais, tende a aumentar de forma incontrolável. Outras preocupações se levantam, (Lund, 2014) apela à preocupação que o uso excessivo de energia elétrica pode trazer para o ambiente, e faz igualmente referência à escassez da fonte primária baseada em combustíveis fósseis. Atualmente, estes problemas são considerados como muito graves pelo referido autor.

Estes problemas levaram as instituições governamentais, nomeadamente a União Europeia (UE) a tomar iniciativas e a definir metas para diminuir o consumo de energia proveniente de combustíveis fósseis, substituindo-a por produção através de fontes renováveis. Diferentes metas foram criadas para os países membros da UE com o objetivo comum de que seja atingido um aumento de 20% na produção total de energia de fontes renováveis até 2020 (European Commission, 2009a). Esta meta foi revista em outubro de 2014, onde foi imposto outro limite para a energia proveniente de fontes renováveis com base em pelo menos 27% do consumo energético da UE até 2030 (European Commission, 2014). Para 2050, a UE apresentou metas mais ambiciosas, com o compromisso de reduzir as emissões para 80-95%, com referência nos valores registados em 1990 (European Commission, 2011). Como consequências da imposição destas metas, foram dados incentivos de maneira a conseguir instalar tecnologia para aumentar a base renovável. Portugal, no ano de 2000 tinha cerca de 109,77 MW de potência eólica instalada, no ano de 2016 regista cerca de 4.922,88 MW; ou seja, atualmente temos instalada cerca de 44,85 vezes mais de potência eólica do que no ano de 2000 (e2p, 2016). Estes valores devem-se muito aos incentivos disponibilizados pelo Governo Português para a instalação de potência de base renovável.

A potência de base em fontes renováveis aumentou não só em Portugal, mas também em todo o Mundo. Ainda assim, a capacidade instalada não representa a energia produzida, porque existem diversas restrições que limitam a sua produção e o seu consumo. A incorporação desta energia no sistema elétrico é um desafio que tem vindo a ser investigado e aplicado com sucesso na atualidade. Diversas mudanças já aconteceram e continuam a acontecer nos sistemas elétricos devido à incorporação da energia produzida através de energia renovável.

A privatização, liberalização e integração dos sistemas internacionais, que anteriormente eram de caráter nacional, são exemplos das mudanças (Sharma et al., 2014) que ocorreram e proporcionaram um grande desenvolvimento do setor elétrico. O que veio facultar uma linha de investigação que utiliza, não só o conhecimento de interfaces entre áreas de conhecimento científico já conhecidas, mas também a criação de novo conhecimento passível de ser incorporado nestes interfaces, adequando-o às novas exigências e características dos mercados de negociação de energia elétrica. Os mercados de eletricidade

têm sido alvo de pesquisa e investigação em todo o mundo, pois estes são ainda restritos à participação de grandes produtores (Meeus et al., 2005), o que torna difícil a incorporação de fontes de energia renovável nos sistemas de energia, já que esta é essencialmente produzida por pequenos produtores.

Atualmente, por todo o mundo, os mercados de energia estão a evoluir para mercados regionais, como é o caso do Mercado Ibérico de Energia Elétrica (MIBEL) e mais recentemente foi implementado um mercado a nível continental na Europa, através da iniciativa *Price Coupling of Regions* (PCR). Esta criação surgiu da aplicação das políticas da UE, que visa criar um mercado interno de eletricidade na Europa (European Commission, 2009b). Esta junção de mercados permite suportar transações de grande quantidade de energia elétrica e permite também o uso eficiente das energias de base renovável que podem ser comercializadas para serem consumidas em lugares distantes da sua produção (Pinto et al., 2015b).

Naturalmente, os mercados de energia apresentam diferentes formas e possibilidades de negociação da eletricidade. Nos EUA, a maioria dos mercados de energia elétrica funciona com um mecanismo baseado na otimização de ofertas (MISO energy, 2015). Os países europeus têm uma forma de funcionamento baseado em leilões simétricos e assimétricos. Praticamente, todos os mercados também suportam a possibilidade de negociação de energia por meio de contratos bilaterais (Algarvio et al., 2015). Contudo, os diferentes mercados que apresentam características distintas tendem a ficar cada vez mais similares, de modo a facilitarem a transação de eletricidade entre eles e construírem um mercado unificado.

Com estas evoluções e mudanças nos mercados de eletricidade, como é o caso da inclusão de novas entidades no mercado, o *modus operandi* dos mercados tornou-se diferente, mais competitivo, onde os compradores e vendedores de energia praticam um jogo de ofertas e onde o resultado final é o lucro ou o prejuízo. Desta forma, torna-se essencial para os profissionais desta área compreender os princípios de mercado e saber como avaliar os investimentos neste ambiente de economia competitiva (Cerjan et al., 2014). Para tentar colmatar estes problemas são usadas ferramentas de simulação. Através destas pretende-se perceber como funcionam os mecanismos de mercado, e como a integração de novas entidades de mercado pode afetar os resultados de mercado.

As ferramentas utilizadas são os simuladores de mercado, cujo desenvolvimento foi possível graças à utilização da Inteligência Artificial (IA), que desempenha um papel importante neste domínio. A simulação com base Multiagente é uma das áreas da IA que permite analisar sistemas dinâmicos e adaptativos com iterações complexas entre Agentes/Componentes, como por exemplo os mercados de energia (Praça et al., 2003). Os simuladores de mercados de energia proporcionam aos utilizadores dos mesmos a possibilidade de testar soluções, validar e experimentar diferentes e novas alternativas para o funcionamento dos mercados. Outra das possibilidades é a simulação da inclusão de novos agentes permitindo perceber como reage o mercado.

Noutro sentido, surge um conceito novo, denominado de *Smart-Grid* (SG). O aparecimento deste novo paradigma deve-se ao facto do aumento maciço de pequenos produtores, geralmente produtores de energias renováveis. Têm sido muitos os projetos, em todo o mundo, que têm sido implementados com o objetivo de provar a sua fiabilidade (Lund et al., 2012). As SG consideram-se um subsistema do sistema geral, considerando também a gestão da geração local, cargas e sistema de armazenamento como independentes do sistema principal, embora conectados com o sistema principal, podendo também operar como um sistema isolado. Esta é mais uma mudança que vem contribuir para a complexidade e dinamismo do sistema de energia elétrica. Neste sentido, os simuladores tornam-se fulcrais para os intervenientes no mercado conseguirem perceber as alterações que a introdução destes novos conceitos causa nos mercados (Meeus et al., 2005).

Várias ferramentas de simulação têm surgido no âmbito dos mercados de eletricidade, entre as quais podemos destacar as seguintes: *Electricity Market Complex Adaptive System* (EMCAS) (Koritarov, 2004), *Agent-based Modelling of Electricity Systems* (AMES) (Li et al., 2011) e *Multi-Agent Simulator for Competitive Electricity Markets* (MASCEM) (Praça et al., 2003). Estas ferramentas de simulação são vantajosas em termos de operação e regulação do mercado, pois foram construídas na perspetiva de funcionamento de mercado dando pouca importância ao apoio à decisão das entidades que participam nas negociações.

Do ponto de vista da negociação, o apoio à decisão é uma área com pouca exploração, mas deve ser tida em atenção pois é essencial na tomada da decisão das entidades intervenientes nas negociações, permitindo-lhes adaptar-se aos ambientes de mercado, que estão em

constante mudança, e ter a possibilidade de alcançar mais vantagens na participação nos mercados (Pinto et al., 2015b).

Com a existência destas lacunas, surge a necessidade de desenvolvimento e criação de ferramentas capazes de prestar ajuda positiva aos intervenientes nas negociações de energia elétrica. Com o apoio destas ferramentas será possível disponibilizar auxílio aos utilizadores de mercado auxílio que lhe permitirá escolher a ação mais benéfica. Contando com a capacidade das ferramentas IA, nomeadamente a capacidade de aprendizagem e adaptação, os participantes podem usufruir destas características de modo a alterarem o seu comportamento e serem capazes de encontrar a melhor solução possível.

1.2. OBJETIVOS

As limitações encontradas anteriormente são o principal objetivo deste estudo. Destas limitações surge a necessidade do desenvolvimento de ferramentas que apoiem a participação dos interessados nos mercados de eletricidade, de modo a que estes sejam capazes de realizar ações que lhes permitam retirar o maior proveito possível. Assim, este trabalho pretende contribuir para uma melhoria significativa no apoio à decisão que os agentes de mercado necessitam para realizar as suas ações.

Constatou-se que para esta área de trabalho são necessários conhecimentos de áreas de saber distintos, como é o caso da IA, dos Sistemas Elétricos, Informática e Economia. É também uma finalidade conjugar estas áreas de conhecimentos em prol do bom funcionamento dos mercados de energia elétrica.

Assim, a principal finalidade deste trabalho é o desenvolvimento de um modelo matemático que permita representar a participação nos mercados de eletricidade. Este modelo possibilitará a criação de vários cenários que os participantes dos mercados de eletricidade podem utilizar com o intuito de obterem informação que os auxilie no apoio à decisão e por conseguinte melhorar os seus resultados.

Dada a dificuldade de utilização de modelos não lineares de otimização para a resolução do problema, é necessária também a utilização de técnicas de inteligência artificial para resolver o mesmo e encontrar uma solução num tempo de execução mais rápido. Assim, é proposta a utilização das meta-heurísticas: *Particle Swarm Optimization* (PSO), Algoritmo Genético

(AG) e *Simulated Annealing* (SA). A aplicação destas três técnicas tem como objetivo a comparação de resultados entre elas e com o método determinístico, de forma a permitir a tirada de conclusões acerca das abordagens mais apropriadas em diferentes contextos de utilização (maior necessidade de eficácia dos resultados, ou maior requisito em termos de tempo de execução).

É também proposto o desenvolvimento de uma metodologia de estimação de preços em mercados de eletricidade, que pretende ser utilizada nos mercados de energia onde o preço é variável conforme a quantidade negociada. No desenvolvimento desta metodologia é essencial a utilização de técnicas de IA, sendo elas a técnica de *cluster* (agrupamento de dados) e a aplicação da lógica *fuzzy*.

1.3. CONTRIBUIÇÕES

De forma a atingir os objetivos propostos referidos no subcapítulo anterior foi desenvolvido um modelo matemático que pretende ser utilizado nos mercados de energia elétrica com o intuito de dar apoio aos utilizadores, fornecendo-lhe informação sobre o retorno esperado e do risco incorrido na ação a executar. O modelo criado é passível de ser programado em qualquer linguagem de programação. No trabalho aqui apresentado foi utilizado o *software* Matlab para a obtenção de resultados. Na resolução do problema foram utilizados vários algoritmos de pesquisa inteligente, embora todos eles se baseiem no PSO, AG e SA. Tornou-se também necessário o desenvolvimento de uma metodologia de estimação de preços para os contratos bilaterais utilizando as técnicas de *clusters* e *fuzzy*.

Alguns dos resultados conseguidos a partir da elaboração desta dissertação já se encontram publicados em oito artigos científicos. Neste momento, encontra-se também um artigo em fase de revisão com possibilidade de ser publicado. Estão também em elaboração outros artigos científicos para serem propostos a publicação. Segue-se a lista dos artigos científicos que já se encontram publicados.

Artigos em Revista Científicas:

- **Ricardo Faia**, Tiago Pinto, Zita Vale, “Dynamic Fuzzy Clustering Method for Decision Support in Electricity Markets Negotiation”, *Advances in Distributed Computing and Artificial Intelligence Journal*, vol. 5, no.2, July 2016
- Tiago Pinto, Hugo Morais, Tiago M. Sousa, Tiago Sousa, Zita Vale, Isabel Praça, **Ricardo Faia** and E. J. Solteiro Pires, “Adaptive Portfolio Optimization for Multiple Electricity Markets Participation”, *Transactions on Neural Networks and Learning Systems*, IEEE, August, 2015, in press, Impact Factor (2014): 4.291

Artigos Publicados em Capítulos de Livros:

- **Ricardo Faia**, Tiago Pinto, Zita Vale, “Optimization of Electricity Markets Participation with Simulated Annealing”, *Trends in Practical Applications of Scalable Multi-Agent Systems, the PAAMS Collection, Advances in Intelligent Systems and Computing*, vol. 473, pp. 27-39, Springer International Publishing, 2016
- **Ricardo Faia**, Tiago Pinto, Zita Vale, “Dynamic Fuzzy Estimation of Contracts Historic Information using an Automatic Clustering Methodology”, *Highlights of Practical Applications of Agents, Multi-Agent Systems, and Sustainability - The PAAMS Collection, Communications in Computer and Information Science*, vol. 524, pp. 270-282, Springer International Publishing, 2015

Artigos Publicados em Confêrencia:

- **Ricardo Faia**, Tiago Pinto and Zita Vale, “GA Optimization Technique for Portfolio Optimization of Electricity Market Participation”, 2016 IEEE Symposium on Computational Intelligence Applications in Smart Grid (IEEE CIASG'16) of the 2016 IEEE Symposium Series on Computational Intelligence (IEEE SSCI 2016), Athens, Greece, 06 – 09 December, 2016 (Aceite para publicação)
- **Ricardo Faia**, Tiago Pinto, Zita Vale, “Portfolio Optimization for Electricity Market Participation with NPSO-LRS”, Fifth International Workshop on Artificial Intelligence Techniques for Power Systems and Energy Markets (IATEM 2016) at the 27th International Conference on Database and Expert Systems Applications (DEXA 2016), Porto, Portugal, 05 – 08 September, 2016

- **Ricardo Faia**, Tiago Pinto, Zita Vale, “Optimization of Electricity Markets Participation with QPSO”, EEM 16 – 13th International Conference on the European Electricity Market, Porto, Portugal, 06 – 09 June, 2016
- **Ricardo Faia**, Tiago Pinto, Zita Vale, E. J. Solteiro Pires, “Portfolio Optimization for Electricity Market Participation with Particle Swarm”, Fourth International Workshop on Artificial Intelligence Techniques for Power Systems and Energy Markets (IATEM 2015) at the 26th International Conference on Database and Expert Systems Applications (DEXA 2015), Valencia, Spain, 01 – 04 September, 2015

Outros artigos científicos em desenvolvimento:

Artigos para revista:

- Uma comparação do NPSO-LRS no problema multiobjetivo com todas as resoluções efetuadas para este problema;
- Resultados obtidos pelo MPSO - TVAC com e sem solução inicial e comparação entre todas as resoluções efetuadas para o *single* objetivo.

Artigos para Conferência:

- Uma comparação entre a resolução obtida pelo PSO com uma resolução obtida pelo PSO com indicação da solução inicial;
- Resultados obtidos pelo EPSO;
- Resultados obtidos pelo SA para o problema multiobjetivo;
- Resultados obtidos pelo GA para o problema multiobjetivo;
- Resultados obtidos pelo PSO w6 para o problema multiobjetivo;
- Resultados obtidos pelo NPSO-LRS para o problema multiobjetivo.

Uma das consequências positivas, decorrente da elaboração desta dissertação, foi a oportunidade de desenvolver trabalhos para projetos nacionais e internacionais de I & D em que o GECAD participa, nos quais colaborei com o estatuto de bolseiro (SASGER-MeC_2014-04), sendo que 3 dos projetos são nacionais, havendo também lugar para alguns projetos de envolvimento internacional.

Projetos nacionais:

- MAN-REM – Multi-Agent Negotiation and Risk Management in Electricity Markets (PTDC/EEA-EEI/122988/2010), funded by FCT.
- SASGER-MeC – Simulation and analysis of smart grids with renewable energy sources in the scope of competitive markets (NORTE-07-0162-FEDER-000101), cofunded by COMPETE under FEDER Programme.
- GID-MicroRede – Intelligent and Decentralized Management System for Private Microgrids (ADI - Project no. 34086)

Projetos Internacionais:

- DREAM-GO – Enabling Demand Response for short and real-time Efficient And Market Based smart Grid Operation – An intelligent and real-time simulation approach (H2020-MSCA-RISE Grant Agreement no. 641794)
- SEAS – Smart Energy Aware Systems (project ITEA2 no. 12004)

1.4. ESTRUTURA DO DOCUMENTO

Este documento encontra-se dividido em cinco capítulos. O presente capítulo apresenta uma introdução, os objetivos e as contribuições obtidas com a elaboração deste trabalho.

No Capítulo 2, é abordado o estado atual dos mercados de eletricidade e feita uma pequena descrição do funcionamento dos mesmos. É também explorada a aplicação da teoria das carteiras aos mercados de eletricidade, e do uso de simuladores para o estudo destes ambientes.

No Capítulo 3 é feita a apresentação da metodologia proposta, das ferramentas utilizadas para a resolução do problema e são também explicadas as técnicas usadas para a estimação dos preços nos mercados onde os mesmos variam conforme a quantidade negociada.

Os resultados são apresentados no Capítulo 4. Este capítulo apresenta dois subtópicos distintos: a otimização do lucro onde o problema é resolvido atendendo a um só objetivo, e

a otimização multiobjetivo onde são expostos os resultados para os dois objetivos. Na otimização do lucro é feita a comparação entre todos os métodos utilizados e é apresentada a escolha dos algoritmos a utilizar na resolução do problema multiobjetivo.

As conclusões e considerações finais figuram no Capítulo 5, onde são também apresentadas propostas de trabalho futuro.

2. ESTADO DA ARTE

Neste capítulo é feito um levantamento do estado da arte relativo à situação atual dos mercados de energia elétrica. É abordado também o tema da teoria de investimentos em portfólios de energia com destaque para as ferramentas existentes de simulação de mercado.

O paradigma da produção de eletricidade sofreu grandes alterações, deixando de ser monopólio de uma única empresa, onde a mesma fazia a gestão completa da rede desde a produção, transporte e distribuição, passando a ser um regime liberal onde várias entidades entram em contacto fazendo com que o sistema não colapse.

A história dos mercados de energia elétrica teve início na década de 80, quando ocorreu a liberalização dos mercados de energia, pois os monopólios das empresas de energia tornaram-se ineficientes e desvantajosos com o crescente desenvolvimento. Na década de 90, o Reino Unido tomou a decisão de privatizar o seu mercado de energia (Heddenhausen, 2007). Os países industrializados observaram que esta mudança lhes possibilitava gerar riqueza, que o sistema se tornava mais eficiente, vantajoso e facultava aos utilizadores energia a preços mais reduzidos que facilitavam o acesso de toda a população. Esta mudança, por parte dos países mais industrializados, tornou-se uma tendência mundial, massificando a utilização do regime liberal no setor elétrico (Shahidehpour et al., 2002).

Os seguintes autores, (Meeus et al., 2005) e (Concordia, 1999) são seguidores da ideia que sugere a separação vertical e horizontal do modelo monopolista, permitindo desenvolver o mercado da livre concorrência, uma vez que possibilita a liberalização dos segmentos potencialmente competitivos como a produção, a comercialização, o transporte e a distribuição. Neste tipo de mercado, onde existe uma grande oferta e procura do produto, surge uma maior qualidade de serviço, redução dos custos e um aumento da eficiência. A aplicação deste regime aos mercados de energia elétrica foi um processo demorado, tendo sido alvo de vários estudos porque, apesar do conceito liberal não ser novo, a aplicação dele aos sistemas elétricos de energia era uma novidade e, por isso foram necessários vários ajustes e alterações para tentar melhorar a sua performance.

A tendência da criação dos mercados de eletricidade levou ao aparecimento de mercados Regionais, que a Comissão Europeia menciona num documento de estratégia de 2006 como um passo a seguir para a criação de um mercado pan-europeu (European Commission, 2006). Deste modo, surgiram então os mercados que englobam vários países e regiões, como é o caso de Portugal e Espanha onde foi criado o MIBEL que serve de suporte para as transações energéticas nos países da Península Ibérica. Mas, a UE, como entidade que zela pela igualdade de todos os estados membros, propõe que se estabeleça um mercado interno de eletricidade que proporcione a todos os habitantes dos estados membros um preço de eletricidade com disparidade mínima (PCR, 2015). Segundo a legislação europeia fundamental, para a criação de um mercado interno de eletricidade europeia, todos os consumidores na Europa devem ser livres de comprar eletricidade ao fornecedor da sua escolha, e os fornecedores, por outro lado, devem ter acesso a todos os clientes europeus. Mas, como todos sabemos existem limitações que fazem com que os mercados regionais se tornem concentrados. Pois, a interligação transfronteiriça leva a que a concorrência se faça sentir em menor grau. Esta fraca concorrência reflete-se na transparência dos preços.

2.1. MERCADOS DE ENERGIA ELÉTRICA

No sentido de acelerar a criação do mercado interno europeu foi dado o passo intermédio da criação de mercados regionais. Neste subcapítulo são abordados os mercados regionais europeus atuais, nomeadamente: Mercado Ibérico de Eletricidade (MIBEL) (MIBEL, 2007), Nord Pool Spot (Nord Pool, 2016), *European Power Exchange* (EPEX) Spot (EPEXSPOT,

2016), *Gestore die Mercati Energetici* (GME) (GME, 2016), *Power Spot Exchange* (APX) (APX, 2016), OTE (OTE, 2016) e Belpex (Belpex, 2016).

MIBEL

As entidades governativas de Portugal e Espanha conjugaram esforços para a criação de um mercado de eletricidade ibérico, o conhecido MIBEL. Com este mercado, passou a ser possível a qualquer consumidor em território ibérico, adquirir energia elétrica, a qualquer produtor ou comercializador de Portugal ou de Espanha, no mercado livre de concorrência (MIBEL, 2007).

Este mercado é composto por duas entidades que são responsáveis pela gestão do mercado ibérico de energia: o Operador de Mercado de Energia – Polo Espanhol (OMIE) e o Operador de Mercado de Energia – Polo Português (OMIP). O OMIE é responsável pela gestão dos mercados diários e intradiários, ao passo que o OMIP é responsável pela gestão dos mercados a prazo.

O mercado MIBEL assenta num funcionamento misto, pois integra um mercado em Pool simétrico e voluntário, conjuntamente com a existência de contactos bilaterais físicos e financeiros. Dos mercados de *Pool* fazem parte os mercados diários e intradiários, ambos com funcionamento através de leilão (MIBEL, 2007).

Nord Pool Spot

O *Nord Pool Spot* é um Mercado de energia responsável por transações energéticas nas regiões Nórdicas (Dinamarca, Finlândia, Noruega e Suécia), do Báltico (Estónia, Lituânia e Letónia) e abrangendo também os países da Alemanha e Grã-Bretanha. Dentro deste mercado é possível negociar energia através do mercado diário (Elspot), mercado intradiário (Elbas) e ainda o mercado de ajustes (Nord Pool, 2016).

EPEX Spot

A *European Power Exchange Spot* (EPEX) é uma empresa que faz a gestão dos mercados de energia na região da Europa Central. Esta região é constituída pelos países da Alemanha, Áustria, França e Suíça. No EPEX Spot são abordados dois mercados: o mercado diário e o

mercado intradiário. É considerado um dos mercados mais interessados na integração dos mercados num único mercado europeu, porque está situado no centro da União Europeia.

A EPEX Spot, em parceria com outra empresa, calculam e publicam o Índice de Energia Elétrica Europeu (ELIX), o que serve como referência de preço nos outros países da Europa. Este índice vem reforçar a ideia da criação de um mercado único europeu na área da energia (EPEXSPOT, 2016).

GME

A *Gestore Mercati Energetici* (GME) é o operador responsável pela gestão e organização do mercado de energia italiano, que é denominado de *Italian Power Exchange* (IPEX). Neste mercado, os interessados em participar conectam-se a uma plataforma eletrónica, através da internet, para realizar os contratos *online* de compra e venda de eletricidade. No IPEX existe a possibilidade de se efetuarem negociações no Mercado Spot, no Mercado Forward e na chamada Plataforma de Entrega Física dos Contratos Financeiros. No caso do mercado Spot existe o Mercado diário, o Mercado Intradiário e o Mercado de Serviços Auxiliares (GME, 2016).

APX

A *Amsterdam Power Exchange* (APX), foi o primeiro mercado de eletricidade na Europa Continental. Atualmente, o grupo APX (Power Spot Exchange) é uma bolsa de energia que opera no mercado Spot de eletricidade da Holanda, Reino Unido e Bélgica. Esta bolsa de energia a operar nestes países é um parceiro muito importante na luta pelo objetivo da criação de um mercado de eletricidade europeu totalmente acoplado (APX, 2016).

OTE

A OTE é uma empresa que opera no mercado de eletricidade e de gás da República Checa. Este operador possibilita aos intervenientes a oportunidade de participar em três diferentes tipos de mercados: mercado diário, mercado intradiário e mercado de ajustes (OTE, 2016).

Belpex

Belpex é um Mercado de energia elétrica que opera na Bélgica. Neste mercado é possível fazer negociações a nível do Mercado diário e Mercado intradiário. O Mercado diário do Belpex é acoplado com a APX da Holanda e do Reino Unido, com o EPEX Spot da França e Alemanha e com o Nord Pool da região nórdica. O Mercado intradiário é acoplado com a APX da Holanda e com o Nord Pool da região nórdica. Neste segmento de mercado é possível comercializar energia para o próprio dia até 5 minutos antes da hora de entrega. Estando este mercado fortemente acoplado a muitos outros, é um dos principais colaboradores e interessados na integração dos mercados europeus de energia (Belpex, 2016).

2.2. TIPOS DE MERCADO

Os mercados podem ser classificados quanto ao tempo que vai do fecho da negociação até à entrega (física ao não) da energia. O fecho da negociação é o momento em que ambas as partes interessadas na negociação chegam a acordo. Como é do conhecimento comum, a eletricidade não pode ser armazenada de forma massiva, por isso, a maioria das transações de energia são contratadas algum tempo antes da entrega física.

2.2.1. DAY-AHEAD

O conceito de *Day – Ahead Market* é utilizado para caracterizar os mercados de eletricidade em que o processo de negociação é realizado para o dia seguinte, ou seja no dia $n-1$ determinam-se as propostas aceites, os preços e as quantidades de energia transacionada para o dia n . O tipo de mercados *Day – Ahead* é associado aos Modelos *Pool*, ou bolsas de eletricidade que segue as linhas de um mercado *spot*. Nos mercados *spot*, os vendedores competem pelo fornecimento de energia global e não para conseguir angariar determinados clientes. Neste tipo de mercados, se um vendedor licitar valores demasiado elevados, não será capaz de vender a sua energia. Por outro lado, os compradores competem para comprar energia, mas se as suas licitações forem demasiado baixas, não conseguirão comprá-la (Shahidehpour et al., 2002).

A estes mercados está associado um prazo de negociação muito curto. Por isso, as ofertas são feitas para as 24 horas do dia seguinte. Geralmente, estas propostas podem ser

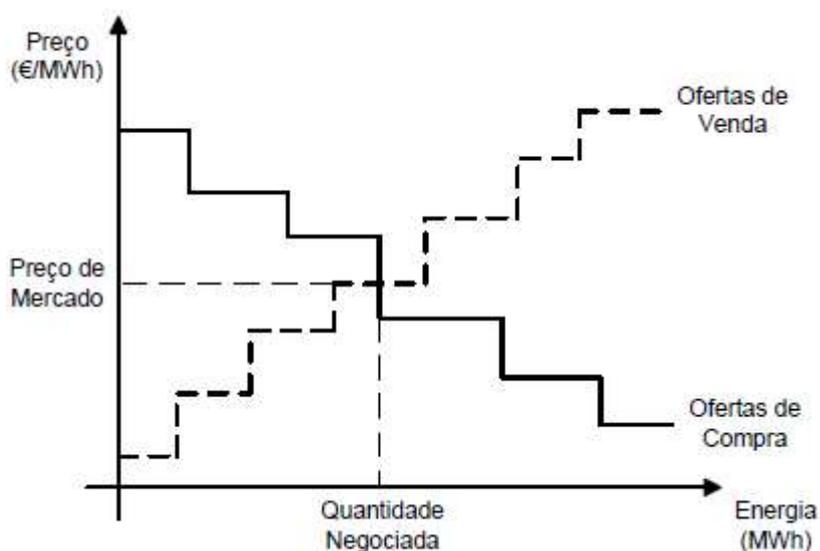
discriminadas de hora a hora ou de trinta em trinta minutos, com a indicação do preço e da energia que se pretende transacionar. Podendo daí resultar 24 ou 48 despachos económicos de produção de energia elétrica.

No modelo *Pool*, existe uma entidade chamada de Operador de Mercado que é responsável pela elaboração destes despachos, mas num formato provisório. Esta entidade tem como compromisso o equilíbrio entre a produção e o consumo. Para tal, o operador é responsável pelo chamado *Market Clearing Price*, que consiste na ordenação das propostas de compra e de venda por ordem de preço, para posteriormente determinar o preço final de cada negociação (Gonçalves, 2013).

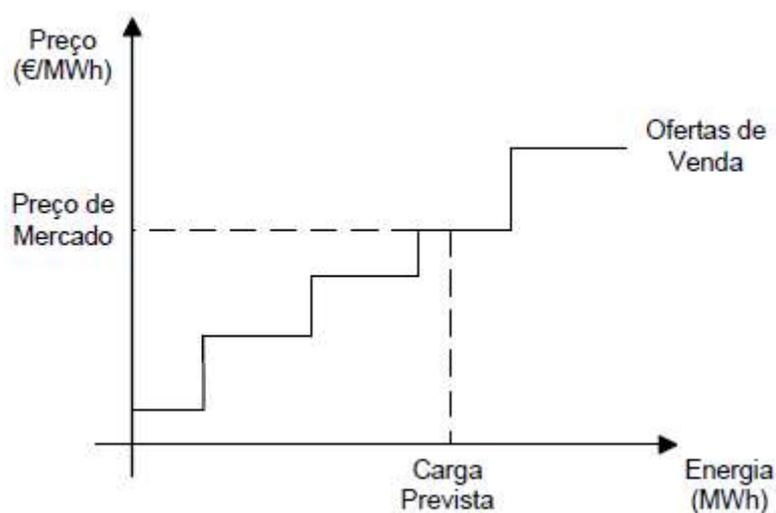
Depois do Operador de Mercado definir os despachos provisórios para o dia seguinte, é necessário que seja verificada a viabilidade técnica dos mesmos. Esta viabilidade técnica consiste na verificação de que as restrições de rede de transporte não são violadas e que não existirá congestionamento na rede elétrica.

O Operador do Sistema é o responsável por verificar se os despachos realizados pelo Operador de Mercado são viáveis. Para isso, o Operador de mercado envia toda a informação necessária. Caso esteja garantida a viabilidade dos despachos provisórios, o Operador do Sistema transmite a informação sobre os valores obtidos e contrata os níveis necessários de serviços auxiliares (Ramos, 2006).

No modelo de negociação em *Pool* existem dois tipos de vertente: o *Pool* Simétrico e o *Pool* Assimétrico. No *Pool* Simétrico, é possível fazer ofertas de compra e de venda e o Operador de mercado, em função das ofertas recebidas para cada período de programação, uma hora ou trinta minutos, ordena por ordem crescente do preço as ofertas de venda e por ordem decrescente as ofertas de compra. Neste tipo de mercado, o preço é determinado normalmente pela interseção da curva das ofertas de compra com a curva das ofertas de venda, por forma a estabelecer um equilíbrio entre a oferta e a procura (Azevedo, 2007). Na Figura 1 é demonstrada a forma como se chega ao preço de mercado e à quantidade negociada em mercados do tipo simétrico.

Figura 1 – *Pool* Simétrico, (Praça et al., 2003)

No modelo *Pool* Assimétrico, apenas são submetidas as ofertas de venda; as ofertas de compra não são contabilizadas neste modelo. As ofertas dispõem-se por ordem crescente de preço pretendido e são aceites todas as ofertas necessárias à total satisfação da procura. O preço de fecho, ou seja o preço que irá ser pago a todos os vendedores cujas ofertas foram aceites, é o preço da oferta de venda mais cara que foi necessário aceitar para satisfazer a procura. Com este modelo, pode considerar-se que a carga prevista é inelástica, sendo por isso capaz de pagar qualquer preço estabelecido pelo mercado (Pereira, 2004). A Figura 2 representa o esquema do modelo explicado.

Figura 2 – *Pool* Assimétrico, (Praça et al., 2003)

2.2.2. MERCADO INTRADIÁRIO

O mercado intradiário, também denominado de mercado de ajustes, é uma forma de gerir os desvios previstos a curto prazo entre os contratos realizados nos mercados diários e contratos bilaterais com a carga prevista num horizonte temporal mais curto.

O mercado diário apresenta frequentemente dois problemas que levam a que o mercado de ajustes seja fundamental para o funcionamento dos sistemas elétricos (Gonçalves, 2013):

- O resultado do modelo em *Pool* e dos contratos bilaterais leva a situações de congestionamento.
- Os intervalos de tempo de uma ou meia hora são longos, tendo em conta a dinâmica dos sistemas elétricos de energia, tornando-se por isso difícil que o valor de energia produzida seja exatamente igual à carga.

Os mercados de ajustes ou intradiários são os mecanismos que funcionam em horas predefinidas do dia, em que se realiza a operação do sistema e que permitem, como o nome indica, ajustar as ofertas de compra e venda de energia e aliviar os congestionamentos (Gonçalves, 2013). Outras das vantagens da utilização do mercado intradiário é a possibilidade de ocorrência de eventuais avarias nos equipamentos presentes na rede. Estes constrangimentos, uns previsíveis outros não, tornam este mercado essencial para o bom funcionamento do sistema elétrico (Martins, 2009).

A participação dos compradores no mercado diário para posteriormente poderem participar no mercado intradiário, depende da obrigatoriedade de participarem na sessão correspondente do mercado diário ou na execução de um contrato Bilateral Físico. No caso dos produtores, têm de participar na sessão correspondente do mercado diário ou na execução de um contrato Bilateral Físico, ou estar indisponível para participar no mercado diário e ficar disponível apenas posteriormente (OMEL, 2016).

A Figura 3 mostra o esquema de funcionamento de um mercado intradiário (do mercado MIBEL), o modo como as seis sessões estão organizadas e o período a que correspondem no mercado diário.

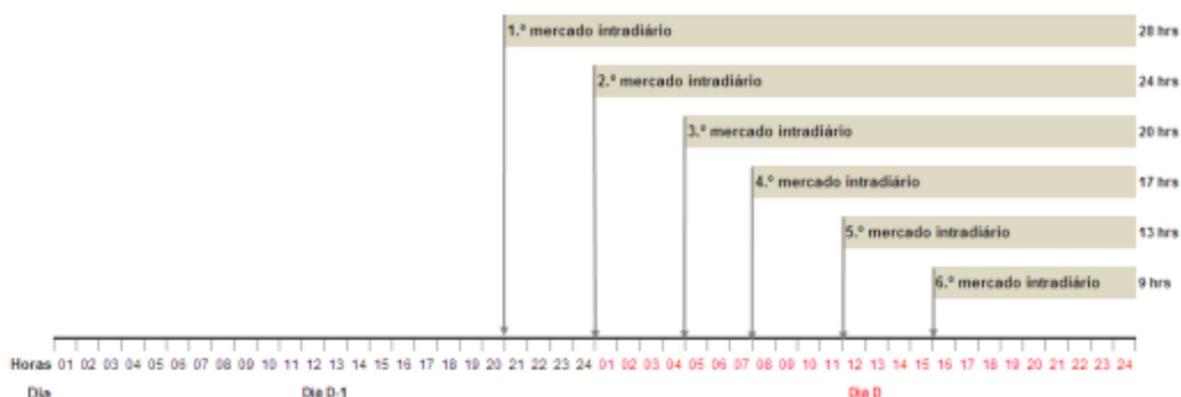


Figura 3 - Mercado intradiário, (MIBEL, 2007)

O exemplo apresentado na Figura 3 diz respeito ao mercado intradiário do MIBEL. A primeira sessão determina o preço para as últimas 3 horas do dia $n-1$ e para as 24 do dia n . A segunda sessão estabelece o preço para as 24 horas do dia n . Na terceira sessão é definido o preço para as 20 horas compreendidas entre as 5 horas e as 24 horas do dia n . A quarta sessão estabelece o preço para as 17 horas compreendidas entre as 12 e as 24 horas do dia n . A quinta sessão determina o preço para as 13 horas compreendidas entre as 12 horas e as 24 horas do dia n . A sexta sessão define o preço para as 9 horas compreendidas entre as 16 horas e as 24 horas do dia n .

2.2.3. CONTRATOS BILATERAIS

Os contratos bilaterais são uma forma alternativa de relacionamento entre os produtores e os consumidores. Normalmente, são utilizados como meio de proteção do risco dos contratos efetuados em mercados a curto prazo, e também para conferir às entidades consumidoras a capacidade real de eleger o fornecedor com o qual se pretende relacionar. Os contratos bilaterais podem ser classificados em contratos *forward*, contratos futuros, contratos de opção e contratos por diferença (Kirschen and Strbac, 2004).

CONTRATOS *FORWARDS*

Neste tipo de contratos as partes interessadas nas negociações definem um preço fixo para o ativo (eletricidade), o qual será cumprido independentemente do preço praticado nos mercados a curto prazo. Neste tipo de contratos são definidas várias cláusulas (os preços, quantidades, data de entrega, pagamento e penalizações por não cumprimento de cláusulas) entre as partes negociadoras. Os contratos *forward* permitem aos agentes negociadores

dividir o risco do preço. Ao agente vendedor é garantida uma receita fixa, estando protegido das baixas de preço registadas nos mercados a curto prazo, e ao agente comprador é garantida a proteção contra subidas de preço nos mercados a curto prazo, uma vez que o ativo mantém um custo fixo.

CONTRATOS FUTUROS

A base dos contratos futuros é a esperança de comprar a um preço baixo e vender futuramente a um preço mais elevado. Estes contratos poderão apresentar um elevado risco, dado que no fim do prazo estabelecido é obrigatória a utilização efetiva do recurso. Essa condição pode levar a perdas financeiras significativas, se o preço do mercado a curto prazo tender para valores inferiores ao estabelecido no contrato (Saraiva and Leão, 2002).

Tanto nos contratos *forward* como nos contratos futuros o bem contratado, neste caso a eletricidade, tem a obrigatoriedade de ser entregue fisicamente, representando perdas ou benefícios para qualquer uma das partes contratuais.

CONTRATOS POR OPÇÃO

Nos contratos por opção não é necessário que a entrega física da eletricidade ocorra. Desta forma, qualquer uma das partes contratuais se analisar uma melhor possibilidade em outro tipo de negociação pode desistir. Assim, estes contratos apresentam um menor risco quando comparados com os contratos *forward* ou futuros.

CONTRATOS POR DIFERENÇA

Neste tipo de contratos estabelece-se um preço alvo entre as duas entidades envolvidas. Estes contratos têm por objetivo a proteção contra a variação de preços nos mercados a curto prazo e funcionam da seguinte forma:

- Se o preço alvo for maior que o preço de mercado a entidade consumidora paga à entidade produtora a diferença entre o preço alvo e o preço de mercado;
- Se o preço alvo for inferior ao preço de mercado a entidade produtora paga à entidade consumidora a diferença entre o preço de mercado e o preço alvo.

2.3. UNIFICAÇÃO DO MERCADO EUROPEU

Uma das principais prioridades da UE é a formação de um mercado europeu único de energia Pan-European Energy Market. Inicialmente, foram definidas sete zonas para tentar acelerar o processo de criação do mercado europeu único. A criação destas zonas tem como objetivo acabar com os mercados nacionais. As zonas criadas foram as seguintes:

- Báltico (Estónia, Letónia e Lituânia);
- Centro Leste (Áustria, República Checa, Alemanha, Hungria, Polónia, Eslováquia e Eslovénia);
- Centro Sul (Áustria, França, Alemanha, Grécia, Itália e Eslovénia);
- Italiano;
- Centro Oeste (Bélgica, França, Alemanha, Luxemburgo e Holanda);
- Nórdico (Dinamarca, Finlândia, Alemanha, Noruega, Polónia e Suécia);
- Sudoeste (França, Portugal e Espanha);
- França, Reino Unido e Irlanda.

Na Figura 4 esta representado o progresso de evolução dos mercados de energia.

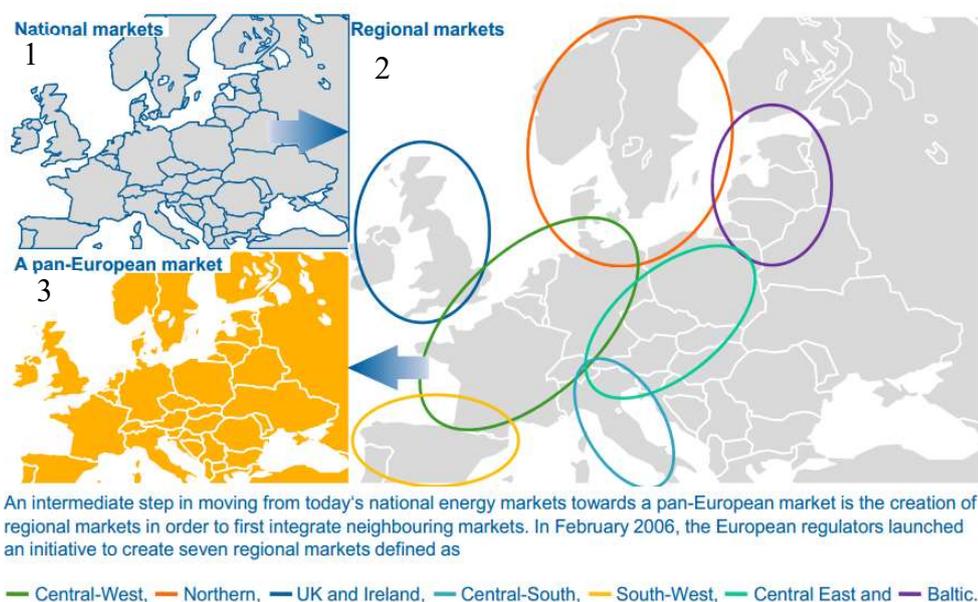


Figura 4 - Principais mudanças nos mercados de eletricidade, adaptado de (EMCC, 2016)

A sequência numérica na Figura 4 indica a evolução dos mercados no espaço europeu. Como é observável, na fase 1 cada país possuía o seu próprio mercado. Na fase 2, posição na qual atualmente a Europa se encontra, estão assinaladas as sete regiões descritas anteriormente.

Por fim, na posição 3 está representado o futuro dos mercados europeus, ou seja, a constituição de um só mercado. A este nível já existem algumas experiências como descrito nas subsecções seguintes (Meeus and Belmans, 2008).

2.3.1. ACOPLAMENTO

O acoplamento de mercado é um mecanismo que permite a negociação entre duas ou mais bolsas de energia usando licitações implícitas de capacidade das ligações transfronteiriças. Quando estes tipos de mercados são integrados, a negociação está sujeita a restrições da capacidade das interligações (EWEA, 2012).

Têm sido implementados alguns projetos de acoplamentos de mercados na UE. Seguidamente serão apresentados três desses projetos. O primeiro deles é o MCR (Multi-Regional Coupling). Trata-se de um projeto de integração de mercados Spot na Europa. Neste projeto conta-se com a cooperação entre as seguintes bolsas de energia: APX, Belpex, EPEX SPOT, Nord Pool Spot e OMIE. Na Figura 5 estão representados os países que fazem parte do projeto MCR.



Figura 5 - Regiões abrangidas pelo MCR, (PCR, 2015)

O MCR permite calcular o preço da eletricidade simultaneamente e os fluxos das interligações entre as zonas com diferentes mercados. Este projeto proporciona o aumento de eficiência na utilização da capacidade das interligações entre os países aderentes (PCR, 2015).

Price Coupling of Regions (PCR) é uma iniciativa de sete bolsas de energia: APX, Belpex, EPEX SPOT, GME, Nord Pool Spot, OMIE e OTE, que tem como objetivo calcular um preço de eletricidade único no mercado diário para todas as bolsas de energia que constituem

o projeto. Outra das funções é atribuir as capacidades diárias nas interligações dos países abrangidos pelas bolsas de energia. A Figura 6 mostra a localização geográfica dos países pertencentes ao projeto PCR, assim com a identificação das bolsas de energia (PCR PXs, 2013).

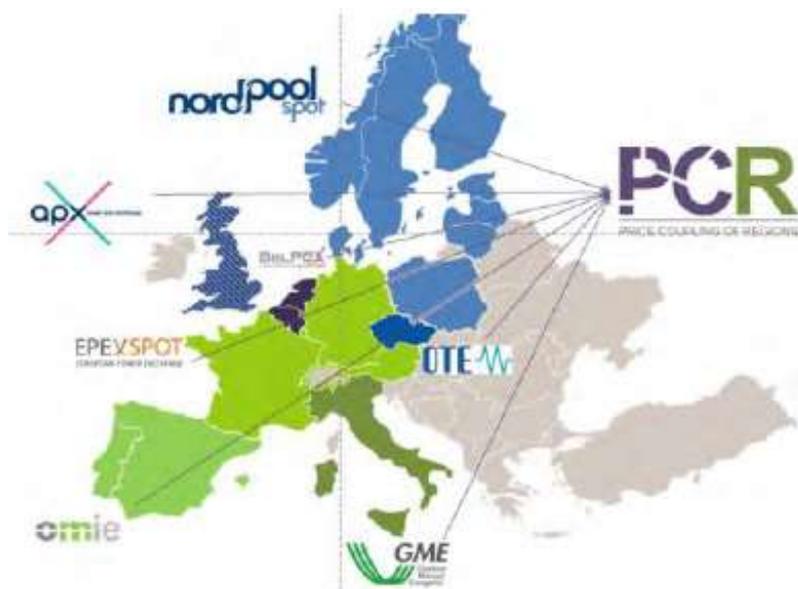


Figura 6 -Principais mercados abrangentes do PCR, (PCR PXs, 2013)

A implementação do projeto PCR constitui um marco importante para o objetivo europeu de criação de um mercado de eletricidade totalmente uniformizado. O projeto encontra-se em fase de desenvolvimento por isso, nem todas as bolsas de energia estão integradas. No Noroeste e Sudoeste da Europa já foi utilizado o projeto PCR para calcular os preços de eletricidade ao mesmo tempo e de forma uniformizada.

A 24 de fevereiro de 2015 o projeto – *Italian Borders Market Coupling* foi implementado com sucesso. Deste projeto fazem parte os seguintes países: Austrália, França, Grécia, Itália, Eslovénia e a Suíça que constituem as seguintes bolsas de energia: BSP, GME, EXAA e LAGIE. Basicamente este projeto tem como centro o país Italiano e une os mercados com os quais faz fronteira. A capacidade de estabelecer interligações a partir de Itália com a Áustria, França e Eslovénia, que estão alocados ao projeto PCR, constitui uma parte importante do projeto europeu de unificação dos mercados da Europa (PCR, 2015).

2.3.2. MERCADO DIÁRIO ACOPLADO

A integração do mercado diário ou seja, o mercado com um dia de antecedência, visa reduzir os preços médios em toda a UE, sincronizando as operações em diferentes mercados em termos de fecho das negociações, procedimentos operacionais e capacidade de transmissão através das interligações transfronteiriças. Este tipo de mecanismo disponibiliza todas as propostas de oferta e produção transfronteiriças para a negociação, e ao mesmo tempo podem ser combinadas automaticamente com a capacidade de transmissão das interligações. Assim, diz-se que a capacidade das interligações pode ser adquirida de forma implícita, juntamente com o comércio de energia. Isto significa que as partes negociadoras têm acesso automático à energia e capacidade transfronteiriça sem que seja necessário adquiri-las em mercados distintos. Deste modo, o acoplamento de mercado contribui para o aumento do fluxo das interligações, o que coopera para a convergência de um preço único e para a redução da volatilidade dos preços. O mecanismo de acoplamento utiliza um algoritmo que otimiza todos os negócios rentáveis resultantes das propostas de venda e de compra entre bolsas de energia. Os operadores do sistema definem restrições, o que pode limitar o fluxo de eletricidade entre mercados (EWEA, 2012).

O algoritmo utilizado no projeto PCR é chamado de EUPHEMIA (Pan – European Hybrid Eletrecity Market integration Algorithm). O principal objetivo do algoritmo é maximizar o excedente económico de todos os participantes e determinar os fluxos que levam a um nivelamento dos preços em todos os mercados. Isto pode significar que a eletricidade mais barata, oferecida num determinado país, pode atender à procura de outro país e reduzir os preços praticados nesse país. Os preços vão ser nivelados sempre que exista capacidade de transmissão suficiente que permita o fluxo da eletricidade. O EUPHEMIA resolve o despacho para todos os períodos de um único dia de uma só vez, tendo em conta as restrições da rede e do mercado. Da sua otimização resultam os preços de equilíbrio de mercado, os volumes correspondentes a cada mercado, os retornos ocorridos em cada área de licitação e os fluxos que ocorrem nas interligações (PCR PXs, 2013). O algoritmo pode incorporar vários tipos de ordens:

- Ordens de agregação horárias – São ordens para todos os participantes que pertençam à mesma área de licitação.

- Ordens Complexas – São simples conjuntos de ordens que afetam o fornecimento de eletricidade de hora em hora, estas pertencem a um único participante do mercado, e podem ser seguidos ao longo dos diferentes períodos.
- Ordens em Bloco – Podem ser ordens de produção ou consumo e podem ser definidas como: fixação de preço limite, o número de períodos, o volume que pode ser diferente em cada período e a relação mínima entre o volume aceite e o volume total.
- Ordens de mérito e PUN (Prezzo Unico Nazionale) – as ordens de mérito são ordens individuais definidas para um dado período, às quais têm associado um número de chamada que é único por período e por tipo de ordem. As ordens PUN são um tipo particular de ordens de mérito de consumo, e o preço único nacional traduzido do “*Prezzo Unico Nazionale*” refere-se a uma ordem para o preço de equilíbrio.

O EUPHEMIA também retorna como saída as ordens a serem executadas. Este problema pode ignorar as ordens descritas anteriormente e a sua resolução torna-se mais simples de se resolver, e pode ser modelado como um problema de programação quadrática (QP). Com a incorporação das ordens referidas o problema torna-se mais complexo. Pois, a introdução de certas ordens implica a incorporação de variáveis binárias (0 ou 1), que torna o cálculo mais difícil tornando-o um problema do tipo quadrático inteiro misto (MIQP). Este problema é constituído por um problema principal chamado de problema de “*Social Welfare Problem*”¹ e três sub-problemas: determinação do preço de equilíbrio de mercado, a procura PUN e a indeterminação do volume. Estes três sub-problemas são interdependentes uns dos outros.

No problema principal é procurado um conjunto de soluções para uma boa seleção das ordens de bloco e ordens MIC (ordens complexas). Nestes problemas as ordens de mérito e PUN não são aplicados, mas quando for encontrada uma solução para o problema inteiro o algoritmo procede para determinar os preços de equilíbrio de mercado. Este sub-problema

¹ *Social Welfare Problem* – É um problema onde a qualidade de vida é tida em conta, incluindo fatores como a qualidade do ambiente (ar, solo, água), nível de criminalidade, extensão do abuso de drogas, ect (WebFinance, 2016). Desta forma foi dado este nome ao problema por se considerar que a eletricidade contribui para o bem-estar social da sociedade.

determina o preço para cada área de licitação, garantindo que nenhuma ordem de bloco e MIC são paradoxalmente aceites. O EUPHEMIA procede com o sub-problema PUN no entanto, se este sub-problema não tiver qualquer solução, pode-se concluir que a seleção de bloco e ordens complexas não são aceites, e a solução inteira para o problema principal deve ser rejeitada (PCR PXs, 2013).

No que toca ao mercado intradiário, ainda não existe qualquer projeto implementado que permita a operação de um mercado intradiário acoplado. Mas, o projeto – XBID Project (Cross-Border Intraday) constitui uma iniciativa de criação de um mercado intradiário integrado. Deste projeto fazem parte as seguintes bolsas de energia: APX/Belpex, EPEX SPOT, GME, Nord Pool Spot e OMIE (XBID, 2015).

2.4. SMART GRID

As redes de energia elétrica estão a sofrer cada vez mais transformações devido às exigências da sociedade atual. Os utilizadores da rede exigem maior qualidade da energia, mais fiabilidade, uma maior escolha de serviço e menores preços (Gulich, 2010). Este tipo de vantagens vem favorecer os mercados locais, os quais têm emergido com o aumento de produção distribuída e veem o seu sucesso dependente das previsões precisas de consumo e da produção dos seus participantes (Silva et al., 2014).

Embora ainda se encontre numa fase inicial de desenvolvimento, conceito de SG, é uma das tendências promissoras e é visto como o futuro da rede elétrica. A sustentabilidade, a integração massiva de fontes de energia renovável e uma maior eficiência são questões energéticas importantes com que diariamente a sociedade é confrontada. A SG é vista como um paradigma que trará a resolução para algumas destas questões.

A SG pode ser definida como um organismo inteligente e interativo, dinâmico, que reage, integra, incorpora, autocorrigue e estabiliza, em torno de um novo ponto de operação. Podemos dizer que é uma plataforma que permite o funcionamento de diferentes tecnologias e sistemas (Lund et al., 2012).

A SG é uma rede de energia elétrica que pode inteligentemente integrar as ações de todos os utilizadores ligados a ela (produtores, consumidores e ambas as partes), a fim de garantir o

fornecimento de energia elétrica de forma eficiente, sustentável, económico e seguro (Nascimento, 2013). A Figura 7 mostra uma representação esquemática do conceito de SG.

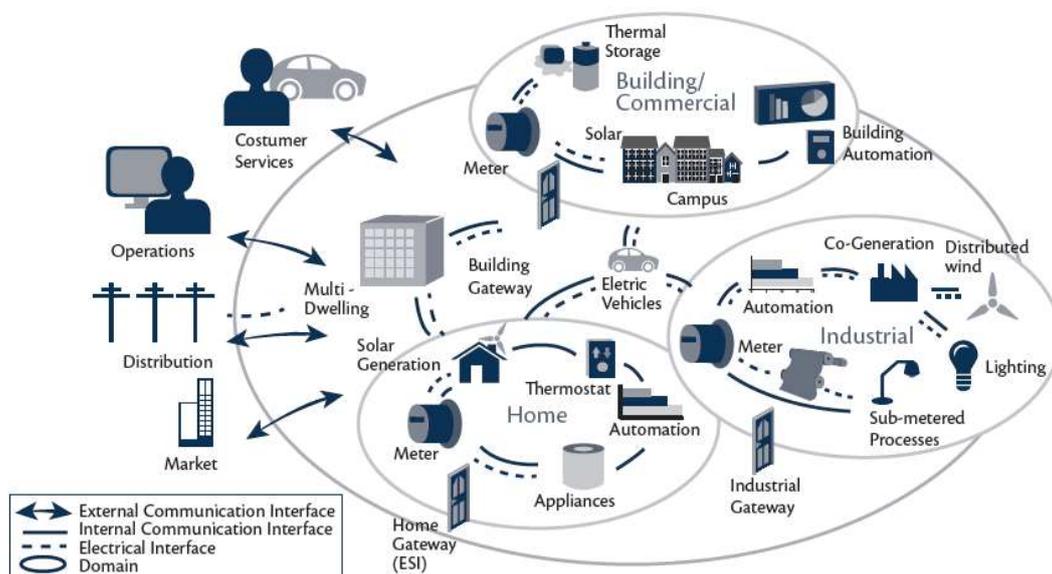


Figura 7 - Ilustração de uma SG (Ramakrishnan and Ramakrishnan, 2013).

Uma vez que as infraestruturas antigas de produção de energia elétrica precisam de renovação, devido ao seu tempo de vida útil de funcionamento estar no limite, a implementação das novas infraestruturas é uma excelente oportunidade para substituir o equipamento antigo por tecnologia adequada à plataforma das SG's.

Como se pode observar na Figura 7, o conceito das SG traz muito de novo ao sistema, nomeadamente a facilidade da integração de fontes de energia renovável, o incentivo ao papel ativo dos consumidores, e a integração dos veículos elétricos. Nesta rede vão estar disponíveis para o utilizador dos veículos elétricos e uma plataforma que lhe permite carregar as baterias quando necessita, podendo o carregamento ser feito na rua ou na própria casa. Os VPPs (Virtual Power Players) é outro dos conceitos que surge ligado a este novo paradigma, e tem como função agregar pequenos produtores e consumidores, e ajudá-los a participar no mercado, o que faz com que o conceito de SG se torne seguro e eficaz, num ponto de vista de integração em mercado (Morais et al., 2012).

Cada novo dispositivo implementado na SG levanta questões complexas em várias áreas. À medida que estes tipos de redes tomam forma, novas tecnologias vão surgir para fornecer

aos utilizadores maior acesso a fontes alternativas de energia, como a eólica, solar, baterias de armazenamento, bem como a auto produção de energia, redes de área local, veículos elétricos e sistemas de carregamento (Gulich, 2010).

2.5. SIMULAÇÃO DE MERCADOS

Nos últimos anos têm surgido uma série de ferramentas de simulação para mercados de energia elétrica, que pretendem dar apoio aos agentes por forma a ajudá-los nas suas ações. Vários destes sistemas utilizam tecnologia multiagente, que é adequada à análise de sistemas dinâmicos e adaptativos com iterações complexas entre os seus constituintes (Pinto et al., 2015a).

A utilização de sistemas multiagente em mercados de energia traz várias vantagens, tais como: a representação natural do domínio, que constitui assim uma abordagem ideal para modelar os mercados de energia, onde a informação e o controlo são distribuídos por natureza; a robustez, onde a sobreposição do conhecimento dos agentes individuais leva a que o sistema global seja mais tolerante a falhas; a confiança e a sobreposição dos agentes individuais tornam o sistema mais fiável (Landaburu, 2006).

Vários simuladores de mercado têm surgido com base em sistemas multiagente, que permitem modelar e simular mercados de energia elétrica. Estes sistemas são ferramentas adequadas à modelização das iterações dos agentes que intervêm no mercado de energia, uma vez que permitem simular essas iterações tendo em conta fatores sociais, económicos e ambientais. As ferramentas mais relevantes neste domínio são: AMES (Agent-based Modelling of Electricity Systems (Li and Tesfatsion, 2009), EMCAS (Electricity Market Complex Adaptive System) (Koritarov, 2004), GAPEX (Genoa Artificial Power Exchange) (Cincotti and Gallo, 2013), e o MASCEM (Multi-Agent Simulator of Competitive Electricity Markets) (Praça et al., 2003) o qual vai ser descrito a seguir.

2.5.1. MASCEM

O MASCEM é uma ferramenta de simulação desenvolvida no GECAD (Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e o Desenvolvimento) do ISEP (Instituto Superior de Engenharia do Porto), que permite simular o ambiente complexo dos mercados de energia elétrica (Pinto, et al. 2014). Foi inicialmente desenvolvido através de uma plataforma *Open Agent Architecture* (OAA), com base na linguagem de programação JAVA, tendo sido posteriormente reestruturado para a plataforma JADE (*java agent development framework*) (Telecom Italia, 2016). O simulador permite simular vários tipos de mercados de energia elétrica, os típicos: modelo em bolsa, contratos bilaterais e ambos. Mas, permite também especificamente simular modelos de mercados de diferentes operadores como é o caso do MIBEL, EPEX e Nord Pool. As entidades de mercado são representadas por agentes computacionais e são autónomos ao ponto de estabelecer os seus próprios objetivos e regras de decisão. Os agentes ao longo das simulações têm a capacidade de adaptar as suas ações com base no sucesso ao em fracassos anteriores (Vale et al., 2011).

2.5.1.1. MODELO MULTIAGENTE

Considera-se um sistema multiagente uma rede fiável de agentes computacionais que operam em conjunto para resolver problemas cuja resolução está para além do conhecimento e das capacidades de cada agente (Jennings et al., 1998). Nos sistemas multiagentes não existe um controlo global do sistema, a informação é distribuída, a computação é assíncrona e cada agente tem informação e controlo limitados do sistema global. Estas características fazem com que estes sistemas sejam aplicados com sucesso em várias aplicações de diversas áreas tais como a Inteligência Artificial, a Economia e em diferentes ramos da Engenharia (Jennings et al., 1998).

Com o simulador MASCEM, como já foi referido anteriormente, é possível simular vários agentes que representam diferentes entidades de mercado (Pinto, et al. 2014), esta característica permite que a simulação se aproxime da realidade e assim seja dado o apoio necessário aos intervenientes nas negociações.

Na Figura 8 estão representados os vários agentes existentes em MASCEM assim como as suas interações (Santos, 2015).

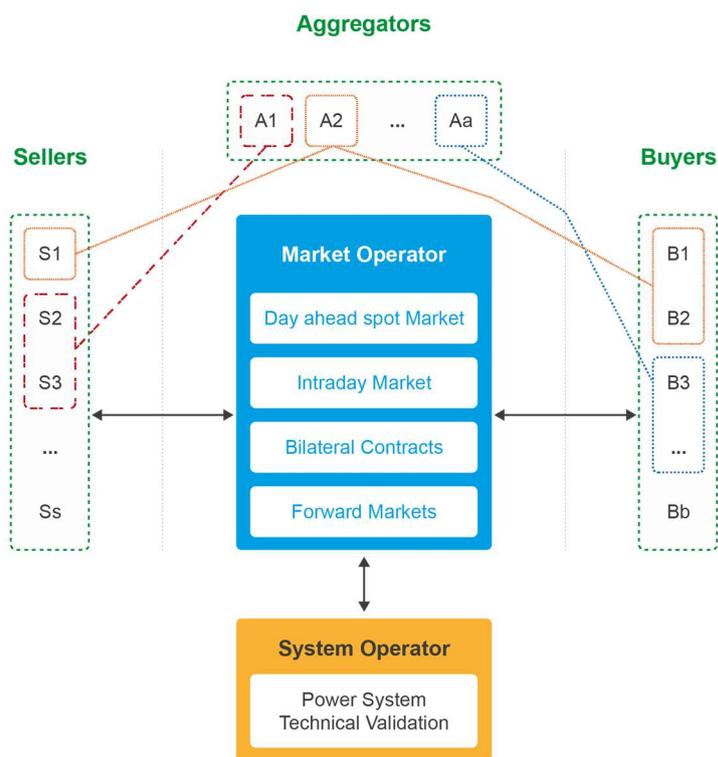


Figura 8 - Agentes em MASCEM, (Santos, 2015)

Como se pode verificar pela Figura 8, o MASCEM inclui os seguintes agentes:

- Facilitador de mercado, este agente coordena e tem conhecimento de todos os agentes, atendendo às regras de mercado. A entrada de um novo agente no mercado terá de ser comunicada ao facilitador dando a indicação da atividade que irá ter no mercado.
- Vendedor ou comprador representam os agentes produtores/vendedores ou consumidores. No MASCEM podem adotar comportamentos específicos ou optar por determinada estratégia.
- Operador de mercado, determina o preço de mercado nos mercados com base nos modelos em bolsa e mistos.
- Operador de sistema, no MASCEM este agente tem como função estabelecer a ligação com outro simulador a fim de viabilizar o trânsito de potências no sistema elétrico,
- *Virtual Power Players* (VPPs), são agentes que representam a junção de vendedores e/ou compradores, assim podem existir VPPs vendedores, compradores ou mistos. A sua participação no mercado é encarada como se tratasse de uma entidade individual. Este mecanismo permite, por exemplo, a um vendedor que detenha uma pequena quantidade

de energia e não consiga vendê-la juntar-se a outros na mesma situação e, como a quantidade de energia de todos juntos é maior a venda já se torna possível.

- Facilitadores dos VPPs, fazendo a analogia com o facilitador de mercado, estes controlam a informação da agregação e o comportamento dos VPPs, têm também o dever de informar o facilitador de mercado sobre a integração com outros agentes.

2.5.1.2. ADAPTIVE DECISION SUPPORT FOR ELECTRICITY MARKETS (AiD-EM)

O sistema AiD-EM foi incorporado no MASCEM com o intuito de apoiar a tomada de decisão dos intervenientes no mercado de energia elétrica na realização de negociações (Pinto et al., 2015a). Este sistema é composto por vários sistemas que têm como função dar apoio à decisão. O *Adaptive Learning Strategic Bidding System* (ALBidS) (Pinto et al., 2014a) faz parte do sistema AiD-EM e direciona-se para os agentes que participam no mercado de energia elétrica. Concretamente, pretende dar apoio à elaboração de licitações que tragam uma boa oportunidade de ganhos nos mercados a leilões, como é o caso do mercado *Day-Ahead* e nos mercados de ajustes da maioria dos mercados europeus de energia. No ALBidS também foi implementado um sistema de eficiência/eficácia (2E) (Pinto et al., 2014a) que permite fazer um balanço entre o tempo de execução e o resultado obtido na simulação. O RealScen (Teixeira et al., 2014) é um simulador utilizado para a criação de cenários realistas com base em dados extraídos geralmente de sites de operadores de mercado. Ao combinar os dados extraídos com os dados resultantes das simulações possibilita a geração de cenários para diferentes tipos de mercados de eletricidade. Como se pode observar na Figura 9, existem ainda outros sistemas que incorporam o AiD-EM como é o caso do *Bilateral Contracts*, considerado o processo central de qualquer mercado de eletricidade em todo o mundo. Os contratos *forward* e futuros são usualmente adaptados para fazer as negociações de energia que podem ter diferentes horizontes temporais. Neste caso o apoio à decisão é feito por um sistema multiagente dividido em duas componentes: o apoio à decisão na fase de pré-negociação e o apoio à negociação propriamente dita. O AiD-EM *Manager* é mais uma componente do sistema AiD-EM que está equipado com três módulos diferentes: a otimização de portfólios, que consiste na alocação da eletricidade nos diferentes tipos de mercados atendendo aos preços de mercado e aos diferentes tipos de contexto (Pinto et al., 2014b), o AiD-EM *2E Management* é um módulo que possibilita ao utilizador definir um tempo de execução mais rápido, o que se reflete numa degradação dos

resultados e, por fim o módulo *Resource Distribution*, que permite otimizar os recursos computacionais distribuindo os agentes e módulos computacionais pelas máquinas disponíveis.

Na Figura 9 é apresentado um esquema onde está presente todo o sistema AiD-EM.

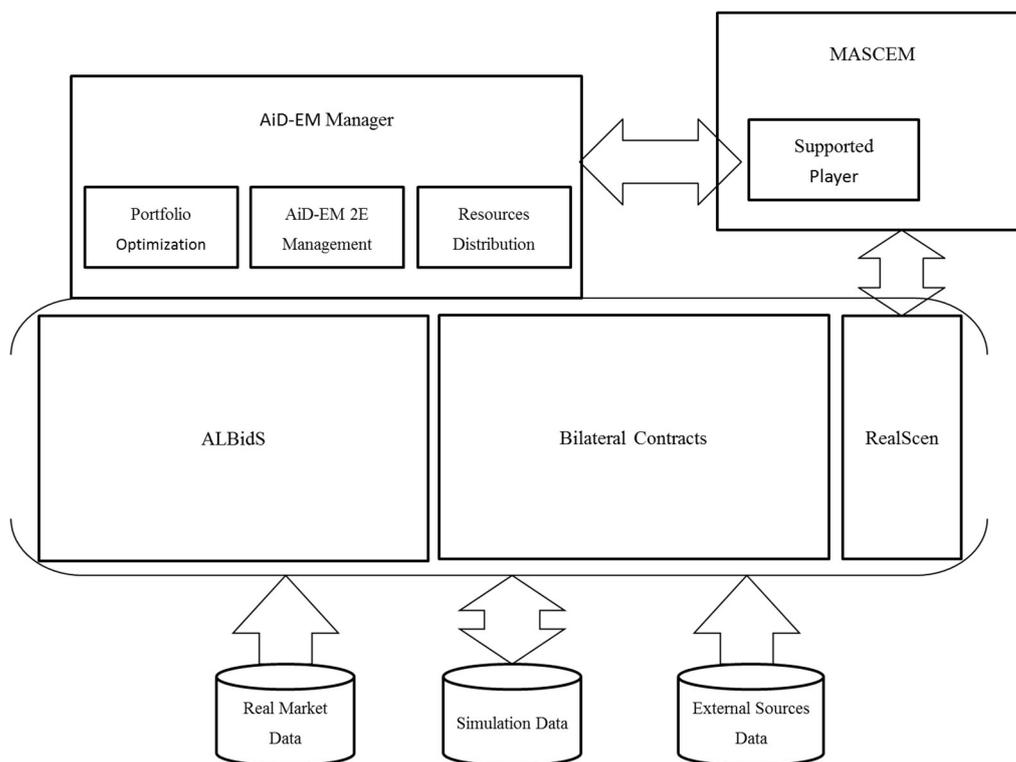


Figura 9 - Esquema de funcionamento do sistema AiD-EM, adaptado de (Pinto et al., 2015a)

O processamento de cada máquina pode condicionar aquilo que pode ser executado em cada uma. Para além disso, pode constatar-se que o modelo tem acesso a dados reais de mercado, dados provindos de simulações passadas e correntes e a dados de fontes externas que possam influenciar nas negociações de energia, por exemplo: condições climáticas, velocidade do vento, intensidade solar, temperatura, preços das matérias-primas, entre outros. As decisões são apresentadas não só com a participação num único mercado, mas sim um misto de negociações entre os diversos tipos de mercados. O tema principal de estudo desta dissertação centra-se na otimização de portfólios, referido num módulo supracitado.

2.6. TEORIA DAS CARTEIRAS

Em qualquer atividade económica existe uma relação entre o risco e o retorno. O correto conhecimento desta relação é fundamental para a atuação comercial num ambiente competitivo. Torna-se necessário ter grande conhecimento do investimento no qual se está envolvido, pois um conhecimento mínimo dos riscos faz com que o investimento seja inviável e inapropriado. Cada mercado apresenta características diferentes, exigindo conhecimento específico para a identificação de fatores de risco.

As ferramentas de simulação abordadas anteriormente vieram proporcionar aos investidores uma grande ajuda na participação nos mercados elétricos de energia, pois a maior parte das decisões, sobretudo as mais importantes, são tomadas com base em algum tipo de conhecimento. Este conhecimento, proveniente das ferramentas de apoio à decisão, é gerado com base em dados previstos, que por si só já originam incerteza na solução dos problemas de otimização que servem de suporte à tomada de decisões. A incerteza das previsões é um facto que pode originar prejuízos significativos, visto que correspondem, eventualmente, a uma redução de lucro.

A teoria moderna de gestão de portfólios “*Modern Portfolio Theory*” foi publicada em 1952 por Harry Markowitz num artigo no *Journal of Finance* (Markowitz, 1952), tendo sido, posteriormente, desenvolvida no livro *Portfolio Selection: Efficient Deversification of Investments* em 1959. Esta publicação garantiu a *Harry Markowitz* a atribuição do prémio nobel em ciências da economia no ano de 1990.

A teoria apresentada é conhecida como o método da média-variância, que permite a obtenção de investimentos de variância mínima para cada nível de retorno esperado. O modelo, inicialmente foi proposto para modelar investimentos no mercado financeiro onde se considerava que os investidores deviam ter em linha de conta o retorno esperado como um fator favorável e a variância dos retornos como um fator desfavorável.

O modelo proposto considera a média dos retornos obtidos ao longo do tempo, que é obtido pelo valor esperado (média) resultante da análise do histórico disponível. O retorno esperado de cada investimento corresponde à multiplicação do investimento a realizar pelo valor esperado correspondente. A avaliação do risco é dada pela variância do portfólio, a qual

mede a variância do retorno esperado. Quando se adicionam investimentos aos projetos, não só contribuem para o retorno esperado, mas também interferem no cálculo do risco total do projeto (Liu and Wu, 2007).

Markowitz concluiu que um dos principais objetivos dos investidores, além da maximização dos lucros das suas carteiras, é a diversificação dos investimentos tanto quanto possível, de forma a minimizar o risco. Constatou também que os investidores selecionam os ativos criteriosamente, ao ponto do risco da carteira corresponder às suas preferências do mesmo. Isto significa que os investidores que têm aversão ao risco investem em ativos de baixo risco e os investidores mais confortáveis com o risco tendem, mais facilmente, a realizar investimentos em ativos de maior risco.

No trabalho desenvolvido por Markowitz (Markowitz, 1952) é mostrada a representação gráfica dos resultados através de um gráfico chamado de Fronteira Eficiente, ou frente de *Pareto*. Normalmente este gráfico é utilizado para representar dois ou mais objetivos. Este caso em concreto representa dois objetivos. Sendo que o eixo das ordenadas corresponde ao valor esperado (lucro) e o eixo das abscissas ao valor do desvio padrão dos resultados (risco).

Na Figura 10 está presente uma representação de uma frente de *Pareto*, onde pode ser observado estão presente dois objetivos, no eixo vertical (yy) está presente o retorno e no eixo horizontal (xx) está presente o risco, como se pode verificar o exemplo apresentado não possui unidades é simplesmente um exemplo para explicar o comportamento das variáveis (retorno vs risco).

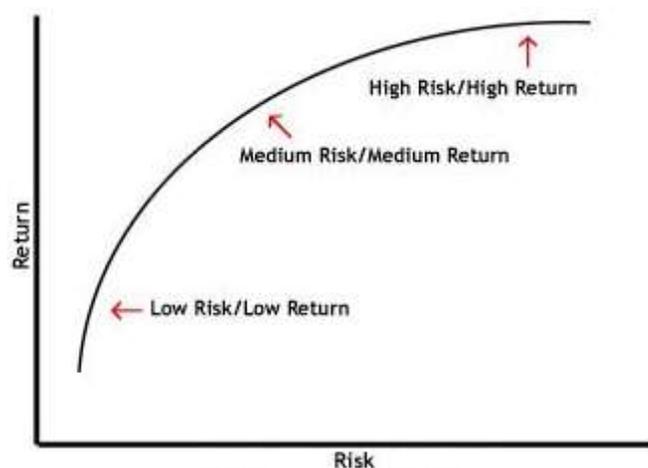


Figura 10 – Frente de *Pareto* adaptado de (FinancialEdge.net, 2016).

Como se pode observar na Figura 10, à medida que o risco aumenta o retorno aumenta também, na representação gráfica é possível constatar que no final um aumento do nível do risco não significa maior retorno, pois o retorno tende a estabilizar no final.

2.6.1. RISCO

O risco apresenta diversas formas de ser explicado, variando com o contexto onde está inserido. Segundo o dicionário (Infopédia, 2016), o risco é a possibilidade de o perigo se materializar, é algo que é incerto mas previsível.

Fazendo a analogia entre os mercados financeiros e os mercados de eletricidade é possível traçar evidências ao nível dos riscos existentes. Em seguida, são apresentados quatro tipos diferentes de riscos dos mercados financeiros, mas que também se podem identificar nos mercados de eletricidade (Morgan, 1996).

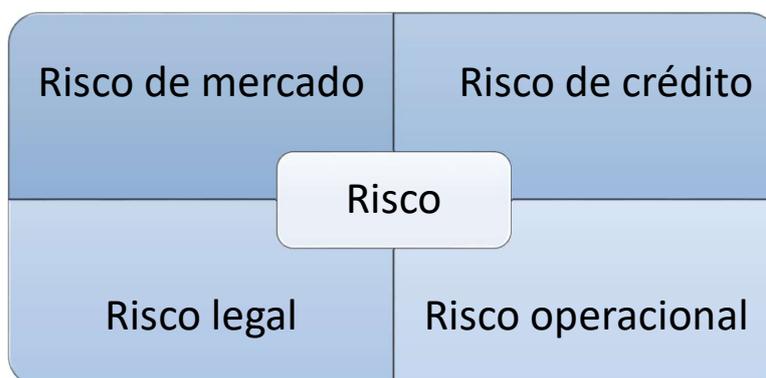


Figura 11 - Diferentes tipos de risco, adaptado de (Bittencourt, 2011).

Na Figura 11 estão apresentados quatro tipos de riscos associados a resultados futuros dos investimentos. Contudo, podem ainda existir mais fatores que levam a diferentes riscos; no entanto no âmbito deste trabalho são abordados apenas os expressos na Figura 11.

- Risco de mercado, este risco está diretamente associado ao comportamento do preço do ativo. Uma forma de compreender e tentar evitar perdas, ocorridas pelas flutuações dos preços dos ativos, é identificar e quantificar as volatilidades e correlações dos fatores que alteram a dinâmica do preço do ativo.
- Risco de crédito traduz-se em perdas quando uma das partes contratantes não honra os seus compromissos.

- Rico legal, este risco pode refletir perdas quando um contrato não pode ser legalmente sustentado, o que pode acontecer por documentação insuficiente, ilegalidades, insolvência, entre outros.
- Risco operacional está relacionado com possíveis ocorrências de perdas por resultado do sistema, falhas de gestão humana e erros humanos.

As explicações dadas para os riscos apresentados têm um carácter financeiro, mas podem muito bem ser identificados nos mercados de electricidade. Como é o caso dos riscos de mercado onde o preço da electricidade nunca é constante ao longo do dia e torna-se difícil prever, embora as técnicas de previsão existentes consigam fazer previsões com uma margem mínima de erro. Os riscos legais também se poderão registar, no entanto estes são muito esporádicos. Os riscos operacionais também ocorrem, como é o caso do congestionamento das linhas de electricidade.

2.6.2. APLICAÇÃO DA TEORIA DE PORTFÓLIOS NOS MERCADOS DE ENERGIA

Têm sido apresentados muitos trabalhos que utilizam a teoria dos portfólios para fazer o planeamento dos investimentos no setor elétrico, sendo que o modelo de Markowitz está presente em muitos deles.

Os autores Bar-Lev e Katz (Bar-Lev and Katz, 1976), foram os pioneiros na aplicação da teoria dos portfólios em investimentos de energia eléctrica. No trabalho intitulado “*A portfolio approach to Fossil Fuel Procurement in the Electric Utility Industry*”, é analisada a aquisição de combustíveis fósseis pela indústria de energia americana. Com este estudo, os autores determinaram a forma de utilizar os recursos energéticos eficientemente.

Em (Yu, 2003) o autor apresenta um trabalho que vai de encontro ao tema estudado nesta dissertação. É apresentado um modelo de gestão de risco a curto prazo, através da aplicação do modelo de Markowitz para otimizar o portfólio e minimizar o risco em mercados de energia eléctrica. Com este estudo, o autor pretende dar suporte à decisão em termos de gestão de risco e de preço.

A teoria dos portfólios é também aplicada em (Krey and Zweifel, 2006), onde são determinadas as combinações eficientes de fontes de geração de electricidade para os EUA e

para a Suíça. Os resultados dão indicação das melhores formas de combinar as fontes de geração dos países referidos. Neste trabalho é traçada a fronteira eficiente, onde está representado o valor mínimo de risco para diversos níveis de restrições e de retorno.

No trabalho apresentado por (Awerbuch, 2004), é feito um estudo para combinar eficientemente as fontes de energia presente no México. O autor sugere que o investimento em energia eólica deve levar a maiores retornos sem aumentar o nível de risco. O mesmo autor, em “*Applying Portfolio Theory to EU Electricity Planning and Policy-Making*” (Awerbuch and Berger, 2003) faz uso da teoria de Markowitz para resolver o problema das combinações de fontes de geração de energia elétrica disponíveis na UE. Nos trabalhos apresentados, os autores concluem que os portfólios ótimos devem alocar maiores investimentos em energia eólica e outras fontes renováveis para se tornarem eficientes. Isto ocorre porque são tecnologias de custo fixo e não estão sujeitas às variações do preço dos combustíveis.

No trabalho intitulado de “Gestão do Risco em Mercados Competitivos de Eletricidade: Previsão de Preços e Otimização do Portfolio de Contratos” (Azevedo, 2007), o autor apresenta uma metodologia de gestão de portfólios para participação nos mercados de energia elétrica. No modelo proposto, é possível a participação em mercados de curto prazo e também existe a possibilidade de efetuar contratos de longo prazo. Para que a otimização possa ser feita, o autor desenvolveu métodos de previsão de preços e de carga para os diferentes horizontes temporais. Ambos os métodos utilizam os dados históricos como base das previsões. A gestão do risco é feita atendendo à variação de preços resultante dos métodos de previsão, ao qual é associado um nível de confiança. Para resolver o problema de otimização é utilizado o PSO que é comparado com o AG. No final, são descritas as conclusões acerca do trabalho realizado, onde se pode encontrar a seguinte frase: “Tal como era de esperar, é possível verificar que quanto maior for o resultado esperado maior é o risco associado, ou seja, maior é o desvio padrão do resultado”. Esta afirmação vai de encontro à teoria de Markowitz.

Na publicação (Chang et al., 2009) à semelhança de (Azevedo, 2007), o problema de otimização é resolvido por técnicas de IA, neste caso é proposta a utilização do AG. Neste trabalho o autor apresenta uma otimização de portfólios utilizando diferentes medidas de

risco e no final faz uma comparação entre elas. As medidas de risco propostas derivam todas do modelo da média variância proposta por Markowitz, sendo elas: a semi-variância, a derivação média absoluta e a variância com assimetria. No final são apresentados os resultados através da fronteira eficiente para cada modelo e para diferentes combinações de ativos. O autor conclui que o AG é um método robusto e efetivo na resolução do problema de otimização de portfólios.

Em (Pinto et al., 2014b), é apresentada uma metodologia para participação em mercados de energia elétrica para o dia seguinte, onde para a resolução da otimização do portfólio também é utilizada uma técnica de IA, o PSO. Inicialmente é feita uma exposição sobre a importância das técnicas de apoio à decisão nos mercados de eletricidade, seguindo-se uma breve descrição do sistema de apoio à decisão, no qual a otimização de portfólios está inserida. A previsão dos preços a utilizar na otimização é realizada através de uma Rede Neuronal Artificial (RNA), a qual é repetida várias vezes para o mesmo período. Depois de realizadas sucessivas previsões, é registado o valor máximo e mínimo previsto, assim como é feita a média do conjunto das previsões para o mesmo período. Para a gestão do risco, o autor pondera os três valores registados e realiza três diferentes otimizações para cada período, considerando que o máximo valor previsto corresponde ao nível maior de risco, o mínimo risco é representado pelo valor mínimo previsto e o valor médio previsto corresponde ao risco médio. No exemplo prático apresentado, o *player* de mercado pode vender a sua eletricidade em cinco diferentes mercados e comprar em apenas um. Um aspeto importante, é a questão da estimação do preço da eletricidade em determinados mercados, que é feita através da técnica de lógica *fuzzy*. Assim, o modelo de otimização é sensível à quantidade negociada. O preço da energia deixa de ser constante e passa a ser variável com a quantidade de energia transacionada. O autor conclui que a metodologia proposta está habilitada para fornecer apoio na participação dos mercados de energia, e o PSO também se mostrou eficiente na resolução do problema de otimização.

Os trabalhos citados, bem como outros (Oliveira et al., 2011; Suksonghong et al., 2014) têm por objetivo fornecer resultados para auxiliar a contratação de energia de uma forma eficiente, tendo em conta os ambientes de mercados impostos pelo utilizador. Todos os trabalhos expostos recorrem a técnicas de otimização para fornecer os resultados. Como se

pode ver, nos trabalhos mais recentes é frequente o uso das técnicas de IA, não só para a resolução do problema de otimização, mas também para outros fins.

No que diz respeito ao tema da dissertação, os trabalhos (Azevedo, 2007; Chang et al., 2009; Pinto et al., 2014b) apresentam pontos importantes que são tidos em conta na abordagem do estudo desenvolvido nesta dissertação, como é o caso da otimização de portfólios, a gestão do risco e utilização de técnicas de IA na abordagem ao problema.

2.7. SUMÁRIO

Neste capítulo foram abordados os dois temas principais desta dissertação: os mercados de energia e a aplicação da teoria das carteiras aos mesmos. Inicialmente foi apresentada uma breve descrição sobre as alterações que os mercados de eletricidade têm sofrido ao longo dos anos, as quais permitiram a passagem do regime monopolista para o regime liberalizado.

São identificados e caracterizados, o funcionamento do modelo de mercado em bolsa (*Day-Ahead*), do mercado intradiário e dos contratos bilaterais, e foi descrita a forma como é realizada a comercialização da eletricidade em cada um deles. É também dada importância à SG e ao tipo de mercado que poderá surgir a partir destas.

Neste capítulo referenciou-se também a importância dos projetos de unificação do Mercado Europeu de eletricidade. Fez-se uma explanação e explicação sobre as iniciativas MCR, PCR e *Italian Borders Market Coupling* que demonstram que é possível a construção de um único mercado europeu de eletricidade.

Apresentaram-se ainda os sistemas multiagente, utilizados nos sistemas elétricos, enunciaram-se vários simuladores de mercado tendo sido apresentada uma explicação mais pormenorizada sobre o simulador MASCEM, por ser utilizado no âmbito deste trabalho.

Foi igualmente feito um levantamento do estado da arte sobre as teorias das carteiras e a sua aplicabilidade nos mercados de energia. Foi também feito um estudo sobre o conceito de risco, tentado transpor o mesmo para os mercados de eletricidade. Por último, fez-se uma descrição do trabalho existente nesta área, sendo enumeradas as principais referências para o desenvolvimento desta dissertação.

Pode ser concluído que a otimização de portfólio é um problema amplamente estudado (Markowitz, 1952) no entanto as abordagens existentes apresentam uma natureza essencialmente económica. Abordagens para a resolução deste problema na perspetiva das transações de energia são quase inexistentes. As existentes (Conejo et al., 2010; Liu and Wu, 2007) fazem suposições limitativas, como a influência do risco nos resultados deste problema (Vercher and Bermúdez, 2015). Características que fazem dos mercados de energia ambientes tão complexos e dinâmicos são também marginalizadas, tais como a possibilidade de compra e venda de energia em diferentes mercados no mesmo período, a influência dos erros de previsão no cálculo do risco de participação, a adaptação aos eventos mais recentes (informação em tempo real), a adaptação a diferentes cenários de mercado e horizontes de otimização, e a dependência dos preços nas quantidades negociadas. Estas limitações fazem com que as soluções atuais não sejam utilizáveis em ambiente real de mercado de energia elétrica, e tornam, portanto, essencial o desenvolvimento do presente trabalho.

3. METODOLOGIA PROPOSTA

Neste capítulo é apresentada a metodologia utilizada na elaboração da dissertação e explicada a formulação matemática proposta neste trabalho. Na Figura 12 está exposta a metodologia proposta e usada na dissertação.

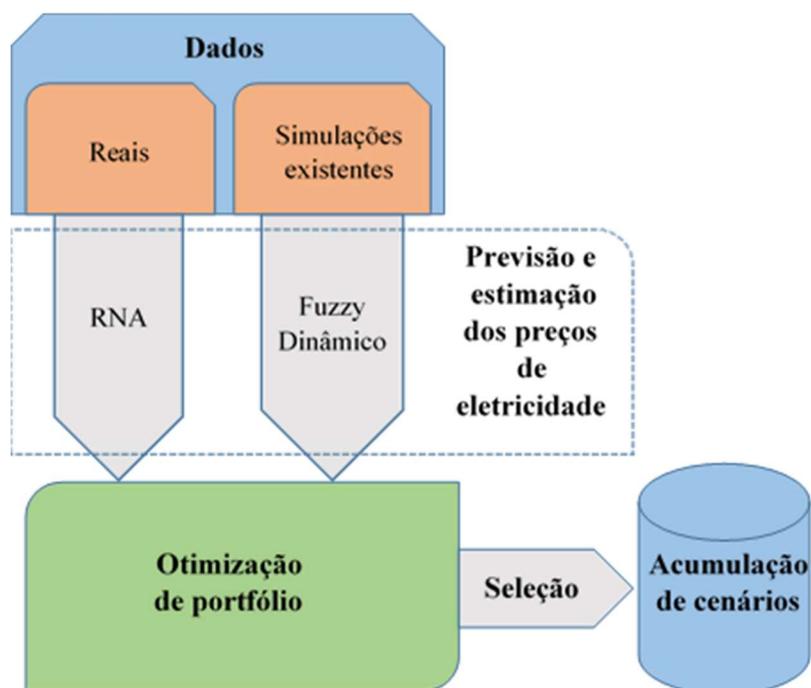


Figura 12 – Visão geral da metodologia Proposta

Inicialmente, como é possível observar na Figura 12, é feita a recolha de dados, que neste caso são dados reais provenientes dos mercados de eletricidade em operação, e os dados oriundos de simulações anteriores. De seguida, é feita a previsão e estimação dos preços de eletricidade através de duas metodologias distintas: a utilização de RNA para previsão de preços, e a metodologia *Fuzzy* dinâmico, proposta em (Faia et al., 2016a) para a estimação dos preços, onde são utilizados dados reais e é feita a interligação com MASCEM e AID-EM. Após serem obtidos os preços esperados de transação em cada sessão de mercado, é realizada a otimização do portfólio, que consiste em encontrar um conjunto de ações que tornem a participação no mercado o mais vantajoso quanto possível, sendo que estas ações compreendem a venda e a compra de eletricidade, podendo até comprar e vender eletricidade dentro do mesmo mercado e período. As características imposta ao problema, como por exemplo, a possibilidade de adaptação do preço à quantidade otimizada, levam a que o problema seja considerado não linear e que seja difícil de formular para uma resolução com métodos exatos. Desta forma os métodos de otimização necessários para resolver o problema são descritos ao longo do presente capítulo. De seguida, é feita a seleção dos portfólios aceites para fazerem parte da base de dados, neste caso são aceites todos os portfólios que cumprirem a condição da equação (3.1).

$$\begin{cases} \text{if } F_{\text{objectivo}} \geq F_{\text{objectivo}}^{\text{médio}} & \in BD \\ \text{if } F_{\text{objectivo}} < F_{\text{objectivo}}^{\text{médio}} & \notin BD \end{cases} \quad (3.1)$$

Onde:

- $F_{\text{objectivo}}$ representa o valor da função objetivo;
- $F_{\text{objectivo}}^{\text{médio}}$ representa o valor médio da função objetivo;
- BD representa a base de dados.

A equação (3.1) demonstra que só pertencem à base de dados as simulações que têm o valor da função objetivo maior ou igual à média de todos os valores da função objetivo registados. As simulações contidas na base de dados serão utilizadas para apoio à decisão dos utilizadores de mercado.

Deste modo, o capítulo apresenta-se dividido em quatro subcapítulos. No subcapítulo inicial é apresentada a formulação do problema e no seguinte são expostos os métodos de

otimização utilizados para a resolução do problema. Estes dois subcapítulos em analogia com a Figura 12 pertencem à metodologia de otimização de portfólios. No subcapítulo 3.4 é também apresentado um método heurístico para calcular a solução inicial utilizada por vários dos métodos de otimização considerados neste trabalho. Os métodos de previsão e estimativa dos preços de eletricidade fazem parte da etapa de previsão e estimação dos preços, como pode ser visto na Figura 12. Os métodos de previsão utilizando RNA e de estimativa de preços baseado na metodologia *Fuzzy* dinâmico são descritos nos subcapítulos 3.5 e 3.6, respetivamente.

3.1. MAXIMIZAÇÃO DO LUCRO

A formulação proposta para o problema tem como principal referência (Pinto et al., 2014b), embora o trabalho (Chang et al., 2009) também tenha sido importante na criação da formulação. Todos os outros trabalhos citados no subcapítulo 2.6.2 foram também relevantes, mas de forma menos significativa.

Pela equação (3.2), $f1$, podemos obter o retorno do portfólio. Esta equação teve origem no trabalho de (Pinto et al., 2014b), embora aqui tivesse sido apresentada a parte dos custos de produção, que poderão ser fixos ou variarem com a produção correspondente de cada produtor.

$$f1(Spow_{M...NumM}, Bpow_{M...NumM}) = \left[\begin{array}{l} \sum_{M=M1}^{NumM} (Spow_{M,d,p} \times pS_{M,d,p} \times Asell_M) - \\ \sum_{M=M1}^{NumM} (Bpow_{M,d,p} \times pB_{M,d,p} \times Abuy_M) - \\ \sum Cost_{d,p}^{TEP} \end{array} \right] \quad (3.2)$$

Onde:

- $Asell_M$ e $Abuy_M$ dão a indicação se o *player* pode participar no mercado M , e são variáveis binárias;
- $Spow_M$ representa a quantidade de eletricidade vendida no mercado M ;
- $Bpow_M$ representa a quantidade de eletricidade comprada no mercado M ;
- $NumM$ representa o número de mercados;
- $Cost$ representa a função dos custos de produção;

- TEP representa o total de energia produzida.

Na equação (3.2), a primeira parcela corresponde ao valor em euros obtido da venda de eletricidade e na segunda parcela é obtido o valor em euros da compra de eletricidade. As variáveis $Spow_{M,d,p}$ e $Bpow_{M,d,p}$ representam a quantidade de venda e de compra de eletricidade em MW, sendo estas as variáveis a ser otimizadas.

Considerações:

$$\forall d \in Nday, \forall p \in Nper, Asell_M \in \{0,1\}, Abuy_M \in \{0,1\}, \lambda \in \{0,1\} \quad (3.3)$$

$$pS_{M,d,p} = \begin{cases} Forecast_{M,d,p}^{ANN} & \text{if } M \notin \text{bilateral contacts} \\ Value(d,p,Spow_M,M) & \text{if } M \in \text{bilateral contacts} \end{cases} \quad (3.4)$$

$$pB_{M,d,p} = \begin{cases} Forecast_{M,d,p}^{ANN} & \text{if } M \notin \text{bilateral contacts} \\ Value(d,p,Bpow_M,M) & \text{if } M \in \text{bilateral contacts} \end{cases} \quad (3.5)$$

$$TEP = \sum Energy_{prod} \quad (3.6)$$

$$Energy_{prod} \in \{Renew_{prod}, Therm_{prod}\} \quad (3.7)$$

$$Cost_{d,p}^{TEP} = a \times Therm_{prod}^2 + b \times Therm_{prod} + c \quad (3.8)$$

Onde:

- $Forecast_{M,d,p}^{ANN}$ representa o valor de preço previsto pela ANN para o mercado M , dia d , e período p ;
- $Value(d,p,Spow_M,M)$, $Value(d,p,Bpow_M,M)$, representa o valor do preço para uma determinada quantidade de eletricidade nos mercados onde o preço é variável;
- $Energy_{prod}$ representa a quantidade de energia produzida pelo *player*;
- $Renew_{prod}$ representa a quantidade de energia renovável produzida;
- $Therm_{prod}$ representa a quantidade de energia termoelétrica produzida;
- a , b e c representam os coeficientes do custo marginal.

Segundo a equação (3.3), o utilizador terá de definir o número de dias e o número de períodos para os quais pretende que a otimização seja realizada. Como já foi supramencionado é imposta a condição de participação ao *player* nos mercados com a utilização de variáveis binárias. Na equação (3.4) e (3.5), a parcela $Value(d,p,Spow_M,M)$ é obtida através de uma

metodologia cuja explicação é feita no subcapítulo 3.6, onde é demonstrada a forma como se estima o preço esperado da eletricidade, caso o *player* decida participar nos mercados onde o preço varia com a quantidade negociada. Neste estudo, estes mercados são designados de contratos bilaterais. O valor do erro a considerar para o cálculo do risco varia mediante o mercado, sendo que em alguns mercados o erro seja o erro de treino da RNA e em outros o erro associado à estimação do preço. As equações (3.6), (3.7) e (3.8) representam as condições que são impostas pelo utilizador.

Restrições:

$$\sum_{M=M1}^{NumM} Spow_M \leq TEP + \sum_{M=M1}^{NumM} Bpow_M \quad (3.9)$$

$$0 \leq Renew_{prod} \leq Max_{prod} \quad (3.10)$$

$$Min_{prod} \leq Therm_{prod} \leq Max_{prod}, \text{ if } Therm_{prod} > 0 \quad (3.11)$$

$$0 \leq TEP \leq TEP_{max} \quad (3.12)$$

A equação (3.9) representa a principal condição imposta, a qual exige que o total de energia vendida tenha de ser menor ou igual ao total de energia produzida pelo *player* somada ao total de energia comprada. Caso o *player* seja um produtor de energia termoelétrica terá de fixar a sua produção num mínimo, pois não é viável desligar completamente a central de produção. A representação dessa condição está presente na equação (3.11). Caso seja produtor de energia renovável, a única restrição é a capacidade máxima de produção, como é possível inferir a partir da equação (3.10).

3.2. FORMULAÇÃO MULTIOBJETIVO

A equação (3.14) representa a função objetivo do problema de otimização multiobjetivo que é resolvido no âmbito desta dissertação, mas optou-se por transformar a equação (3.13) na equação (3.14) para facilitar a resolução do problema.

$$\begin{cases} \text{Maximizar } (f1(Spow_{M...NumM}, Bpow_{M...NumM})) \\ \text{Minimizar } (f2(Risk_{d,p})) \end{cases} \quad (3.13)$$

$$Max \left[\lambda \times (f1(Spow_{M...NumM}, Bpow_{M...NumM})) - (1 - \lambda) \times (f2(Risk_{d,p})) \right] \quad (3.14)$$

Onde:

- λ representa o nível de exposição ao risco $\in [0; 1]$;
- $Risk_{d,p}$ representa o valor do risco no período p e dia d .

Pela análise da equação (3.14), é possível constatar a existência de duas funções $f1$ e $f2$, estas correspondem ao retorno e ao risco respetivamente. Neste problema, como já foi explicado, existem dois objetivos que são: a maximização do lucro e a minimização do risco, e podem dar origem a duas funções objetivo que dependem uma da outra. Deste modo, e como é proposto em (Chang et al., 2009) optou-se por construir uma só função objetivo (3.14) com o parâmetro λ , que é imposto pelo utilizador. Quando o parâmetro λ é igual a 1 o modelo maximiza o retorno e o risco é máximo, à medida que λ vai diminuindo o risco diminui e o retorno do portfólio diminui também. Na equação (3.15) é apresentada a formulação do cálculo do risco.

$$f2(Risk_{d,p}) = \left[\begin{array}{l} \sum_{M=M1}^{NumM} (Spow_{M,d,p} \times pS_{M,d,p} \times error_{M,d,p}) + \\ \sum_{M=M1}^{NumM} (Bpow_M \times pB_{M,d,p} \times error_{M,d,p}) \end{array} \right] \quad (3.15)$$

Onde

- $error_{M,d,p}$ representa o erro no mercado M , dia d e período p .

A equação (3.15) é utilizada para fazer o cálculo do risco no processo de otimização. Este está associado ao erro de previsão e estimação do preço da eletricidade. A alocação dos recursos (compra ou venda de eletricidade) fica condicionada pelo erro que se registou aquando da previsão ou estimação do preço. Para cada mercado existe um erro diferente. Com este modelo, a alocação dos recursos tende a ir para os mercados onde o erro é menor, isto em condições normais. Quando o utilizador impõe uma simulação com alto risco, o erro nos mercados deixa de pesar na otimização.

Considerações:

$$error_{M,d,p} = \begin{cases} ANN_{M,d,p}^{error} & \text{if } M \notin \text{bilateral contacts} \\ Fuzzy_{M,d,p}^{error} & \text{if } M \in \text{bilateral contacts} \end{cases} \quad (3.16)$$

Onde:

- $ANN_{M,d,p}^{error}$ representa o erro de treino da ANN para o mercado M , dia d , e período p ;
- $Fuzzy_{M,d,p}^{error}$ representa o erro da estimação do preços para os mercados onde o preço é variável;

3.3. MÉTODOS DE OTIMIZAÇÃO

Neste subcapítulo são abordados os métodos de otimização utilizados para resolver o problema apresentado. Inicialmente é proposta uma resolução por um método determinístico e depois são aplicados os algoritmos de pesquisa inteligente. O tempo de pesquisa nestes algoritmos de IA é muito menor do que o tempo de execução de um método exato, e por vezes a diferença na solução final não é relevante. Este estudo tem como principal foco o apoio à decisão, deste modo é importante obter resultados num curto espaço de tempo para que o utilizador possa analisar e tomar a melhor decisão que lhe permita retirar o máximo de proveito.

3.3.1. MÉTODO DETERMINÍSTICO

Os métodos determinísticos são muito úteis, pois podem fornecer uma boa referência para a comparação da qualidade da solução, ainda que o tempo de execução não seja aceitável para este tipo de problemas onde é essencial uma resposta num curto espaço de tempo.

PROGRAMAÇÃO INTEIRA MISTA NÃO LINEAR

Mixed integer nonlinear programming (MINLP) é uma classe de problemas de otimização que se caracteriza por restrições e função objetivo não-lineares, enquanto as variáveis são contínuas e discretas. No entanto, a função objetivo pode ser linear e o problema ser classificado como um MINLP caso as condições restantes se verificarem. O problema também é classificado como não-convexo devido às suas características não lineares e variáveis discretas (Lin et al., 2012). Em MINLP existem vários *solvers* disponíveis para resolver este tipo de problemas, por exemplo, AlphaECP, Baron, DICOPT, KNITRO, LINDOGlobal, MINLP e SBB. Normalmente, os *solvers* convergem melhor quando as primeiras derivadas são fornecidas, mas não existe a garantia de encontrar um ótimo global nos problemas MINLP e, em geral, são muito difíceis de resolver.

PROGRAMAÇÃO INTEIRA MISTA LINEAR

Mixed integer linear programming (MILP) é um tipo de problemas de otimização que se caracteriza por restrições lineares e função objetivo linear enquanto as variáveis são contínuas e discretas. O problema é não-convexo, mas é normalmente resolvido como uma aproximação convexa (Boyd and Vandenberghe, 2004). Há muitos *solvers* maduros no mercado para este tipo de problema, ou seja, CPLEX, Gurobi, MINTO, MOSEK, XpressMP. Problemas do tipo MILP são geralmente muito mais fáceis de resolver do que MINLP, mas mesmo com o *hardware* disponível esses programas podem exigir horas ou dias para obter um resultado, e no entanto não garantem uma solução ótima (Klotz and Newman, 2013).

3.3.2. PSO

O *Particle Swarm Optimization* (PSO) é um algoritmo de pesquisa que é utilizado para resolver problemas de otimização. Este algoritmo foi introduzido por Kennedy e Eberhart em 1995 (Kennedy and Eberhart, 1995) e tem como inspiração o movimento coletivo dos bandos de pássaros e dos cardumes de peixes. No PSO *standard* o algoritmo é iniciado com uma solução inicial para cada partícula que representa diferentes soluções para o problema. Durante o processo de otimização, as partículas procuram uma nova solução de acordo com uma regra que direciona o seu movimento no espaço, equação (3.17) e (3.18).

$$v_i^{k+1} = w \cdot v_i^k + c_1 \cdot r_1^k \cdot (Pbest_i^k - x_i^k) + c_2 \cdot r_2^k \cdot (Gbest_i^k - x_i^k) \quad (3.17)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1} \quad (3.18)$$

Onde:

- k - iteração;
- i - partícula;
- v_i^k - representa a velocidade da partícula i na iteração k ;
- v_i^{k+1} - representa a velocidade da partícula i na iteração $k+1$;
- x_i^k - representa a posição da partícula i na iteração k ;
- x_i^{k+1} - representa a posição da partícula i na iteração $k+1$;
- $Pbest$ - melhor solução pessoal;
- $Gbest$ - melhor solução global;

- w – inércia;
- c_1 – termo de atração local;
- c_2 – termo de atração global;
- r_1, r_2 – números aleatórios, $\in [0,1]$.

Na Figura 13, está representado o método de funcionamento do PSO. Como se pode observar, inicia-se com a distribuição das partículas aleatoriamente no espaço de pesquisa, e é dado um valor aleatório à componente da velocidade. Em seguida, o algoritmo entra no do ciclo que só termina quando o critério de paragem for atingido. Dentro deste ciclo é executado outro ciclo que faz com que cada partícula realize a sua pesquisa, sendo calculada a nova posição através da equação (3.18) após ter sido atualizada a velocidade pela equação (3.17). O cálculo da função objetivo é uma característica do problema em questão. Todas as partículas são avaliadas e caso obtenham uma melhor avaliação que a anterior, a posição da partícula é atualizada. Cada avaliação feita é comparada globalmente e a melhor é guardada.

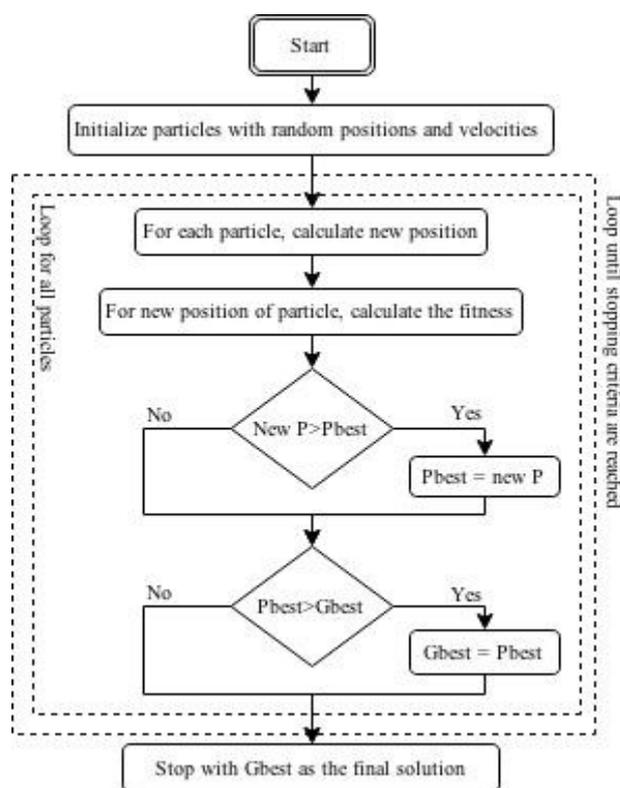


Figura 13- Fluxograma do PSO, (Faia et al., 2015b)

Quando o critério de paragem é atingido, o algoritmo retorna a melhor solução global encontrada ao longo da pesquisa. É claro que, durante a pesquisa existem restrições que podem variar de problema para problema.

Na pesquisa do PSO existem componentes que influenciam a pesquisa e o resultado final. Na análise da equação (3.17) o termo $c_1 \cdot r_1^k \cdot (Pbest_i^k - x_i^k)$ é chamado de componente cognitiva e avalia a performance de cada partícula em relação à posição passada, assim é utilizada a memória individual, pela utilização da melhor solução pessoal. O termo $c_2 \cdot r_2^k \cdot (Gbest_i^k - x_i^k)$ é denominado de componente social e avalia a performance de cada partícula relativamente ao total de todas as partículas. Esta componente faz com que as partículas sigam a melhor solução global, pelo que o algoritmo pode cair num ótimo local e retornar a uma solução aquém do esperado. Os valores aleatórios r_1^k e r_2^k mantêm a influência estocástica na componente cognitiva e social da pesquisa.

O termo $w \cdot v_i^k$ que é designado de inércia, e define o quanto a solução anterior influencia a pesquisa da próxima solução. Existem diferentes formas de calcular o fator de inércia. Neste estudo fez-se uma comparação com 18 fórmulas diferentes de cálculo de inércia como é possível ver nas equações (3.19) - (3.36).

Tabela 1 -Diferentes estratégias de inércias

Nome	Legenda	Estratégia de inércia	Ref.	Eq.
Constant Inertia Weight	w1	$w = c$	(Shi and Eberhart, 1998)	(3.19)
Random Inertia Weight	w2	$w = 0.5 + \frac{Rand()}{2}$	(Eberhart and Shi, 2001)	(3.20)
Linear Decreasing Inertia Weight	w3	$w_k = w_{max} - \frac{w_{max} - w_{min}}{iter_{max}} \times k$	(Xin et al., 2009)	(3.21)
The Chaotic Inertia Weight	w4	$z = 4 \times z \times (1 - z)$ $w_k = (w_{max} - w_{min}) \times \frac{iter_{max} - k}{iter_{max}} + w_{min} \times z$	(Feng et al., 2007)	(3.22)
Simulated Annealing Inertia Weight	w5	$w_k = w_{min} + (w_{max} - w_{min}) \times \lambda^{k-1}$	(Al-Hassan et al., 2006)	(3.23)

Nome	Legenda	Estratégia de inércia	Ref.	Eq.
Oscillating Inertia Weight	w6	$T_k = \frac{2S_1}{3 + 2k^*}$ $w_k = \frac{w_{min} + w_{max}}{2} + \frac{w_{max} - w_{min}}{2} \cos\left(\frac{2\pi k}{T_k}\right)$	(Kentzoglanakis and Poole, 2009)	(3.24)
Exponent Decreasing Inertia Weight	w7	$w_k = (w_{max} - w_{min} - d_1) \exp\left(\frac{1}{1 + \frac{d_2 k}{iter_{max}}}\right)$	(Li and Gao, 2009)	(3.25)
Logarithm Decreasing Inertia Weight	w8	$w_k = (w_{max} - w_{min} - d_1) \log_{10}\left(a + \frac{10k}{iter_{max}}\right)$	(Gao et al., 2008)	(3.26)
Sigmoid Increasing Inertia Weight	w9	$u = 10^{(\log(iter_{max})-2)}$ $w_k = \frac{(w_{min} - w_{max})}{(1 + e^{u(k-n \times iter_{max})})} + w_{max}$	(Malik et al., 2007)	(3.27)
Sigmoid Decreasing Inertia Weight	w10	$u = 10^{(\log(iter_{max})-2)}$ $w_k = \frac{(w_{min} - w_{max})}{(1 + e^{-u(k-n \times iter_{max})})} + w_{max}$	(Malik et al., 2007)	(3.28)
Natural Exponent Inertia Weight Strategy 1	w11	$w_k = w_{min} + (w_{max} - w_{min}) e^{\left(\frac{k}{\frac{iter_{max}}{10}}\right)}$	(Chen et al., 2006)	(3.29)
Natural Exponent Inertia Weight Strategy 2	w12	$w_k = w_{min} + (w_{max} - w_{min}) e^{\left(\frac{k}{\frac{iter_{max}}{4}}\right)^2}$	(Chen et al., 2006)	(3.30)
Chaotic Random Inertia Weight	w13	$z = 4 \times z \times (1 - z)$ $w_k = 0.5 \times rand() + 0.5 \times z$	(Eberhart and Shi, 2001)	(3.31)
Nonlinear time-varying Inertia	w14	$w_k = \left(\frac{2}{k}\right)^{0.3}$	(Lei et al., 2006)	(3.32)
Adaptive Inertia 1	w15	$m_k^p = \frac{Gbest_k - current_k}{Gbest_k + current_k}$ $w_k^p = w_{min} + (w_{k-1} - w_{min}) \times \frac{e^{m_k^p} - 1}{e^{m_k^p} + 1}$	(Eberhart and Shi, 2001)	(3.33)

Nome	Legenda	Estratégia de inércia	Ref.	Eq.
Adaptive Inertia 2	w16	$ISA_k^p = \frac{ current_k^p - Pbest_k^p }{ current_k^p - Gbest_k + \varepsilon}$ $w_k^p = 1 - \alpha \left(\frac{1}{1 + e^{ISA_k^p}} \right)$	(Qin et al., 2006)	(3.34)
Adaptive Inertia 3	w17	$w_k^p = w_{min} + (w_{max} - w_{min}) \frac{Rank_p^i}{Total\ Population}$	(Panigrahi et al., 2008)	(3.35)
Adaptive Inertia 4	w18	$w_k^v = 1.1 - \frac{Gbest}{average(Pbest_v)}$	(Arumugam and Rao, 2008)	(3.36)

Na Tabela 1 podemos observar as estratégias de inércia implementadas na elaboração desta dissertação. Quando a velocidade é demasiado elevada pode ocorrer que de iteração em iteração a partícula “salte” e não passe pela solução ótima e seja difícil encontra-la. Por outro lado, se a velocidade for demasiado baixa pode ocorrer que a solução caia sobre um ótimo local. Considerando este facto, são apresentadas as diferentes estratégias de cálculo da inércia.

Com o intuito de poder comparar resultados e consolidar os resultados obtidos, foram implementadas cinco variantes diferentes do PSO, as quais são: o PSO *standard* (apresentado), o *Evolutionary Particle Swarm Optimization* (EPSO), o *Non-Linear Particle Swarm Optimization with Local Random Search* (NPSO-LRS), o *Quantum Particle Swarm Optimization* (QPSO) e o *Migration Particle Swarm Optimization with Time Varying Acceleration coefficients* (MPSO-TVAC).

EPSO

O EPSO (Miranda and Fonseca, 2002) difere do PSO *standard* pois em cada iteração é realizado um conjunto de cinco processos, designados de:

- Replicação - cada partícula é replicada r vezes;
- Mutação – em cada partícula são mutados os pesos w_{ik} ;
- Reprodução – cada partícula gera uma nova partícula de acordo com a regra do movimento das partículas;
- Avaliação – cada partícula é avaliada atendendo à função objetivo do problema;

- Seleção – são selecionadas as partículas para dar início a uma nova iteração.

O cálculo da velocidade é alterado para uma nova equação (3.37) que define a regra do movimento das partículas.

$$v_i^{k+1} = w_{i0}^* \cdot v_i^k + w_{i1}^* \cdot (Pbest_i^k - x_i^k) + w_{i2}^* \cdot (Gbest_i^{k*} - x_i^k) \quad (3.37)$$

$$w_{ik}^* = w_{ik} + \tau N(0,1) \quad (3.38)$$

$$Gbest_i^{k*} = Gbest_i^k + \tau' N(0,1) \quad (3.39)$$

O parâmetro $N(0,1)$ é uma variável aleatória com distribuição gaussiana onde a média é 0 e a variância 1. Os valores de τ e τ' podem ser fixos ou variáveis dependendo da preferência e conhecimento do utilizador. Estas alterações nos w_{ik} são denominadas de mutações.

NPSO-LRS

O NPSO-LRS é muito similar ao PSO *standard*, apresentando duas diferenças, uma das quais na equação do movimento e outra no facto de realizar uma pesquisa local. As alterações na equação do movimento das partículas são expressas na equação (3.40)(3.17):

$$v_i^{k+1} = w \cdot v_i^k + c_{1b} \cdot r_{1b}^k \cdot (Pbest_i^k - x_i^k) + c_{1w} \cdot r_{1w}^k \cdot (Pworst_i^k - x_i^k) + c_2 \cdot r_2^k \cdot (Gbest_i^k - x_i^k) \quad (3.40)$$

Esta equação, relativa a esta variante, vai substituir a equação (3.17), sendo incluído o parâmetro $Pworst_i^k$ que representa a má experiência em que as partículas passaram. Desse modo, a posição mais desfavorável é guardada na memória, mas estas posições serão sempre válidas pelas restrições. Com a inclusão desta nova componente, a pesquisa terá mais facilidade em sair dos pontos considerados ótimos locais, e alcançar os pontos muito próximos do ótimo global. Os parâmetros c_{1b} e c_{1w} são designados de parâmetros de termos de atração local pela melhor solução pessoal, e a atração local pela pior solução pessoal, r_{1b}^k e r_{1w}^k são designados de parâmetros aleatórios.

O critério que indicia a pesquisa local é definido pelo utilizador, podendo ser a geração de um número aleatório. No trabalho (Selvakumar and Thanushkodi, 2007), a pesquisa local é realizada atendendo às seguintes equações:

$$x_i^{min} = lim_i^{min} + (x_i^k - lim_i^{min}) \times \beta \quad (3.41)$$

$$x_i^{max} = lim_i^{max} + (lim_i^{max} - x_i^k) \times \beta \quad (3.42)$$

$$R_i^k = x_i^{min} + x_i^{max} \quad (3.43)$$

$$x_i^{k+1} = x_i^k + R_i^k \times r_l \quad (3.44)$$

Na equação (3.41) e (3.42) os lim_i correspondem ao limites mínimos e máximos das variáveis do problema, o parâmetro β é chamado de parâmetro local de área, r_l da equação (3.44) corresponde a uma número aleatório com limite mínimo -1 e 1 de máximo. Depois de realizar a pesquisa local, cada solução encontrada que seja melhor do que a anterior, ficará na memória e será utilizada no início da próxima pesquisa.

QPSO

No QPSO (Sun et al., 2004) o cálculo da velocidade expressa na equação (3.17) deixa de ser aplicado e a posição das novas partículas é calculada de forma diferente, tal como definido nas equações seguintes.

$$x_i^{k+1} = P_i^k + \beta \cdot |Mbest_i^k - x_i^k| \cdot \ln \frac{1}{u}, \text{ if } k1 \geq 0,5 \quad (3.45)$$

$$x_i^{k+1} = P_i^k - \beta \cdot |Mbest_i^k - x_i^k| \cdot \ln \frac{1}{u}, \text{ if } k1 < 0,5 \quad (3.46)$$

$$P_i^k = \frac{c_1 \cdot r_1 \cdot Pbest_i^k + c_2 \cdot r_2 \cdot Gbest}{c_2 \cdot r_1 + c_2 \cdot r_1} \quad (3.47)$$

$$Pbest_i^k = \varphi Pbest_i^k + (1 - \varphi) Gbest \quad (3.48)$$

$$\beta = \beta_0 + (\max it - it) \cdot \frac{\beta_1 - \beta_0}{it} \quad (3.49)$$

$$Mbest_i^k = \frac{1}{N} \sum_{i=1}^N Pbest_i^k \dots N \quad (3.50)$$

As variáveis r_1 , r_2 , $k1$, u e φ são números gerados aleatoriamente entre 0 e 1, c_1 e c_2 são parâmetros definidos pelo utilizador, o β_0 é um número inferior a 0,6 e β_1 pode variar entre 0,8 a 1,2 sendo eles definidos pelo utilizador dentro dos limites referidos. Como se pode observar pela equação (3.45) e (3.46), o cálculo da velocidade deixa de ser feito e o cálculo da nova posição é feito atendendo a uma média das melhores posições pessoais das partículas. O contributo da melhor posição global é contabilizado nas equações (3.47) e (3.48). O parâmetro β é atualizado a cada iteração, pela equação (3.49).

MPSO-TVAC

O MPSO-TVAC (Gang et al., 2012) rege-se pelas mesmas ordens de movimento do PSO *standard*, embora tenha uma particularidade, a existência de vários sub-enxames dentro do mesmo algoritmo.

No exemplo ilustrado pela Figura 14 existem 5 sub-enxames com 6 partículas cada um, e as setas indicam o sentido de deslocação da partícula.

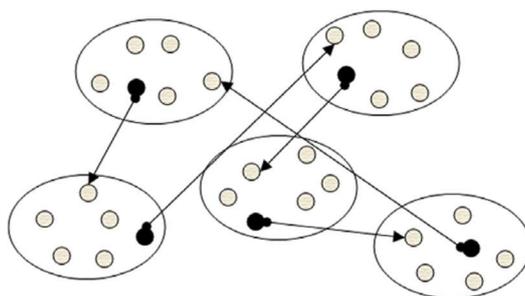


Figura 14 - Migração das partículas, (Coelho, 2008)

Neste caso, independentemente do número de sub-enxames, as partículas que migram para os diferentes sub-enxames são aquelas que têm menor valor de função objetivo, ficando ao critério do utilizador definir a quantidade de partículas a migrar. Para a migração ocorrer é necessário que o utilizador defina um parâmetro para que isso aconteça, por exemplo a cada 5 iterações.

O método TVAC é utilizado para alterar o valor dos coeficientes c_1 e c_2 da equação (3.17). Com a equação implementada, a cada iteração o coeficiente da componente cognitiva diminui e o da componente social aumenta. Com isto, pretende-se que no início da solução as partículas se guiem por si próprias e não deem importância à melhor solução global encontrada. Quando o número de iterações aumenta o coeficiente da componente social aumenta, logo as partículas são encaminhadas para a melhor solução global encontrada. Com este método, a tendência de cair num ótimo local fica reduzida. As seguintes equações expressam a forma como se calcula os coeficientes.

$$c_1 = (c_{1f} - c_{1i}) \frac{iter}{iter_{max}} + c_{1i} \quad (3.51)$$

$$c_2 = (c_{2f} - c_{2i}) \frac{iter}{iter_{max}} + c_{2i} \quad (3.52)$$

Onde c_{1i} , c_{1f} , c_{2i} e c_{2f} são os valores iniciais e finais da componente cognitiva e social respetivamente. Segundo a referência (Coelho, 2008) são-lhe atribuídos os seguintes valores:

$$c_{1i} = c_{2f} = 2,5 \text{ e } c_{1f} = c_{2i} = 0,5.$$

3.3.3. AG

O AG (Holland, 1992) é um algoritmo de otimização, baseado na evolução biológica através do processo de seleção natural de sobrevivências dos indivíduos na natureza. Basicamente o esquema de funcionamento do algoritmo pode ser descrito da seguinte maneira atendendo ao diagrama da Figura 15:

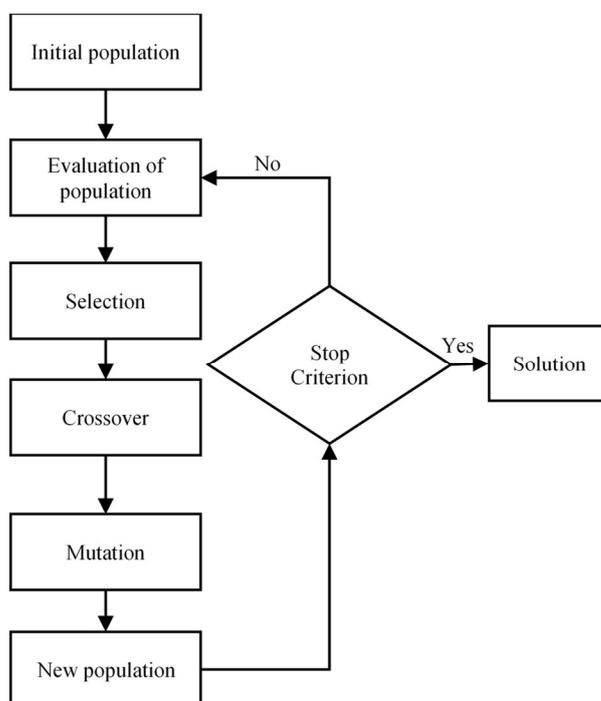


Figura 15 – Fluxograma AG

O algoritmo de pesquisa do AG inicia-se com a criação de uma população inicial que poderá ser de forma aleatória, depois de existir uma população é necessário avaliar a performance de cada indivíduo utilizando a função objetivo do problema em questão. O seguinte passo é seleccionar os indivíduos, para que possam dar origem a novos e uma nova população, a criação e modificação dos indivíduos inicia-se com o processo de cruzamento (*crossover*) onde se faz o cruzamento de informação de uns indivíduos para os outros, e termina com a mutação do indivíduo onde é feita a alteração do indivíduo. Depois de ter a nova população criada é aferido o critério de paragem. Caso este não tenha atingido o ciclo volta novamente

à avaliação da população como mostra a figura, caso seja atingido o algoritmo retorna a solução mais viável, com melhor função objetivo (Goldberg, 1989).

SELEÇÃO

O passo fundamental deste algoritmo é a seleção dos indivíduos, que determinam os novos indivíduos, a seleção segue o conceito da seleção natural onde os indivíduos mais aptos e com melhores capacidades de reprodução têm maior probabilidade de se reproduzir, no entanto os indivíduos com menor aptidão para participar no processo de seleção para gerar novos indivíduos podem também ser selecionados dependendo do método utilizado para fazer a seleção. Existem vários tipos de seleção de indivíduos, neste estudo vai ser utilizada e explicada a seleção por roleta, que dá possibilidade de os indivíduos menos aptos se reproduzirem.

Segundo (Schmitt, 2004), a seleção por roleta indicia que o indivíduo mais apto, ou seja, tem maior avaliação segundo a função objetivo, tem maior probabilidade de ser escolhido para dar origem à geração seguinte. Para uma melhor compreensão, pode-se comparar esta técnica ao jogo da roleta, ou seja, depois de estar atribuído a cada indivíduo a sua probabilidade de escolha é-lhe atribuída uma fatia da roleta proporcional à sua aptidão. Desta forma, os indivíduos com a maior fatia da roda têm maior probabilidade de serem selecionados. Este possui um componente aleatório que lhe pode permitir fugir dos ótimos locais.

CRUZAMENTO

A geração dos novos indivíduos é realizada após a seleção dos progenitores através da alteração da solução pelos métodos de cruzamento e mutação. Existem diferentes métodos de cruzamento e os mesmos consistem em trocar informação de uns cromossomas (soluções) para os outros, assim podemos destacar o cruzamento de ponto único (*single-point crossover*). Este método quebra duas soluções num ponto único e faz a troca de ambas as partes originando duas novas soluções. O outro método de cruzamento designa-se de cruzamento uniforme (*uniform crossover*). Este método considera um número aleatório ou não, o qual serve para definir o número de cortes nos cromossomas que vão dar origem à nova solução. Na Figura 16 é apresentado um cruzamento uniforme, com dois pontos de corte como é visível na imagem.

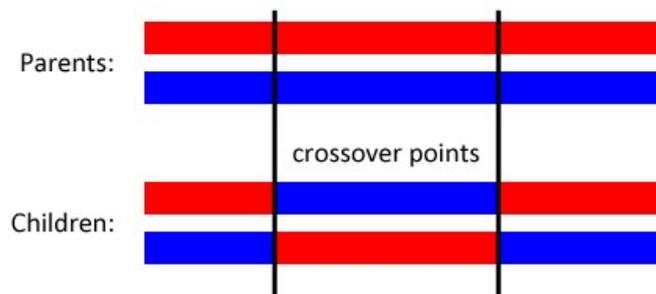


Figura 16 – Cruzamento de dois pontos

O processo funciona da seguinte maneira, dois pontos de cortes são selecionados aleatoriamente. Assim, o indivíduo é dividido em três partes. A intersecção dos indivíduos é feita através da combinação da primeira e da terceira parte do primeiro indivíduo com a segunda parte do segundo indivíduo, e a primeira e terceira parte do segundo recombina-se com a segunda parte do primeiro indivíduo dando origem a um novo indivíduo (*children*), tal como representado na Figura 16. Se o ponto desenhado é o ponto de partida ou no final, o sorteio deve ser feito novamente.

MUTAÇÃO

Após o processo de mutação e de cruzamento ser realizado, em que um ou mais indivíduos (que foram selecionadas) são modificadas. A mutação pode ser descrita como uma baixa probabilidade de modificação aleatória de um cromossoma de um indivíduo. A mutação é usada para promover a diversidade genética ao longo das gerações. É análogo à mutação biológica observada durante a meiose (Cederberg and Rannug, 2006) ou a replicação de ADN (Bertram, 2000). A mutação pode alterar um ou mais valores de genes num cromossoma observado na Figura 17. Daí, o GA pode chegar a melhores soluções usando a mutação.



Figura 17 - Processo de mutação

A mutação ocorre durante a evolução de acordo com a probabilidade de mutação definido pelo utilizador. Esta probabilidade é normalmente definida como um valor baixo. Se for muito alto, o processo de busca vai se transformar numa pesquisa aleatória primitiva.

No trabalho realizado são utilizadas três variantes do AG, sendo duas delas resultam do processo de cruzamento, onde numa é executado o cruzamento de um único ponto (denominado de AG1) e na outra é realizado o cruzamento de dois pontos (AG2) como foi explicado pela Figura 16, depois foi também criada uma variante onde o processo de mutação se realiza com o contributo do melhor indivíduo (AG3). Aqui como sabemos é selecionado o indivíduo atendendo à probabilidade de mutação definida pelo utilizador e o gene a ser mutado (variável do problema) é alterado pelo gene do indivíduo mais apto (melhor função objetivo).

3.3.4. SA

O SA é um algoritmo de pesquisa local (Laarhoven and Aarts, 1987). Deve o seu nome ao facto do seu processo de pesquisa ser baseado no processo físico de recozimento dos sólidos, onde um sólido é aquecido e, em seguida deixa-se arrefecer muito lentamente até atingir a estrutura cristalina mais regular possível (Kerrache and Benhidour, 2014). O SA tenta encontrar o ótimo global num problema de otimização imitando o processo termodinâmico do arrefecimento dos materiais. Além disso, este algoritmo tem uma particularidade, ao longo das iterações de pesquisa, o SA vai procurar soluções guardando sempre a melhor solução encontrada. Por outro lado, os movimentos do algoritmo podem ser comparados à subida de uma montanha onde temos subidas e descidas, onde as subidas são a aceitação de soluções melhores e as descidas são a aceitação de soluções piores. À medida que a temperatura decresce, as subidas na montanha tendem a ser de menor distância, e o valor da temperatura é recalculado, afetando a aceitação ou não das soluções encontradas em cada iteração (Henderson et al., 2003). Na Figura 18 está representado o fluxograma de funcionamento do algoritmo SA. Para que o algoritmo dê início à pesquisa, é necessário definir uma temperatura inicial e uma solução inicial a partir da qual o algoritmo começa a fazer a sua pesquisa. Este algoritmo tem três passos essenciais que determinam a pesquisa do mesmo, um deles é a perturbação da solução, o outro é o facto de o algoritmo aceitar

soluções de menor qualidade, e por fim a avaliação da qualidade da solução (Ledesma et al., 2008).

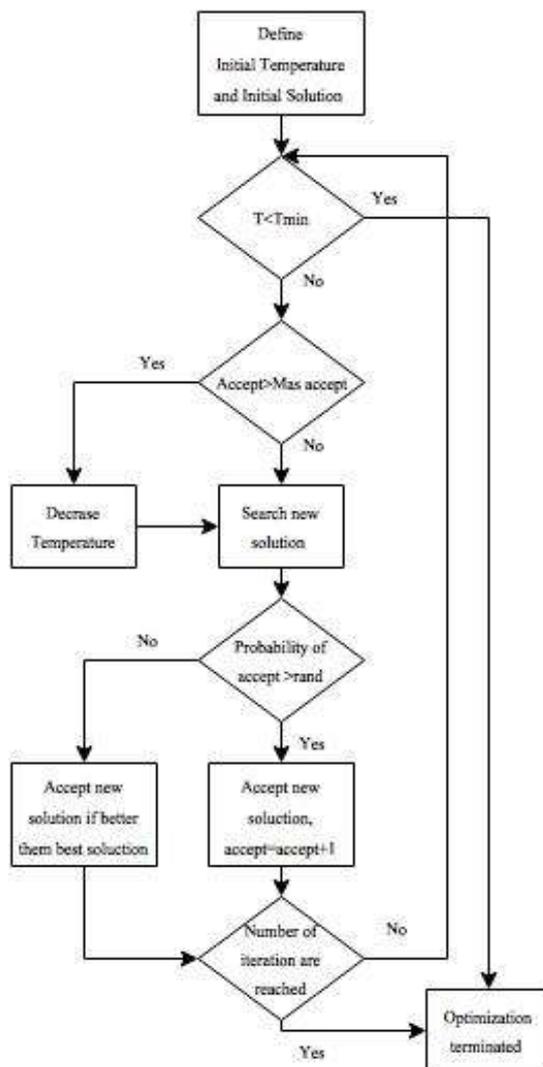


Figura 18 - Fluxograma do SA, (Faia et al., 2016b)

Seguindo o diagrama da Figura 18 e começando no primeiro ponto, é observada a condição inicial onde a temperatura condiciona a paragem do algoritmo. Pois, enquanto a temperatura corrente for maior que a temperatura mínima, o algoritmo segue a sua pesquisa. Em seguida, é imposta outra condição. Esta define se é feito o decréscimo da temperatura e caso o número de aceitação seja maior que o número máximo de aceitações o decréscimo é efetuado. Independentemente da condição anterior se registar ou não, o algoritmo executa a pesquisa de uma nova solução que é obtida a partir da equação (3.53).

$$\text{new solution} = \text{solution} + S \times N(0,1) \quad (3.53)$$

Na expressão (3.53) a *solution* representa a solução anterior, $N(0,1)$ representa um número aleatório com distribuição normal e a variável S obtém-se através da equação (3.54).

$$S = 0.01 \times (\text{upbound} - \text{lwbound}) \quad (3.54)$$

Na equação (3.54), a multiplicação pela subtração $\text{upbound} - \text{lwbound}$ é efetuada para que a nova solução não saia dos limites aos quais variáveis do problema podem chegar. Feita a pesquisa é posta à prova a condição de aceitação. Assim, caso a probabilidade de aceitação seja maior que um número gerado aleatoriamente, esta vai aceitar a solução caso seja melhor. Se a probabilidade de aceitação não se registar, este vai aceitar uma solução mesmo que esta seja pior que a melhor encontrada até ao momento. Em seguida, caso o número máximo de iterações se registre, o algoritmo dá por terminada a pesquisa. Caso a solução não se verifique, o ciclo repete-se até que um dos critérios de paragem seja atingido: temperatura mínima ou número máximo de iterações, as equação do decréscimo da temperatura assim como da probabilidade de aceitação podem ser observada nas equações, (3.55) - (3.58).

$$\text{SA 1} \quad T_i = T_{i-1} \times \alpha; P = (2\pi T)^{-\frac{D}{2}} e^{\left(\frac{-\Delta x}{K \times T}\right)} \quad (3.55)$$

$$\text{SA 2} \quad T_i = \frac{T_0}{i}; P = \frac{T_0}{(\Delta x^2 + T^2)^{\frac{(D+1)}{2}}} \quad (3.56)$$

$$\text{SA 3} \quad T_i = T_0 e^{-ci^{\frac{1}{D}}}; P = \prod_{d=1}^D \frac{1}{2(|y_d| + Ti) \ln\left(1 + \frac{1}{T_i}\right)} \quad (3.57)$$

$$\text{SA 4} \quad T_i = T_0 \times \alpha^i; T_i = \frac{1}{1 + e^{\frac{\Delta x}{T_{max}}}} \quad (3.58)$$

Desta forma dentro do SA obtemos 4 variantes atendendo ao decréscimo da temperatura e à probabilidade de aceitação: temperatura e probabilidade 1 equação (3.55) (Huang and Hsieh, 2011), temperatura e probabilidade 2 equação (3.56) (Huang and Hsieh, 2011), temperatura e probabilidade 3 equação (3.57) (Huang and Hsieh, 2011) e temperatura e probabilidade 4 equação (3.58) (Chen et al., 2012).

3.4. HEURÍSTICA PARA SOLUÇÃO INICIAL COM BASE NO CONHECIMENTO

As três meta-heurísticas utilizadas neste trabalho necessitam de uma (SA) ou de um conjunto (PSO e AG) de soluções iniciais, de forma a dar início ao processo de procura do algoritmo. Estas soluções iniciais são, tradicionalmente, calculadas aleatoriamente. No entanto, o uso de heurísticas baseadas no conhecimento *ad-hoc* do problema, é normalmente, uma forma de melhorar tanto a qualidade dos resultados dos algoritmos, como o seu tempo de execução, ao iniciar a procura em pontos mais próximos do ótimo global (Sousa et al., 2014).

Por estas razões, foi desenvolvida neste trabalho uma heurística para cálculo da solução inicial, que foi criada com base no conhecimento. Atendendo às regras das negociações nos mercados considerados, originou-se uma heurística que aloca a energia a ser transacionada, aos diferentes mercados. Esta heurística é sensível também ao preço da eletricidade previsto para o período de negociação, e espera-se que com ela os resultados venham a melhorar. De seguida são apresentadas as regras impostas para encontrar a solução que os algoritmos utilizarão como solução inicial da sua pesquisa.

As regras criadas para a solução inicial são:

- 1º - No mercado Spot, como é impossível comprar energia, quando o *player* participa para vender, o valor dessa variável é automaticamente zero;
- 2º - O preço do mercado Spot é comparado com os preços dos mercados de ajustes, e o preço maior fica guardado;
- 3º - É calculado o preço de venda ou compra para a quantidade máxima de transação nos mercados Bilateral e SG. Caso o preço máximo de venda seja maior que estes, é alocada a quantidade máxima de compra nos dois mercados anteriores;
- 4º - Uma vez que nas várias sessões do mercado de ajustes apenas é possível realizar uma das ações (compra ou venda), o preço máximo verificado em todos os mercados é comparado com o preço de compra da quantidade máxima em cada uma das sessões do mercado de ajustes. Caso o preço máximo seja maior, é automaticamente alocada a quantidade máxima de compra nas sessões do mercado de ajustes;

- 5º - É feita a soma da quantidade de eletricidade que foi comprada com a quantidade disponível resultante de produção própria, obtendo assim a quantidade disponível para vender;
- 6º - Dado que existem mercados onde o preço depende da quantidade de venda, o preço de venda nesses mercados é calculado para quantidades de 10 em 10 MW até ao máximo disponível para venda;
- 7º - É feita uma pesquisa, através de métodos interativos, para procurar se existe uma quantidade de eletricidade em que o preço seja máximo dentro do mercado e maior que o preço máximo encontrado. Esta pesquisa é feita apenas nos mercados Bilateral e SG, caso exista é-lhe alocada a quantidade referente.
- 8º - É atualizada a quantidade disponível para venda atendendo à quantidade alocada nos dois mercados anteriores;
- 9º - Para alocar a eletricidade que falta, procura-se o mercado onde a quantidade que resta pode ser mais lucrativa e, atendendo à impossibilidade de compra e venda no mesmo mercado, esta quantidade é alocada.

Após concluir os passos anteriormente descritos, e para garantir a viabilidade da solução, são impostas restrições a fim de acautelar que o algoritmo comece a pesquisa com uma solução válida.

3.5. MÉTODO DE PREVISÃO

Para a elaboração deste trabalho foi necessário obter a previsão dos preços da eletricidade. Assim, para abordar os métodos de previsão foi tido como referência um trabalho já desenvolvido que utiliza as redes neuronais artificiais como método de previsão (Pinto et al., 2012).

O termo redes neuronais artificiais deriva do inglês *Artificial Neural Network*, e tem como principal objetivo o reconhecimento de padrões e classificação de dados. A sua principal característica é a aprendizagem através da experiência, isto significa que os bons resultados são fruto de uma boa aprendizagem. Assim, para esta poder ser realizada é necessário conter

uma considerável coleção de dados de diferentes naturezas que se relacionem com os dados aos quais a RNA pretende dar saída (Panapakidis and Dagoumas, 2016).

As RNA's são um conjunto de técnicas computacionais que tentam, de alguma forma, simular as estruturas neuronais de organismos inteligentes, como o cérebro humano. As RNA's são estruturas interligadas de unidades computacionais (neurónios), que fazem um processamento massivamente paralelo e distribuído e têm capacidade de aprendizagem. O conhecimento, à semelhança do cérebro humano, é adquirido através de um método de aprendizagem ou treino, que é caracterizado pela utilização de um conjunto de dados de entrada e saída. A relação entre estes dados é determinada pelo algoritmo e armazenada nas ligações, sob a forma de pesos, entre os neurónios pertencentes à rede (Haykin, 1998). Do ponto de vista interno, os neurónios são organizados por camadas e interligados por ligações unidireccionais, com um peso associado. Os pesos são parâmetros ajustáveis durante o processo de treino (Amjady et al., 2010).

Existem diversas formas de classificação das RNA's, duas delas e as mais importantes são: segundo a sua arquitetura e segundo o processo de aprendizagem utilizado. Em geral, é possível identificar fundamentalmente três diferentes classes de arquiteturas (Haykin, 1998):

- Redes *Feedforward* com uma única camada, em que o fluxo da informação é exclusivamente unidirecional, e é composta unicamente por uma camada de entrada interligada a uma camada de saída;
- Redes *Feedforward* multicamadas são idênticas às anteriores, no entanto estas distinguem-se pela presença de uma ou mais camadas intermédias (ou ocultas). Esta arquitetura de rede, uma das mais utilizadas, foi a selecionada para aplicar no estudo de caso em análise nesta dissertação.
- Redes Recorrentes, estas distinguem-se das *Feedforward* pelo facto de possuírem pelo menos um circuito de realimentação. Por exemplo, o sinal de saída da rede pode ser encaminhado para a camada de entrada.

3.6. ESTIMATIVA DOS PREÇOS EM CONTRATOS BILATERAIS

A RNA considerada (Bian and Chen, 2014; Quan et al., 2014) caracteriza-se como uma rede neural *feedforward*, recebendo como entradas os preços de mercado e quantidade total de

energia negociado no mercado, referindo-se: um dia antes do dia previsto desejado, em uma semana antes, duas semanas antes, e três semanas antes. A RNA considera quatro nós na camada intermediária, e um na saída - o preço de mercado previsto. Esta topologia foi apresentada em (Pinto et al., 2012), e tem sido redefinida após algumas análises e experiências, tal como apresentado em (Pinto et al., 2011a). A estrutura deste RNA é apresentado na Figura 19.

O algoritmo *backpropagation* utiliza o método de gradiente descendente (Rudd et al., 2014), que tem sido utilizado como algoritmo de treino para a RNA. Isto requer o cálculo da derivada da função do erro quadrático em relação aos pesos da rede. A função de erro quadrático E para o único neurónio de saída é definido na equação (3.59).

$$E = \frac{1}{2}(t - y)^2 \quad (3.59)$$

Onde t é a saída de destino para uma amostra de treino, e y é o valor real do neurónio de saída. Para cada neurónio j , a saída o_j é definida pela utilização da equação (3.60).

$$o_j = f\left(\sum_{k=1}^n w_{kj}x_k\right) \quad (3.60)$$

Onde n é o número de unidades de entrada para neurónio J , e w_{kj} é o peso entre neurónios de k e j . Assim, a entrada para a função de ativação f de um neurónio é a soma ponderada das saídas dos neurónios o_j anteriores. A função de ativação utilizada, f , é uma função log-sigmoide, que é calculada atendendo à equação (3.64).

$$f(z) = \frac{1}{1 + e^{-z}} \quad (3.61)$$

O número de dias anteriores considerados para o treino é dependente das restrições do mecanismo 2E, em termos de tempo de execução. Isso indica se a RNA vai usar mais ou menos valores no seu processo de treino, ou seja, uma previsão mais rápida, mais incerta, ou uma previsão mais lenta, mas mais eficaz. Note-se que, considerando uma quantidade exagerada de dados pode levar a um excesso de treino, fazendo com que a RNA memorize os exemplos, em vez de executar aprendizagem da relação entre os dados. À medida que a quantidade necessária de dados aumenta, o mesmo acontece com o tempo necessário para

recuperar os dados a partir da base de dados, devido ao número necessário de consultas. Para suavizar o aumento deste tempo, foi utilizada a programação paralela, dividindo cada matriz de dados em vários, e criando um segmento diferente para preencher cada uma dessas matrizes menores.

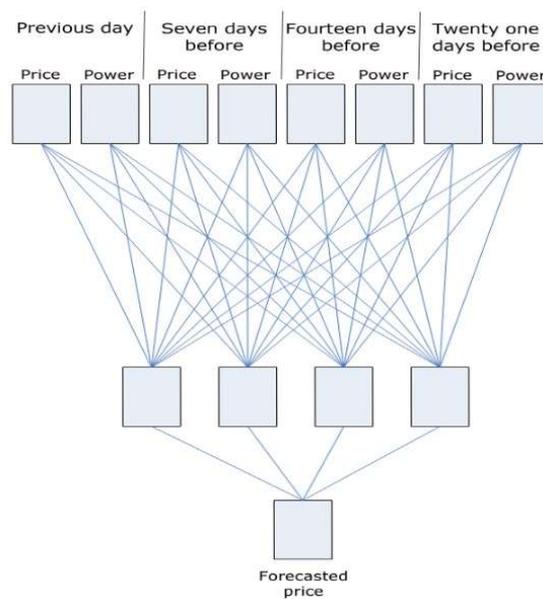


Figura 19 - Topologia da RNA utilizada, (Pinto et al., 2015a)

3.6.1. CLUSTERING

A técnica de *clustering* consiste no agrupamento de objetos com características semelhantes. Com este agrupamento faz-se a formação de grupos com o objetivo de obter agregados que apresentem características semelhantes e maximizem a similaridade, ou seja tentar constituir um *cluster* com a máxima homogeneidade possível. Pelo contrário, tenta-se minimizar a similaridade entre os dados dos outros grupos. Esta técnica é útil, na medida em que permite ao utilizador retirar conhecimento a partir de um conjunto de dados. Muitos algoritmos podem ser usados para fazer a análise de *clusters*, no entanto, o mais popular é o algoritmo *K-Means* (Jain, 2010).

O algoritmo K-Means foi implementado pela primeira vez por James MacQueen em 1967 (MacQueen, 1967). Este algoritmo, como já foi referido, é utilizado para fazer a partição de *clustering*, sendo necessário que lhe seja dada a informação de quantos grupos o utilizador vai querer à partida. O algoritmo termina quando as combinações entre objetos e grupos

minimizem um critério específico e, após convergir para e apresentar uma solução. Tipicamente como critério de paragem é utilizado o erro quadrático, equação (3.62).

$$\min \sum_{i=1}^k \sum_{x \in C_i} \|x - \mu_i\|^2 \quad (3.62)$$

Onde:

- (x_1, x_2, \dots, x_n) representam o conjunto de observações;
- n representa o número de observações;
- C_i representa o *cluster* i ;
- μ_i representa o centro do *cluster* i .

É aceite a combinação entre objetos e grupos que minimizem a soma do erro quadrático entre o centro do *cluster* e os objetos pertencentes.

Com o intuito de conseguir avaliar a qualidade do agrupamento de dados são utilizados dois indicadores: o *Mean Index Adequaxy* (MIA) e o *Cluster's Dispersion Indicator* (CDI) (Jain, 2010). O indicador MIA utiliza a distância euclidiana, por forma a obter uma média dos agrupamentos realizados com um conjunto inicial. A equação (3.63) demonstra a forma de cálculo do MIA.

$$\text{MIA} = \sqrt{\frac{1}{K} \sum_{n=1}^{n^k} d^2(r^k, D^k)} \quad (3.63)$$

O indicador CDI utiliza a distância entre elementos pertencentes ao mesmo cluster conjuntamente com a distância entre clusters. A equação (3.64) expressa a fórmula de cálculo do indicador.

$$\text{CDI} = \frac{\sqrt{\frac{1}{K} \sum_{k=1}^k \left[\frac{1}{2 \cdot n^{(k)}} \sum_{n=1}^{n^k} d^2(d^n, D^k) \right]}}{d(R)} \quad (3.64)$$

Os dois indicadores atrás apresentados são utilizados para avaliar a aptidão dos *clusters*. Uma vez que o algoritmo K-Means é necessário definir o número de *clusters*, utilizou-se o MIA e o CDI pra chegar ao número de *clusters* ideal. Iniciou-se com dois *clusters* e no fim do algoritmo acabar o agrupamento calculavam-se os respetivos indicadores.

Posteriormente, repetia-se o ciclo só que aumentando o número de *clusters* para três (mais um grupo), no final do agrupamento recalculavam-se novamente os indicadores. Como a tendência dos indicadores é diminuir, a diferença entre o indicador da iteração anterior e a atual é positiva. Pelas experiências realizadas, constatou-se que a tendência da diminuição se invertia e a diferença tornava-se negativa. Este facto é usado para o algoritmo K-Means parar e retorna um possível intervalo de possíveis *clusters*.

3.6.2. LÓGICA FUZZY

O conceito de Lógica *Fuzzy* foi apresentado pela primeira vez em 1965 pelo autor Lofti A. Zadeh (Zadeh, 1965). Atualmente, a lógica *fuzzy* é uma ferramenta utilizada para tratar incertezas. Neste caso vai ser utilizado para estimar o preço da eletricidade que varia com a quantidade de energia negociada, pois o preço não é linear. A lógica *fuzzy* é um processo que é utilizado para obter o controlo de estados intermédios, definindo um valor numérico associado a um estado que seria indefinido. Um exemplo da sua aplicabilidade será a negociação de energia: no caso de um vendedor negociar 50 MW de energia a um preço específico, não será igual ao negociar 70 MW, pois o preço por MW poderá ser diferente, pode aumentar ao diminuir com a quantidade negociada. Na Figura 20, está visível o esquema da lógica *fuzzy* implementada.

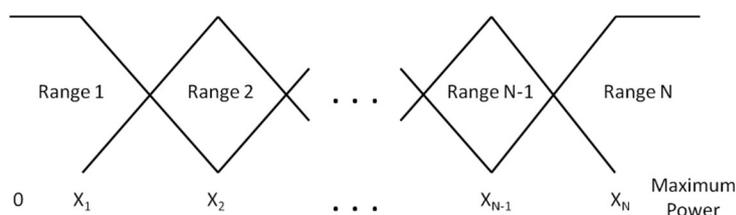


Figura 20- Representação gráfica da lógica *fuzzy*, (Pinto et al., 2015a)

A construção da lógica difusa é feita após o número ideal de *clusters* ser encontrado. Como se pode observar na figura acima representada, os pontos X são definidos pelas coordenadas dos *centroides* dos *clusters* e o Max Power é o valor mais alto de energia negociada. O número de intervalos é proporcional ao número de *clusters*.

A metodologia da estimativa dos preços de energia (Faia et al., 2015a), pode ser resumida pela explicação do diagrama da Figura 21.

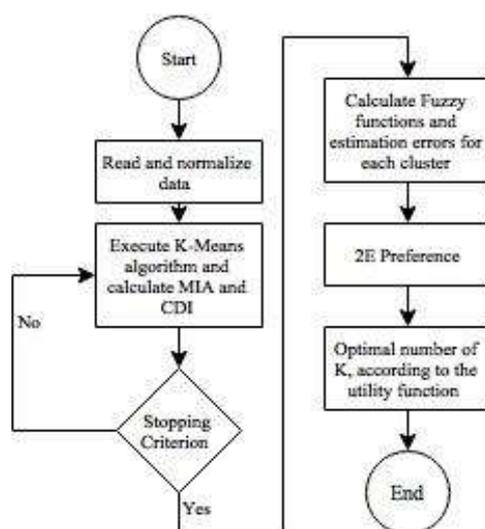


Figura 21 - Metodologia para a estimação de preços, (Faia et al., 2016a)

Inicialmente como se pode ver pela Figura 21 os dados são carregados e normalizados, na execução deste trabalho foram utilizados dados reais (MIBEL, 2007). De seguida dá-se início a um ciclo, o qual vai ditar um conjunto de possíveis valores de número de *clusters*.

O ciclo inicia-se com a execução do algoritmo *K-Means*, este tem a particularidade de necessitar da imposição de um número para que possa fazer os agrupamentos dos *clusters*, então inicialmente começa por fazer um único grupo, de seguida são calculados os indicadores MIA, equação (3.63) e CDI, equação (3.64). É através destes indicadores que o critério de paragem é verificado, equação (3.65) e (3.66), caso não seja verificado o ciclo prossegue e os dados são reagrupados novamente com mais um grupo, o ciclo repete-se até que o critério de paragem seja verificado.

$$m1_i = \left| \frac{MIA_i - MIA_{i-1}}{K_i - K_{i-1}} \right| \quad (3.65)$$

$$m2_i = \left| \frac{CIA_i - CIA_{i-1}}{K_i - K_{i-1}} \right|$$

$$m1_{i-1} - m1_i < 0$$

$$\vee$$

$$m2_{i-1} - m2_i < 0 \quad (3.66)$$

Quando uma das condições da equação (3.66) for atendida, o algoritmo retorna um conjunto de valores para o número de *clusters*. Por exemplo, se o critério de paragem se verificar no número 7 (7 *clusters*), o seguinte conjunto de valores serão definidos para o número de *clusters* ideal [4, 5, 6, 7, 8, 9, 10]. Após ser definido o conjunto de valores é feito o

agrupamento para cada número definido no intervalo e são calculadas as funções *Fuzzy* Figura 20, onde também é calculado o valor do erro incorrido por cada conjunto de agrupamentos, equação (3.67).

$$MADP = \frac{\sum_{x=1}^N \|F_x - A_x\|}{\sum_{x=1}^N \|A_x\|} \quad (3.67)$$

Na equação (3.67) esta representado o *Mean Absolute Deviation Percent* (MADP) que é utilizado para calcular o erro entre os *centroides* do *clusters* e as observações de cada *clusters*. Após ser realizado este passo como indica no diagrama, passa a ser implementado o mecanismo 2E (Pinto et al., 2011b) onde tem em conta dois parâmetros, o número de *clusters* e o valor do MADP e o utilizador pode dar a preferência que entender a qualquer um dos parâmetros, sendo que poderá definir pesos para cada um dos parâmetros, equação (3.68).

$$K_{best} = \min(wc \times K_{norm} + we \times MADP_{norm}) \quad (3.68)$$

Onde:

- K_{best} representa o número ideal de *clusters*;
- wc e we representam o peso dado ao número de *clusters* e ao MADP;
- K_{norm} e $MADP_{norm}$ representam o número de clusters e o valor do MADP normalizados.

Segundo a equação (3.68) o número de *clusters* ideal é escolhido atendendo aos pesos que o utilizador define, caso o utilizador opte por dar mais peso ao número de *clusters* o que o modelo vai fazer é optar por um número com menos *clusters* mas com um erro maior, caso seja o contrário o utilizador der mais peso ao valor do erro a metodologia vai apontar por um agrupamento com mais *clusters* mas com menor erro.

3.7. SUMÁRIO

Neste capítulo, intitulado de metodologia proposta, foi apresentada a formulação criada para o objeto de trabalho nesta dissertação. São igualmente apresentadas a função objetivo, as restrições aplicadas ao problema e explicadas as variáveis que incorporam a formulação proposta.

São apresentados também todos os algoritmos utilizados para resolver o problema proposto. Além do método exato utilizado, para cada algoritmo foram consideradas diferentes componentes que fazem com que surjam novas variantes que são utilizadas com o intuito de comparação de resultados. No caso do PSO são propostas 18 estratégias diferentes de inércia e 4 variantes diferentes que derivam do PSO *standard*. No AG são propostas 3 variantes, uma variante que utiliza um ponto de cruzamento, outra que utiliza dois pontos de cruzamento e outra que executa a mutação de acordo com a sua função *fitness*. Relativamente ao SA, são propostas 4 variantes nas quais varia a probabilidade de aceitação e o decréscimo da temperatura. No total são 29 os algoritmos/variantes que são aplicados no problema.

Foi também apresentada uma heurística que define qual a solução inicial a atribuir às técnicas de otimização propostas. Com a utilização desta heurística, espera-se que a pesquisa se torne mais fácil para os algoritmos. Pois, pelos trabalhos já realizados e pesquisa efetuada, conclui-se que a solução inicial é um fator importante na pesquisa do algoritmo. Por fim, é apresentada uma explicação sobre os métodos de previsão aplicados e sobre a metodologia de estimação de preços, que foi desenvolvida no âmbito desta dissertação e que conta com a utilização da técnica de *clustering* e da lógica *fuzzy*.

4. CASOS DE ESTUDO

Conforme referido anteriormente, o objetivo deste trabalho é utilizar a metodologia proposta de forma a obter resultados realistas que possam servir de apoio à decisão para a participação nos mercados de energia elétrica por parte dos vendedores e compradores da mesma. Na metodologia apresentada, é possível constatar que foram analisados dois tipos muito distintos de mercados, em que aquilo que os distingue é a possibilidade de o preço da eletricidade não ser fixo e poder variar com a quantidade negociada. Um exemplo relevante deste tipo de mercado é a negociação através de contratos bilaterais, que se realizam no âmbito dos mercados de energia elétrica. O horizonte temporal deste tipo de contratos é bastante variável, tendo sido apenas considerados, para efeitos do presente estudo, contratos com duração reduzida.

Para o problema consideraram-se 24 períodos ao longo de um dia. São também considerados 5 mercados onde existe a possibilidade de vender eletricidade e 4 mercados de compra de eletricidade. De forma a melhorar a análise do problema foram dados os seguintes nomes aos mercados, tendo como referência os mercados reais do MIBEL (MIBEL, 2007):

- Spot: mercado do dia-seguinte;
- Bilaterais: negociação de contratos bilaterais;

- Balancing1: primeira sessão do mercado de ajustes;
- Balancing2: segunda sessão do mercado de ajustes;
- Smart-Grid: mercado local, ao nível das SG.

Foram também criadas regras específicas para as suas negociações. No mercado Spot apenas é possível a venda de eletricidade para agentes vendedores, enquanto nos outros mercados é possível vender e comprar, ficando estabelecido que é possível comprar no máximo 10 MW em cada mercado e no total é permitido vender 50 MW de eletricidade (compra de 10 MW nos quatro mercados mais 10 MW de TEP). O total de 10 MW de energia produzida é a partir de fontes renováveis e é assumida como sem encargos financeiros, de forma a facilitar a análise dos resultados. Nos mercados Bilaterais e Smart-Grid o preço da eletricidade é obtido a partir da metodologia apresentada no subcapítulo 3.6., e existe a possibilidade de comprar e vender energia no mesmo período. Nos outros mercados, a realização de uma ação (compra ou venda) implica a impossibilidade da realização da outra.

Este capítulo compreende três casos de estudo, nos quais são apresentados os resultados obtidos nas simulações realizadas. No primeiro caso de estudo são apresentados os resultados obtidos com a metodologia proposta para estimação de preços para os mercados onde o preço varia com a quantidade negociada. No segundo caso de estudo são apresentados os resultados de todos os métodos aplicados na resolução do problema de otimização sem a consideração do risco para o primeiro período – problema de maximização de lucro, apresentado no subcapítulo 3.1. É também feita a comparação entre os resultados obtidos e escolhidos os métodos mais apropriados a utilizar. No terceiro caso de estudo são apresentados os resultados do problema multiobjetivo com diferentes níveis de risco para o primeiro período do dia, onde se obtêm diferentes tipos de resultados.

4.1. ESTIMATIVA DE PREÇOS ATRAVÉS DO FUZZY DINÂMICO

Neste subcapítulo são apresentados os resultados alcançados com a aplicação da metodologia proposta para a estimação do preço da eletricidade nos mercados onde a quantidade de eletricidade negociada influencia no preço. É apresentado um exemplo, assim como um resumo dos resultados para os 24 períodos de um dia ilustrativo, em formato de tabela.

É de realçar que a metodologia utiliza o número de *clusters* considerado ótimo, para fazer a criação dos números *fuzzy*. Para que a determinação do número ótimo de *clusters* possa ser automática utilizaram-se dois indicadores: o MIA e o CDI. O utilizador tem também um papel importante, pois pode dar a indicação dos pesos que são aplicados numa função de ponderação onde o número de *clusters* e o valor do erro são ponderados. Desta forma, o utilizador pode optar por ter um número menor de *clusters* mas ter um erro maior, ou pode ter maior número de *clusters* e o erro diminui. No Anexo A é apresentado um exemplo com dados do problema, com o intuito de explicar melhor a metodologia implementada na estimação dos preços. Nas Figura 23 e Figura 24 são apresentados gráficos com os preços e com a estimação dos mesmos efetuada pela metodologia descrita para os mercados onde o preço da eletricidade é variável com a quantidade negociada.

Através da Figura 22 é possível perceber o funcionamento do critério de paragem representado na Figura 21, que é obtido através do cálculo dos indicadores MIA e CDI. Como se pode observar o critério de paragem é acionado quando o número de *clusters* é igual a 6 o que significa que vai existir o seguinte conjunto de números para possível número ideal de *clusters*: {3,4,5,6,7,8,9}.

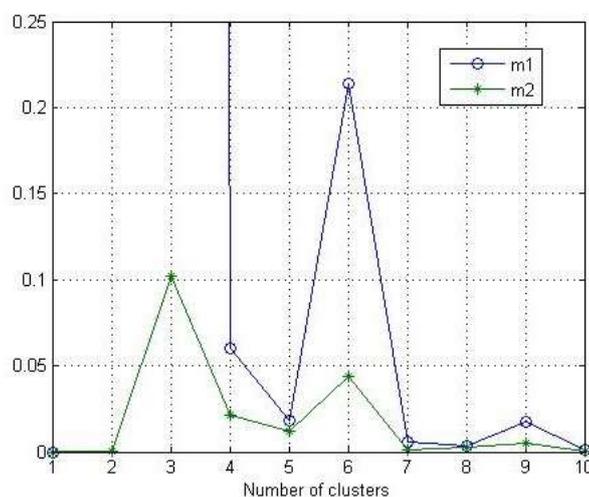


Figura 22 – Evolução dos indicadores *m1* e *m2*

Apos ser obtido o conjunto de números, o utilizador escolhe a sua preferência utilizando os pesos da equação (3.68), com a aplicação desta equação é possível obtermos os valores da Tabela 2.

Tabela 2 – Diferentes pesagens para diferentes números de *clusters* / erro de estimação

<i>we</i>	K (número de <i>clusters</i>)							<i>we</i>
	3	4	5	6	7	8	9	
0,1	0,1	0,2171106	0,3582992	0,4839011	0,6254085	0,7632176	0,9	0,9
0,2	0,2	0,2675545	0,383265	0,4678023	0,5841503	0,6931018	0,8	0,8
0,3	0,3	0,3179984	0,4082308	0,4517034	0,5428921	0,6229861	0,7	0,7
0,4	0,4	0,3684423	0,4331967	0,4356045	0,5016339	0,5528703	0,6	0,6
0,5	0,5	0,4188863	0,4581625	0,4195056	0,4603757	0,4827545	0,5	0,5
0,6	0,6	0,4693302	0,4831283	0,4034068	0,4191176	0,4126388	0,4	0,4
0,7	0,7	0,5197741	0,5080942	0,3873079	0,3778594	0,342523	0,3	0,3
0,8	0,8	0,570218	0,53306	0,371209	0,3366012	0,2724073	0,2	0,2
0,9	0,9	0,6206619	0,5580258	0,3551101	0,295343	0,2022915	0,1	0,1

Através dos valores da Tabela 2 é possível perceber o funcionamento da metodologia, pois se a preferência do utilizador for o valor do erro (*we*) vai ser apresentado um maior número de *clusters* como é o caso das seguintes combinações de pesagens: [(*we* ; *we*)], [(0,6;0,4) , (0,7;0,3) e (0,8;0,9)] que vai resultar sempre em 9 *clusters*. Caso seja o contrário o utilizador tenha preferência pelo número de *clusters* o modelo apresenta-lhe um agrupamento com menores números de *clusters*, como é o caso das seguintes combinações: [(0,1;0,9) , (0,2;0,8) e (0,3;0,7)] que resultam em 3 *clusters*. Os dados apresentados pertencem ao mercado Bilaterals e ao primeiro período.

Na Figura 23 está representada a estimação dos preços para o mercado Bilaterals no primeiro período. Como é possível observar, os dados existentes foram agrupados em 9 *clusters* e depois, aplicando a teoria da lógica *fuzzy*, podemos obter o valor estimado.

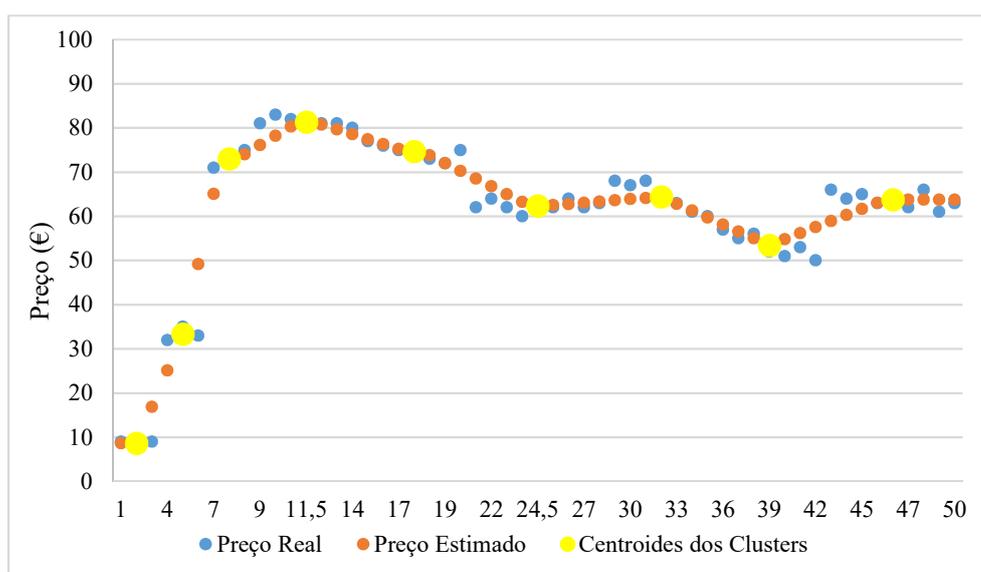


Figura 23 – Estimação dos preços no mercado Bilaterals

Como é possível observar na Figura 23, os valores estimados para o mercado Bilaterals são muito próximos dos registados, apresentando em erro médio absoluto de 2,6788. Na ilustração estão localizadas as posições dos centros dos *clusters* que determinaram os intervalos onde em cada um deles existe uma função que calcula o valor estimado para a quantidade de energia específica.

Na Figura 24 está representada a estimação dos preços de eletricidade no mercado SG para o primeiro período. Neste caso, como é possível observar, os dados foram agrupados em 8 *clusters*. E, também neste caso os valores estimados encontram-se muito próximos dos reais e o erro médio absoluto é de 1,2766. À semelhança da Figura 23 os *clusters* também representam os limites de intervalos onde existe uma função que faz a estimação do preço, a qual difere de intervalo para intervalo.

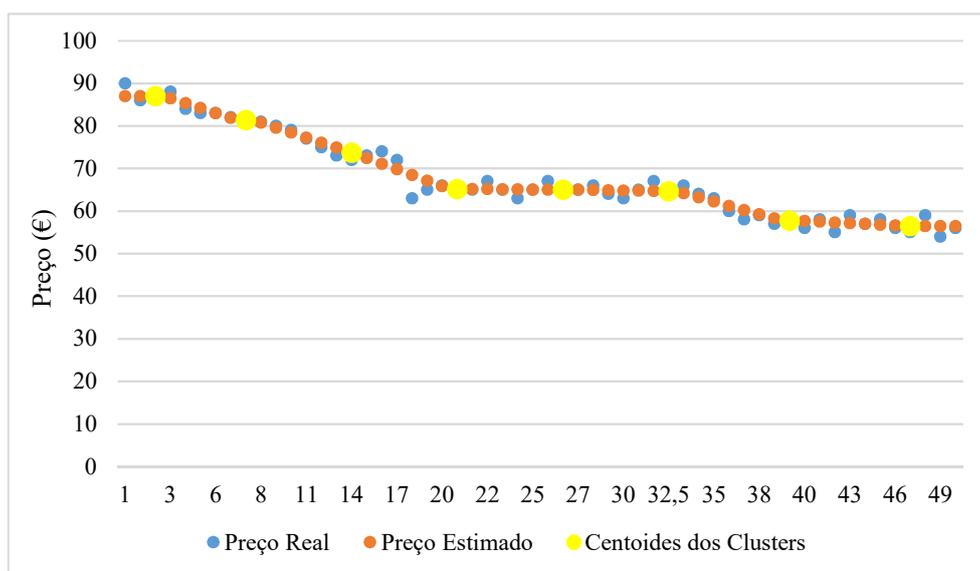


Figura 24 – Estimação dos preços no mercado SG

Na Tabela 3 são apresentados os números ideais de *clusters* obtidos pela metodologia proposta, para os mercados em questão sendo eles o mercado Bilaterals e o mercado SG. São apresentados os resultados para os 24 períodos considerados neste caso de estudo como se pode ver pela Tabela 3. O número de *clusters* difere de período para período, pois os mercados apresentam diferentes perfis de preços nos diferentes períodos.

Tabela 3 - Número de *clusters*

Período	Bilaterals	Smart-Grid
1	9	8
2	9	6
3	6	8
4	8	8
5	9	7
6	8	7
7	6	7
8	10	10
9	7	10
10	8	9
11	8	6
12	9	10
13	9	7
14	8	7
15	7	10
16	8	6
17	9	6
18	9	7
19	8	7
20	8	9
21	8	6
22	7	10
23	8	12
24	7	10

4.2. OTIMIZAÇÃO DO LUCRO

Neste caso de estudo são apresentados os resultados de todos os algoritmos aplicados para a resolução do problema, considerando apenas uma parte da função objetivo, o lucro. Para isso considerou-se a equação (3.14), o que significa que a componente do risco não tem importância na otimização e o problema é resolvido por forma a obter o máximo de retorno o que leva a correr o máximo de risco.

Como já foi explicado anteriormente, foram utilizados três algoritmos diferentes para resolver o problema e, dentro de cada algoritmo foram experimentadas várias modificações que conduzem a resultados distintos. Para todos os testes em cada uma destas modificações foram executadas 1000 simulações. Deste modo, é feita a comparação dentro de cada um dos três grupos (PSO, AG e SA), atendendo ao valor da função objetivo, ao tempo de execução de cada algoritmo, ao número de iterações e no final será feita uma resenha das melhores variantes de cada grupo.

4.2.1. MÉTODO DETERMINÍSTICO

Como foi explicado no subcapítulo 3.3.1 os métodos determinísticos vão ser usados com o intuito de servirem de referência para os métodos de resolução aproximada. O problema

inicialmente era classificado como não linear, mas após serem feitas umas modificações o problema ficou linear. Com estas modificações o problema ficou muito mais pesado mas mais fácil de ser resolvido, sendo que foi resolvido como um problema MILP, e foi utilizado *toolbox* Tomlab que pertence ao *software* Matlab, sendo que foi utilizado o *solver simplex*. Na Tabela 4 são apresentados os resultados do método determinístico.

Tabela 4 - Resolução determinística

Período	Determinístico	
	Função objetivo (€)	Tempo de execução (h)
1	2000,6456	68,678941

Como se pode observar na Tabela 4 o tempo de execução é demasiado elevado, num problema onde se necessita de resultados em menos de uma hora este tipo de resoluções deixa de ser passível de ser executado.

4.2.2. RESULTADOS DA METODOLOGIA BASEADA NO PSO

Como foi mencionado anteriormente, foi implementado o PSO *standard*, o EPSO, o QPSO, o NPSO-LRS, o MPSO-TVAC, e ainda, dentro do PSO *standard*, foram implementadas 18 diferentes estratégias de cálculo do coeficiente de inércia.

Na Tabela 5 estão presentes os resultados da implementação das equações da Tabela 1.

Tabela 5 - Resultados das estratégias de cálculo de inércia

Inércias	Função Objetivo (€)				Tempo de execução (s)				Número de Iterações			
	Min	Max	Mean	STD	Min	Max	Mean	STD	Min	Max	Mean	STD
w1	571,4824	1998,601	1483,835	270,3166	0,1172	0,4369	0,1836	0,0353	42	119	64	10,9145
w2	444,8956	2000,646	1535,16	351,6517	0,0759	30,5615	2,8343	7,4635	27	10000	1033	2726,893
w3	935,0451	2000,646	1802,21	160,4235	0,0911	2,1218	1,0118	0,2879	33	790	364	101,3678
w4	448,531	2000,646	1618,602	316,5736	0,0870	1,9378	0,4865	0,3753	30	669	173	134,383
w5	665,6891	2000,305	1565,889	251,3641	0,0924	0,2722	0,1238	0,0151	33	62	43	4,2325
w6	1227,777	2000,646	1801,005	155,9684	0,2739	0,8723	0,5654	0,0856	102	292	203	28,5653
w7	1227,777	2000,646	1798,605	159,9215	0,3647	1,2876	0,7284	0,1310	144	392	262	43,5402
w8	1145,403	2000,646	1802,178	153,8245	0,0888	1,2147	0,5809	0,1116	34	342	208	37,4837
w9	1113,985	2000,646	1806,297	154,0475	0,1495	3,0664	1,2289	0,4589	53	1104	443	164,413
w10	255,5252	1915,381	989,5448	318,2123	0,0489	0,2092	0,0752	0,0127	17	41	25	2,9147
w11	1123,781	2000,646	1794,183	157,4724	6,1068	22,1113	13,4719	2,6573	99	337	208	39,7237
w12	1227,777	2000,646	1800,646	155,079	1,3630	32,8944	20,1776	4,5962	21	521	313	70,6490
w13	493,989	2000,646	1614,062	319,8066	0,0817	2,1791	0,4588	0,3529	27	701	163	126,7996

Inércias	Função Objetivo (€)				Tempo de execução (s)				Número de Iterações			
	Min	Max	Mean	STD	Min	Max	Mean	STD	Min	Max	Mean	STD
w14	473,1102	1983,957	1484,764	278,2137	0,0822	0,2753	0,1064	0,0129	28	51	37	3,3480
w15	930,7379	2000,645	1747,196	176,4664	0,1834	3,0088	0,5600	0,3146	64	972	193	108,3896
w16	77,55506	1809,204	793,7311	318,4755	0,0204	1,9284	0,0488	0,0694	6	506	16	19,4170
w17	1154,965	2000,646	1807,083	151,7726	0,0625	3,5692	1,3244	0,5119	21	1232	440	170,1553
w18	776,7735	1999,369	1600,276	229,6418	0,1841	0,5197	0,3319	0,0568	67	185	116	19,4069

Como pode ser observado pela Tabela 5 a comparação é feita através de três parâmetros, sendo, para cada um deles, apresentado o valor mínimo, o médio, o máximo e encontrado o desvio padrão. Considera-se que o parâmetro que corresponde ao valor obtido pela função objetivo é mais relevante do que os outros dois, pois a intenção do problema é obter o máximo de lucro. O parâmetro tempo também deve ser tido em consideração, pois em ambientes de negociação o tempo de decisão tem muita influência nos possíveis lucros.

Na Figura 25 estão representados os resultados atendendo ao parâmetro objetivo. A partir da figura é possível concluir que a maioria das estratégias de inércia utilizadas conseguiu obter um resultado máximo muito bom. A estratégia de inércia que obteve melhor resultado foi a w17, com 2000,64557535607 €, seguindo da estratégia w9 com uma diferença de 0,0000000110% e a estratégia w13 com 0,0000000591% de diferença relativamente ao melhor resultado. Como se pode observar pela Figura 25 estes foram os três melhores resultados, mas é impossível visualizar as diferenças descritas.

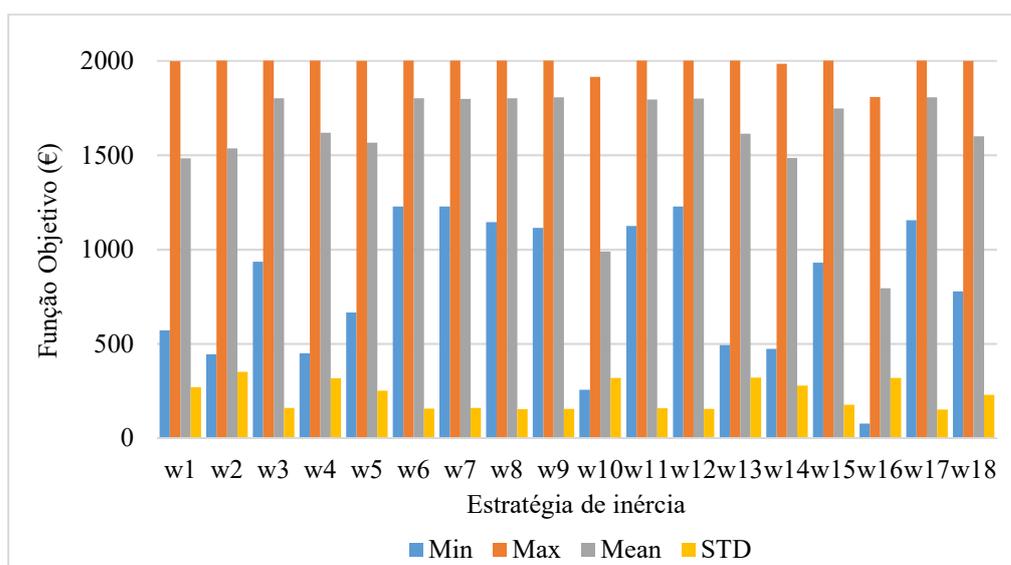


Figura 25 - Resultados do parâmetro função objetivo, para as diferentes estratégias de inércia

As outras medidas apresentadas no gráfico são: a média das 1000 simulações feitas para cada estratégia de inércia, o mínimo valor ao qual se chegou em cada estratégia e o desvio padrão para cada um dos grupos das 1000 simulações. Neste caso, como o problema é de maximização e o ideal é escolher a estratégia que obtenha um máximo, mínimo e uma média que seja máximos no conjunto. O desvio padrão espera-se que seja o menor, pois esta medida representa a disparidade entre os resultados e quanto menor melhor.

No que diz respeito ao tempo de execução, os resultados, sob a forma de gráfico, estão expressos na Figura 26 e aí são apresentadas as mesmas medidas também expostas na Figura 25. Neste caso e para este parâmetro interessa uma estratégia de inércia que tenha uma média de tempos baixa e um desvio padrão pequeno, pois isso significa que os restantes resultados se aproximam da média.

A estratégia que apresenta uma média de menores tempos de execução é a w16 com 0,0488 segundos, seguida da estratégia w10 com 54,1% e da w14 com 118% de diferença relativamente ao menor valor encontrado. Pela Figura 26, não é possível discriminar os valores mais pequenos.

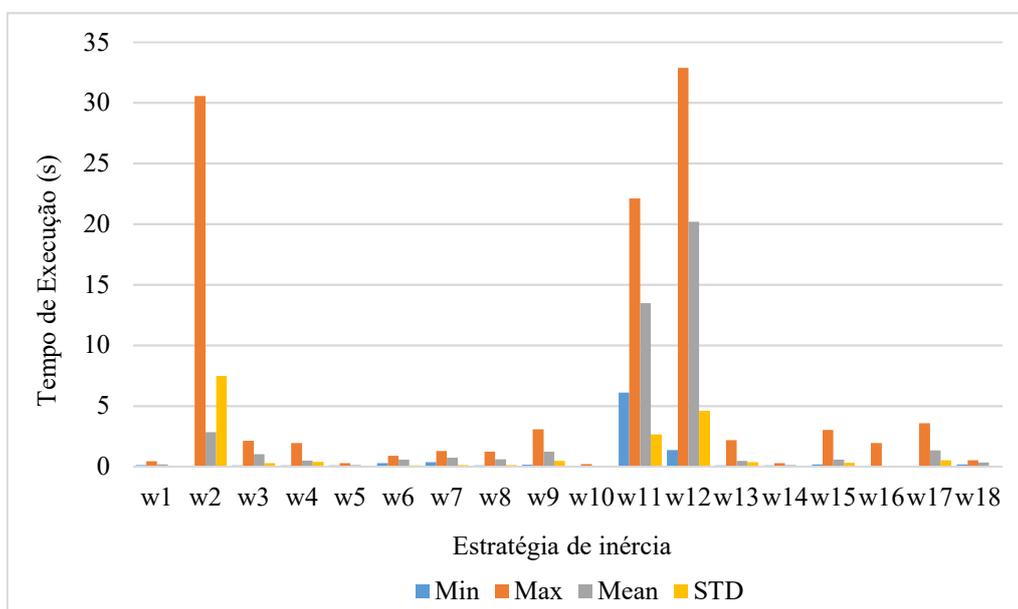


Figura 26- Resultados do parâmetro tempo, estratégias de inércia

Como se pode observar na Figura 26 as estratégias w2, w11 e w12 são as estratégias que apresentam os maiores valores de média e desvio padrão, o que significa que têm um tempo de execução maior e poderão ser excluídos pela análise deste parâmetro.

Na Figura 27 estão expressos os resultados relativamente ao número de iterações. Também neste caso, à semelhança do parâmetro tempo, vão ser apresentados os melhores resultados relativamente à média e ao desvio padrão.

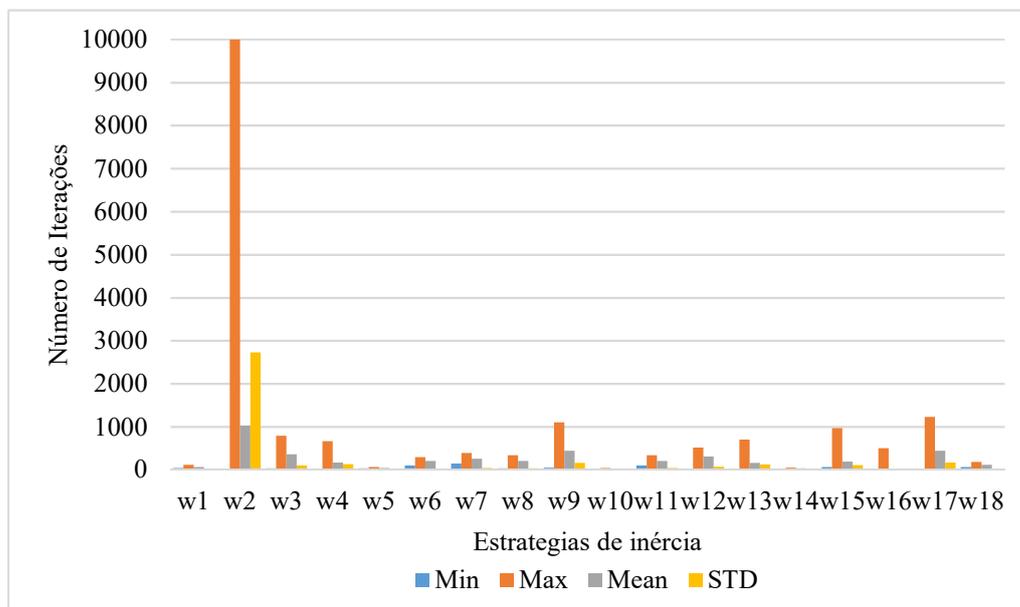


Figura 27 - Resultados para o parâmetro iterações, estratégias de inércia

Pela análise da Figura 27 a estratégia de inércia w2 pode ser excluída, pois apresenta uma média e um desvio padrão muito superiores em relação aos apresentados, a estratégia w16 é a que apresenta um menor número médio de iterações seguindo-se a estratégia w10 e a w14.

Na Tabela 6 são apresentados os resultados para as três melhores estratégias de inércia para cada parâmetro de modo a ser possível mais facilmente fazer comparações.

Tabela 6 -Comparação entre os parâmetros

	Legenda	Valor máximo da função objetivo (€)	Tempo de execução médio (s)	Número médio de iterações
Melhores estratégias segundo o parâmetro objetivo	w17	2000,645575	1,324371685	440,397
	w8	2000,645574	0,580862187	208,057
	w13	2000,645574	0,458776606	162,88
Melhores estratégias segundo o parâmetro tempo	w16	1809,203517	0,048799327	15,588
	w10	1915,380759	0,075177866	25,416
	w14	1983,957282	0,106428157	36,835
Melhores estratégias segundo o parâmetro iterações	w16	1809,203517	0,048799327	15,588
	w10	1915,380759	0,075177866	25,416
	w14	1983,957282	0,106428157	36,835

Como pode ser observado na Tabela 6, as estratégias que apresentam melhores resultados para o parâmetro função objetivo não se repetem nos outros dois parâmetros, o que pode levar a inferir que, quando o tempo médio e o número de iterações médios são maiores, o PSO obtêm melhores resultados. Podemos considerar também que, as estratégias que apresentam um menor número médio de tempo de execução apresentam igualmente um menor número de iterações médias.

Atendendo a estes resultados, optou-se por escolher uma estratégia de inércia intermédia que concilie os três parâmetros, a estratégia w6. Em termos de função objetivo, o máximo encontrado é muito próximo da estratégia de inércia w17, ao nível de resultados médios aproxima-se muito do máximo, e o desvio padrão, dentro do contexto de resultados, é dos menores. No que respeita ao tempo, em média, uma otimização com a estratégia w6 demora aproximadamente 6 segundos o que pode considerar-se um bom tempo. Nas iterações apresenta um número médio dentro do contexto das outras estratégias.

Em seguida, na Tabela 7, são apresentados os resultados obtidos com a aplicação das variantes do PSO. Os parâmetros utilizados no PSO *standard* também foram utilizados nestas variantes, à exceção da variante QPSO que não utiliza estratégia de inércia. Nas restantes foram utilizadas a estratégia de inércia mais básica a w1, que é uma inércia constante.

Tabela 7- Resultados para as variantes do PSO

Variante PSO	Valor da função Objetivo (€)				Tempo de Execução (s)				Número de Iterações			
	Min	Max	Mean	STD	Min	Max	Mean	STD	Min	Max	Mean	STD
EPSO	482,822	2000,645	1579,395	307,018	0,597	251,121	27,930	54,814	36	10000	1620,589	3173,915
QPSO	320,735	1998,944	1231,961	305,612	0,026	0,784	0,292	0,116	3	193	60,974	35,205
NPSO-LRS	1416,429	2000,646	1762,368	144,416	0,033	4,176	1,500	0,466	7	943	362,754	112,686
MPSO-TVAC	1416,616	2000,646	1947,159	133,266	5,282	28,181	6,841	0,871	398	10000	491,648	60,161

Na Figura 28 é possível observar, em formato de gráfico, os resultados obtidos para o parâmetro objetivo das variantes do PSO aplicadas. Foram também adicionados os resultados do PSO – w1 para estabelecer comparações.

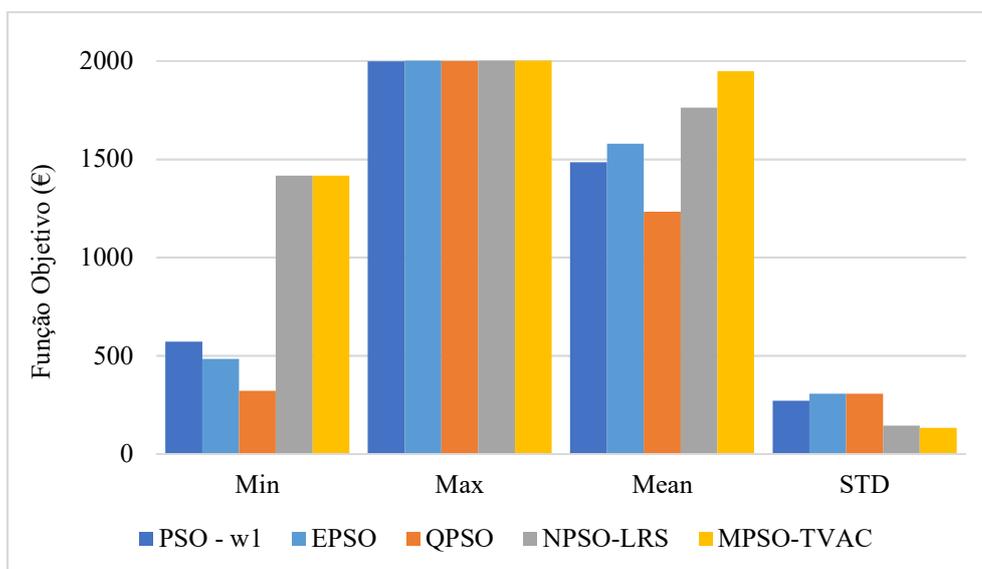


Figura 28 - Comparação dos valores para o parâmetro objetivo, das variantes PSO

Como se pode ver na Figura 28, todas as versões conseguiram chegar a máximos muito próximos uns dos outros, embora nas outras medidas estatísticas diverjam, nomeadamente em termos de mínimo. A versão QPSO foi a que registou um menor mínimo. Embora não se consiga perceber pela Figura 28 nem pela Tabela 7, a versão que registou um mínimo maior foi o MPSO – TVAC. O MPSO-TVAC foi também o algoritmo que registou um máximo mais elevado com 2000,64557541745 €, o NPSO-LRS e o EPSO obtiveram igualmente valores muito próximos, embora menores. Na média das iterações o MPSO-TVAC foi o algoritmo que registou o maior valor como é possível inferir a partir da Figura 28. Segundo o desvio padrão, o MPSO-TVAC também registou o melhor resultado do conjunto com o menor valor. O desvio padrão deste método é também o menor. A variante NPSO-LRS apresenta resultados muito próximos aos do MPSO-TVAC, embora um pouco abaixo na qualidade de resultados, seguida da variante EPSO.

Na Figura 29 é feita a análise das variantes do PSO aplicadas em termo de tempo de execução.

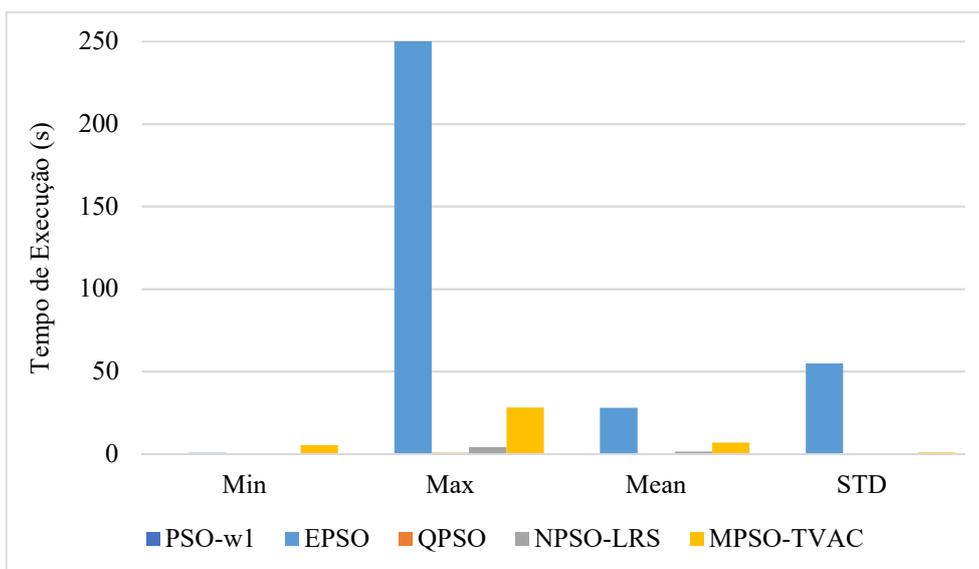


Figura 29- Comparação dos valores para o parâmetro tempo, para as variantes PSO

Como é possível observar o EPSO é o algoritmo que apresenta valores mais elevados. Assim, neste caso, pela análise ao tempo de execução, o EPSO seria um algoritmo a descartar e os algoritmos NPSO-LRS e QPSO apresentam os menores valores em ambas as medidas estatísticas.

Na Figura 30 estão representados os resultados relativamente ao número de iterações para as variantes do PSO aplicadas.

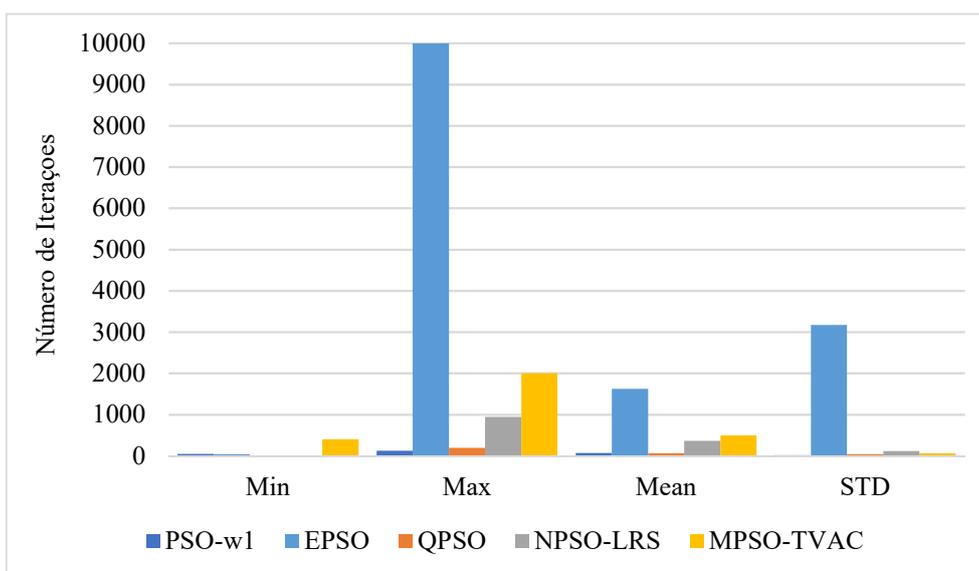


Figura 30 -Comparação dos valores para o parâmetro iterações, variantes PSO

À semelhança dos resultados representados na Figura 29, o EPSO também demonstra que é o algoritmo que, em média, precisa de mais iterações para convergir.

Pela análise dos três parâmetros podemos concluir que o NPSO-LRS e o MPSO-TVAC, dentro das variantes do PSO, são as que apresentam melhores resultados, mostrando um maior equilíbrio entre a qualidade de resultados obtida, a fiabilidade dos seus resultados, o tempo de execução, e o número de iterações necessário para chegar a uma solução.

4.2.3. RESULTADOS DA METODOLOGIA BASEADA NO AG

Na Tabela 8 são mostrados os resultados da aplicação das variantes do AG escolhidas para a aplicação ao problema, sendo elas a AG 1 – *crossover* de um ponto, AG 2 – *crossover* de dois pontos e a AG 3 – mutação de acordo com o *fitness*. Estas variantes são fruto da alteração de determinados parâmetros. No final da comparação é escolhida a melhor variante do AG.

Tabela 8 - Resultados para AG

AG variante	Valor da função Objetivo (€)				Tempo de Execução (s)				Número de Iterações			
	Min	Max	Mean	STD	Min	Max	Mean	STD	Min	Max	Mean	STD
AG 1	1545,451	2000,624	1971,173	76,410	5,094	9,226	7,478	0,679	1915	3076	2625,148	218,034
AG 2	1453,132	2000,615	1971,422	77,122	5,001	9,426	7,494	0,685	1884	3088	2625,586	219,248
AG 3	1444,391	2000,622	1971,088	77,534	5,031	9,361	7,497	0,682	1889	3121	2624,491	218,845

Como podemos observar na Tabela 8 o valor da função objetivo a variante AG 1 foi a que apresentou um maior valor e também apresenta um menor valor de STD, embora que a variante AG 2 é a que apresenta uma média maior de função objetivo. Em termos de tempo de execução é também AG 1 que apresenta um menor tempo de execução tanto em termos médios como em valor máximo registado. Nos números de iterações é também a variante que apresenta o valor mais inferior tanto em termos de média como de número máximo atingido.

Na Figura 31 estão representados os resultados das variantes do AG para os valores obtidos na função objetivo.

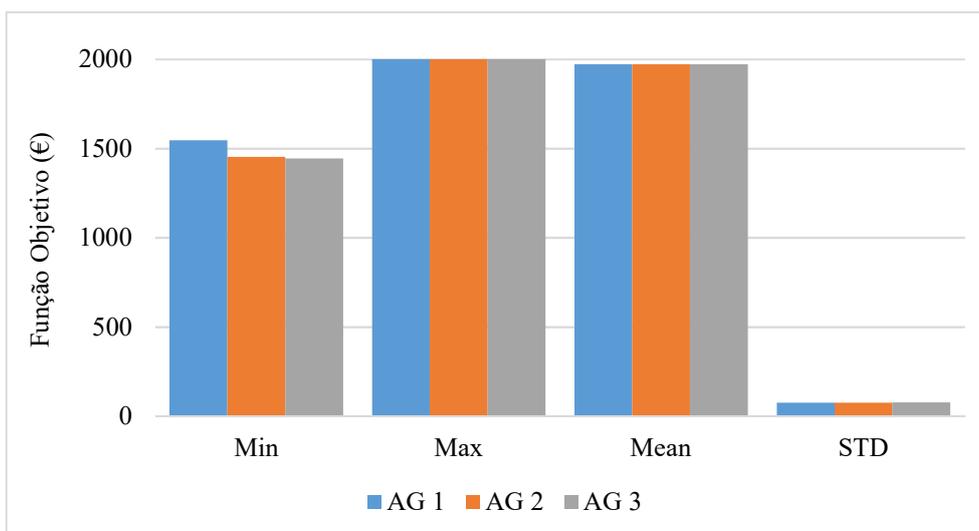


Figura 31 - Comparação dos valores para o parâmetro objetivo, variantes AG

Como se pode observar pela Figura 31, não existe grande variabilidade nos resultados encontrados quando comparados com as variantes do PSO. Uma das grandes diferenças encontradas é o valor da média que é superior, e o valor do desvio padrão que é inferior aos encontrados nas variantes do PSO. O facto da média encontrada estar muito perto do valor máximo encontrado e o desvio padrão ser pequeno revela que os resultados encontrados não têm muita variabilidade, o que pode ser um fator importante na escolha do algoritmo para resolver o problema.

Na Figura 32 estão representados os resultados para o tempo de execução das variantes do AG.

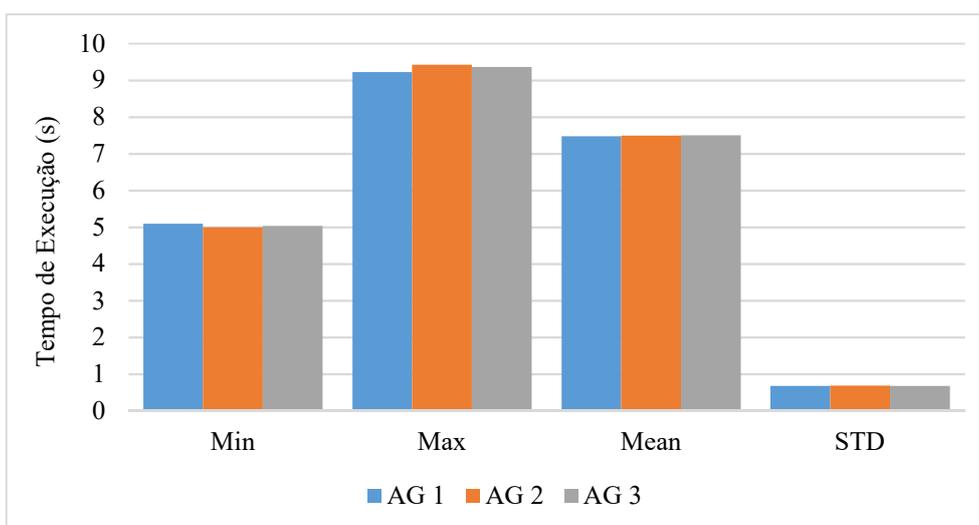


Figura 32- Comparação dos valores para o parâmetro tempo de execução, das variantes AG

Como se pode observar na Figura 32, assim como na Figura 31, não existe muita variabilidade dos resultados entre as variantes implementadas. É possível concluir, a partir da observação do gráfico que, as variantes do AG obtiveram uma média de aproximadamente 7,5 segundos sendo que é superior à média obtida pelas variantes do PSO, exceto o EPSO que apresentou um valor mais elevado. Nestes resultados, o desvio padrão apresentado também é bastante bom, o que quer dizer que as simulações não apresentam valores de tempos de execução muito distantes da média.

Na Figura 33, estão expostos os resultados referentes ao número de iterações.

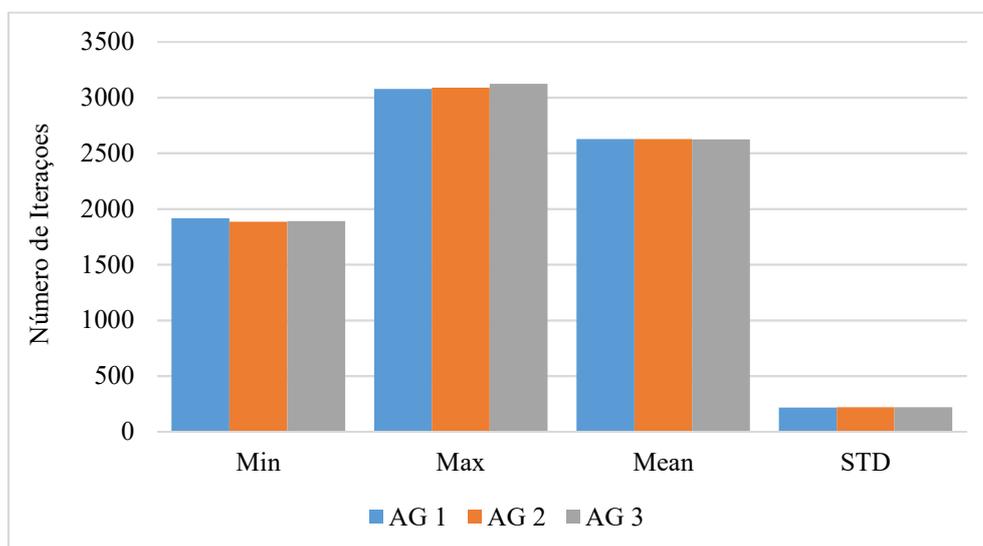


Figura 33 - Comparação dos valores para o parâmetro iterações, variantes AG

No que diz respeito ao número de iterações, os resultados também são homogêneos dentro das variantes do AG implementadas. Como se pode observar, o número de iterações neste caso é muito maior quando comparado com o número encontrado pelas variantes do PSO.

Após a análise dos resultados das variantes do AG podemos concluir que, em termos de número de iterações e tempo de execução, este algoritmo apresenta valores maiores, mas no que toca a valores de função objetivo apresenta uma média mais próxima do valor máximo encontrado. No valor máximo encontrado ambos os algoritmos obtiveram valores muito similares. Postos estes resultados, e como não existe grande diferença de resultados entre as variantes para os três parâmetros, optou-se por escolher a variante do AG que utiliza o *crossover* de 2 pontos o AG 2, com a utilização de ferramentas estatísticas (subcapítulo

4.2.5) é feita uma melhor explicação da razão da escolha, e será esta a utilizada para resolver o problema multiobjetivo.

4.2.4. RESULTADOS DA METODOLOGIA BASEADA NO SA

Na Tabela 9 são apresentados os resultados para as variantes do SA aplicadas, sendo elas o SA 1 (equação (3.55)), SA 2 (equação (3.56)), SA 3 (equação (3.57)) e o SA 4 (equação (3.58)). À semelhança do que foi feito no PSO e AG, neste também vão ser apresentados os resultados referentes aos três parâmetros, função objetivo, tempo de execução e número de iterações.

Tabela 9 - Resultados SA

Variante SA	Valor da função Objetivo (€)				Tempo de Execução (s)				Número de Iterações			
	Min	Max	Mean	STD	Min	Max	Mean	STD	Min	Max	Mean	STD
SA 1	1781,481	1927,242	1884,045	55,501	0,495	0,868	0,551	0,021	1720	1907	1831,357	26,064
SA 2	1782,445	1933,566	1882,495	56,438	0,497	1,163	0,555	0,036	1720	1900	1830,232	25,772
SA 3	1782,520	1930,147	1883,281	56,020	0,504	0,846	0,555	0,026	1720	1898	1830,306	26,359
SA 4	980,919	1925,366	1616,227	203,593	0,129	0,227	0,149	0,011	449	597	487,406	28,276

A Tabela 9 mostra os resultados obtidos pelas variantes do SA implementadas, em termos de função objetivo a variante SA 2 foi a que obteve o maior máximo entre as variantes do SA, em termos de valores médios a SA 1 foi a que teve o valor maior do conjunto. Em termos de tempo de execução a SA 4 foi a que obteve o menor tempo em termos médios, mas este faz-se refletir nos valores da função objetivo onde esta variante perde, por esta razão as outras três variantes apresentam valores muito parecidos no tempo de execução e seria uma melhor escolha. Em termos de número de iterações o SA 2 e SA 3 apresentam o menor número em termos médios.

Na Figura 34 estão representados os valores referentes à função objetivo para as variantes do SA implementado.

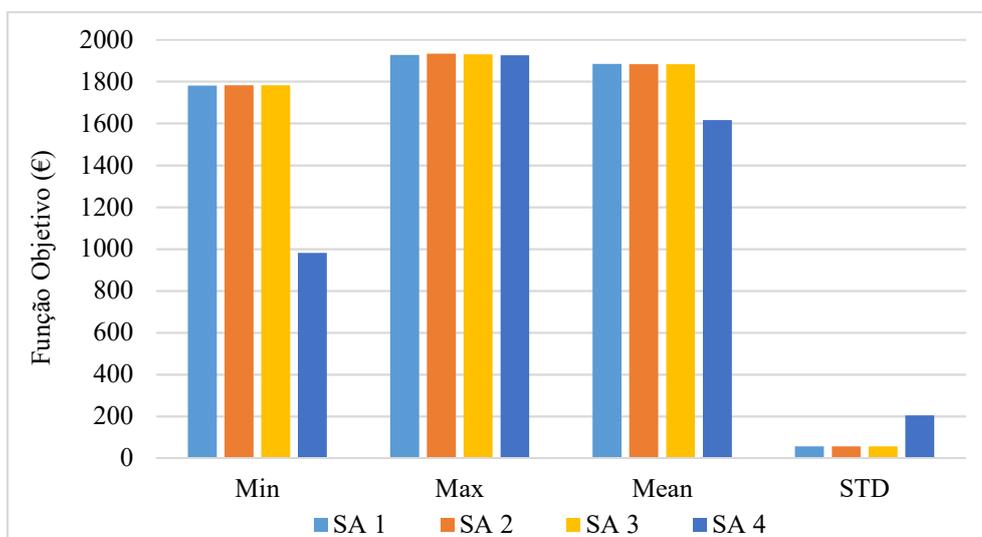


Figura 34 - Comparação dos valores para o parâmetro objetivo, variantes SA

Como se pode observar na Figura 34, dentro das variantes do SA aplicadas existe variabilidade nos resultados, como também pode ser verificado pelos resultados na Tabela 9. Quando comparados os valores máximos destas variantes com as dos outros algoritmos, estas são relativamente menores. O desvio padrão das variantes temperatura e probabilidade 1, 2 e 3 são bons, pois apresentam um valor pequeno o que significa que os valores encontrados aproximam-se da média, que, por sua vez, também é consideravelmente boa.

Na Figura 35 são apresentados os resultados para o tempo de execução de cada variante do SA aplicada.

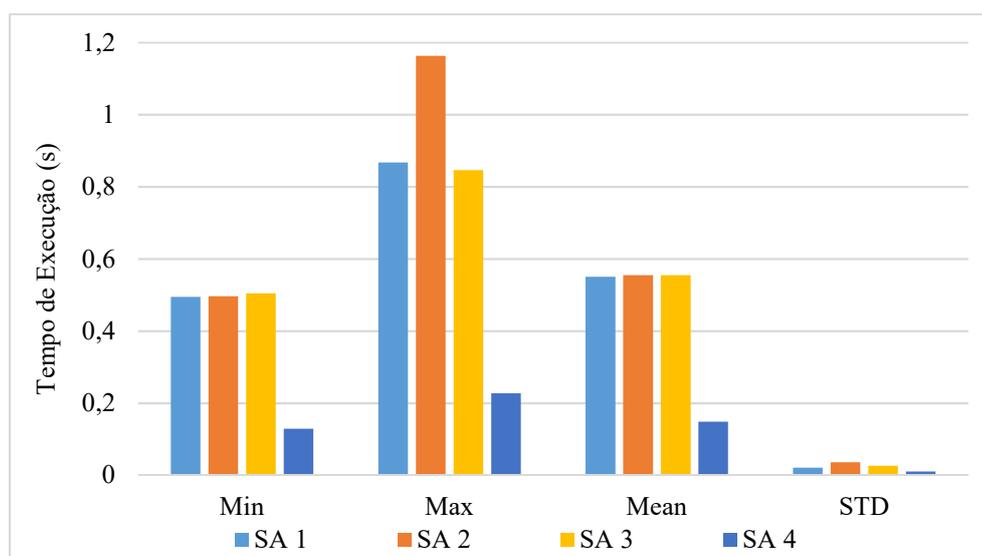


Figura 35 - Comparação dos valores para o parâmetro tempo, variantes SA

Como pode ser observado na Figura 35, em termos médios, as temperaturas e probabilidade 1 e 2 apresentam os maiores valores com cerca de 0,5 segundos. Em termos de desvio padrão as 4 variantes apresentam um valor muito baixo o que demonstra, que os tempos de execução são próximos dos valores da média.

Na Figura 36 são apresentados os resultados para o número de iterações para as variantes do SA.

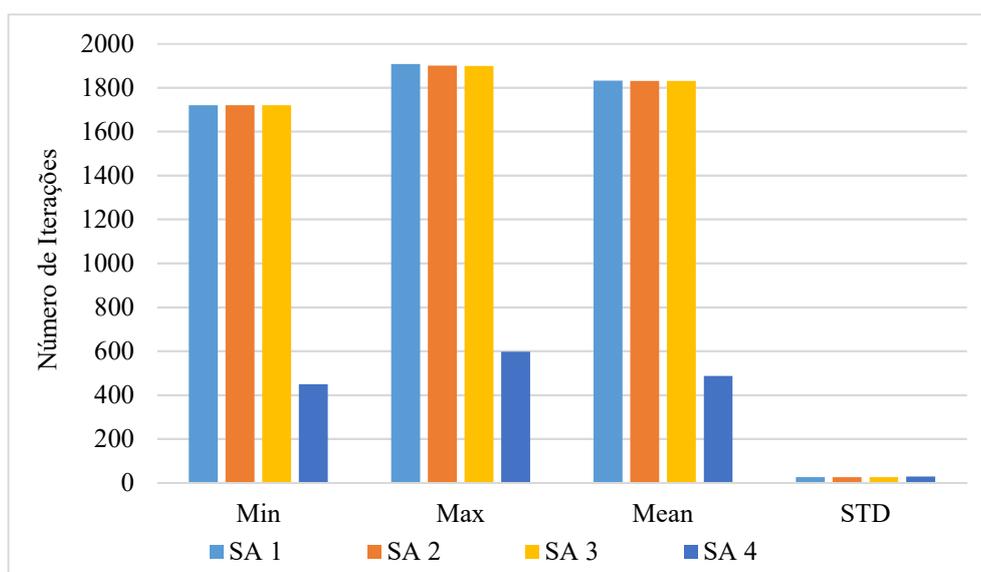


Figura 36 - Comparação dos valores para o parâmetro iterações, variantes SA

Como é possível observar pela Figura 36, em termos médios as temperaturas e probabilidade 1, 2 e 3 apresentam um número maior de iterações.

Pelas comparações feitas dentro dos três parâmetros analisados, optou-se por escolher a variante SA 1, para justificar esta escolha recorreu-se a elementos estatísticos presentes no subcapítulo 4.2.5. Quando comparados com a variante SA 2 e SA 3, não existem grandes diferenças mas, no conjunto dos três parâmetros, a variante SA 1 apresenta maiores valores, as outras duas variantes, embora no número de iterações e tempo de execução obtenham melhores valores, no caso da função objetivo os valores encontrados são inferiores.

4.2.5. ANÁLISE ESTATÍSTICA DOS RESULTADOS OBTIDOS

De seguida são analisados, com mais pormenor, os resultados das variantes de cada método escolhidas como mais adequadas. É apresentado o diagrama de extremos e quartis para os

algoritmos/variantes, assim como uma explicação em cada um. É ainda feita uma análise dos intervalos de confiança (IC) para os mesmos algoritmos/variantes, e a mesma atenderá aos resultados obtidos na função objetivo das 1000 simulações executadas. Em anexos são apresentados todos os diagramas de extremos e quartis para todos os algoritmos/variantes implementados ao problema, 0 e 0.

O diagrama de extremos e quartis é construído com base nos parâmetros observados a partir dos resultados obtidos nas simulações, sendo eles o máximo e o mínimo, e a partir de três parâmetros calculados: a mediana, o valor do 1º quartil e 3º quartil. Esta ferramenta é muito útil, pois permite obter uma representação de como os dados se distribuem quanto à maior ou menor concentração, simetria ou existência de valores fora do contexto dos resultados. É também muito útil na comparação de grupos de resultados.

Na Figura 37 é apresentado o diagrama de extremos e quartis para a variante do PSO com a estratégia de inércia w6.

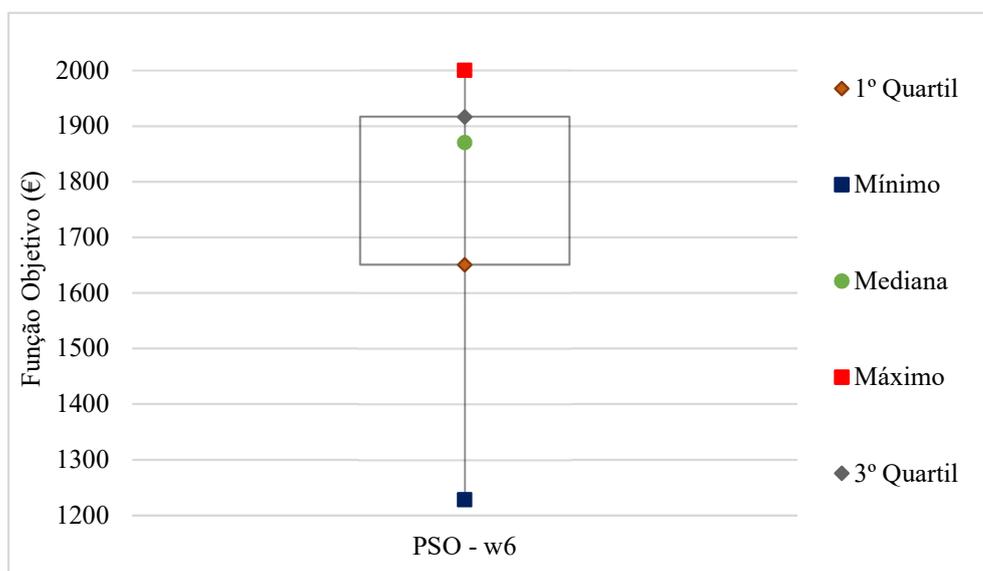


Figura 37 - Diagrama de extremos e quartis para PSO - w6

A partir o diagrama de extremos e quartis da Figura 37, podemos concluir que 25% dos resultados estão entre o valor mínimo registado, 1227,777 €, e o valor do 1º quartil 1650,599 €, e os outros 25% das observações estão compreendidos entre o valor do 3º quartil 1916,575 €, e do máximo 2000,646 €. Os 50% restantes então compreendidos entre o 1º quartil e 3º quartil. É possível constatar que existe algum enviesamento na parte superior do diagrama,

pois os dados na parte inferior são mais dispersos, ou menos concentrados. Na parte central existe também algum enviesamento da parte superior. O valor da mediana 1870,312 € está mais próximo do valor do 3º quartil do que do 1º quartil, o que quer dizer que os valores estão mais concentrados na parte superior do diagrama, portanto, mais próximos do valor máximo.

Na Figura 38 esta representado o intervalo de confiança de 95% para o valor esperado.

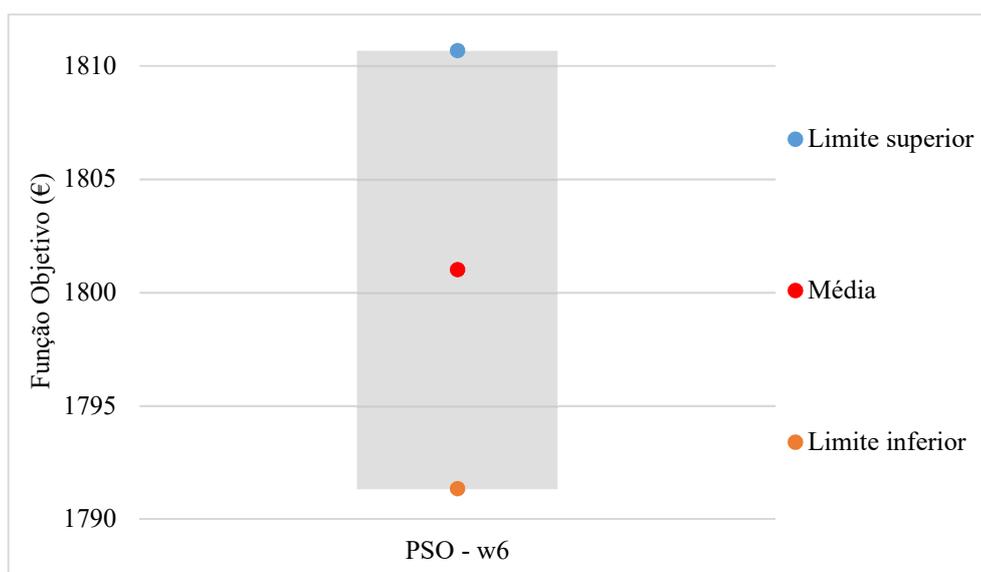


Figura 38 - Intervalo de confiança para o valor esperado, PSO-w6

No gráfico da Figura 38 está representado o IC de 95%, assim como os valores do limite inferior 1791,343 €, a média 1801,005 € e o limite máximo 1810,667 €. Desta representação podemos inferir que, segundo a amostra obtida através dos resultados da função objetivo, existe uma probabilidade de 95% de ocorrer um valor entre o limite máximo e o limite mínimo e, neste caso o erro ou tolerância é de 9,662.

O diagrama de extremos e quartis para o algoritmo NPSO – LRS está representado na Figura 39.

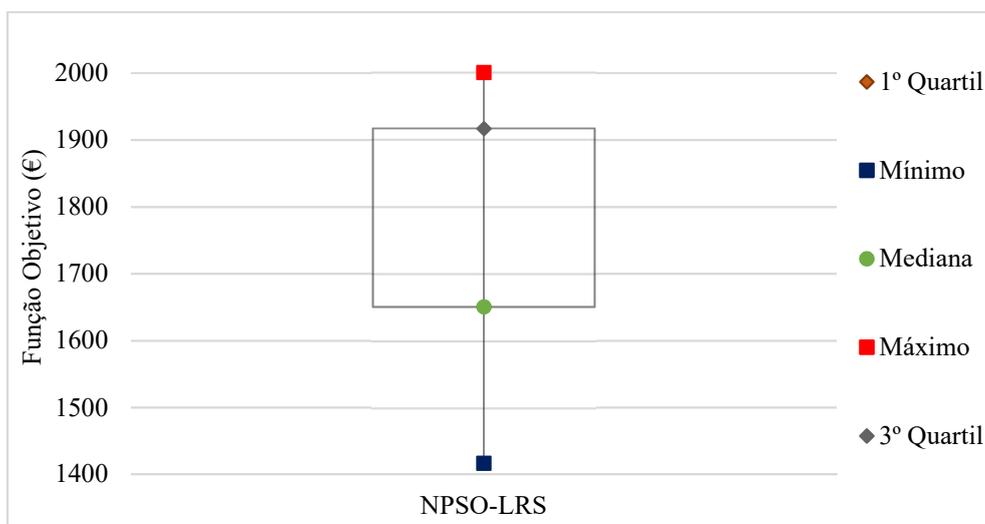


Figura 39 -Diagrama de extremos e quartis para NPSO – LRS

Neste caso temos um diagrama onde 25% das observações estão entre 1416,429 € e 1650,599 € que são respetivamente o mínimo e o valor do 1º quartil. Entre o 3º quartil 1916,611 € e o máximo 2000,646 € foram também observados 25% dos registos. Os restantes 50% foram registados entre o valor do 1º quartil e 3º quartil. Como se pode visualizar o comprimento da linha do mínimo ao 1º quartil é maior do que a linha do 3º quartil ao máximo, o que significa que as observações estão mais concentradas na parte superior do diagrama. É também possível constatar que o valor da mediana 1650,599 está mais próximo do valor do 1º quartil, significa portanto que existe um enviesamento na parte inferior do diagrama. Na Figura 40 está representado o IC de 95% para esta variante.

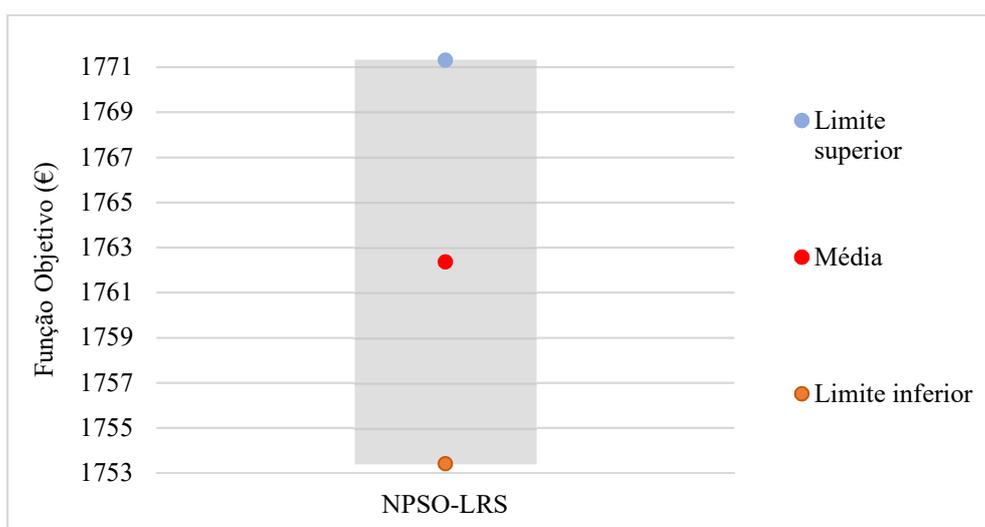


Figura 40 - Intervalo de confiança para o valor esperado, NPSO-LRS

O IC de 95% tem como extremos, 1753,422 € e 1771,315 € que são respetivamente o limite inferior e o limite superior. Com estes resultados, e segundo o IC calculado existe 95% da probabilidade de ocorrer o valor entre o extremo mínimo e máximo. O valor do erro ou tolerância é de 8,946. Comparando os resultados desta variante com a variante PSO-w6 observou-se que o valor do erro é menor no NPSO-LRS, mas os limites do IC no PSO-w6 são mais elevados. Isto deve-se ao facto do valor da média ser mais elevado no PSO-w6.

Na Figura 41 - Diagrama de extremos e quartis para AG 2 Figura 41 está representado o diagrama de extremos e quartis para o AG 2. Na figura estão feitas duas representações Figura 41 a) e a Figura 41 b). A representação da direita (Figura 41 a)) mostra todos os pontos da legenda, a representação da esquerda foi concebida, uma vez que na da direita (Figura 41 b)) não é possível observar, com pormenor, os valores do 1º quartil até ao limite máximo.

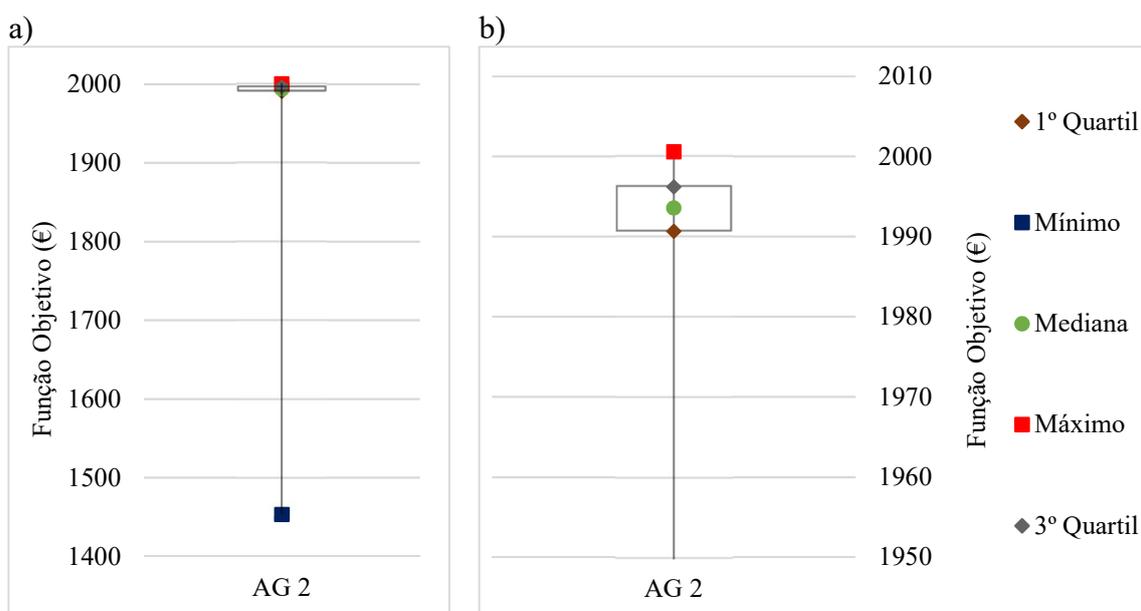


Figura 41 - Diagrama de extremos e quartis para AG 2

Neste caso, podemos constatar que existe uma maior concentração dos dados na parte superior, pois do valor do 1º quartil, 1990,683 € até ao valor máximo 2000,615 € estão 75% das observações. Assim, pela visualização do diagrama, pode concluir-se que existe um enviesamento na parte superior do gráfico. Pelo comprimento da linha, que une o mínimo 1453,132 € ao 1º quartil, presume-se que os 25% dos dados que constituem este intervalo se encontram mais dispersos. O valor da mediana 1993,616 €, como se pode observar, encontra-se no centro do retângulo construído entre o 1º quartil e o 3º quartil 1996,244 €.

Na Figura 42 esta represento o IC de 95% para o AG 2.

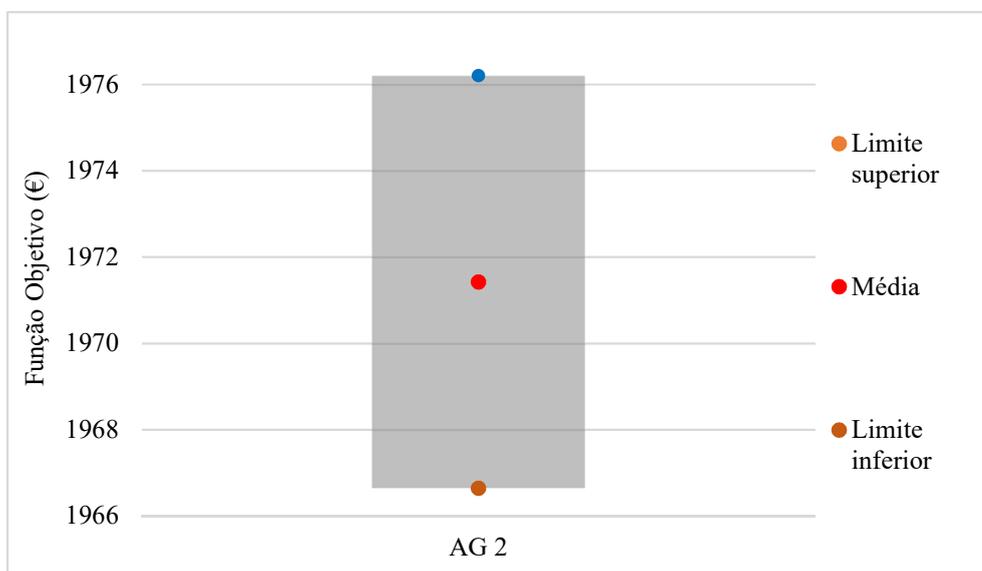


Figura 42 -Intervalo de confiança para o valor esperado, AG 2

Neste caso temos um limite inferior de 1966,645 € e um limite superior de 1976,200 €. O valor do erro ou tolerância é de 4,776, o que representa cerca de metade do erro registado nos IC calculados nos outros dois algoritmos. Neste algoritmo o IC é menor, o que revela, comparativamente com os outros, que este algoritmo é mais confiável, pois, com a mesma probabilidade, a gama de valores que podemos obter é muito menor neste caso. Outra das características que pode ser observada é o valor da média ser mais elevado, o que revela que este algoritmo tem melhor performance que os anteriores.

Na Figura 43 está representado o diagrama de extremos e quartis para o SA 1. Neste caso também houve a necessidade de fazer a representação com ampliação, pois na figura da direita (Figura 43 a)) na era perceptível a parte superior do diagrama. Os resultados são muito parecidos aos resultados encontrados no algoritmo anterior.

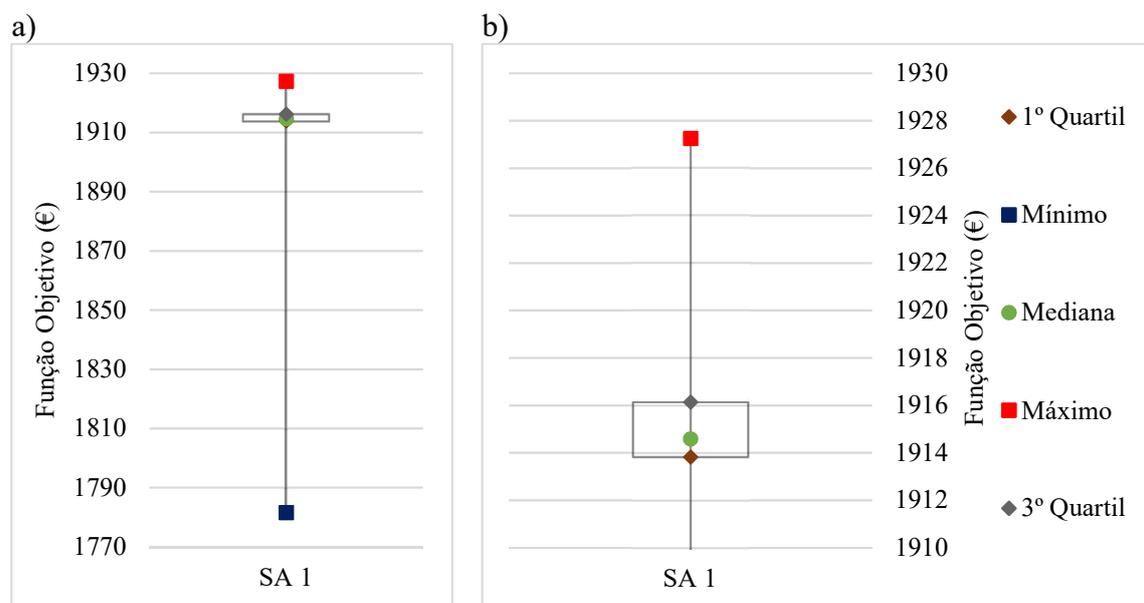


Figura 43 - Diagrama de extremos e quartis para SA 1

Como é possível observar existe uma maior concentração dos dados na parte superior, pois entre o valor do 1° quartil 1913,816 € e o valor máximo 1927,242 € foram registadas 75% das otimizações. O comprimento da linha que une o ponto mínimo 1781,481 € ao 1° quartil, quando comparado com o comprimento do 3° quartil 1916,126 € ao máximo, é muito maior. Isto significa que os dados na parte inferior são mais dispersos.

A Figura 44 expressa o IC de 95% para o SA 1.

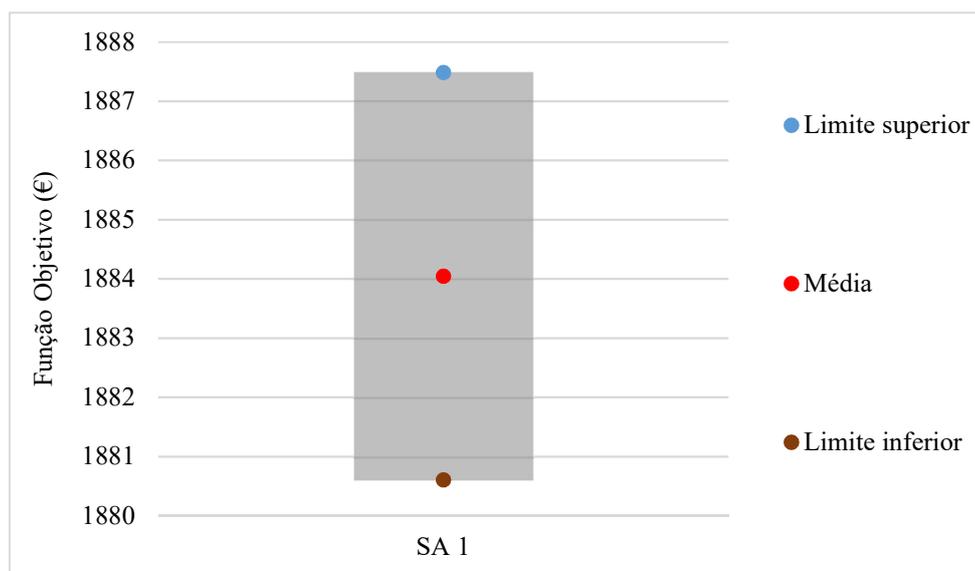


Figura 44 – Intervalo de confiança para o valor esperado, SA 1

Segundo o intervalo de confiança existe 95 % de probabilidade de ocorrer um valor entre 1887,483 € e 1880,607 € que são, respetivamente o limite superior e o limite inferior. Este algoritmo, do conjunto dos quatro apresentados, foi o que obteve o menor valor de erro, 3,438. O valor da média é 1884,045 €.

Na Tabela 10 é apresentado um resumo dos valores referentes ao digrama de extremos e quartis, e ao IC para os algoritmos seleccionados anteriormente.

Tabela 10 - Tabela de resumo da análise estatística dos vários métodos/variantes, atendendo ao valor da função objetivo (em €)

Algoritmos		PSO-w6	NPSO-LRS	AG 2	SA 1
Diagrama de extremos e quartis	Mínimo	1227,777	1416,429	1453,132	1781,481
	1º Quartil	1650,599	1650,599	1990,683	1913,816
	Mediana	1870,312	1650,599	1993,616	1914,58
	3º Quartil	1916,575	1916,611	1996,244	1916,126
	Máximo	2000,646	2000,646	2000,615	1927,242
IC 95%	Limite inferior	1791,343	1753,422	1966,44	1880,607
	Média	1801,005	1762,368	1971,173	1884,045
	Limite superior	1810,667	1771,315	1975,906	1887,483
	Erro	9,662008	8,946359	4,73346	3,438234

Como é possível observar na Tabela 10, do conjunto dos algoritmos/ variantes escolhidas o que apresentou o maior máximo de função objetivo foi o NPSO-LRS, o SA 1 é o algoritmo que apresenta a menor diferença entre o 1º quartil e o 2º quartil, o que significa que é o algoritmo que apresenta menos discrepâncias nas soluções encontradas. O maior valor mínimo encontrado também foi pelo SA 1.

Nos resultados do IC o SA 1 é o algoritmo mais confiável, pois é o que apresenta o menor valor de erro, embora o AG 2 apresente um maior valor médio de resultados, assim como também mostra o maior valor de limite superior do intervalo de confiança.

Nesta comparação foi apenas abordado o valor da função objetivo, pois considera-se ser o critério mais importante. O valor do tempo de execução nos algoritmos/variantes apresentados também variam. Em termos médios o AG 2 é o que apresenta um maior valor tempo de execução ao contrário do SA 1 que apresenta o menor valor médio. Relativamente ao valor do número de iteração o PSO-w6 é o algoritmo/ variante que tem o menor valor médio de iteração e o AG 2 apresenta o maior valor médio da mesma.

4.2.6. RESULTADOS COM SOLUÇÃO INICIAL BASEADOS NA HEURÍSTICA PROPOSTA

Na Tabela 11 são apresentados os resultados dos vários métodos, utilizando a solução inicial gerada pela heurística proposta no subcapítulo 3.4. Todos os algoritmos apresentados iniciam, portanto, a sua pesquisa a partir de uma solução já definida pelo conjunto de regras expressas pela heurística. Neste caso os resultados são apenas apresentados para o primeiro período do dia. Os resultados para o primeiro período poderão não refletir a realidade que ocorrerá nos restantes períodos, pois, embora as regras criadas tenham caráter universal, poderão não funcionar de igual forma em alguns dos períodos. É feita a comparação entre os algoritmos com a solução inicial (ST) e sem solução inicial.

Tabela 11 - Resultados com a solução inicial baseada na heurística proposta

Algoritmo s	Valor da função Objetivo (€)				Tempo de Execução (s)				Número de Iterações			
	Min	Max	Média	STD	Min	Max	Média	STD	Min	Max	Média	STD
PSO - w1	571,5	1998,6	1483,8	270	0,117	0,437	0,184	0,035	42	119	64	10,9
PSO - w1 - ST	1805,7	2000,6	1981,1	47,4	0,451	2,288	1,046	0,277	168	872	384	101
EPSO	482,8	2000,6	1579,4	307	0,597	251,12	27,930	54,81 4	36	10000	1621	317 3,9
EPSO - ST	1875,1	2000,6	1972,7	28,4	0,544	181,72	13,168	30,56 8	33	10000	783	180 8,2
QPSO	320,7	1998,9	1232,0	305	0,026	0,784	0,292	0,116	3	193	61	35,2
QPSO - ST	1730,2	2000,6	1939,2	56,4	0,090	0,634	0,282	0,090	11	192	63	26,0
NPSO- LRS	1416,4	2000,6	1762,4	144	0,033	4,176	1,500	0,466	7	943	363	112
NPSO- LRS - ST	1889,1	2000,6	1992,1	20,9	0,866	5,818	1,806	0,499	226	1466	448	122
MPSO- TVAC	1416,6	2000,6	1947,2	133	5,282	28,181	6,841	0,871	398	2000	492	60,2
MPSO- TVAC - ST	1816,7	2000,6	1873,7	85,1	3,518	6,185	4,059	0,232	270	340	298	11,4
AG 1	1545,5	2000,6	1971,2	76,4	5,094	9,226	7,478	0,679	1915	3076	2625	218
AG 1 - ST	1730,2	2000,6	1993,0	40,3	0,006	5,544	4,728	0,743	1	1712	1663	255
SA 1	1781,5	1927,2	1884,0	55,5	0,495	0,868	0,551	0,021	1720	1907	1831	26,1
SA - ST	1945,0	2000,6	1988,3	11,7	0,484	0,889	0,510	0,020	1710	1749	1730	6,4

Como se pode observar pela Tabela 11, quando os algoritmos são executados utilizando a solução inicial gerada pela heurística proposta, os valores observados para a função objetivo sofrem alterações. Os algoritmos que utilizaram a solução inicial como era de esperar, apresentam uma solução mínima maior do que aqueles que não a utilizaram. Em termos de máximo alcançado, a maioria dos algoritmos consegue atingir máximos muito próximos, com ou sem solução inicial. Os algoritmos utilizando a solução inicial apresentam uma média superior aos outros, assim como também apresentam um desvio padrão menor, o que

significa que a gama de resultados quando utilizada uma solução inicial é menor. Em termos de valor de tempo de execução e número de iterações, não se registam grandes diferenças, embora os valores sofram uma diminuição. Pode concluir-se que, a indicação de uma solução inicial apropriada para os algoritmos começarem a pesquisar resultam em pequenas vantagens, como é possível constatar pelos resultados obtidos.

4.2.7. ESCALONAMENTO NOS DIFERENTES MERCADOS

Neste subcapítulo é realizada uma apresentação do escalonamento das quantidades de eletricidade vendida e comprada nos diferentes mercados, resultante da execução dos diferentes métodos. São também apresentados os resultados dos melhores algoritmos nas Tabela 12 e Tabela 13, assim como a média e o desvio padrão calculados a partir dos resultados dos algoritmos apresentados, os valores aqui expostos são para a simulação que encontrou o maior valor de função objetivo.

Tabela 12 - Escalonamento das Vendas

Algoritmo	Vendas (MW)					Total [0,50]
	Spot	Bilaterals	Balancing 1	Balancing 2	Smart Grid	
PSO w6	12,78	15,54	0	0	7,59	35,91
NPSO-LRS	14,65	11,50	0	0	8,58	34,73
AG 2	14,78	11,50	0	0	8,47	34,76
SA 1	20,08	11,52	0	0	8,55	40,14
Média	15,57	12,51	0	0	8,30	
STD	2,72	1,75	0	0	0,41	

Como é possível observar pela Tabela 12, os algoritmos apresentaram resultados semelhantes na venda da eletricidade, o que já era de esperar pois, o valor da função objetivo também é muito parecido. É possível constatar que o desvio padrão é relativamente pequeno, o que demonstra que os valores registados são muito próximos da média. É de realçar que o algoritmo SA 1 apresentou um valor no mercado Spot diferente dos restantes algoritmos, o que fez com que o desvio padrão fosse alterado. No escalonamento das compras de eletricidade, como se pode verificar na Tabela 13, os valores entre os algoritmos não variam muito, apesar do mercado das SG apresentar variações na quantidade de eletricidade comprada, pois no NPSO-LRS e no AG 2 não se registou compra e no PSO w6 e SA 1 registaram-se.

Tabela 13 - Escalonamento Compras

Algoritmo	Compras (MW)					Total [0,40]
	Spot	Bilaterals	Balancing 1	Balancing 2	Smart Grid	
PSO w6	0	3,58	8,35	9,76	4,22	25,91
NPSO-LRS	0	4,73	10,00	10,00	0	24,73
AG 2	0	4,76	10,00	10,00	0	24,76
SA 1	0	4,85	10,00	10,00	5,30	30,14
Média	0	4,48	9,59	9,94	2,38	
STD	0	0,52	0,71	0,10	2,41	

Pela observação do escalonamento, podemos concluir que as restrições impostas foram cumpridas. No caso do mercado Spot unicamente era possível a venda e foi o que ocorreu. No caso dos mercados de ajustes, apenas era possível uma das ações e foi o que se registou. No caso da compra de eletricidade foi extipulado o máximo de 10 MW para cada mercado e, como se pode observar pela Tabela 13, esse máximo foi atingido nos mercados de ajustes. Pelas regras impostas apenas é permitida a venda no total de 50 MW e a compra de 40 MW e como se pode observar pelas Tabela 12 e Tabela 13, na coluna do total, nenhuma simulação ultrapassou esse máximo.

Como se pode observar na Figura 45 existem mercados onde o preço não é constante, e aqui é possível ver a variação.

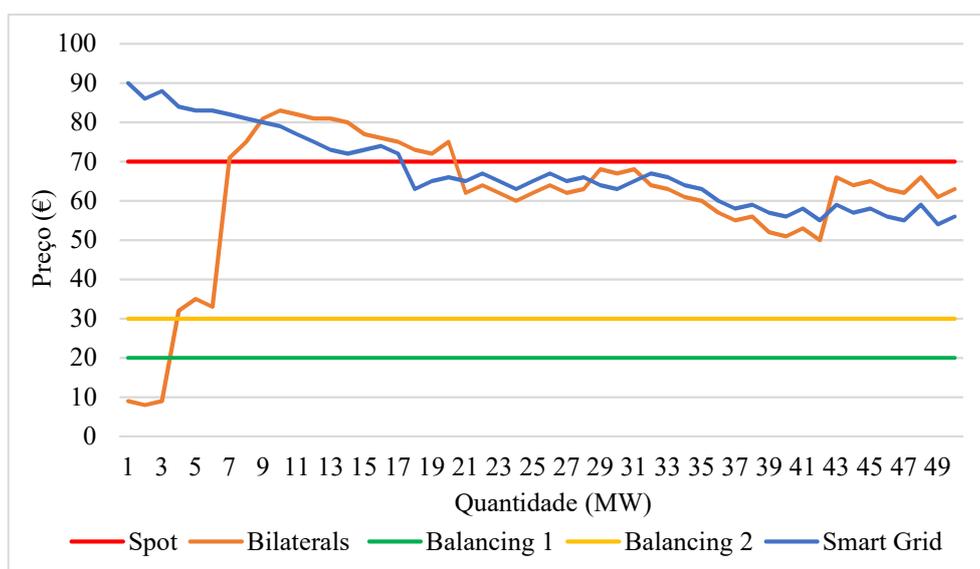


Figura 45 - Preços para o 1º período

Fazendo o cruzamento dos valores do escalonamento de vendas e compras com os valores dos preços, é possível justificar os valores apresentados na Tabela 12 e Tabela 13. Como era de esperar, o modelo implementado irá comprar a eletricidade aos mercados onde o preço será inferior, como é o caso dos mercados de ajustes, uma vez que para a quantidade de 10 MW são os mercados que apresentaram o preço mais baixo. No mercado Bilateral o modelo apresentou compra e venda de eletricidade, sendo que 5 MW foram comprados e dois dos algoritmos também compraram eletricidade no mercado das Smart Grid. Na venda, o modelo vai procurar os mercados onde o valor da venda da eletricidade é mais rentável. Como é possível observar pelos resultados, é mais rentável fazer combinações de mercados e não vender num só mercado. No caso dos resultados expostos, o escalonamento apresentado foi a solução que maior valor de função objetivo mostrou. Um dado curioso, é o facto de, como já foi indicado, haver dois algoritmos que realizaram compras no mercado das Smart Grid's, mas no valor da função objetivo não sofreram grandes alterações, embora tenham mais eletricidade disponível para vender, mas também têm mais despesa na aquisição da mesma, daí não existir diferença no resultado final da função objetivo. Como é de esperar que assim aconteça quando o modelo realiza compras e vendas nos mesmos mercados, estas ações correspondem aos picos de maior e menores preços desses mesmos mercados.

4.3. OTIMIZAÇÃO MULTIOBJETIVO

Tendo em conta os resultados obtidos para o 1º período, foram escolhidos determinados algoritmos para resolver o problema multiobjetivo. Como já foi mencionado no Capítulo 3.1, o problema multiobjetivo de dois objetivos foi substituído por apenas um objetivo, utilizando um fator de ponderação (λ). Neste caso, foram definidos vários níveis de ponderação (pesos). A equação (3.14) é a função objetivo que neste caso vai ser otimizada, interpretando os fatores de pesagens e fazendo variar o valor de λ entre 0 e 1 e o valor da função objetivo vai ser alterado. Quando o valor de $\lambda = 1$ significa, como já foi dito, que o modelo assume o risco total, quando o valor de λ se faz reduzir para 0 o modelo tem em conta o fator risco e a otimização apresentará diferentes valores, tanto de valor objetivo final como de valor das variáveis, que, neste caso, correspondem ao valor de eletricidade comprada e vendida.

De seguida vão ser apresentados os resultados do problema multiobjetivo para o primeiro período com os seguintes valores de $\lambda = \{0,1; 0,15; 0,2; 0,25; 0,5; 0,75; 1\}$, e com a resolução dos diferentes algoritmos escolhidos anteriormente como os mais adequados. O PSO com a estratégia de inércia w6, o NPSO-LRS, o SA 1, o AG 2 e ainda foi utilizado um algoritmo onde é usada a heurística da solução inicial o PSO-ST.

Na Figura 46 está representado o valor do lucro em relação à exposição ao risco.

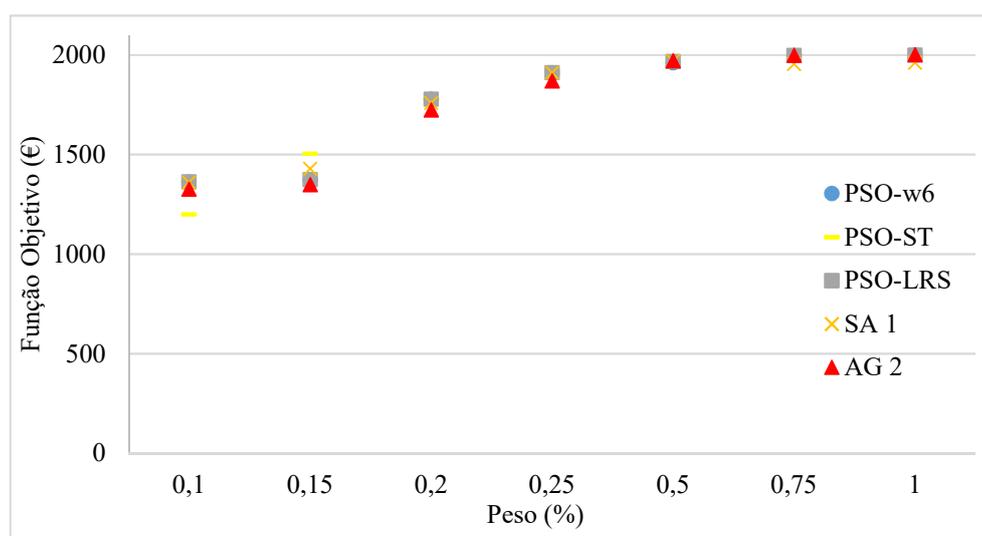


Figura 46 - Lucro em função da exposição ao risco

Os valores representados no gráfico da Figura 46 são referentes aos valores registados pela equação (3.2), que calcula o lucro que é obtido a partir da otimização. Como era de esperar quando a exposição ao risco aumenta o lucro aumenta também, como se pode observar pelos resultados dos diferentes algoritmos. Os algoritmos para cada nível de risco apresentam valores muito parecidos. A Tabela 14 apresenta o valor da média e do desvio padrão existente entre as soluções máximas encontradas pelos algoritmos. Quando comparado o valor do desvio padrão como a grandeza dos valores obtidos pelos algoritmos, pode dizer-se que o desvio padrão é razoavelmente bom.

Tabela 14 - Valores médios e desvio padrão para o lucro nos diferentes níveis de risco

	0,1	0,15	0,2	0,25	0,5	0,75	1
Média (€)	1322,247	1405,524	1763,299	1902,462	1965,445	1988,887	1992,257
STD	62,7324	55,5392	21,04355	16,49513	4,130409	17,52365	16,05288

Os resultados obtidos da otimização tem como objetivo ajudar na construção de cenários para poderem ser apresentados aos utilizadores dos mercados. Neste caso, cada valor de

lucro é resultado de ações de compra e de venda de uma determinada quantidade de eletricidade. Dessa forma, os valores médios apresentados na Tabela 14 são apenas usados para termos comparativos, não podendo ser aproveitados para construir cenários.

Na Figura 47 está representada a comparação dos dados resultantes das simulações efetuadas, referentes ao peso das componentes lucro e risco no valor da função objetivo.

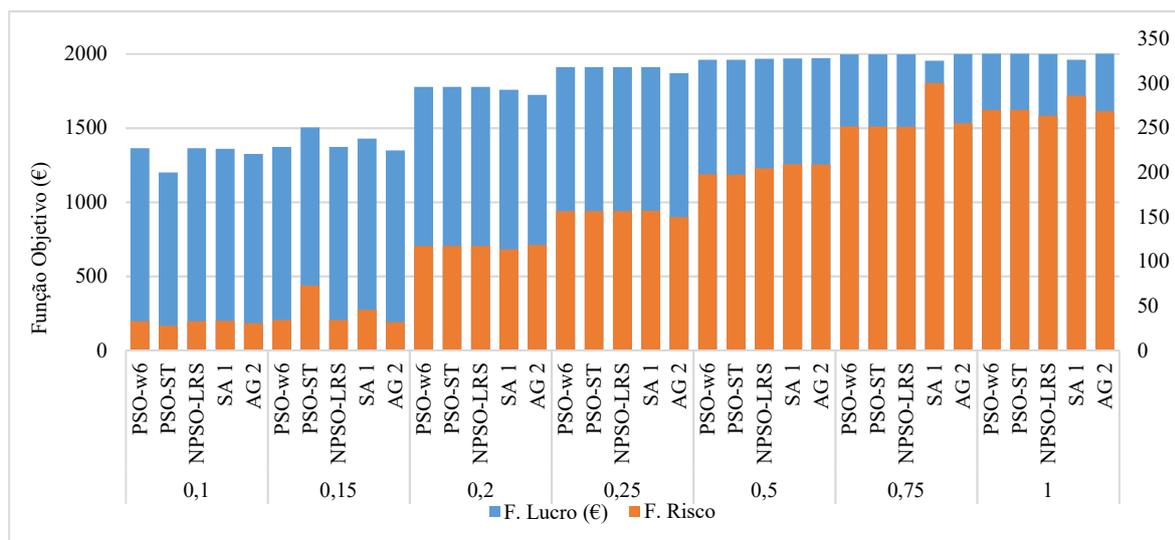


Figura 47 - Valor de lucro e risco dos diferentes algoritmos para os diferentes níveis de risco

Na Figura 47 está representado o valor de lucro em € e o valor do risco, este não possui unidade que possa ser apresentada, o qual se considera adimensional. No eixo horizontal é representada a exposição ao risco e para cada categoria são apresentados os valores encontrados de cada algoritmo. Podemos concluir, que quando a exposição ao risco aumenta o lucro e valor do risco aumentam também. Nas Figura 46 e Figura 47 podemos observar que o lucro tende a estabilizar a partir do valor de $\lambda = 0,5$. No caso deste modelo, se se fizesse tender o valor de λ para 0, iria-se ter uma exposição ao risco nula, logo não teríamos valor de lucro. Em seguida, na Tabela 15 são mostrados os valores de erro, em %, utilizando o *Mean Absolute Percentage Error* (MAPE) registados nos mercados que fazem parte do caso de estudo.

Tabela 15 - Valores de erro registados em cada mercado, em %

Períodos	Spot	Bilaterals	Balancing 1	Balancing 2	Smart Grid
1	0,01	0,05	0,07	0,25	0,17

Como pode ser observado na Tabela 15 o mercado que detém o maior erro é o Balancing 2, e, por outro lado, o mercado Spot é aquele que apresenta o menor valor de erro. Em seguida, realizar-se-á o cruzamento dos valores de erros, nos diferentes mercados, com os resultados do escalonamento de compra e de venda da eletricidade atendendo ao valor de exposição ao risco. A Tabela 16 apresenta um resumo da Tabela 21 do 0, neste caso são expostos os escalonamentos dos algoritmos que apresentaram maior lucro em cada um dos níveis de exposição ao risco.

Tabela 16 – Resultados máximos obtidos para os diferentes níveis de pesagem

Peso	Algoritmo	Mercados									
		Venda (MW)					Compra (MW)				
		Spot	Bilateral	Balancing 1	Balancing 2	Smart Grid	Spot	Bilateral	Balancing 1	Balancing 2	Smart Grid
0,10	NPSO-LRS	23,14	0,00	0,00	0,00	0,00	0,00	3,14	10,00	0,00	0,00
0,15	PSO-ST	12,10	11,50	0,00	0,00	0,00	0,00	3,60	10,00	0,00	0,00
0,20	PSO-ST	33,88	0,00	0,00	0,00	0,00	0,00	3,88	10,00	10,00	0,00
0,25	PSO-w6	22,56	11,50	0,00	0,00	0,00	0,00	4,06	10,00	10,00	0,00
0,50	AG 2	19,19	11,53	0,00	0,00	3,68	0,00	4,41	10,00	9,99	0,00
0,75	AG 2	15,83	11,66	0,00	0,00	7,25	0,00	4,75	10,00	10,00	0,00
1,00	PSO-w6	14,64	11,50	0,00	0,00	8,59	0,00	4,73	10,00	10,00	0,00

Como já foi dito a exposição ao risco vai aumentando de 0 a 1 passando pelos intervalos descritos na Tabela 16 e, à medida que vão aumentando, aumenta também o valor do risco. Como pode ser verificado, o limite máximo de compra de 10 MW não é ultrapassado, as ações de venda e compra não são registadas nos mercados de ajustes e também não é registada a compra no mercado Spot. Significa portanto, que o modelo cumpriu as regras impostas.

Quando o valor do peso é 0,1 o valor de risco encontrado é de 33,04. Como se pode ver pela Tabela 16, o modelo vende a eletricidade no mercado onde o valor do erro é menor, mercado Spot, e vai comprar eletricidade nos mercados onde o erro também é menor, o que faz sentido, pois a exposição ao risco é mínima e o valor do erro é tido em conta na otimização pelo modelo. Quando fazemos aumentar a exposição ao risco para 0,15 o modelo vai comprar quase a mesma quantidade que anteriormente embora na venda se divida entre o mercado Spot e o mercado Bilateral, e o valor total de risco neste patamar é de 73,17. Aumentando novamente o peso para 0,2, o modelo volta a vender toda a eletricidade ao mercado Spot, isto acontece pois o cálculo do risco é obtido mediante a alocação de

eletricidade no mercado. O modelo também está interessado em aumentar o lucro, pois a exposição ao risco vem aumentando, o que leva a que de 0,15 para o 0,2 o modelo decida vender a eletricidade num só mercado. Na compra, o modelo vai comprar nos mercados Bilateral e nos dois mercado de ajustes, o que também difere do anterior que não executava compra no mercado Balancing 2. Passando para o peso com o valor de 0,25, o modelo aumentou em pequena quantidade a eletricidade comprada, sendo que o valor de risco é de 156,77, e a venda da eletricidade disponível será feita em dois mercados, no mercado Spot e Bilateral. Aumentando novamente o valor do peso e desta vez para 0,5, o valor do risco passa para 209,07, e o modelo na venda passa a utilizar mais um mercado, o mercado da S.G. Como é mostrado na Tabela 16 o valor do erro é maior no mercado da S.G. do que no mercado Balancing 1, mas o modelo utiliza ambos os mercados pois é rentável a compra no mercado Balancing 1 e a venda no mercado S.G., e a exposição ao risco permite esta operação. Analisando o que acontece no 0,7 e 1, o modelo executa exatamente a mesma ação que executou em 0,5, embora o modelo aumente a quantidade de venda nos mercados onde o risco é maior, mas por outro lado o lucro também é maior. No mercado Spot, como pode ser observado, a quantidade de eletricidade vendida vem diminuindo à medida que se aumenta o nível de risco, isto acontece porque existe um mercado, neste caso S.G., onde a venda da eletricidade rende mais, mas este mercado também possui um erro maior, daí que a venda da eletricidade só aconteça no final, pois o modelo considera a venda mais arriscada neste mercado. A Tabela 16 apresenta apenas um resumo do algoritmo que obteve o maior valor de função por nível de pesagem, mas na Tabela 22 do Anexo E são apresentados todos os resultados dos algoritmos escolhidos para fazer a resolução do problema multiobjetivo.

4.4. SUMÁRIO

No Capítulo 4 colocaram-se em prática as metodologias propostas no Capítulo 3. No subcapítulo 4.1 apresentaram-se os resultados da estimativa de preços dos contratos de eletricidade nos mercados com a utilização das metodologias de *clustering* e da lógica *fuzzy*. O subcapítulo 4.2 apresentou os resultados de todos os métodos utilizados para o problema considerando um só objetivo: o lucro. Por fim, no subcapítulo 4.3 são apresentados os resultados para o problema multiobjetivo. Inicialmente, foram apresentados os resultados para a metodologia criada na negociação dos contratos bilaterais, a mesma demonstrou-se

adaptativa em mercados, pois adaptou-se ao perfil de preços de diferentes mercados. É de salientar que os resultados desta metodologia estão publicados na seguinte publicação científica (Faia et al., 2015a).

Foi apresentada uma resolução determinística onde o tempo de execução é demasiado elevado logo é impossível de ser praticada, em termos de função objetivo como se pode ver pela Tabela 17 a resolução determinística foi a que apresentou o maior valor, sendo este o resultado de referência usado para fazer a comparação.

Tabela 17 - Comparação de valor da função objetivo

Método/variante	Função objetivo (€)	Diferença relativamente ao maior	
Determinístico	2000,645575	0	
PSO	w1	1998,600570	-0,001022173
	w2	2000,645573	-1,02441E-09
	w3	2000,645567	-4,43189E-09
	w4	2000,645515	-3,02127E-08
	w5	2000,304511	-0,000170477
	w6	2000,645574	-7,99682E-10
	w7	2000,645574	-6,42578E-10
	w8	2000,645574	-6,21624E-10
	w9	2000,645575	-1,40505E-10
	w10	1915,380759	-0,042618652
	w11	2000,645563	-6,19772E-09
	w12	2000,645571	-2,33556E-09
	w13	2000,645574	-6,22529E-10
	w14	1983,957282	-0,008341454
	w15	2000,645001	-2,8693E-07
	w16	1809,203517	-0,095690142
	w17	2000,645575	-3,06801E-11
	w18	1999,369172	-0,000637996
EPSO	2000,645441	-6,74344E-08	
QPSO	1998,943579	-0,000850724	
NPSO-LRS	2000,645575	-5,2648E-11	
MPSO-TVAC	2000,645575	-1,6394E-12	
AG	AG 1	2000,624022	-1,0773E-05
	AG 2	2000,614695	-1,54353E-05
	AG 3	2000,622041	-1,17634E-05
SA	SA 1	1927,242146	-0,036689872
	SA 2	1933,56638	-0,033528775
	SA 3	1930,146688	-0,035238069
	SA 4	1925,366054	-0,037627615

Pelos resultados da Tabela 17 é possível ver que existem métodos como é o caso do MPSO-TVAC, NPSO-LRS e PSO-w17 que apresentam diferenças muito pequenas, é de realçar que os valores aqui apresentados são relativos aos máximos encontrados por cada método.

De seguida foram apresentados os resultados de todos os algoritmos/variantes aplicadas. Houve a necessidade de executar esta tarefa pois foi essencial para comparar e escolher quais os algoritmos/variantes a utilizar na resolução do problema multiobjetivo. A comparação baseou-se em três parâmetros, resultantes das simulações efetuadas, que foram o valor da função objetivo, o número de iterações e o tempo necessário para que o algoritmo convirja para uma solução. Os resultados são apresentados por algoritmos, e dentro de cada algoritmo foi selecionada uma ou mais variantes. Os resultados da estratégia de inércia aplicada já foram aceites para revisão e encontram-se também na mesma revisão para publicação na revista científica *Integrated Computer-Aided Engineering* (ICAE).

Foi realizada uma apresentação dos resultados utilizando ferramentas estatísticas, o diagrama de extremos e quartis e os intervalos de confiança, pretendeu-se com isto, justificar a seleção dos algoritmos/variantes a utilizar posteriormente, nesta seleção teve-se em conta principalmente o máximo valor objetivo encontrado e também se teve em conta a concentração dos resultados finais da função objetivo, com menos importância mas que também foram tidos em conta foi o tempo de execução e o número de iterações. Como foi possível constatar o uso da heurística para a criação da solução inicial veio trazer vantagens na resolução do problema pois os algoritmos conseguem mais facilmente encontrar uma solução ótima. Foi também dada uma explicação do comportamento do modelo perante as exigências impostas.

No final, são apresentados os resultados dos algoritmos escolhidos para o problema multiobjetivo. Optou-se por juntar as duas equações do problema multiobjetivo (3.2) e (3.15) numa só utilizando pesos, (3.14). Neste caso foram dados os resultados para várias combinações de pesos, onde é possível ver que à medida que o valor do risco aumenta o lucro também aumenta. É igualmente dada uma explicação de como o modelo se comporta com a maior ou menor exposição ao risco na compra e venda de eletricidade. Como se pode observar na Figura 47 o valor do lucro tende a estabilizar, por exemplo: com 0,5 o lucro é de 1970,48 €, tendo sido o AG 2 a registar este valor, e com 1 o lucro é de 2000,278 €, valor

obtido também pelo AG 2, estes dois valores tem uma diferença de 1% em relação ao maior valor, este facto leva a optar pelo valor do 0,5 pois a diferença é mínima e no caso do risco verifica-se uma maior diferença cerca de 22%.

5. CONCLUSÕES

5.1. CONCLUSÕES

A preocupação com o funcionamento dos mercados de eletricidade tem vindo, ao longo dos tempos, a tornar-se cada vez mais objeto de estudo por diversas entidades. A complexidade existente e a imprevisibilidade encontrada são efeitos da reestruturação ocorrida. Esta reestruturação trouxe novos métodos de negociação, novas entidades de mercados e novos conceitos surgiram nomeadamente as SG, levando também a um aumento de competitividade.

Os mercados de eletricidade deixaram de se orientar por um regime monopolista onde só os grandes produtores podiam participar e passaram a funcionar como um regime liberal onde é possível a participação de qualquer vendedor ou comprador. Neste âmbito, também surgiram os VPPs com objetivo de ajudar os pequenos produtores a realizarem as suas participações nos mercados.

A maior competitividade e complexidade trazidas pela reestruturação do mercado obrigaram os participantes a enfrentarem novos desafios, o que provocou um aumento na dificuldade de tomada de decisão, levando à necessidade de apoio por parte das entidades. As ferramentas de simulação existentes representam já um apoio importante para os utilizadores

de mercado, pois fornecem-lhes informações que são tidas em conta no planeamento das ações futuras. Contudo, existe a falta de ferramentas de apoio aos participantes no processo de tomada de decisão, relativamente às negociações nos mercados de energia elétrica.

Este trabalho teve por objetivo desenvolver um modelo de participação nos mercados de energia elétrica. Para isso, foi explorada uma vasta área de conhecimento com o intuito de compreender o funcionamento dos mercados e das ferramentas existentes. O modelo criado pretende apoiar a participação nos mercados de energia elétrica criando um portfólio de ofertas dos mercados existentes.

Um dos aspetos fundamentais para que o modelo proposto se tornasse funcional, foi o desenvolvimento da metodologia de estimação dos preços esperados de negociação nos contratos bilaterais, onde o preço da eletricidade varia com a quantidade negociada. A metodologia desenvolvida e os resultados alcançados estão apresentados no capítulo 4.1. Esta metodologia mostrou-se adaptável a qualquer tipo de perfil de preços observados neste tipo de mercados.

A otimização do portfólio foi resolvida através de métodos de otimização exatos e também aproximados. Numa primeira fase, foi aplicada uma série de algoritmos/variantes para fazer uma seleção dos melhores atendendo ao valor da função objetivo, número de iterações e tempo de execução. Os algoritmos/variantes que obtiveram os melhores resultados, e que foram, conseqüentemente utilizados para resolver o problema multiobjetivo foram: PSO-w6, NPSO-LRS, AG 2 e o SA 1. Cada método utilizado apresenta resultados diferentes, o que traz vantagens para a criação de cenários, pois contribui para a diversificação de resultados.

A heurística criada funcionou bem e trouxe melhorias aos resultados quando comparados com os obtidos sem ela para o caso da otimização do lucro.

Como é possível observar pelos resultados do capítulo 4.2.7, o modelo proposto respeitou as regras impostas na negociação, o que faz deles cenários válidos e os métodos utilizados apresentam resultados em tempos muito inferiores à aqueles que o utilizador despender para fazer a negociação. Deste modo, é possível ao utilizador interpretar os cenários obtidos para concretizar a sua melhor ação no mercado de eletricidade.

A metodologia desenvolvida no âmbito deste trabalho foi criada com o intuito de ser parte integrante de um sistema de apoio à decisão que permitirá dar apoio, no âmbito financeiro, aos participantes dos mercados de energia elétrica, nomeadamente aos vendedores e compradores de eletricidade, através da integração com o sistema de apoio à decisão AiD-EM, e conseqüente ligação ao simulador de mercados MASCEM.

A metodologia apresentada possui limitações na sua utilização, nomeadamente o facto de ter sido desenvolvida numa perspetiva de vendedor de energia, embora também possa ser utilizada na perspetiva de comprador, outra das limitações é o horizonte temporal, onde apenas é considerado um período. Neste trabalho, não foi considerada a validação técnica dos resultados, apenas foi ponderada a questão financeira, o que acarreta limitações na utilização da metodologia. É apenas considerado o risco dos métodos de previsão, contudo existem outros tipos de riscos, nos mercados de energia elétrica, que podem ter influência no preço da eletricidade.

A utilização da heurística para fazer a procura da solução inicial ficou limitada. Pois foi criada sem a afetação do risco, o que considera que o utilizador não tem aversão ao risco, para a resolução da equação (3.2) (função lucro) funciona perfeitamente e, pelos resultados do subcapítulo 4.2, é possível ver essas vantagens. Quando a resolução da equação (3.14) (função multiobjetivo) não resulta da melhor forma, pois, como foi explicado no subcapítulo 4.3, o risco é tido em conta, mas na construção da heurística não o foi. Foi apenas aplicada uma versão do PSO com a heurística a PSO-ST (Tabela 11, resultados), e podemos concluir que, dada uma solução inicial que esteja fora dos limites de risco, o modelo corrige pela pesquisa de novas soluções e encontra uma solução válida, provavelmente isto poderá ter vantagens em termos de tempo de execução e iterações como foi demonstrado no subcapítulo 4.2.6.

5.2. TRABALHO FUTURO

Para a resolução do problema de otimização nesta dissertação foram utilizados diferentes algoritmos que garantem uma solução viável num curto espaço de tempo, os quais foram aplicados a uma função objetivo criada a partir de dois objetivos, tendo, desta forma, um problema uni-objetivo. Um dos trabalhos futuros passa pela utilização de algoritmos multiobjetivos que façam a otimização das duas funções objetivo, sem ser necessário utilizar

a técnica de pesos, como por exemplo o *Non-dominated sorting genetic algorithm* (NSGA-II), (Deb et al., 2002).

Fruto da pesquisa e trabalho efetuado com os algoritmos de pesquisa inteligente, nomeadamente com o PSO, surgiram ideias, como por exemplo: utilizar sub-enxames dentro do PSO e quando as partículas de todos os enxames convergem para uma solução enviar as partículas para os limites do espaço de pesquisa (como se ocorresse uma explosão e as partículas fossem os destroços), e depois continuar a pesquisa onde na velocidade das partículas fosse dada liberdade para pesquisarem por si sós (não utilizar componente social da pesquisa) que podem vir a ser consideradas para o desenvolvimento de uma variante do PSO. Estas ideias podem ser utilizadas por forma a criar uma variante de pesquisa do PSO passível de ser utilizada e comparada com outras técnicas de pesquisa inteligente demonstrando as suas vantagens.

Como a Figura 12 demonstra os cenários depois de selecionados vão incorporar uma base de dados, desta forma pretende-se também como trabalho futuro, o desenvolvimento de uma ferramenta que selecione os cenários mais apropriados mediante critérios impostos pelo utilizador, e desta forma seja mais fácil para ele tomar decisões sobre as ações a realizar no futuro. É, nomeadamente proposto o desenvolvimento de uma abordagem de aprendizagem por casos (Watson and Gardingen, 1999) para a escolha automática dos métodos mais apropriados para cada contexto de utilização.

A par dos desenvolvimentos que têm ocorrido no setor dos mercados de energia, como é o caso da criação do mercado europeu, propõe-se como trabalho futuro a criação de uma metodologia de negociação de energia elétrica que modele o funcionamento dos mercados da mesma e consiga fazer a iteração com diferentes tipos de negociação (mercado *Spot*, sessões de mercado de ajustes, contratos bilaterais), o que implicará negociações com diferentes horizontes temporais. Seria importante também, embora se torne uma tarefa mais complicada de ser efetuada, a inclusão da parte técnica no modelo (validação do trânsito de potências nas linhas de transmissão), uma vez que poderão existir fenómenos de natureza técnica que poderão alterar a negociação da energia elétrica.

Referências Documentais

- Algarvio, H., Lopes, F., Santana, J., 2015. Highlights of Practical Applications of Agents, Multi-Agent Systems, and Sustainability - The PAAMS Collection: International Workshops of PAAMS 2015, Salamanca, Spain, June 3-4, 2015. Proceedings. In: Bajo, J., Hallenborg, K., Pawlewski, P., Botti, V., Sánchez-Pi, N., Duque Méndez, D.N., Lopes, F., Julian, V. (Eds.), . Springer International Publishing, pp. 260–269.
- Al-Hassan, W., Fayek, M.B., Shaheen, S.I., 2006. PSOSA: An Optimized Particle Swarm Technique for Solving the Urban Planning Problem. 2006 Int. Conf. Comput. Eng. Syst.
- Amjady, N., Daraeepour, A., Keynia, F., 2010. Day-ahead electricity price forecasting by modified relief algorithm and hybrid neural network. IET Gener. Transm. Distrib. 4, 432.
- APX, 2016. Power Spot Exchange - Making Markets Work [WWW Document]. URL <https://www.apxgroup.com/> (accessed 2.12.16).
- Arumugam, M.S., Rao, M.V.C., 2008. On the improved performances of the particle swarm optimization algorithms with adaptive parameters, cross-over operators and root mean square (RMS) variants for computing optimal control of a class of hybrid systems. Appl. Soft Comput. 8, 324–336.
- Awerbuch, S., 2004. Building Capacity for Portfolio-Based Energy Planning in Developing Countries: Shifting the grounds for debate. Renew. Energy Energy Effic. Partnersh.
- Awerbuch, S., Berger, M., 2003. Applying Portfolio Theory to EU Electricity Planning and Policy Making. Paris.
- Azevedo, F., 2007. Gestão do Risco em Mercados Competitivos de Electricidade: Previsão de Preços e Optimização do Portfolio de Contratos. Universidade de Trás-os-Montes e Alto Douro.

-
- Bar-Lev, D., Katz, S., 1976. A Portfolio Approach to Fossil Fuel Procurement in the Electric Utility Industry. *J. Finance* 933–47.
- Belpex, 2016. Belpex [WWW Document]. URL <http://www.belpex.be/> (accessed 3.1.16).
- Bertram, J.S., 2000. The molecular biology of cancer. *Mol. Aspects Med.* 21, 167–223.
- Bian, W., Chen, X., 2014. Neural Network for Nonsmooth, Nonconvex Constrained Minimization Via Smooth Approximation. *IEEE Trans. Neural Networks Learn. Syst.*
- Bittencourt, D., 2011. Determinação do Nível Ótimo de Contratação de Energia Elétrica para Grandes Consumidores Baseado em Técnicas de Gerenciamento de Risco. Universidade Federal de Santa Catarina.
- Boyd, S., Vandenberghe, L., 2004. *Convex optimization*. New York.
- Cederberg, H., Rannug, U., 2006. Mechanisms of human minisatellite mutation in yeast. *Mutat. Res. Mol. Mech. Mutagen.* 598, 132–143.
- Cerjan, M., Matijaš, M., Delimar, M., 2014. Dynamic Hybrid Model for Short-Term Electricity Price Forecasting. *Energies* 7, 3304.
- Chang, T.-J., Yang, S.-C., Chang, K.-J., 2009. Portfolio optimization problems in different risk measures using genetic algorithm. *Expert Syst. Appl.* 36, 10529–10537.
- Chen, G., Huang, X., Jia, J., Min, Z., 2006. Natural Exponential Inertia Weight Strategy in Particle Swarm Optimization. 2006 6th World Congr. *Intell. Control Autom.*
- Chen, S., Xudiera, C., Montgomery, J., 2012. Simulated annealing with threshold convergence. *Evol. Comput. (CEC)*, 2012 IEEE Congr.
- Cincotti, S., Gallo, G., 2013. Genoa Artificial Power-Exchange. *Agents Artificial Intelligence*. In: Filipe, J., Fred, A. (Eds.), . Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 348–363.
- Coelho, L. dos S., 2008. A quantum particle swarm optimizer with chaotic mutation

- operator. *Chaos, Solitons and Fractals* 37, 1409–1418.
- Concordia, C., 1999. *Electric power systems: past, present, and future*. IEEE Power Eng. Rev.
- Conejo, A.J., Carrión, M., Morales, J.M., 2010. *Decision Making Under Uncertainty in Electricity Markets*, International Series in Operations Research & Management Science. Springer US, Boston, MA.
- Deb, K., Pratap, A., Agarwal, S., Meyarivan, T., 2002. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Trans. Evol. Comput.*
- e2p, 2016. EVOLUÇÃO DA POTÊNCIA INSTALADA EM PORTUGAL [WWW Document]. *Energias endógenas Port.* URL <http://e2p.inegi.up.pt/?Lang=PT#Tec3> (accessed 2.10.16).
- Eberhart, R.C., Shi, Y., 2001. Tracking and optimizing dynamic systems with particle swarms. *Evol. Comput.* 2001. Proc. 2001 Congr.
- EMCC, 2016. Market Coupling [WWW Document]. URL <http://www.marketcoupling.com/> (accessed 9.1.16).
- EPEXSPOT, 2016. European Power Exchange [WWW Document]. URL <https://www.epexspot.com/en/> (accessed 2.20.16).
- European Commission, 2006. Documento de estratégia 2006 [WWW Document].
- European Commission, 2009a. The 2020 climate and energy packages [WWW Document]. *Clim. Action*. URL http://ec.europa.eu/clima/policies/package/index_en.htm (accessed 10.2.15).
- European Commission, 2009b. Directive 2009/28/EC of the European Parliament and of the Council. April 2009 [WWW Document].
- European Commission, 2011. A Roadmap for moving to a competitive low carbon economy in 2050 [WWW Document]. URL <http://eur-lex.europa.eu/legalcontent/> (accessed

7.1.15).

European Commission, 2014. 2030 framework for climate and energy policies [WWW Document]. URL http://ec.europa.eu/clima/policies/2030/index_en.htm (accessed 10.5.15).

EWEA, 2012. Creating the Internal Energy Market in Europe.

Faia, R., Pinto, T., Vale, Z., 2015a. Dynamic Fuzzy Estimation of Contracts Historic Information Using an Automatic Clustering Methodology. In: Bajo, J., Hallenborg, K., Pawlewski, P., Botti, V., Sánchez-Pi, N., Duque Méndez, N.D., Lopes, F., Julian, V. (Eds.), Highlights of Practical Applications of Agents, Multi-Agent Systems, and Sustainability - The PAAMS Collection SE - 23. Springer International Publishing, pp. 270–282.

Faia, R., Pinto, T., Vale, Z., 2016a. Dynamic Fuzzy Clustering Method for Decision Support in Electricity Markets Negotiation. *Adv. Distrib. Comput. Artif. Intell. J.* 5.

Faia, R., Pinto, T., Vale, Z., 2016b. Optimization of Electricity Markets Participation with Simulated Annealing. In: de la Prieta, F., Escalona, J.M., Corchuelo, R., Mathieu, P., Vale, Z., Campbell, T.A., Rossi, S., Adam, E., Jiménez-López, D.M., Navarro, M.E., Moreno, N.M. (Eds.), Trends in Practical Applications of Scalable Multi-Agent Systems, the PAAMS Collection. Springer International Publishing, Cham, pp. 27–39.

Faia, R., Pinto, T., Vale, Z., Pires, E.J.S., 2015b. Portfolio Optimization for Electricity Market Participation with Particle Swarm. Fourth Int. Work. Artif. Intell. Tech. Power Syst. Energy Mark. (IATEM 2015) 26th Int. Conf. Database Expert Syst. Appl. (DEXA 2015).

Feng, Y., Teng, G.F., Wang, A.X., Yao, Y.M., 2007. Chaotic Inertia Weight in Particle Swarm Optimization. *Innov. Comput. Inf. Control.* 2007. ICICIC '07. Second Int. Conf.

FinancialEdge.net, 2016. Stocks [WWW Document]. URL <https://financialedge.net/resources/stocks/> (accessed 6.1.16).

-
- Gang, M., Wei, Z., Xiaolin, C., 2012. A novel particle swarm optimization algorithm based on particle migration. *Appl. Math. Comput.* 218, 6620–6626.
- Gao, Y. l., An, X. h., Liu, J. m., 2008. A Particle Swarm Optimization Algorithm with Logarithm Decreasing Inertia Weight and Chaos Mutation. *Comput. Intell. Secur.* 2008. CIS '08. Int. Conf.
- GME, 2016. GME - Gestore dei Mercati Energetici [WWW Document]. URL <http://www.mercatoelettrico.org/En/Default.aspx> (accessed 2.15.16).
- Goldberg, D.E., 1989. *Genetic Algorithms in Search, Optimization and Machine Learning*, 1st ed. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA.
- Gonçalves, J., 2013. *Modelos para a Comercialização de Energia Elétrica em Ambiente de Mercado*. Instituto Politécnico de Coimbra.
- Gulich, O., 2010. TECHNOLOGICAL AND BUSINESS CHALLENGES OF SMART GRIDS- Aggregator's Role in Current Electricity Market. *Eur. Technol. Platf. SmartGrids – Strateg. Res. Agenda*. LAPPEENRANTA UNIVERSITY OF TECHNOLOGY.
- Haykin, S., 1998. *Neural Networks: A Comprehensive Foundation*, 2nd ed. Prentice Hall PTR, Upper Saddle River, NJ, USA.
- Heddenhausen, M., 2007. Privatisations in Europe ' s liberalised electricity markets – the cases of the United Kingdom , Sweden , Germany , and France. *Policy*.
- Henderson, D., Jacobson, S.H., Johnson, A.W., 2003. The Theory and Practice of Simulated Annealing. In: Glover, F., Kochenberger, G.A. (Eds.), *Handbook of Metaheuristics*. Springer US, Boston, MA, pp. 287–319.
- Holland, J., 1992. Genetic algorithms. *Sci. Am.* 66 – 72.
- Huang, K.-Y., Hsieh, Y.-H., 2011. Very fast simulated annealing for pattern detection and seismic applications. *Geosci. Remote Sens. Symp. (IGARSS), 2011 IEEE Int.*

-
- Infopédia, 2016. Dicionários Porto Editora [WWW Document]. URL <http://www.infopedia.pt/>
- Jain, A.K., 2010. Data clustering: 50 years beyond K-means. *Pattern Recognit. Lett.* 31, 651–666.
- Jennings, N.R., Sycara, K., Wooldridge, M., 1998. A Roadmap of Agent Research and Development. *Auton. Agent. Multi. Agent. Syst.* 1.
- Kennedy, J., Eberhart, R., 1995. Particle swarm optimization. *Neural Networks, 1995. Proceedings., IEEE Int. Conf.* 4, 1942–1948 vol.4.
- Kentzoglanakis, K., Poole, M., 2009. Particle Swarm Optimization with an Oscillating Inertia Weight. In: *Proceedings of the 11th Annual Conference on Genetic and Evolutionary Computation, GECCO '09*. ACM, New York, NY, USA, pp. 1749–1750.
- Kerrache, S., Benhidour, H., 2014. Topology-Aware Simulated Annealing. *Artif. Intell. Model. Simul. (AIMS), 2014 2nd Int. Conf.*
- Kirschen, D., Strbac, G., 2004. *Fundamentals of Power System Economics*. John Wiley & Sons, Ltd, Manchester.
- Klotz, E., Newman, A., 2013. Practical guidelines for solving difficult mixed integer linear programs. In: *Surveys in Operations Research and Management Science* 18. pp. 1–2, 18–32.
- Koritarov, V.S., 2004. Real-world market representation with agents. *IEEE Power Energy Mag.* 2, 39–46.
- Krey, B., Zweifel, P., 2006. *Efficient Electricity Portfolios for Switzerland and the United States*. Zurich.
- Laarhoven, P.J.M. van, Aarts, E.H.L., 1987. *Simulated Annealing: Theory and Applications*. Springer Netherlands, Dordrecht.
- Landaburu, P., 2006. *Optimal Allocation and Scheduling of Demand in Deregulated Energy*

Markets], Viena University of Technology, Vienna, Austria.

- Ledesma, S., Aviña, G., Sanchez, R., 2008. Practical Considerations for Simulated Annealing Implementation. In: Ming, C. (Ed.), *Simulated Annealing*. InTech.
- Lei, K., Qiu, Y., He, Y., 2006. A new adaptive well-chosen inertia weight strategy to automatically harmonize global and local search ability in particle swarm optimization. 2006 1st Int. Symp. Syst. Control Aerosp. Astronaut.
- Li, H., Sun, J., Tesfatsion, L., 2011. Computational Methods in Economic Dynamics. In: Dawid, H., Semmler, W. (Eds.), . Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 135–158.
- Li, H., Tesfatsion, L., 2009. Development of open source software for power market research: The AMES test bed [WWW Document]. *J. Energy Mark.*
- Li, H.R., Gao, Y.L., 2009. Particle Swarm Optimization Algorithm with Exponent Decreasing Inertia Weight and Stochastic Mutation. 2009 Second Int. Conf. Inf. Comput. Sci.
- Lin, M.-H., Tsai, J.-F., Yu, C.-S., 2012. A Review of Deterministic Optimization Methods in Engineering and Management. In: *Mathematical Problems in Engineering*, pp. 1–15.
- Liu, M., Wu, F.F., 2007. Portfolio optimization in electricity markets. *Electr. Power Syst. Res.* 77, 1000–1009.
- Lund, H., 2014. *Renewable Energy Systems, Renewable Energy Systems – A Smart Energy Systems Approach to the Choice and Modeling of 100% Renewable Solutions*, 2nd Editio. ed, Energy Research & Social Science.
- Lund, H., Andersen, A.N., Østergaard, P.A., Mathiesen, B.V., Connolly, D., 2012. From electricity smart grids to smart energy systems – A market operation based approach and understanding. *Energy* 42, 96–102.
- MacQueen, J., 1967. Some Methods for Classification and Analysis of MultiVariate Observations. In: *5th Symposium on Mathematical Statistics and Probability*. pp. 281–

297.

Malik, R.F., Rahman, T.A., Hashim, S.Z.M., Ngah, R., 2007. New Particle Swarm Optimizer with Sigmoid Increasing Inertia Weight. *Int. J. Comput. Sci. Secur.* 1, 35–44.

Markowitz, H., 1952. PORTFOLIO SELECTION*. *J. Finance* 7, 77–91.

Martins, A.M., 2009. Mercado Ibérico de Electricidade Simulação de um Modelo em Concorrência Perfeita. Faculdade de Economia, Universidade do Porto.

Meeus, L., Belmans, R., 2008. Electricity market integration in Europe. *Revue-E* 124.

Meeus, L., Purchala, K., Belmans, R., 2005. Development of the Internal Electricity Market in Europe. *Electr. J.* 18, 25–35.

MIBEL, 2007. Mercado Iberico de Eletrecidade [WWW Document]. URL <http://www.mibel.com/index.php?lang=pt> (accessed 2.27.16).

Miranda, V., Fonseca, N., 2002. EPSO - best-of-two-worlds meta-heuristic applied to power system problems. *Evol. Comput. 2002. CEC '02. Proc. 2002 Congr.*

MISO energy, 2015. MISO energy [WWW Document]. URL <https://www.misoenergy.org/Pages/Home.aspx> (accessed 10.10.15).

Morais, H., Pinto, T., Vale, Z., Praça, I., 2012. Multilevel Negotiation in Smart Grids for VPP Management of Distributed Resources. *Intell. Syst. IEEE.*

Morgan, J.P., 1996. RiskMetrics – Tecchnical Document.

Nascimento, M.N.V. Do, 2013. Agentes comerciais: Modelos de Avaliação de Risco e Rentabilidade. INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA.

Nord Pool, 2016. Nord Pool SPOT [WWW Document]. URL <http://www.nordpoolspot.com> (accessed 2.10.16).

Oliveira, F.A., Paiva, A.P., Lima, J.W.M., Balestrassi, P.P., Mendes, R.R.A., 2011. Portfolio optimization using Mixture Design of Experiments: Scheduling trades within electricity

-
- markets. *Energy Econ.* 33, 24–32.
- OMEL, 2016. OMEL [WWW Document]. URL <http://www.omelholding.es/omel-holding/> (accessed 3.5.16).
- OTE, 2016. OTE [WWW Document]. URL <http://www.ote-cr.cz/> (accessed 2.27.16).
- Panapakidis, I.P., Dagoumas, A.S., 2016. Day-ahead electricity price forecasting via the application of artificial neural network based models. *Appl. Energy* 172, 132–151.
- Panigrahi, B.K., Ravikumar Pandi, V., Das, S., 2008. Adaptive particle swarm optimization approach for static and dynamic economic load dispatch. *Energy Convers. Manag.* 49, 1407–1415.
- PCR, 2015. ITALIAN BORDERS SUCCESSFULLY COUPLED.
- PCR PXs, 2013. EUPHEMIA Public Description.
- Pereira, I., 2004. Sistema Multi-Agente para Apoio à Negociação em Mercados de Electricidade. Universidade de Trás-os-Montes E Alto Douro.
- Pinto, T., Morais, H., Oliveira, P., Vale, Z., Praça, I., Ramos, C., 2011a. A new approach for multi-agent coalition formation and management in the scope of electricity markets. *Energy* 36, 5004–5015.
- Pinto, T., Morais, H., Sousa, T.M., Sousa, T., Vale, Z., Praça, I., Faia, R., Pires, E.J.S., 2015a. Adaptive Portfolio Optimization for Multiple Electricity Markets Participation. *Neural Networks Learn. Syst. IEEE Trans.* PP, 1.
- Pinto, T., Sousa, T.M., Vale, Z., 2012. Dynamic artificial neural network for electricity market prices forecast. *Intell. Eng. Syst. (INES)*, 2012 IEEE 16th Int. Conf.
- Pinto, T., Vale, Z., Praça, I., Pires, E.J.S., Lopes, F., 2015b. Decision Support for Energy Contracts Negotiation with Game Theory and Adaptive Learning. *Energies* 8, 9817–9842.
- Pinto, T., Vale, Z., Rodrigues, F., Morais, H., Praça, I., 2011b. Bid Definition Method for

- Electricity Markets Based on an Adaptive Multiagent System. In: Demazeau, Y., Pěchouček, M., Corchado, J.M., Pérez, J.B. (Eds.), *Advances on Practical Applications of Agents and Multiagent Systems: 9th International Conference on Practical Applications of Agents and Multiagent Systems*. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 309–316.
- Pinto, T., Vale, Z., Sousa, T.M., Praça, I., Santos, G., Morais, H., 2014a. Adaptive Learning in Agents Behaviour: A Framework for Electricity Markets Simulation. *Integr. Comput. Eng.* 21, 399–415.
- Pinto, T., Vale, Z., Sousa, T.M., Sousa, T., Morais, H., Praça, I., 2014b. Particle Swarm Optimization of Electricity Market Negotiating Players Portfolio. *Highlights Pract. Appl. Heterog. Multi-Agent Syst., Communications in Computer and Information Science* 430, 273–284.
- Praça, I., Ramos, C., Vale, Z., Cordeiro, M., 2003. MASCEM: a multiagent system that simulates competitive electricity markets. *IEEE Intell. Syst.*
- Qin, Z., Yu, F., Shi, Z., Wang, Y., 2006. Adaptive Inertia Weight Particle Swarm Optimization. In: *Proceedings of the 8th International Conference on Artificial Intelligence and Soft Computing, ICAISC'06*. Springer-Verlag, Berlin, Heidelberg, pp. 450–459.
- Quan, H., Srinivasan, D., Khosravi, A., 2014. Short-Term Load and Wind Power Forecasting Using Neural Network-Based Prediction Intervals. *IEEE Trans. Neural Networks Learn. Syst.*
- Ramakrishnan, S., Ramakrishnan, S., 2013. WoT (Web of Things) for Energy Management in a Smart Grid-Connected Home.
- Ramos, S., 2006. *Utilização de Técnicas de Data Mining para Apoio aos Agentes dos Mercados Retalhistas de Energia Eléctrica*. Universidade Técnica de Lisboa, Instituto Superior Técnico.
- Rudd, K., Muro, G.D., Ferrari, S., 2014. A Constrained Backpropagation Approach for the

-
- Adaptive Solution of Partial Differential Equations. *IEEE Trans. Neural Networks Learn. Syst.*
- Santos, G., 2015. Ontologies for the interoperability of multiagent electricity markets simulation platforms. Polytechnic of Porto – School of Engineering (ISEP/IPP).
- Saraiva, J., Leão, M., 2002. Mercados de Electricidade - Regulação e Tarificação de Uso das Redes. FEUP Edições, Porto.
- Schmitt, L.M., 2004. Theory of Genetic Algorithms II: models for genetic operators over the string-tensor representation of populations and convergence to global optima for arbitrary fitness function under scaling. *Theor. Comput. Sci.* 310, 181–231.
- Selvakumar, A.I., Thanushkodi, K., 2007. A New Particle Swarm Optimization Solution to Nonconvex Economic Dispatch Problems. *IEEE Trans. Power Syst.*
- Shahidehpour, M., Yamin, H., Li, Z., 2002. Market Overview in Electric Power Systems. *Mark. Oper. Electr. Power Syst. Sched. Risk Manag.*
- Sharma, K.C., Bhakar, R., Tiwari, H.P., 2014. Strategic bidding for wind power producers in electricity markets. *Energy Convers. Manag.* 86, 259–267.
- Shi, Y., Eberhart, R., 1998. A modified particle swarm optimizer. *Evol. Comput. Proceedings, 1998. IEEE World Congr. Comput. Intell. 1998 IEEE Int. Conf.*
- Silva, P.G. Da, Germany, K., Karnouskos, D.I.S., 2014. The Impact of Smart Grid Prosumer Grouping on Forecasting Accuracy and Its Benefits for Local Electricity Market Trading. *IEEE Trans. Smart Grid* 5, 402–410.
- Sousa, T., Morais, H., Castro, R., Vale, Z., 2014. A new heuristic providing an effective initial solution for a simulated annealing approach to energy resource scheduling in smart grids. *2014 IEEE Symp. Comput. Intell. Appl. Smart Grid.*
- Suksonghong, K., Boonlong, K., Goh, K.-L., 2014. Multi-objective genetic algorithms for solving portfolio optimization problems in the electricity market. *Int. J. Electr. Power Energy Syst.* 58, 150–159.

-
- Sun, J., Feng, B., Xu, W., 2004. Particle swarm optimization with particles having quantum behavior. *Evol. Comput.* 2004. CEC2004. Congr.
- Teixeira, B., Silva, F., Pinto, T., Praça, I., Santos, G., Vale, Z., 2014. Data mining approach to support the generation of Realistic Scenarios for multi-agent simulation of electricity markets. *Intell. Agents (IA)*, 2014 IEEE Symp.
- Telecom Italia, 2016. Jade [WWW Document]. URL <http://jade.tilab.com/> (accessed 5.10.16).
- Vale, Z., Pinto, T., Praça, I., Morais, H., 2011. MASCEM: Electricity Markets Simulation with Strategic Agents. *IEEE Intell. Syst.* 26, 9–17.
- Vercher, E., Bermúdez, J.D., 2015. Portfolio optimization using a credibility mean-absolute semi-deviation model. *Expert Syst. Appl.* 42, 7121–7131.
- Watson, I.D., Gardingen, D., 1999. A Distributed Case-Based Reasoning Application for Engineering Sales Support. In: *Proceedings of the Sixteenth International Joint Conference on Artificial Intelligence*. Morgan Kaufmann Publishers Inc, Stockholm, Sweden, pp. 600–605.
- WebFinance, 2016. Business Dictionary [WWW Document]. URL <http://www.businessdictionary.com/>
- XBID, 2015. Cross-Border Intraday: Questions & Answers.
- Xin, J., Chen, G., Hai, Y., 2009. A Particle Swarm Optimizer with Multi-stage Linearly-Decreasing Inertia Weight. *Comput. Sci. Optim.* 2009. CSO 2009. Int. Jt. Conf.
- Yu, Z., 2003. A spatial mean-variance MIP model for energy market risk analysis. *Energy Econ.* 25, 255–268.
- Zadeh, L.A., 1965. Fuzzy sets. *Inf. Control* 8, 338–353.

Anexo A. Estimação dos preços, exemplo explicativo

Vai ser feito um exemplo explicativo da aplicação da metodologia utilizada para a estimação dos preços de eletricidade. Os dados aqui utilizados foram retirados das simulações efetuadas e apresentadas neste trabalho.

Mercado bilateral:

Após a aplicação do algoritmo *K-Means* para fazer o agrupamento em *clusters*, não só apresenta o número de clusters, mas também demonstra as coordenadas (x e y) dos centros de cada *cluster*.

Tabela 18 - Coordenadas dos centros dos *clusters*

Centroides	C1	C2	C3	C4	C5	C6	C7	C8	C9
x	2	5	7,5	11,5	17,5	24,5	32	39	46,5
y	8,666	33,333	73	81,333	74,667	62,375	64,429	53,429	63,75

Com a aplicação da Logica *Fuzzy* é possível desenhar a seguinte figura:

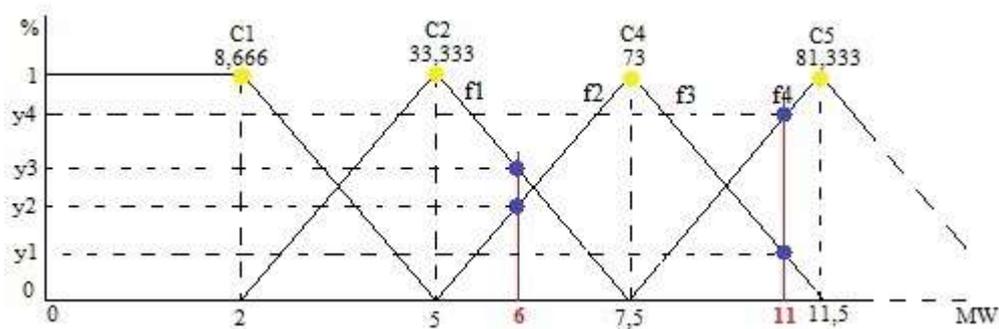


Figura 48 - Ilustração da aplicação da lógica fuzzy

Como é possível ver na Figura 48 os valores apresentados a vermelho são os que pretendemos estimar. Cada valor intersesta duas retas e é necessário calcular as ordenadas (yy) dos pontos de interseção.

Na figura, cada intervalo, exceto o primeiro, possui duas retas uma descendente (declive negativo) e outra ascendente (declive positivo) por isso, é necessário calcular os declives de cada uma dessas retas, assim como a ordenada na origem, e obter a seguinte expressão $f(y) = mx + b$ para cada uma das retas.

Tabela 19 - Declives e ordenadas na origem

Intervalo	1		2		3		4		5	
Limites	0	2	2	5	5	7,5	7,5	11,5	11,5	17,5
m	1		-0,33333	0,33333	-0,4	0,4	-0,25	0,25	-0,16667	0,16667
b	1		1,66667	-0,66667	3	-2	2,875	-1,875	2,91667	-1,91667

Os dados expostos na tabela anterior foram obtidos através dos dados presentes na figura. Com estes dados é possível escrever as seguintes expressões:

- $f1(y) = -0,4x + 3$
- $f2(y) = 0,4x - 2$
- $f3(y) = -0,25x + 2,785$
- $f4(y) = 0,25x - 1,875$

Substituindo o valor das referentes abscissas nas correspondentes expressões e multiplicando pelo referido *centroide*, obtemos os seguintes valores:

- $y1 = (-0,25 \times 11 + 2,785) \times C4 = 0,125 \times 73 = 9,125$
- $y2 = (0,4 \times 6 - 2) \times C4 = 0,4 \times 73 = 29,2$
- $y3 = (-0,4 \times 6 + 3) \times C2 = 0,6 \times 33,333 = 20$
- $y4 = (0,25 \times 11 - 1,875) \times C5 = 0,875 \times 81,333 = 71,167$

Fazendo a soma dos referentes valores podemos obter a estimação do preço:

Tabela 20 - Estimação dos preços

Quantidade (MW)	Preço Real (€)	Preço estimado (€)
6	33	$y_2 + y_3 = 49,2$
11	82	$y_1 + y_4 = 80,292$

Anexo B. Diagrama de extremos e quartis para as diferentes variantes do PSO aplicadas

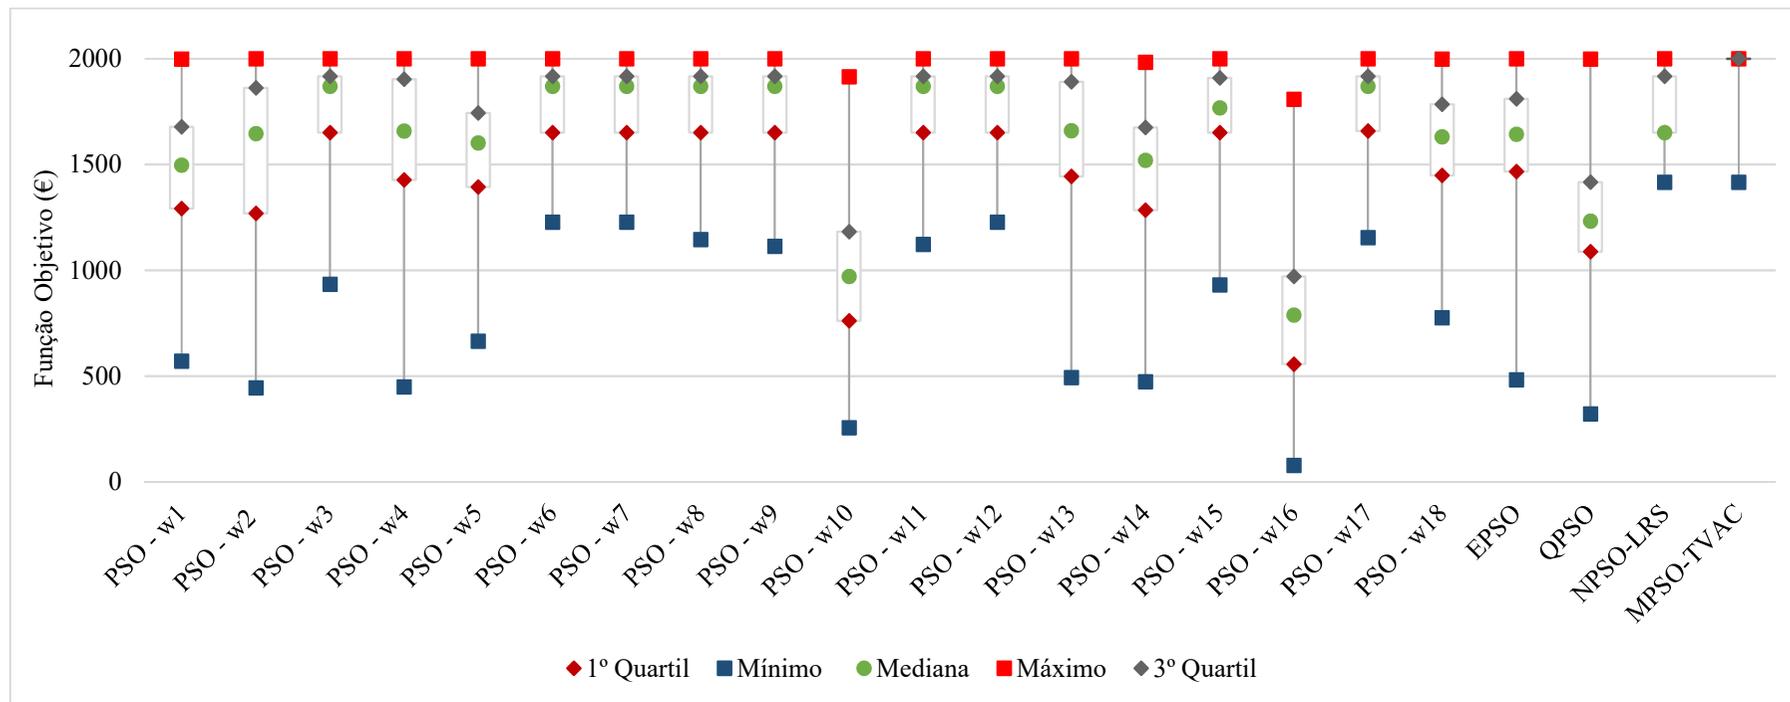


Figura 49 - Digrama de extremos e quartis das variantes do PSO

Anexo C. Diagrama de extremos e quartis para as diferentes variantes do AG e SA aplicadas

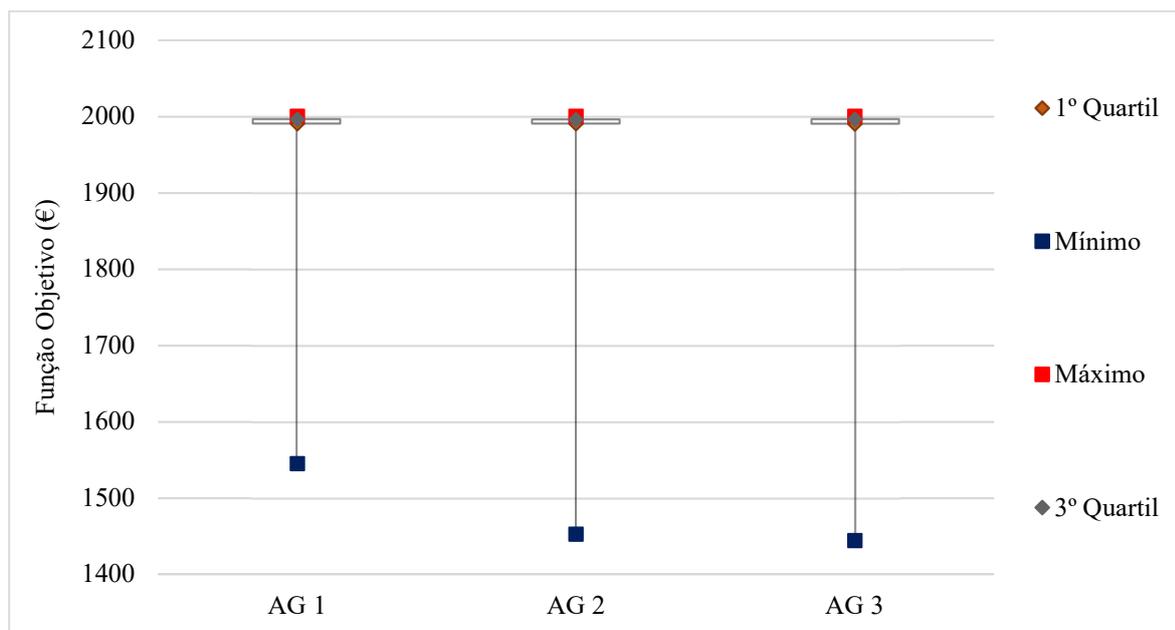


Figura 50- diagrama de extremos quartis das variantes do AG

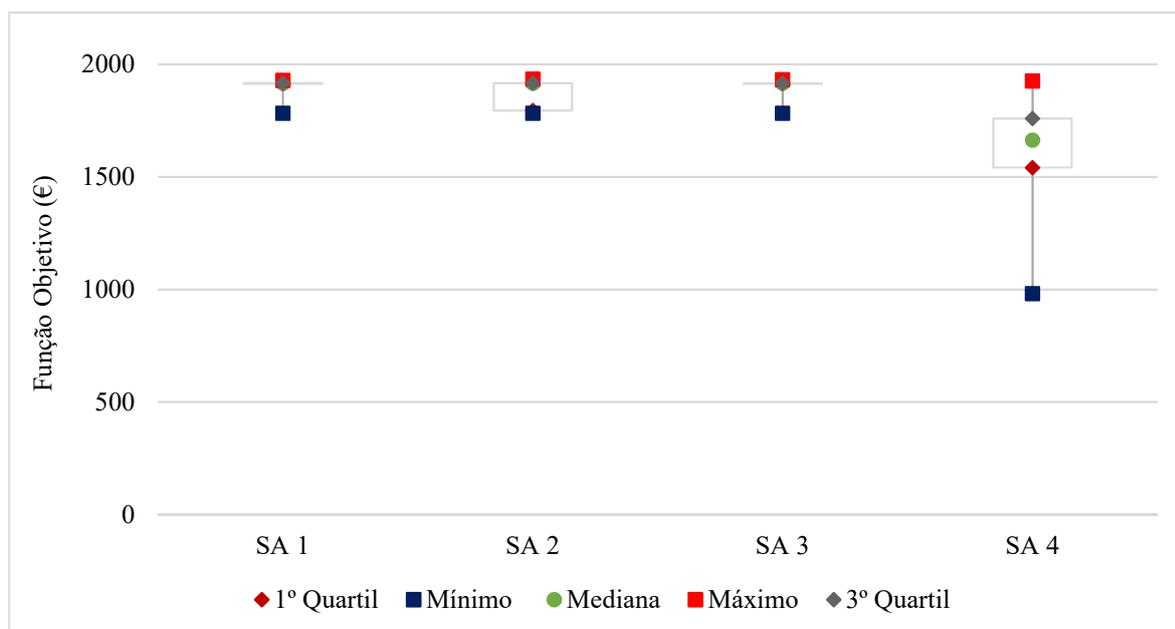


Figura 51 - Diagrama de extremos e quartis das variantes do SA

Anexo D. Escalonamento da quantidade de compra e venda de eletricidade para os diferentes mercados e correspondentes valores de exposição ao risco

Tabela 21 – Resultados dos algoritmos/variantes aplicados para cada nível de risco

Pesos	Algoritmos	Máximo F. Objetivo	F. Lucro (€)	F. Risco	Mercados										
					Compra (MW)					Venda (MW)					
					Spot	Bilateral	Balancing 1	Balancing 2	Smart Grid	Spot	Bilateral	Balancing 1	Balancing 2	Smart Grid	
0,1	PSO-w6	106,59	1363,27	33,04	23,14	0,00	0,00	0,00	0,00	0,00	0,00	3,14	10,00	0,00	0,00
	PSO-ST	94,80	1200,00	28,00	20,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	10,00	0,00	0,00
	NPSO-LRS	106,59	1363,27	33,04	23,14	0,00	0,00	0,00	0,00	0,00	0,00	3,14	10,00	0,00	0,00
	SA 1	105,91	1359,06	33,33	23,06	0,00	0,00	0,05	0,00	0,00	0,00	3,16	9,96	0,00	0,00
	AG 2	105,01	1325,64	30,61	22,09	0,00	0,00	0,00	0,00	0,00	0,00	2,16	9,94	0,02	0,00
0,15	PSO-w6	176,74	1373,48	34,45	23,60	0,00	0,00	0,00	0,00	0,00	0,00	3,60	10,00	0,00	0,00
	PSO-ST	163,38	1503,81	73,17	12,10	11,50	0,00	0,00	0,00	0,00	0,00	3,60	10,00	0,00	0,00
	NPSO-LRS	176,74	1373,48	34,45	23,60	0,00	0,00	0,00	0,00	0,00	0,00	3,60	10,00	0,00	0,00
	SA 1	175,33	1427,94	45,72	25,20	0,00	0,00	0,00	0,00	0,00	0,00	3,98	10,00	1,22	0,00
	AG 2	175,23	1348,91	31,89	22,67	0,00	0,00	0,01	0,00	0,00	0,00	2,70	9,99	0,00	0,00
0,2	PSO-w6	261,68	1777,97	117,39	33,88	0,00	0,00	0,00	0,00	0,00	0,00	3,88	10,00	10,00	0,00
	PSO-ST	261,68	1777,97	117,39	33,88	0,00	0,00	0,00	0,00	0,00	0,00	3,88	10,00	10,00	0,00
	NPSO-LRS	261,68	1777,97	117,39	33,88	0,00	0,00	0,00	0,00	0,00	0,00	3,88	10,00	10,00	0,00
	SA 1	260,83	1758,59	113,61	33,52	0,00	0,00	0,00	0,00	0,00	0,00	4,07	10,00	9,46	0,00
	AG 2	249,98	1723,98	118,52	17,65	11,51	0,00	0,00	0,00	0,00	0,00	3,67	9,99	5,49	0,01

Pesos	Algoritmos	Máximo F. Objetivo	F. Lucro (€)	F. Risco	Mercados									
					Compra (MW)					Venda (MW)				
					Spot	Bilateral	Balancing 1	Balancing 2	Smart Grid	Spot	Bilateral	Balancing 1	Balancing 2	Smart Grid
0,25	PSO-w6	360,08	1910,62	156,77	22,56	11,50	0,00	0,00	0,00	0,00	4,06	10,00	10,00	0,00
	PSO-ST	360,08	1910,62	156,77	22,56	11,50	0,00	0,00	0,00	0,00	4,06	10,00	10,00	0,00
	NPSO-LRS	360,08	1910,50	156,73	22,55	11,50	0,00	0,00	0,00	0,00	4,05	10,00	10,00	0,00
	SA 1	359,98	1911,10	157,06	22,68	11,49	0,00	0,00	0,00	0,00	4,16	10,00	10,00	0,00
	AG 2	355,11	1869,47	149,68	20,80	11,97	0,00	0,00	0,01	0,00	3,63	10,00	9,15	0,00
0,5	PSO-w6	881,38	1960,75	198,00	20,17	11,50	0,00	0,00	2,82	0,00	4,49	10,00	10,00	0,00
	PSO-ST	881,38	1960,39	197,64	20,19	11,50	0,00	0,00	2,80	0,00	4,49	10,00	10,00	0,00
	NPSO-LRS	881,18	1967,00	204,63	19,53	11,50	0,00	0,00	3,35	0,00	4,38	10,00	10,00	0,00
	SA 1	879,63	1968,60	209,34	19,64	11,42	0,00	0,00	3,64	0,00	4,70	10,00	10,00	0,00
	AG 2	880,70	1970,48	209,07	19,19	11,53	0,00	0,00	3,68	0,00	4,41	10,00	9,99	0,00
0,75	PSO-w6	1435,23	1997,54	251,68	16,14	11,50	0,00	0,00	7,01	0,00	4,65	10,00	10,00	0,00
	PSO-ST	1435,23	1997,53	251,65	16,14	11,50	0,00	0,00	7,00	0,00	4,65	10,00	10,00	0,00
	NPSO-LRS	1435,17	1997,30	251,21	16,05	11,50	0,00	0,00	7,00	0,00	4,55	10,00	10,00	0,00
	SA 1	1390,29	1953,85	300,37	18,04	11,97	0,00	0,00	7,50	0,00	4,88	10,00	10,00	2,63
	AG 2	1434,81	1998,23	255,47	15,83	11,66	0,00	0,00	7,25	0,00	4,75	10,00	10,00	0,00
1	PSO-w6	2000,65	2000,65	270,25	14,64	11,50	0,00	0,00	8,59	0,00	4,73	10,00	10,00	0,00
	PSO-ST	2000,65	2000,65	270,21	14,65	11,50	0,00	0,00	8,58	0,00	4,73	10,00	10,00	0,00
	NPSO-LRS	1999,55	1999,55	264,04	15,56	11,50	0,00	0,00	7,94	0,00	5,00	10,00	10,00	0,00
	SA 1	1960,16	1960,16	286,59	17,39	12,37	0,00	0,00	7,02	0,00	4,70	10,00	10,00	2,08
	AG 2	2000,28	2000,28	268,91	14,64	11,61	0,00	0,00	8,45	0,00	4,69	10,00	10,00	0,01

Anexo E. Resultados para o problema multiobjetivo

Tabela 22 - Resultados para o problema multiobjetivo

Pesos	Algoritmos	Máximo F. Objetivo	Média F. Objetivo	STD Objetivo	Média iterações	STD iterações	Média Tempo	STD Tempo
0,1	PSO-w6	106,588	55,764	57,011	151,204	67,486	0,404	0,180
	PSO-ST	94,800	50,702	9,964	160,992	112,171	62,436	63,960
	NPSO-LRS	106,588	51,654	23,777	10000,000	0,000	41,440	0,365
	SA 1	105,906	73,302	8,794	1834,539	19,750	1,483	0,057
	AG 2	105,012	69,248	8,875	2273,871	80,138	6,190	0,236
0,15	PSO-w6	176,735	120,437	57,390	174,515	55,080	0,474	0,150
	PSO-ST	163,376	135,822	6,903	223,500	76,087	90,025	65,051
	NPSO-LRS	176,735	99,783	32,065	10000,000	0,000	41,519	0,403
	SA 1	175,330	156,215	4,568	1853,958	20,265	1,490	0,044
	AG 2	175,232	139,008	15,976	2341,223	85,226	6,430	0,262
0,2	PSO-w6	261,683	201,902	61,886	179,644	49,550	0,491	0,136
	PSO-ST	261,683	232,874	11,633	234,084	82,528	91,645	65,324
	NPSO-LRS	261,683	166,250	49,542	10000,000	0,000	41,641	0,461
	SA 1	260,832	248,799	7,624	1862,217	20,588	1,113	0,461
	AG 2	249,977	216,852	21,606	2371,491	114,295	6,557	0,336
0,25	PSO-w6	360,078	289,438	71,386	187,135	40,066	0,515	0,111
	PSO-ST	360,078	333,300	18,122	252,066	81,660	117,932	90,932
	NPSO-LRS	360,077	247,907	58,580	10000,000	0,000	41,826	0,537
	SA 1	359,976	342,025	13,945	1868,835	20,005	1,440	0,242
	AG 2	355,105	291,092	36,823	2368,678	156,646	6,605	0,421
0,5	PSO-w6	881,375	763,164	94,630	200,536	33,325	0,564	0,097
	PSO-ST	881,376	865,264	33,461	321,819	68,153	153,609	107,099
	NPSO-LRS	881,185	712,575	89,375	10000,000	0,000	42,476	0,442
	SA 1	879,630	799,090	23,868	1853,567	20,789	1,527	0,038
	AG 2	880,704	711,084	179,731	2316,408	275,750	6,573	0,773
0,75	PSO-w6	1435,233	1275,880	125,578	204,627	28,801	0,582	0,085
	PSO-ST	1435,233	1419,919	40,393	332,234	59,370	189,005	135,046
	NPSO-LRS	1435,172	1180,341	108,549	10000,000	0,000	42,693	0,346
	SA 1	1390,291	1323,771	37,802	1836,701	24,768	1,603	0,073
	AG 2	1434,806	1259,568	195,253	2375,229	232,140	6,769	0,670

Pesos	Algoritmos	Máximo F. Objetivo	Média F. Objetivo	STD Objetivo	Média iterações	STD iterações	Média Tempo	STD Tempo
1	PSO-w6	2000,646	1792,806	147,160	203,322	29,761	0,582	0,088
	PSO-ST	2000,646	1978,517	50,284	331,691	60,570	177,383	123,977
	NPSO-LRS	1999,554	1687,784	114,626	10000,000	0,000	42,727	0,300
	SA 1	1960,161	1883,720	55,879	1831,584	25,201	1,608	0,099
	AG 2	2000,278	1771,208	218,248	2393,342	209,706	6,834	0,614