



Otimização Robusta de Recursos Energéticos em Edifícios utilizando Meta-Heurística

NUNO DOS SANTOS BORGES

novembro de 2016

OTIMIZAÇÃO ROBUSTA DE RECURSOS ENERGÉTICOS EM EDIFÍCIOS UTILIZANDO META-HEURÍSTICA

Nuno dos Santos Borges



Departamento de Engenharia Eletrotécnica

Mestrado em Engenharia Eletrotécnica – Sistemas Eléctricos 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: Nuno dos Santos Borges, Nº 1110700, 1110700@isep.ipp.pt

Orientação científica: Zita Maria Almeida do Vale, zav@isep.ipp.pt

Instituição: GECAD

Coorientação: João André Pinto Soares, joaps@isep.ipp.pt



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

2016

“Quanto mais aumenta o nosso conhecimento, mais evidente fica a nossa ignorância”

(John F. Kennedy)

Agradecimentos

Agradeço a todos que cooperaram e contribuíram de forma direta e indireta para a realização e conclusão desta dissertação.

Gostaria de agradecer á instituição Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e o Desenvolvimento (GECAD) que proporcionou as condições necessárias, incluindo dados, modelos computacionais e o apoio à instalação e utilização do *hardware* e *software* envolvidos.

Queria ainda agradecer em particular ao meu orientador institucional, Professora Doutora Zita Vale, e ao orientar do GECAD, Engenheiro João Soares, pelo apoio e orientação apresentados durante a realização deste trabalho.

À minha família, em especial aos meus pais e ao meu irmão, por toda a confiança e esperança que depositaram em mim, e pelo apoio e incentivo demonstrado que de alguma forma contribuíram para a realização e conclusão deste trabalho.

A todos os meus amigos por todo o apoio, paciência e compreensão nos momentos mais difíceis.

A todos, um muito obrigado!

Resumo

A utilização da produção distribuída é vista como uma solução para responder aos desafios energéticos e ambientais dos dias de hoje, existindo cada vez maior integração destas unidades de produção de pequena escala nos edifícios. Com o aumento da produção distribuída por fontes de energia renováveis, como é o caso da eólica e fotovoltaica, são introduzidas novas dificuldades no escalonamento de recursos, isto devido às incertezas das condições atmosféricas que levam a erros de previsão. Dito isto, as ferramentas de gestão de recursos energéticos em edifícios têm que ser capazes de modelar este comportamento incerto.

A principal contribuição desta dissertação foca-se no desenvolvimento de uma metodologia capaz de resolver o problema da gestão de recursos energéticos em edifícios para o dia seguinte, considerando as incertezas associadas à produção de energia das unidades fotovoltaicas e eólicas. Para modelar esta incerteza foi incorporado um modelo de otimização robusta no *multi-objective particle swarm optimization*. A otimização robusta numa meta-heurísticas representa uma importante contribuição desta dissertação, tendo em conta a escassez de trabalhos que abordam esta temática na literatura atual, especialmente na área da gestão de edifícios. Este tipo de abordagem permite obter uma solução mais conservadora, a melhor solução considerando os piores cenários. O problema proposto nesta tese considera dois objetivos conflitantes, a maximização dos lucros e minimização das emissões de CO₂. Outras contribuições relevantes são os modelos de negócios considerados, nomeadamente, o facto do edifício poder em cada período comprar energia a diferentes comercializadores de energia e o uso do *vehicle-to-building*, onde o veículo pode fornecer energia ao edifício, e ainda o uso de sistemas de armazenamento. Adicionalmente, foi proposto um modelo inovador de gestão da procura, que considera o preço diário da potência de pico e um incentivo para a minimizar. É apresentado um caso de estudo de um edifício real de Portugal, de forma a verificar a viabilidade do algoritmo robusto implementado.

Palavras-Chave

Edifícios Inteligentes, Gestão da Procura, Gestão de Recursos Energéticos, *Multi-Objective Particle Swarm Optimization*, Otimização Robusta, Veículos Elétricos

Abstract

The use of distributed generation is seen as one of the possible solutions to answer today's energy and environmental challenges with an increasing integration of this small scale production units in buildings. With the increasing of distributed generation from renewable energy sources, such as wind and photovoltaic, new difficulties are introduced in resources scheduling, due to the uncertainties from weather conditions that lead to forecast errors. That said, the energy resource management tools in buildings need to be able to model this uncertain behaviour.

The main contribution of this thesis focuses on the development of a methodology to solve the day-ahead energy resource management problem in buildings, considering the uncertainties associated with the energy production from photovoltaic and wind units. To model this uncertainty a robust optimization was incorporated in multi-objective particle swarm optimization. The robust optimization applied to a meta-heuristic, taking into account the scarcity of studies addressing this subject, especially in the area of building management, is an important contribution of this work. This approach allows a more conservative solution, the best solution considering the worst-case scenarios. The proposed problem in this thesis considers two conflicting objectives, maximizing profits and minimizing CO₂ emissions. Other relevant contributions are the business models considered, namely the fact that the building can buy energy from different external suppliers in each period, the use of vehicle-to-building, in which the electric vehicle can supply energy to the building, and the use of storage systems. In addition, an innovative demand response model has been proposed, which considers a daily peak power pricing and an incentive to minimize it. A case study is presented using a real building facility from Portugal, in order to verify the feasibility of the robust algorithm implemented.

Keywords

Demand Response, Electric Vehicles, Energy Resource Management, Multi-Objective Particle Swarm Optimization, Robust Optimization, Smart Building

Índice

AGRADECIMENTOS	I
RESUMO	III
ABSTRACT	V
ÍNDICE	VII
ÍNDICE DE FIGURAS	XI
ÍNDICE DE TABELAS	XV
ACRÓNIMOS	XVII
NOMENCLATURA	XIX
1. INTRODUÇÃO	1
1.1. OBJETIVOS DO TRABALHO	3
1.2. CONTRIBUIÇÕES DO TRABALHO.....	4
1.3. ORGANIZAÇÃO DO TRABALHO.....	7
2. GESTÃO DE RECURSOS ENERGÉTICOS EM EDIFÍCIOS	9
2.1. INTRODUÇÃO	9
2.2. REDES INTELIGENTES	11
2.2.1. MICRO REDES	12
2.2.2. CASAS INTELIGENTES.....	14
2.2.3. EDIFÍCIOS INTELIGENTES.....	14
2.3. RECURSOS ENERGÉTICOS DISTRIBUÍDOS	16
2.3.1. PRODUÇÃO DISTRIBUÍDA.....	16
2.3.2. TIPOS DE CARGA	18
2.3.3. GESTÃO DA PROCURA	18
2.3.4. SISTEMA DE ARMAZENAMENTO DE ENERGIA	20
2.3.5. VEÍCULOS ELÉTRICOS	20
2.4. ESTADO DE ARTE DA GESTÃO DE RECURSOS ENERGÉTICOS	21
2.4.1. INCERTEZA NA PREVISÃO DE RECURSOS ENERGÉTICOS	24
2.4.2. GESTÃO CENTRALIZADA/DESCENTRALIZADA.....	27
2.5. CONCLUSÕES	29
3. METODOLOGIA DE OTIMIZAÇÃO	31
3.1. TIPOS DE METODOLOGIAS DE OTIMIZAÇÃO	33
3.1.1. PROGRAMAÇÃO ESTOCÁSTICA	34

3.1.2. PROGRAMAÇÃO ROBUSTA	34
3.1.3. PROGRAMAÇÃO MULTIOBJECTIVO	35
3.2. MODELO DE OTIMIZAÇÃO	38
3.2.1. MODELO USADO - MULTI-OBJECTIVE PARTICLE SWARM OPTIMIZATION	38
3.2.2. MODELO COMPARATIVO – PROGRAMAÇÃO ESTOCÁSTICA DE DOIS ESTÁGIOS	43
3.3. FORMULAÇÃO MATEMÁTICA	44
3.3.1. FUNÇÃO OBJETIVO	44
3.3.2. RESTRIÇÕES	45
3.3.2.1. BALANÇO	45
3.3.2.2. PRODUÇÃO	45
3.3.2.3. SISTEMAS DE ARMAZENAMENTO DE ENERGIA	46
3.3.2.4. VEÍCULOS ELÉTRICOS	49
3.3.2.5. GESTÃO DA PROCURA	51
3.4. CONCLUSÕES	52
4. CASO DE ESTUDO	54
4.1. DESCRIÇÃO DO EDIFÍCIO	54
4.2. DESCRIÇÃO DOS RECURSOS DO EDIFÍCIO	56
4.2.1. SISTEMA FOTOVOLTAICO E EÓLICO	60
4.3. ESTRUTURA DOS TESTES REALIZADOS	60
4.4. RESULTADOS E ANÁLISES	63
4.4.1. OTIMIZAÇÃO ROBUSTA – CRITÉRIO DO LUCRO	64
4.4.2. OTIMIZAÇÃO – CRITÉRIOS IGUALMENTE RELEVANTES	70
4.4.3. OTIMIZAÇÃO ROBUSTA – CRITÉRIO DAS EMISSÕES DE CO ₂	79
4.4.4. OTIMIZAÇÃO – SEM INCERTEZA	89
4.4.5. COMPARAÇÃO DE TESTES	98
4.5. VERIFICAÇÃO DA VARIABILIDADE DO MÉTODO	100
4.6. COMPARAÇÃO DE MÉTODOS	102
5. CONCLUSÕES	107
5.1. PRINCIPAIS CONCLUSÕES E CONTRIBUIÇÕES	107
5.2. SUGESTÕES PARA TRABALHO FUTURO	110
REFERÊNCIAS DOCUMENTAIS	113
ANEXO A. CARATERÍSTICAS DOS VEÍCULOS ELÉTRICOS	122
ANEXO B. SOLUÇÕES DO OR-CL	123
ANEXO C. SOLUÇÕES DO O-CIR	124
ANEXO D. SOLUÇÕES DO OR-CE	125
ANEXO E. SOLUÇÕES DO O-SI	126

ANEXO F. SOLUÇÕES DA PROGRAMAÇÃO ESTOCÁSTICA.....	127
ANEXO G. SOLUÇÕES DA PROGRAMAÇÃO ROBUSTA	128

Índice de Figuras

Figura 1 – Visão geral das <i>Micro Grids</i> , adaptado de [17]	13
Figura 2 – Modelo de um sistema de gestão num <i>Smart Building</i>	15
Figura 3 – Metodologia de gestão de recursos energéticos em edifícios	32
Figura 4 – Exemplo da relação de dominância	37
Figura 5 – Fluxograma do MOPSO desenvolvido	41
Figura 6 - Mapa dos edifícios do campus do ISEP	55
Figura 7 – Perfil de produção de energia do fotovoltaico e eólica	58
Figura 8 – Consumo versus PD total	58
Figura 9 – Consumo das viagens e número de VEs ligados à rede e em viagem	59
Figura 10 – Sistema de produção do GECAD	60
Figura 11 – Estrutura do escalonamento para o dia seguinte	61
Figura 12 – Frente de Pareto do OR-CL	64
Figura 13 – Escalonamento de recursos ótimo da NDS-L no OR-CL	65
Figura 14 – Escalonamento de recursos ótimo da NDS-R no OR-CL	65
Figura 15 – Percentagem de uso dos recursos de produção da NDS-L no OR-CL	66
Figura 16 – Percentagem de uso dos recursos de produção da NDS-R no OR-CL	67
Figura 17 – Escalonamento do consumo da NDS-L no OR-CL	67
Figura 18 – Escalonamento do consumo da NDS-R no OR-CL	68
Figura 19 – Percentagem dos recursos de consumo da NDS-L no OR-CL	68
Figura 20 – Percentagem dos recursos de consumo da NDS-R no OR-CL	69
Figura 21 – Frente de <i>Pareto</i> do O-CIR	70
Figura 22 – Escalonamento de recursos ótimo da NDS-L no O-CIR	72
Figura 23 – Escalonamento de recursos ótimo da NDS-R no O-CIR	72

Figura 24 – Percentagem de uso dos recursos de produção da NDS-L no O-CIR	73
Figura 25 – Percentagem de uso dos recursos de produção da NDS-R no O-CIR	73
Figura 26 – Escalonamento do consumo da NDS-L no O-CIR	74
Figura 27 – Escalonamento do consumo da NDS-R no O-CIR	74
Figura 28 – Percentagem dos recursos de consumo da NDS-L no O-CIR	75
Figura 29 – Percentagem dos recursos de consumo da NDS-R no O-CIR	75
Figura 30 – Frentes de <i>Pareto</i> do O-CIR e OR-CL	77
Figura 31 – Frente de <i>Pareto</i> do OR-CE	80
Figura 32 – Escalonamento de recursos ótimo da NDS-L no OR-CE	81
Figura 33 – Escalonamento de recursos ótimo da NDS-R no OR-CE	81
Figura 34 – Percentagem de uso dos recursos de produção da NDS-L no OR-CE	82
Figura 35 – Percentagem de uso dos recursos de produção da NDS-R no OR-CE	82
Figura 36 – Escalonamento do consumo da NDS-L no OR-CE	83
Figura 37 – Escalonamento do consumo da NDS-R no OR-CE	83
Figura 38 – Percentagem dos recursos de consumo da NDS-L no OR-CE	84
Figura 39 – Percentagem dos recursos de consumo da NDS-R no OR-CE	84
Figura 40 – Frentes de <i>Pareto</i> do OR-CE e OR-CL	87
Figura 41 – Frente de <i>Pareto</i> do O-SI	89
Figura 42 – Escalonamento de recursos ótimo da NDS-L no O-SI	90
Figura 43 – Escalonamento de recursos ótimo da NDS-R no O-SI	90
Figura 44 – Percentagem de uso dos recursos de produção da NDS-L no O-SI	91
Figura 45 – Percentagem de uso dos recursos de produção da NDS-R no O-SI	91
Figura 46 – Escalonamento do consumo da NDS-L no O-SI	92
Figura 47 – Escalonamento do consumo da NDS-R no O-SI	92
Figura 48 – Percentagem dos recursos de consumo da NDS-L no O-SI	93
Figura 49 – Percentagem dos recursos de consumo da NDS-R no O-SI	93

Figura 50 – Frentes de <i>Pareto</i> do O-SI e OR-CL	95
Figura 51 – Frentes de <i>Pareto</i> obtidas para todos os testes	98
Figura 52 – Variabilidade da frente de <i>Pareto</i> obtida no método do OR-CL	101
Figura 53 – Frentes de <i>Pareto</i> obtidas para a abordagem robusta e estocástica	103

Índice de Tabelas

Tabela 1 – Revisão do estado de arte e características do modelo proposto	24
Tabela 2 – Informação geral dos dados usados	56
Tabela 3 – Dados dos recursos de energia	56
Tabela 4 – Fornecedores de energia externos considerados no caso de estudo	57
Tabela 5 – Tabela de preços da potência de pico	57
Tabela 6 – Parâmetros do MOPSO	62
Tabela 7 – Soluções não dominadas selecionadas do OR-CL	64
Tabela 8 – Comparação entre a solução NDS-L e NDS-R do OR-CL	70
Tabela 9 – Soluções não dominadas selecionadas do O-CIR	71
Tabela 10 – Comparação entre a solução NDS-L e NDS-R do O-CIR	76
Tabela 11 – Comparação entre as soluções do O-CIR e do OR-CL	79
Tabela 12 – Soluções não dominadas selecionadas do OR-CE	80
Tabela 13 – Comparação entre a solução NDS-L e NDS-R do OR-CE	86
Tabela 14 – Comparação entre as soluções do OR-CE e do OR-CL	88
Tabela 15 – Soluções não dominadas selecionadas do O-SI	89
Tabela 16 – Comparação entre a solução NDS-L e NDS-R do O-SI	94
Tabela 17 – Comparação entre as soluções do O-SI e o OR-CL	98
Tabela 18 – Soluções NDS-L e NDS-R e tempo de execução para todos os testes	100
Tabela 19 – Métricas para a medição da variabilidade do MOPSO	102
Tabela 20 – Comparação de resultados entre a abordagem robusta e estocástica	105

Acrónimos

BT	Baixa Tensão
CA	Corrente Alternada
CC	Corrente Contínua
CHP	<i>Combined Heat and Power</i> (Cogeração)
DR	<i>Demand Response</i> (Gestão da Procura)
EVeSSi	<i>Electric Vehicle Scenario Simulator</i> (Simulador de Cenários de Veículos Elétricos)
MC	Monte Carlo
MG	<i>Micro Grids</i> (Micro Redes)
MOPSO	<i>Multi-Objective Particle Swarm Optimization</i>
MT	Média Tensão
NDS	<i>Non-dominated Solution</i> (Solução Não-dominada)
O-CIR	Otimização – Critérios Iguamente Relevantes
OR-CE	Otimização Robusta – Critério das Emissões de CO ₂
OR-CL	Otimização Robusta – Critério do Lucro
O-SI	Otimização – Sem Incerteza
PD	Produção Distribuída
PLIM	Programação Linear Inteira Mista
PSO	<i>Particle Swarm Optimization</i>
SB	<i>Smart Building</i> (Edifício Inteligente)
SG	<i>Smart Grid</i> (Rede Inteligente)
SH	<i>Smart Home</i> (Casa Inteligente)

V2B *Vehicle-to-Building*

V2G *Vehicle-to-Grid*

VE Veículo Elétrico

Nomenclatura

Índices

d	Índice das unidades de produção distribuída (PD)
t	Índice dos períodos de tempo
l	Índice das cargas
s	Índice dos fornecedores externos de energia
v	Índice dos veículos elétricos (VEs)
st	Índice das unidades de armazenamento de energia

Conjuntos

Ω_{dg}^e	Conjunto das unidades de PD com emissões de CO ₂
Ω_{sp}^e	Conjunto dos fornecedores externos com emissões de CO ₂
Ω_{dg}^d	Conjunto das unidades de PD escalonáveis
Ω_{dg}^{nd}	Conjunto das unidades de PD não escalonáveis

Parâmetros

N_{dg}	Número total de unidades de PD
N_l	Número total de cargas
N_{sp}	Número total de fornecedores externos
N_v	Número total de VEs
N_{st}	Número total de sistemas de armazenamento de energia
$c_{disch}^v(t)$	Custo de descarregamento do VE de índice v no período t (m.u.)
$c_{disch}^{st}(t)$	Custo de descarregamento do sistema de armazenamento de índice st no período t (m.u.)
$c_{dg}^d(t)$	Custo de produção da unidade de PD de índice d no período t (m.u.)
$c_{sp}^s(t)$	Preço da energia fornecida pelo fornecedor externo de índice s no período t (m.u.)
$E_{dg}^d(t)$	Emissões de CO ₂ da unidade de PD de índice d no período t (kgCO ₂ /kWh)

$E_{sp}^s(t)$	Emissões de CO ₂ do fornecedor externo de índice s no período t (kgCO ₂ /kWh)
$c_{charg}^v(t)$	Preço de carregamento do VE de índice v no período t (m.u./kWh)
$c_{charg}^{st}(t)$	Preço de carregamento do sistema de armazenamento de índice st no período t (m.u.)
Variáveis	
$P_{dg}^d(t)$	Potência ativa gerada pela unidade de PD de índice d no período t (kW)
$P_{sp}^s(t)$	Potência ativa gerada pelo fornecedor externo de índice s no período t (kW)
$P_{disch}^v(t)$	Descarga de energia do VE de índice v no período t (kW)
$P_{disch}^{st}(t)$	Descarga de energia do sistema de armazenamento de índice st no período t (kW)
$P_{charg}^v(t)$	Carregamento de energia do VE de índice v no período t (kW)
$P_{charg}^{st}(t)$	Carregamento de energia do sistema de armazenamento de índice st no período t (kW)
$P_{load}^l(t)$	Potência ativa consumida pela carga l no período t (kW)
$C_{peakPower}$	Custo da potência de pico (m.u.)
$r_{peakPower}$	Receita pelo cumprimento do valor de potência de pico (m.u.)
R	Receita total (m.u.)
E	Valor total de emissões de CO ₂ (kg)
C	Custo total (m.u.)

1. INTRODUÇÃO

O aumento da penetração das unidades de produção baseadas em fontes de energia renováveis, como é o caso da energia eólica e da energia fotovoltaica, é visto como uma solução para a redução significativa das emissões de CO₂. No entanto, contrariamente às unidades de geração convencionais, as fontes renováveis são caracterizadas por um elevado grau de incerteza. Existe então a necessidade de utilizar modelos de programação avançada, recorrendo-se a modelos de controlo robustos e modelos preditivos, capazes de lidar e modelar este comportamento incerto. A motivação de estabelecer um modelo robusto está associada ao desafio de enfrentar a variabilidade e incerteza dos recursos energéticos renováveis associados às redes inteligentes¹ (SGs), às micro redes² (MGs) e aos edifícios, uma vez que estes recursos constituem uma parte significativa do total da produção atual e futura.

¹ *Smart Grid* (SG), na designação anglo-saxónica.

² *Micro Grid* (MG), na designação anglo-saxónica.

Atualmente os edifícios são vistos como um simples consumidor, contudo, cada vez mais estes dispõem de diversos recursos que podem ter um comportamento ativo na rede, como é o caso das unidades de Produção Distribuída (PD), dos sistemas de armazenamento de energia e dos Veículos Elétricos (VEs). Tendo em conta este novo conceito torna-se necessária a realização da gestão de recursos energéticos num edifício.

Este trabalho apresenta uma metodologia que tem como objetivo a resolução do problema da gestão de recursos energéticos num edifício para o dia seguinte. O modelo proposto é capaz de gerir diversos tipos de recursos energéticos num horizonte temporal de 24 horas, com uma granularidade de 1 hora, e integra recursos como a PD, os sistemas de armazenamento e os VEs. A metodologia desenvolvida tem a capacidade de modelar a incerteza existente nos valores de produção de PD (eólica e fotovoltaica). Para modelar esta incerteza foi incorporado um modelo de otimização robusta numa meta-heurística. Este tipo de abordagem permite obter uma solução robusta, ou seja, uma solução mais adversa ao risco. O problema proposto retrata um problema multiobjectivo solucionado através da implementação de uma meta-heurística, o *Multi-Objective Particle Swarm Optimization* (MOPSO), implementado em MATLAB – *MATrix LABoratory* [1]. No problema são considerados dois objetivos conflitantes, a maximização dos lucros e a minimização das emissões de CO₂. Os objetivos são conflitantes uma vez que para se obter um valor de lucro mais elevado, os níveis de emissão de CO₂ terão que ser por sua vez também maiores (uso de recursos com mais emissões, como o caso dos fornecedores externos, mas com custo mais barato), e vice-versa (uso de recursos sem emissões, com a descarga de veículos, com um custo mais elevado).

O MOPSO desenvolvido foi testado para um caso de estudo de um edifício real em Portugal, o edifício do Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e o Desenvolvimento (GECAD). A infraestrutura engloba a supervisão e o controlo de microprodução (um gerador eólico com uma capacidade máxima de 1,0 kW e um sistema fotovoltaico com uma capacidade máxima de 7,5 kW) e o consumo existente no edifício. Tendo em conta estes dados reais monitorizados, foi criado um caso de estudo que pretende representar um edifício de escritórios em Portugal. A principal vantagem da utilização deste caso de estudo remonta para o facto de se poder usar dados reais, quer de consumo quer de produção, lidos praticamente em tempo real e que se encontram armazenados numa base de dados. Para tornar o caso de estudo mais interessante, foram

integrados no edifício um sistema de armazenamento (10kW) e três VEs (disponibilidade máxima de 9kW), com capacidade de carregamento e de descarga. Para este caso de estudo foram realizados quatro testes diferentes: o primeiro teste considera uma otimização robusta dando importância ao critério do lucro; o segundo teste onde ambos os critérios são igualmente relevantes; um terceiro teste em que a otimização robusta dá mais relevância ao critério das emissões de CO₂, e por último um teste sem incertezas; ou seja, é considerada que a previsão para o dia seguinte é perfeita.

Para confirmar a validade do MOPSO, foi realizada uma verificação do grau de variabilidade do método. Esta avaliação é necessária pois sempre que se executa o algoritmo são obtidas soluções ligeiramente diferentes, isto devido a se tratar de um método de pesquisa não exata (aleatoriedade existente nos processos de pesquisa). Não obstante, os resultados obtidos pela metodologia desenvolvida foram comparados com os resultados obtidos por uma programação estocástica implementada em TOMLAB, que é uma ferramenta de otimização avançada para MATLAB, usando CPLEX *solver*.

1.1. OBJETIVOS DO TRABALHO

O aumento da PD a partir de fontes de energia renováveis, como é o caso da energia eólica e da energia fotovoltaica, introduz novas dificuldades no escalonamento de recursos em edifícios. Os níveis de produção deste tipo de fontes de energia estão diretamente dependentes das condições atmosféricas (sol e vento), que acarretam um elevado grau de incertezas, levando a erros de previsão. Para lidar com as incertezas é necessário a utilização de modelos de programação robustos capazes de lidar e modelar todo este comportamento incerto. Esta dissertação tem por objetivo o desenvolvimento de uma metodologia capaz de lidar com o problema das incertezas associadas aos recursos energéticos de produção existentes num edifício, sendo a incerteza da produção modelada através do uso da otimização robusta.

A concretização do objetivo principal deste trabalho envolveu a abordagem e realização dos seguintes tópicos:

- Análise do estado da arte;
- Definição da formulação matemática para o problema de gestão de recursos energéticos em edifícios;

- Desenvolvimento e implementação de um algoritmo de otimização robusta usando uma meta-heurística;
- Desenvolvimento de um caso de estudo realístico e respetiva simulação;
- Análise de resultados e conclusões;

1.2. CONTRIBUIÇÕES DO TRABALHO

O trabalho desenvolvido nesta dissertação remete para uma metodologia de apoio à gestão dos recursos energéticos em edifícios. A metodologia permite gerir diversos tipos de recursos num horizonte temporal de 24 horas, integrando recursos como a PD, os sistemas de armazenamento e os VEs. O principal contributo é o facto de esta metodologia considerar as incertezas associadas à produção de energia por fontes renováveis, sendo essas incertezas modeladas com o uso de um modelo de otimização robusto, implementado na meta-heurística MOPSO. Outras contribuições relevantes são os modelos de negócios considerados, nomeadamente, o facto do edifício poder em cada período comprar energia a diferentes comercializadores de energia e o uso do *Vehicle-to-Building*³ (V2B), onde o veículo pode fornecer energia ao edifício. Adicionalmente, foi proposto um modelo inovador de gestão da procura⁴ (DR), que considera o preço diário da potência de pico e um incentivo para a minimizar. Estes modelos de negócio são apresentados de forma mais detalhada no capítulo 3.

O trabalho desenvolvido no âmbito desta dissertação contribuiu para a evolução de alguns projetos no âmbito do Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e o Desenvolvimento - GECAD. Os projetos considerados foram:

- **AVIGAE** - Assistente Virtual Inteligente para a Gestão Ativa da Energia em Edifícios, P2020 003401;

³ *Vehicle-to-Building* (V2B), na designação anglo-saxónica. Um veículo elétrico com possibilidade de V2B é capaz de armazenar energia elétrica e, quando solicitado, fornecê-la ao edifício

⁴ *Demand Response* (DR), na designação anglo-saxónica. A DR pode ser definida como a modificação dos padrões de consumo habituais, em resposta a fatores como: a mudança do preço da eletricidade e incentivos monetários

- **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-2014; projeto nº 641794;
- **ELECON** – *Electricity Consumption Analysis to Promote Energy Efficiency Considering Demand Response and Non-technical Losses*, FP7-PEOPLE – IRSES, 318912- FP7-PEOPLE;
- **GID-MicroRede** – Sistema de Gestão Inteligente e Descentralizado de Micro-redes de Distribuição Privadas, QREN Ref.34086;
- **IMaDER** – Gestão Inteligente de Recursos Energéticos Distribuídos a Curto Prazo em Ambiente Competitivo, PTDC/SEN-ENR/122174/2010;
- **SASGER-MeC** – Simulação e Análise de *Smart Grids* com Energias Renováveis e Mercado Competitivo, ON2 NORTE-07-0162-FEDER-000101;
- **SEAS** – *Smart Energy Aware Systems*, ITEA2 nº 12004, cluster EUREKA.

O trabalho desenvolvido nesta dissertação resultou em vários artigos científicos, dos quais os seguintes devem ser referidos:

Cinco artigos em **revistas científicas internacionais indexadas no SCI⁵**:

- João Soares, Nuno Borges, Zita Vale, Paulo B. Oliveira
“Enhanced Multi-objective Energy Optimization by Signaling Method”
Energies, vol.9, número. 807, outubro de 2016
- João Soares, Nuno Borges, Mohammad A. Fotouhi, Zita Vale, Paulo B. Oliveira
“Scenario Generation for Electric Vehicles Uncertain Behavior in a Smart City Environment”
Energy, vol.111, pp. 664-675, setembro de 2016
- João Soares, Nuno Borges, Mohammad A. Fotouhi, Zita Vale
“A Stochastic Model for Energy Resources Management in Smart Grids”
Electric Power Systems Research, (aceite em outubro de 2016)
- João Soares, Mohammad A. Fotouhi, Nuno Borges, Zita Vale

⁵ Science Citation Index® (SCI®);

http://thomsonreuters.com/products_services/science/science_products/a-z/science_citation_index/

“EVs optimal pricing considering renewable-based generation, storage, and other loads flexibility using stochastic programming”

Energy

(em revisão)

- Nuno Borges, João Soares, Zita Vale,
“Multi-objective Approaches to Solve Energy Resources Management in Buildings Using a Robust Metaheuristic”
Energy and Buildings
(em preparação)

Sete artigos em conferências internacionais:

- João Soares, Nuno Borges, M. Ali Fotouhi, Zita Vale
“The Effect of Demand Response in the Minimum Available Reserve of Energy Management”
IEEE PES General Meeting 2016
Boston, MA, USA, 17-21 julho, 2016
- Nuno Borges, João Soares, Zita Vale, Bruno Canizes
“Weighted sum approach using Parallel, Particle Swarm Optimization to Solve Multi-objective Energy Scheduling”
IEEE Transmission & Distribution Conference & Exposition (T&D 2016)
Dallas, USA, 02-05 maio, 2016
- João Soares, Zita Vale, Nuno Borges
“Current status and new business models for electric vehicles demand response design in smart grids”
Simulation of consumers and markets towards real time demand response, Primeiro Workshop DREAM-GO, Instituto de Engenharia - Politécnico do Porto, Porto, Portugal, 06-07 abril, 2016
- João Soares, Nuno Borges, Cristina Lobo, Zita Vale
“VPP Energy Resources Management considering Emissions: The case of northern Portugal 2020 to 2050”
SSCI 2015
Cape Town, South Africa, 08-10 dezembro, 2015
- Bruno Canizes, João Soares, Zita Vale, Nuno Borges
“Distribution Network Reconfiguration in a Smart Grid”

Regulatory context of smart grids in Europe and Brazil: current state and trends,
Terceiro Workshop ELECON, University of Grenoble – Grenoble Polytechnic
Institute, Grenoble, France, 17-18 novembro, 2015

- João Soares, Zita Vale, Hugo Morais, Nuno Borges
*“Demand Response in Electric Vehicles Management: Optimal Use of End-user
Contracts”*
Mexican International Conference on Artificial Intelligence
Cuernavaca, Mexico, 25-31 outubro, 2015
- João Soares, Nuno Borges, Bruno Canizes, Zita Vale
*“Probabilistic Estimation of the State of Electric Vehicles for Smart Grid
Applications in Big Data Context”*
IEEE PES General Meeting 2015
Denver, Colorado, USA, 26 – 30 julho, 2015

Um capítulo em livro:

- Nuno Borges, João Soares, Zita Vale
*“Fuzzy Probabilistic Estimation of the Electric Vehicles Energy Consumption
Advances in Artificial Intelligence and Its Applications”*
Lecture Notes in Computer Science, vol. 9414, pp 26-36, dezembro de 2015
Springer

1.3. ORGANIZAÇÃO DO TRABALHO

A dissertação está dividida nos seguintes cinco capítulos. O capítulo um apresenta a motivação referente ao trabalho elaborado, os principais objetivos e contribuições resultante da metodologia desenvolvida. O segundo capítulo aborda o estado da arte no que toca ao panorama atual dos edifícios, focando-se essencialmente nos sistemas de gestão dos seus recursos de energia, nomeadamente, as suas cargas, unidades de produção, e nos sistemas de armazenamento de energia. No capítulo três é apresentada a metodologia do modelo de otimização robusto proposto para a realização da gestão dos recursos energéticos em edifícios. No quarto capítulo é apresentado um caso de estudo que permite avaliar e analisar o desempenho da ferramenta de gestão dos recursos energéticos, no contexto dos edifícios. O caso de estudo foi desenvolvido considerando quatro testes diferentes. São apresentados todos os resultados considerados indispensáveis para a realização do trabalho. Os resultados obtidos são apresentados e discutidos, sendo feita uma análise entre testes. O último capítulo

apresenta as principais conclusões e contribuições do trabalho realizado, sendo ainda apresentadas sugestões para trabalho futuro.

2. GESTÃO DE RECURSOS ENERGÉTICOS EM EDIFÍCIOS

2.1. INTRODUÇÃO

O consumo de energia por parte dos edifícios representa 20 a 40% do consumo total de eletricidade de um país desenvolvido [2]. Os edifícios representam 40% do consumo total na União Europeia [3] e 37% nos Estados Unidos [2], sendo estes alguns dos exemplos do cenário atual. A realidade é que o consumo de energia por parte dos edifícios é tendencialmente crescente, tendência essa que se reflete devido à cada vez maior dimensão dos edifícios, ao aumento dos requisitos mínimos dos níveis de conforto, ao aumento da quantidade e diversidade dos aparelhos domésticos, e a integração dos VEs, que representam um incremento significativo nos consumos de energia [4]. Outro fator importante é o crescimento dos países subdesenvolvidos, pois a obtenção dos requisitos mínimos de qualidade de vida destes países levará a um aumento significativo dos consumos energéticos nos seus edifícios. Posto isto, este aumento de consumo de energia estará diretamente interligado com o aumento das emissões de CO₂, criando problemas a nível ambiental. Um

grande número de diretivas para o controlo dos níveis das emissões de CO₂ estão atualmente em vigor, estimulando uma redução desses níveis no setor elétrico [2].

Com a crescente preocupação em relação às mudanças climáticas globais, tais como o aquecimento global e a poluição atmosférica, foram criadas políticas que têm como objetivo promover a produção elétrica a partir de fontes de energia renovável. O aumento da PD, baseada em fontes renováveis (painéis fotovoltaicos, turbinas eólicas, mini-hídrica, etc.), apresenta-se como uma solução capaz de diminuir consideravelmente as emissões de CO₂. Contudo, com a grande penetração deste tipo de PD existirá maior incerteza face aos valores de produção, uma vez que os recursos primários como o vento e o sol não podem ser controlados, resultando numa mais complexa operação e planeamento ao nível da rede elétrica, e particularmente ao nível do edifício.

No contexto atual os consumidores finais são vistos como uma simples carga que necessita de ser alimentada pela rede. A realidade é que cada vez mais estes serão intervenientes ativos na rede, necessitando de realizar uma gestão dos seus recursos, nomeadamente, as suas cargas, as unidades de PD e os sistemas de armazenamento. Porém, para esta participação ser possível, é essencial uma infraestrutura denominada de SG [5]. As SGs estão associadas a uma melhoria da rede elétrica em termos de fiabilidade e qualidade de energia, sendo estas capazes de controlar e gerir a produção de energia e o consumo de todos os seus intervenientes. Como é descrito em [6], a SG pretende maximizar a penetração das fontes de energia renovável e, por outro lado, incluir programas de DR nos consumidores. A DR consiste numa mudança do padrão normal do uso de eletricidade (consumo) por parte dos clientes finais em resposta a uma mudança do preço de eletricidade ou devido a pagamentos de incentivos [7].

A iluminação e os sistemas de climatização são os principais responsáveis pelo maior nível de consumos em edifícios. Os sistemas de climatização e de iluminação são responsáveis por cerca de 40% e 15% do consumo [8], respetivamente. O grande potencial da aplicação da DR será então nos sistemas de climatização e de iluminação dos edifícios. Estes tipos de estudos permitem a reflexão sobre os consumos energéticos que ocorrem nos edifícios, tendo em conta, as próprias atitudes e ações dos utilizadores, que afetaram diretamente a sustentabilidade energética no edifício.

Conceitos como as casas inteligentes⁶ (SHs) e edifícios inteligentes⁷ (SBs), representam soluções que irão permitir uma gestão interna dos recursos energéticos através de uma rede de comunicação entre todos os dispositivos, permitindo o controlo, a monitorização e o acesso remoto a todas as aplicações, e serviços do sistema de gestão, aumentando a eficiência e sustentabilidade dos edifícios.

2.2. REDES INTELIGENTES

A SG representa um novo conceito que se pretende adotar nas redes elétricas. Ainda não existe propriamente um consenso em relação a uma definição técnica e funcional sobre o que é uma rede inteligente [9], [10]. A definição de SG, partilhada pela maioria das definições existente na literatura atual, caracteriza uma SG como a integração de tecnologias de informação e comunicação na rede existente, permitindo um fluxo bidirecional de informações e de eletricidade entre os produtores e consumidores [10]–[13]. Este tipo de redes inclui contadores de energia inteligentes⁸ (*smart meters*) nos consumidores, comunicação entre o consumidor e os produtores, e um sistema de receção e gestão de dados que tornam a informação disponível para o operador do sistema. O principal objetivo é tornar a rede mais ativa e eficiente, integrando técnicas de medição inteligente com os processos comerciais e, simultaneamente, abrindo caminho para uma operação flexível a todos os níveis de distribuição, aumentando a eficiência e a qualidade do serviço, adiando investimentos para reforço da rede, enquanto se diminui o investimento e os custos de operação.

De acordo com as referências [14], [15], as SGs têm como principais objetivos:

- Autorreparação: a completa sensorização da rede permitirá utilizar a informação em tempo real para antecipar, detetar e responder a problemas na rede;

⁶ *Smart Homes* (SHs), na designação anglo-saxónica.

⁷ *Smart Buildings* (SBs), na designação anglo-saxónica.

⁸ *Smart meters*, na designação anglo-saxónica

- **Motivação e envolvimento dos consumidores:** uma rede elétrica inteligente incorpora tecnologias que permitem que os consumidores controlem os equipamentos dos seus edifícios, possibilitando uma gestão dos consumos de energia mais eficiente e reduzindo os custos finais na fatura de eletricidade;
- **Maior fiabilidade:** a informação em tempo real proveniente da rede permite aos operadores gerir os fluxos elétricos de modo a redirecioná-los por percursos alternativos que garantam o serviço nas zonas afetadas pelo defeito ocorrido;
- **Acomodação de todas as opções de produção e armazenamento de energia:** a interconexão eficiente de várias fontes de produção de energia distribuída permite que os consumidores residenciais, comerciais e industriais, que produzam eletricidade em excesso, possam fornecer essa energia à rede. Este fator melhora a fiabilidade e a qualidade da energia, reduz os preços da eletricidade e aumenta as escolhas do consumidor;
- **Maior eficiência:** a SG minimiza os custos de operação e de manutenção da rede. Os fluxos de energia otimizados reduzem os desperdícios energéticos e maximizam o uso de recursos energéticos de baixo custo. A harmonização da distribuição local com fluxos de energia inter-regionais na rede de transporte reduz os congestionamentos e pontos de críticos na rede.

Numa visão ampla das SG é possível verificar que estes sistemas podem integrar a PD, a DR, as tecnologias inteligentes de medição e monitorização dos consumos de energia elétrica, as tecnologias de armazenamento de energia elétrica, onde se podem incluir os VEs com capacidade de *Vehicle-to-Grid*⁹ (V2G), e os padrões de comunicação e interoperabilidade da rede.

2.2.1. MICRO REDES

Com a crescente necessidade de integrar a PD de pequena escala na rede elétrica, surge o conceito das MGs. As MGs são referenciadas como redes de energia locais que retratam um

⁹ *Vehicle-to-Grid* (V2G), na designação anglo-saxónica. Um veículo elétrico com possibilidade de V2G é capaz de armazenar energia elétrica e, quando solicitado, fornecê-la novamente à rede

subconjunto da rede principal, conceito esse que se resume a um agrupamento de todas as unidades de PD, das cargas locais e dos sistemas de armazenamento [16], [17], sendo estas capazes de operar como um único sistema controlável. Num conceito geral, uma MG tem como principal função controlar todas as cargas, dispositivos de armazenamento e produção, a nível da rede de distribuição de Baixa Tensão (BT). Fazendo uma comparação direta entre a PD individualizada e uma MG, verifica-se que a MG pode proporcionar mais benefícios técnicos e flexibilidade de controlo para a rede elétrica principal [18].

A MG pode funcionar de dois modos: um modo em que está conectada à rede elétrica; e um outro que está independente da rede (modo ilha) [17], [19], [20]. A maioria das PDs que podem ser instaladas numa MG não são adequadas para uma conexão direta com a rede elétrica devido a características da energia produzida, sendo necessária a utilização de inversores eletrónicos de potência (CC/CA ou CA/CC/CA) [20]. A MG dispõe ainda de um controlo central instalado na subestação de MT/BT, sendo que este tem funções de controlo e de gestão económica.

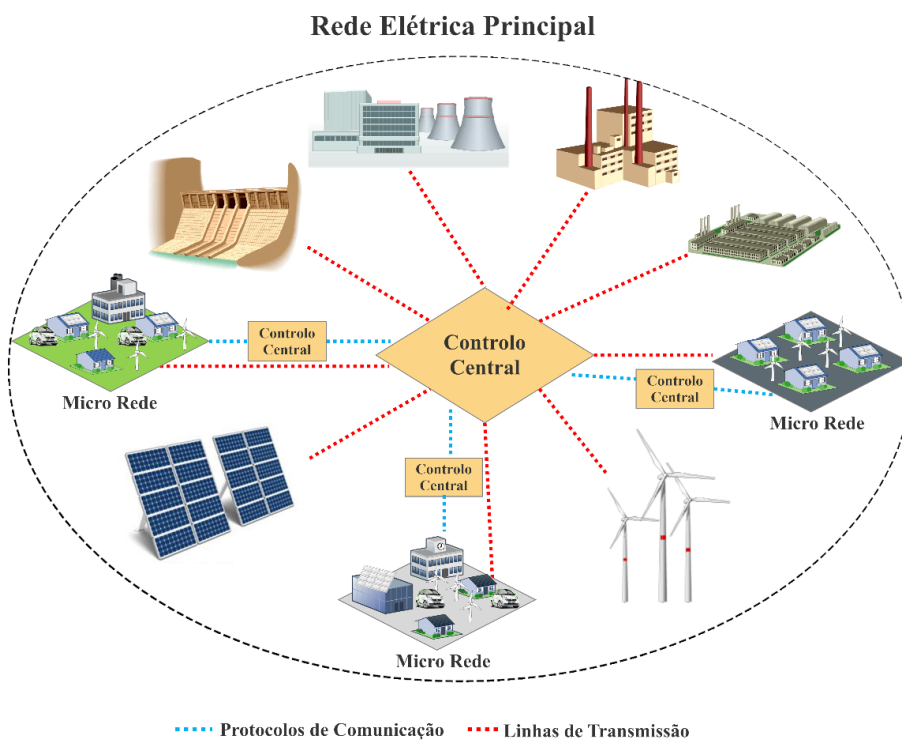


Figura 1 – Visão geral das *Micro Grids*, adaptado de [18]

Como se pode verificar na Figura 1, cada MG é uma parcela da rede elétrica principal e dispõe de PD para fornecer energia às suas cargas locais. Assumindo que uma determinada MG está em situação de consumo de pico, proveniente das suas cargas locais, e no caso da

sua produção local não ser capaz de o suportar, as outras MGs ou a rede principal poderão fornecer-lhe a energia em falta. No caso inverso, ou seja, quando a produção excede a procura, o excesso de energia pode ser transferido para outras partes da rede. É notório que cada MG tem uma unidade de controlo central, unidade essa que é responsável pelo diagnóstico de operação em modo conectado à rede ou em modo ilha. Todas estas unidades das MGs representam um subconjunto e estão interligadas entre si por interveniente de uma unidade de controlo central da rede principal. A unidade de controlo principal tem acesso a todas as informações relativamente à produção das centrais elétricas e das unidades de PD, e as necessidades de energia existentes. Com base nestes dados serão tomadas as decisões apropriadas das ações funcionais a executar, sendo estas informações novamente enviadas para os controladores de cada MG [18].

2.2.2. CASAS INTELIGENTES

O termo SH pode ser aplicado a qualquer tipo de residência, seja ela uma moradia unifamiliar ou um edifício multifamiliar. Por definição uma SH retrata uma residência equipada com um sistema composto por alta tecnologia, cuja sua principal função é fornecer serviços que respondam às necessidades dos seus habitantes [21]. Uma SH possui de uma inteligência e controlo automático que lhe permite responder aos comportamentos dos seus moradores. Através do uso de um conjunto de sensores é possível reunir diferentes tipos de dados, sendo estes analisados por dispositivos com capacidade de computação (por exemplo, os microcontroladores), identificando as ações dos residentes ou os eventos ocorridos. Posteriormente irão responder a essas ações e eventos através do controlo de mecanismos específicos [22].

2.2.3. EDIFÍCIOS INTELIGENTES

Baseando-se no conceito de uma MG, e motivado pelas necessidades de melhorar a eficiência energética, juntamente com a integração das unidades de produção de energia nos edifícios, surge o conceito SB. Num SB quase todos os aparelhos são administráveis e a coordenação do consumo de energia é realizada localmente. Este novo conceito de SB está a tornar-se cada vez mais atrativo e viável na indústria da construção, implicando a implementação de sensores interconectados e dispositivos inteligentes, para a obtenção de edifícios energeticamente eficientes e capazes de tornar a vida dos seus utilizadores mais fácil.

De acordo com a referência [23], um edifício para ser considerado inteligente deve conter três constituintes principais: sistemas de controlo inteligente; uma rede de comunicação; e a automação do edifício. Os sistemas de controlo têm de ser capazes de receber e interpretar a informação recolhida pelos sensores, processar essa informação de uma forma inteligente e enviar as ações para os atuadores. A rede de comunicação pode ser realizada de diferentes formas (*wireless, power lines, IP/Ethernet, etc.*), sendo o seu principal intuito permitir uma conexão entre os diversos dispositivos. A automação do edifício é composta pelos atuadores e os dispositivos sensores.

Melhorar a eficiência energética nos edifícios é uma questão crítica para a redução da pegada de CO₂, ou seja, quanto maior for a eficiência de um edifício, menor será o seu consumo energético, reduzindo drasticamente as necessidades de energia proveniente da rede e conduzindo a uma diminuição das emissões, diminuição essa que será maior quanto maior for a taxa de penetração da produção por fontes fósseis poluentes presentes na rede. A introdução das unidades de produção de energia com base em fontes renováveis nos edifícios, por sua vez também têm um impacto direto na redução dos níveis de emissões de CO₂, já que o consumo poderá parcialmente ser alimentado localmente, sem necessitar da energia proveniente da rede principal.

Nos SB a integração da produção por fontes renováveis do próprio edifício com a rede elétrica implica a existência de modelos de previsão dos consumos e produção inerentes ao edifício. Estes modelos, juntamente com outros modelos, devem ser integrados no âmbito do sistema de gestão de energia (ver Figura 2).

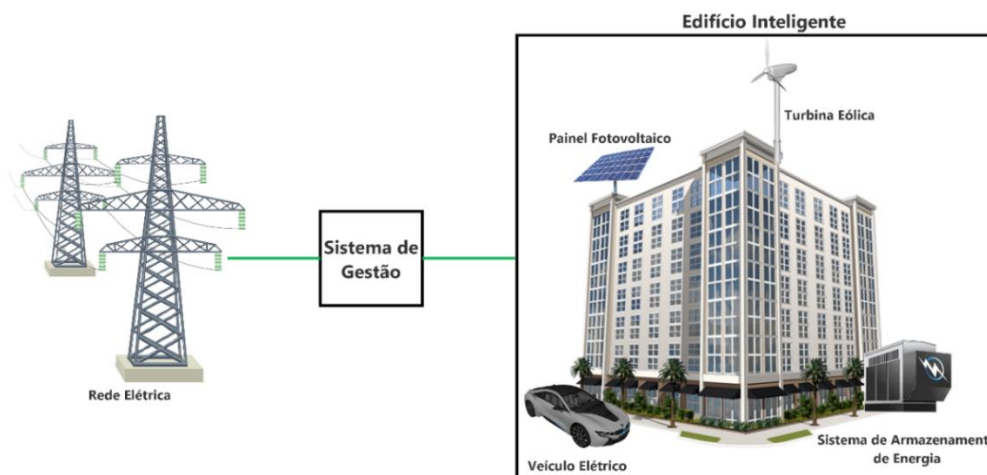


Figura 2 – Modelo de um sistema de gestão num *Smart Building*

Sumariamente podemos verificar que ao nível da definição, os SBs e as SHs têm conceitos bastante semelhantes, sendo os principais fatores de diferenciação, os níveis e perfis de ocupação que irão afetar o comportamento das cargas (consumo), bem como os modelos de negócio adotados, como por exemplo o V2B e os programas de DR.

2.3. RECURSOS ENERGÉTICOS DISTRIBUÍDOS

Os recursos energéticos distribuídos referem-se a fontes de produção geograficamente distribuídas, na maior parte dos casos com utilização de fontes de energia renovável, aos sistemas de armazenamento e às cargas controláveis, que podem ser ligados à rede de distribuição ou transmissão. Tipicamente, estes recursos encontram-se distribuídos proximamente dos consumidores, fornecendo uma ampla gama de energia, dependente do tipo de fonte utilizada. Nesta subsecção serão abordadas, de forma geral e teórica, os recursos energéticos integrados no sistema de gestão típico de um edifício. Este sistema é constituído essencialmente por tecnologias de PD, a utilização de programas de DR, os sistemas de armazenamento e os VEs.

2.3.1. PRODUÇÃO DISTRIBUÍDA

A PD está amplamente disseminada, tendo algumas tecnologias de produção utilizadas atingindo um grau de maturidade bastante aceitável. São exemplos disso os aproveitamentos hidroelétricos, a cogeração e os parques eólicos, que representam as tecnologias mais usadas, seguidas pelos aproveitamentos de biomassa/biogás, fotovoltaicos e geotérmicos. Outras tecnologias começam a dar sinais de crescimento, como o caso do solar térmico, com concentradores solares e as pilhas de combustível, estando outras ainda em fase de desenvolvimento, como por exemplo o aproveitamento das marés. No contexto atual pode-se verificar que os sistemas de gestão da energia de um edifício não se focam apenas na gestão do consumo, mas também efetuam a gestão da produção, nomeadamente os sistemas de microprodução. Deste modo, pode ser incluído num edifício a produção de micro ou pequena escala, como os geradores eólicos, painéis fotovoltaicos e as unidades de cogeração¹⁰ (CHP).

¹⁰ *Combined Heat and Power* (CHP), na designação anglo-saxónica.

A produção eólica é reconhecida como uma das tecnologias com maior potencial energético na integração em sistemas de energia, no entanto, também é aquela que tem um grau de imprevisibilidade maior [24]. A implementação desta tecnologia requer a instalação de sistemas de eletrónica de potência para permitir a ligação entre o gerador eólico e a rede eléctrica. Nas áreas urbanas existem problemas face à instalação de geradores eólicos de pequena escala, devendo-se sobretudo à turbulência e à ausência de vento devido às obstruções provocadas pela elevada dimensão dos edifícios.

Os sistemas fotovoltaicos, nomeadamente os de pequena dimensão, são sistemas com muita popularidade no setor residencial, sendo possível encontrar um elevado número de painéis solares instalados nos telhados de diversas casas. A energia produzida por estas unidades é usada sobretudo para efeitos de autoconsumo. Em situações em que não seja possível consumir diretamente a energia produzida é necessário injetar essa energia diretamente na rede ou utilizar as baterias para a armazenar [25].

As unidades de CHP permitem a produção de energia eléctrica e térmica de forma combinada, sendo estas bastante flexíveis, uma vez que permitem o aproveitamento das infraestruturas de gás pré-existent no edifício para efetuar a alimentação das unidades CHP. Uma das principais características deste tipo de produção de energia é a rápida resposta que a unidade dá a cada necessidade excepcional de consumo de energia eléctrica. Por exemplo, em casos onde a variação do consumo é inesperada, as unidades de CHP conseguem em pouco tempo satisfazer as necessidades da procura de energia [26].

Na referência [27] são apresentadas as principais vantagens acerca da integração da PD no sistema de energia:

- Receber incentivos (apoio financeiro) para a instalação de tecnologias de produção a partir de fontes renováveis;
- Possibilidade de reduzir os custos na fatura energética devido à possibilidade do autoconsumo;
- Redução do preço da energia devido a um consumo da energia mais local e redução do congestionamento da rede.

A PD em pequena escala não tem atualmente capacidade para participar no mercado grossista de energia, uma vez que não representam um valor significativo de produção singularmente. É então necessário o emprego de entidades agregadoras capazes de juntar as

unidades de PD, de forma a criar uma maior quantidade de energia. Na verdade, este conceito de agregador [28] abre caminho para uma entidade completamente nova, que não se traduz unicamente num vendedor de energia, tendo funções de gestão e operação de recursos [27].

2.3.2. TIPOS DE CARGA

As cargas utilizadas por um consumidor final têm diferentes tipos de controlo, podendo ser divididas em quatro tipos [29]:

- Cargas não interrompíveis: são cargas que não podem ser desligadas pois isso colocaria em causa o bom funcionamento de determinada atividade (exemplos: equipamento de escritório, equipamentos hospitalares, forno);
- Cargas parametrizáveis: são cargas em que os parâmetros de funcionamento podem ser alterados (exemplos: aquecedor, ventoinha, cilindro elétrico, ar condicionado, iluminação);
- Cargas interrompíveis: são cargas possíveis de interromper por um determinado período de tempo (exemplo: frigorífico, sistemas de climatização, máquina de lavar loiça);
- Cargas deslocáveis: são cargas que podem ser utilizadas num período diferente do habitual (exemplos: máquina de secar ou lavar roupa, máquina de lavar loiça).

Perante a proporção atual do consumo verificado num edifício, vários são os desenvolvimentos realizados de modo a reduzir o consumo total verificado e otimizar a utilização das cargas. Considerando os momentos onde não é necessário ter determinado equipamento ligado, ou situações onde se opta por ligar determinada carga nos períodos onde a produção é superior à procura, o consumo total poderá ser diminuído perante uma boa gestão do comportamento das cargas perante este tipo de acontecimentos, tendo então o edifício um papel ativo na rede.

2.3.3. GESTÃO DA PROCURA

A DR pode ser definida como a modificação dos padrões de consumo habituais em resposta a fatores como a mudança do preço da eletricidade e incentivos monetários [30]. Além de permitir a redução ou o corte de uma carga, a DR tem muitos outros tipos de programas, como o deslocamento da carga (o consumo da carga é transferido de um período para um

outro) e a eficiência energética (o perfil do consumo mantém-se no mesmo padrão, mas com valores mais baixos). Os programas de DR podem ser divididos em duas categorias:

- Programas baseados nos preços da energia: o preço varia para diferentes períodos de tempo. Estão relacionados com as mudanças no consumo de energia elétrica por parte dos consumidores em resposta às variações da tarifa de energia aplicada.
- Programas baseados em incentivos: são programas voluntários ou obrigatórios, onde o consumidor reage através de estímulos monetários.

Seguidamente são descritos alguns dos programas de DR mais usados e com implementação mais promissora [31], [32]:

- *Direct Load Control*: o operador da rede ou o agregador tem um acesso livre às cargas dos consumidores, permitindo um controle direto sobre o consumo da carga;
- *Interruptible/Curtailable*: o consumidor assina um contrato aprovando o corte ou a interrupção de certa quantidade de carga num momento ou período específico;
- *Demand Bidding*: os consumidores podem negociar um preço, com o operador da rede ou com o agregador, para reduzir uma quantidade de energia;
- *Emergency DR*: os consumidores podem optar por responderem, ou não, a sinais de emergência enviados pelo operador da rede ou agregador;
- *Capacity Market*: o consumidor assina um contrato onde se compromete a entregar uma certa quantidade de energia quando o operador ou agregador tem necessidade;
- *Time-of-use (TOU)*: um dos programas de DR mais utilizados. É baseado num sistema de multi-tarifa que altera a tarifa de energia de acordo com diferentes períodos horários, diferentes tipos de dias (semana, fim de semana, feriados) ou estação do ano;
- *Real-Time Pricing (RTP)*: os preços da eletricidade estão disponíveis em tempo real para os consumidores, logo estes podem escolher se devem, ou não, reduzir a carga quando os preços são mais elevados;
- *Critical Peak pricing (CPP)*: o preço aplicado à energia é maior quando a rede está em horários de pico, ou quando a confiabilidade do sistema está em risco. Desta forma, os consumidores pagam mais pela energia nesses períodos. Este programa é um misto entre o TOU e o RTP.

Como já foi dito anteriormente, a participação dos consumidores em programas de DR deverá ser um outro recurso que um edifício deverá considerar, permitindo uma gestão dos

consumos durante este tipo de eventos de uma forma automática e inteligente. Através da DR o controlo das cargas pode ser realizado de acordo com ordens externas provenientes do operador de sistema ou de agregadores [33].

2.3.4. SISTEMA DE ARMAZENAMENTO DE ENERGIA

Devido à intermitência associada à produção das fontes de energia renovável, como é o caso da produção eólica e fotovoltaica, surge a necessidade do desenvolvimento e aplicação de sistemas de armazenamento de energia. Estes sistemas podem ser utilizados para armazenar o excedente de energia que resulta da produção, ou quando o custo da energia é baixo. Além disso, podem fornecer energia em situações críticas, ou quando o custo de produção é elevado, sendo deste modo um equipamento fundamental para a gestão do sistema de um edifício. Existem várias tecnologias de armazenamento, tais como: volante de inércia; baterias; supercondensadores; ar comprimido; hidro-bombagem.

2.3.5. VEÍCULOS ELÉTRICOS

O VE consiste num veículo com um motor elétrico que é alimentado a eletricidade proveniente de um acumulador. O acumulador contém energia armazenada sob a forma de um potencial eletroquímico, de forma a utilizar uma propulsão por meio do motor elétrico. A recarga dessas baterias pode ser realizada via rede elétrica, sendo que uma parcela da recarga também poderá surgir através da energia gerada pela travagem regenerativa. Existe ainda um outro tipo de veículos elétricos onde se consegue prolongar a autonomia, isto combinando a propulsão do motor elétrico com o da combustão interna. Estes veículos são chamados de híbridos. Existem basicamente três tipos de VEs: os puramente elétricos¹¹ (BEVs); os híbridos¹² (HEVs); e os a célula de combustível¹³ (FCVs) [34].

¹¹ *Battery Electric Vehicles* (BEVs), na designação anglo-saxónica

¹² *Hybrid Electric Vehicles* (HEVs), na designação anglo-saxónica

¹³ *Fuell Cell Vehicles* (FCVs), na designação anglo-saxónica

Um VE com possibilidade de V2G é capaz de armazenar energia elétrica e, quando solicitado, devolvê-la à rede elétrica. Este conceito foi proposto pela primeira vez por *Kempton* [35]. Quando se encontra ligado à rede elétrica, o VE poderá fornecer energia em horas de ponta. Desta forma, o VE passa a ser mais que uma carga do ponto de vista da rede. Um dos principais problemas do V2G é o facto de um VE apresentar uma potência baixa, quando comparada com outras tecnologias que competem em ambiente de mercado, pelo que o processo de compra e venda de energia nesses mercados é manifestamente difícil. Para colmatar esta limitação surgiu o conceito de agregador de VEs, consistindo num modelo de negócio que agrega vários VEs. Nesse modelo, os impactos negativos da integração de grande quantidade de VEs na frota automóvel poderão vir a ser atenuados. Esta situação é mais favorável quando comparada com uma situação de gestão de VEs de forma individualizada, uma vez que a previsão da potência total e da energia elétrica disponível em cada hora é realizada com menos incerteza, resultando em maiores benefícios económicos para o agregador [36].

No ponto de vista da gestão energética nos edifícios, os VEs podem ser vistos como unidades de armazenamento, permitindo armazenar a energia quando existe excesso de produção ou quando os preços de energia são mais baixos [37]. Para além disso, os VEs poderão ser usados para fornecer a energia existente na sua bateria para alimentar o consumo de edifício em situações de consumo de pico, onde o preço da energia seja elevado. Em termos de consumo, os diferentes perfis de utilização dos VEs, que dependem das necessidades dos consumidores, podem originar alterações no diagrama diário do consumo caso a sua penetração seja elevada [38].

2.4. ESTADO DE ARTE DA GESTÃO DE RECURSOS ENERGÉTICOS

O aumento tendencialmente crescente das unidades de produção com fontes de energia renováveis, como é o caso da eólica e fotovoltaica, contribui positivamente para a redução da pegada das emissões de CO₂ e para uma independência do uso de combustíveis fósseis na produção de energia. Contrariamente às unidades de geração convencionais, as fontes renováveis são caracterizadas por um elevado grau de incerteza e variabilidade. Deste modo, torna-se necessário a utilização de modelos de controlo robustos e modelos preditivos capazes de lidar e modelar todo este comportamento incerto. A motivação de estabelecer uma modelagem robusta está associada ao desafio de enfrentar a variabilidade e incerteza

dos recursos energéticos renováveis nas MGs e nos edifícios, uma vez que estes recursos podem constituir uma grande parte do total da produção atual e futura.

O tema da gestão de energia em MGs e edifícios, considerando a componente das incertezas, ainda é pouco explorado na literatura atual. Todavia, a otimização robusta tem-se revelado um método promissor para lidar com as incertezas nos problemas de otimização. Vários trabalhos têm sido apresentados na literatura recente. Na referência [39] foi usada a otimização robusta, com o intuito de modelar as incertezas existentes na produção de um sistema fotovoltaico, sendo o principal objetivo desta metodologia realizar o escalonamento dos vários tipos de cargas presentes nessa residência. Outro trabalho bastante similar a este é apresentado em [40], onde é proposto um modelo de otimização robusta para lidar com as incertezas impostas por um sistema fotovoltaico. O principal objetivo do trabalho é realizar o escalonamento das cargas de uma SH, sendo definido um parâmetro de adaptação para controlar o nível de robustez da solução final ideal. O trabalho apresentado em [41] avalia a DR baseada no preço em tempo real ao nível da gestão das cargas residenciais. São apresentadas duas abordagens diferentes, uma otimização estocástica e uma otimização robusta. A otimização estocástica adota a abordagem baseada na simulação de Monte Carlo (MC) de forma a minimizar o pagamento esperado de eletricidade para o dia inteiro, enquanto controla os riscos financeiros associados às incertezas dos preços da eletricidade em tempo real. Na otimização robusta são considerados intervalos de incerteza no preço para minimizar o pagamento de eletricidade no pior dos casos, permitindo um ajuste flexível na robustez solução. Ambas as abordagens são formuladas através de uma programação linear inteira mista (PLIM). Na referência [42] é apresentada uma programação robusta capaz de determinar a capacidade ótima das tecnologias PD num edifício, considerando a incerteza associada ao consumo de energia. A otimização considera três critérios relacionados, o económico, a poupança de energia primária e o aspeto ambiental, retratando uma otimização multiobjectivo. A referência [43] apresenta um sistema de gestão de energia de um edifício sob a influência de múltiplas fontes de incerteza, nomeadamente, na procura de energia, nos custos (como o custo das emissões de CO₂, na poupança de energia primária, etc.) e nos preços (como os preços das tarifas de combustível e eletricidade). A otimização representa um problema multiobjectivo que pretende por um lado minimizar os custos, e por outro minimizar o consumo de energia de um edifício comercial. Para superar o ambiente das incertezas mencionadas anteriormente, este modelo usa uma programação robusta. Na referência [44] é desenvolvida uma *framework* capaz de realizar a gestão de energia numa

MG, baseada numa otimização robusta. São consideradas vários tipos de incertezas, tais como, a produção dos geradores baseados em fontes renováveis, o custo da produção e o consumo de energia. A incerteza é representada por intervalos de previsão, estimados por uma rede neuronal e pelo *Non-dominated Sorting Genetic Algorithm* (NSGA-II), de forma a ser possível obter os limites inferior e superior de previsão. Estes limites representam um espectro de valores onde é expectável que os parâmetros com incerteza incidam, com um determinado nível de confiança. Em [45] é apresentada um método para realizar a gestão dos recursos energéticos de uma MG conectada à rede e que incorpora tecnologias de produção de fontes renováveis. O principal objetivo é minimizar os custos de operação da MG, tais como, a produção da PD convencional, as penalizações dos sistemas de armazenamento, o uso de cargas elásticas e os custos de transações (MG vende o excesso de energia à rede principal ou compra energia caso necessite). Para lidar com incerteza existente nas unidades de produção de recursos energéticos renováveis é usada uma formulação robusta.

É importante referenciar que na literatura atual, o tema da otimização robusta aplicado a meta-heurísticas não se encontra muito explorado, sendo mais usada a programação robusta baseada num modelo matemático, que por sua vez é resolvido por interveniente de um método determinístico. No entanto, em situações em que o número de variáveis é elevado, torna-se impraticável o uso deste tipo de abordagem. A otimização robusta aplicada ao MOPSO que foi desenvolvida nesta dissertação é baseada nas referências [46] e [47]. Em [46] é usado o *S-metric selection evolutionary multi-objective algorithms* (SMS-EMOA) para resolver um problema multiobjectivo, sendo um dos objetivos o conforto térmico e um outro o consumo de energia do edifício. É implementada a otimização robusta para lidar com as incertezas existentes a nível da estrutura física do edifício. A referência [47] usa o *Evolutionary Particle Swarm Optimization* (EPSO) para resolver um problema de despacho ótimo no sistema elétrico de energia. É usada a otimização robusta para lidar com as incertezas provenientes da produção eólica. Tendo em conta a fraca exploração existente na literatura atual relativamente ao tema da otimização robusta aplicada a meta-heurísticas, estes dois trabalhos serviram de base para implementar o modelo robusto ao MOPSO desenvolvido nesta dissertação.

A Tabela 1 apresenta uma análise sumarizada relativamente ao estado de arte, no contexto da gestão energética em edifícios com a modelação robusta da incerteza, referenciado

anteriormente. Para além disso, são expostas as características da metodologia desenvolvida nesta tese, permitindo uma comparação direta entre o estado de arte e o modelo proposto.

Tabela 1 – Revisão do estado de arte e características do modelo proposto

Ref	Gestão em:		Recursos				Muti objetivo	Incerteza			
	Edifício	Outro	DR	VE	SAE ¹⁴	PD		Consumo	PV ¹⁵	Eólica	Outro
[39]				✓	✓				✓		
[40]	✓		✓	✓		✓			✓		
[41]	✓		✓	✓							✓
[42]	✓				✓	✓	✓	✓			
[43]	✓				✓	✓	✓	✓			✓
[44]		✓	✓			✓		✓	✓	✓	✓
[45]		✓		✓	✓	✓			✓	✓	
[46]	✓						✓				✓
[47]		✓		✓	✓	✓				✓	
Tese	✓		✓	✓	✓	✓	✓		✓	✓	

2.4.1. INCERTEZA NA PREVISÃO DE RECURSOS ENERGÉTICOS

Nos problemas de gestão de recursos energéticos os processos estocásticos são representados com variáveis aleatórias contínuas ou discretas. Lidar com um conjunto finito de cenários possíveis é a maneira adotada em problemas de tomada de decisões condicionados pela incerteza, caso contrário, seria impossível resolver este tipo de problemas [48]. A adequada representação de uma variável aleatória usando um conjunto finito de valores pode ser difícil de concretizar, logo é necessário usar diferentes tipos de técnicas capazes de gerar cenários representativos, como por exemplo a redução de cenário [48]. Com o intuito de melhorar a rastreabilidade computacional, a redução de cenário é geralmente empregue para reduzir o tamanho de um cenário definido, mantendo as informações estocásticas o mais fieis possível.

¹⁴ SAE – Sistema de Armazenamento de Energia

¹⁵ Photovoltaic (PV), na designação anglo-saxónica

As técnicas de redução de cenário começam primeiramente por considerar um grande conjunto de cenários, sendo esse conjunto reduzido a um conjunto mais pequeno, tentando sempre fazer prevalecer a função de distribuição de probabilidade inicial. Para medir a qualidade do processo de redução basta fazer uma comparação entre a solução ótima obtida com o conjunto reduzido e a solução ótima obtida com o conjunto original. Se as soluções forem bastante aproximadas, significa que foi obtida uma boa redução. No entanto, esta comparação só é possível em casos de pequena dimensão, devido a limitações computacionais.

Os problemas de gestão de recursos energéticos envolvem várias fontes de incerteza, como por exemplo a nível da procura de energia (consumo) e a produção por fontes renováveis como é o caso da fotovoltaica e eólica. Além desses, a presença de VEs representa uma fonte adicional de incerteza, uma vez que as viagens e a procura de energia dos VEs dependem do comportamento dos usuários, comportamento esse que é difícil de prever.

A falta de dados históricos realistas é uma barreira para construir casos de estudos precisos, sendo que, na maioria dos casos, as previsões e os erros associados são assumidos com base em simulações do comportamento do mundo real. A geração de cenários é um tema amplo, sendo que, na literatura atual, alguns autores têm apresentado possíveis abordagens. Na referência [49] a incerteza existente na produção e no consumo num edifício é representada através da geração de cenário em MC. Para a produção eólica foi considerada diretamente a distribuição da velocidade vento na simulação de MC. No que diz respeito à produção fotovoltaica, são gerados cenários em MC, considerando uma distribuição normal da radiação solar, juntamente com um valor médio obtido a partir dos dados históricos de radiação solar de um ano típico em Hong Kong, e ainda um desvio padrão de 10%. Relativamente ao consumo, foram consideradas no MC diferentes distribuições (normal e triangular) para os parâmetros considerados influenciadores diretos do consumo, sendo esses parâmetros baseados em dados de outras referências. Em [50] é usado o MC para gerar um conjunto de cenários para as variáveis sujeitas a incerteza, tais como: o fator de aprendizagem, o preço de produção de energia para as diferentes tecnologias e o custo das emissões de CO₂. É assumido que as variáveis com incerteza seguem uma distribuição normal, sendo definido um valor médio e um desvio padrão, a serem considerados para efeitos de simulação em MC, sendo geradas 10 000 cenários diferentes. Na referência [47] é estimado o erro de previsão da produção eólica, e posteriormente são gerados 1000 cenários

em MC. É realizado uma redução de cenários a partir de uma técnica de agrupamento¹⁶, onde os 1000 cenários iniciais são reduzidos para apenas 15 cenários. Em [51] os autores usam a simulação de MC para representar a incerteza da previsão da energia eólica. A técnica de redução de cenário é usada para reduzir o número de cenários gerados pelo MC. Além disso, eles assumem um valor de erro e uma distribuição normal para gerar os cenários da produção do sistema fotovoltaico. Finalmente, os autores consideram 10 cenários independentes para a geração de energia eólica e outros 10 cenários para a geração fotovoltaica. Através de uma combinação em árvore são representados um total de 100 cenários com uma probabilidade de acontecimento igual para todos de 0.01. Uma simulação de tráfego é usada em [52] para observar os períodos de partida e chegada, e os consumo de energia para cada veículo. Os autores modelam estas variáveis como variáveis estocásticas usando distribuições representativas. Estas distribuições permitem gerar diferentes padrões de condução (cenários) para cada veículo individual. Na referência [53] é usado o método *bootstrap* como alternativa ao MC, com o intuito de modelar as incertezas temporais nos períodos de carregamento dos VEs. Na referência [54] é proposto um modelo para estimar os consumos de energia elétrica de uma frota de veículos *plug-in*¹⁷ (PHEVs). Este modelo é utilizado para avaliar os impactos ao ligar essas cargas (veículos) à rede de distribuição. Este trabalho utiliza a simulação de MC para gerar virtualmente as distâncias das viagens, e leva em consideração as variações de hábitos de condução, a diferente gama dos veículos, os múltiplos eventos de carregamento por dia, e a variação do tempo da recarga. A referência [55] utiliza o método MC para avaliar os impactos nas redes de distribuição sujeitas á integração de VEs. Este caso de estudo usa uma pequena ilha dos Açores, onde foi simulada a substituição de veículos comuns por VEs. São considerados dois cenários diferentes, um onde os veículos elétricos representam 25% da atual frota de veículos e outro em que representam 50%. O movimento de cada VE, ao longo de um dia, também é simulado, definindo-se quatro estados possíveis para cada VE em cada intervalo de 30 minutos. Os

¹⁶ *Clustering*, na designação anglo-saxónica

¹⁷ *Plug-In Hybrid Electric Vehicles* (PHEV), na designação anglo-saxónica.

estados possíveis são: veículo em movimento, veículo estacionado em área industrial, veículo estacionado em área comercial e veículo estacionado em área residencial.

Nesta dissertação para a geração de cenário optou-se por utilizar uma abordagem semelhante ao descrito na referência [51]. Usando um perfil de produção representativo da produção fotovoltaica e da produção eólica, que neste caso representariam a previsão da produção para cada hora do dia seguinte, são gerados 10 cenários diferentes de produção fotovoltaica e 10 cenários de produção eólica. Estes cenários são gerados através da utilização do método de MC, seguindo uma distribuição normal e considerando um erro de previsão de 0,15. Nesta distribuição normal, o valor médio é dado em função do valor de produção previsto para cada hora (perfil de produção inicial), e o desvio padrão é igual ao valor do erro de previsão.

2.4.2. GESTÃO CENTRALIZADA/DESCENTRALIZADA

Nos últimos anos tem-se assistido a um desenvolvimento no âmbito dos SBs, sendo cada vez mais importante a utilização de equipamentos de medição de energia inteligente. Um sistema de gestão, seja ele centralizado ou descentralizado, visa assegurar uma gestão adequada e otimizada do funcionamento dos recursos inerentes ao edifício, minimizando os desperdícios de energia. Um sistema de gestão em edifícios centralizado é caracterizado por ter uma unidade de controlo central, onde todas as aplicações existentes no edifício funcionam como uma única unidade. Por outro lado, um sistema descentralizado é baseado em vários multi-controladores, onde cada um tem a responsabilidade de controlar diferentes aplicações de forma individualizada. Um exemplo de um sistema centralizado é apresentado em [56], onde o sistema *Power Flex House* controla as cargas, como a iluminação, os sistemas AVAC¹⁸ ou frigoríficos. O controlo é realizado remotamente por um controlador central do sistema. O controlador consegue ainda aceder a várias informações do sistema da rede elétrica, como por exemplo, o preço dinâmico da energia ou a potência disponível na rede. Em [57] é apresentado um sistema de gestão centralizado num edifício residencial. O sistema central utiliza as informações recolhidas do funcionamento dos aparelhos domésticos para descobrir os hábitos dos utilizadores, e, em seguida, ajusta o sistema para

¹⁸ Sistema de Aquecimento, Ventilação e Ar Condicionado (AVAC).

se adaptar a esse utilizador. Este sistema não necessita da configuração dos parâmetros de entrada por parte do utilizador, uma vez que este sistema aprende a parametrizá-los automaticamente. A referência [58] apresenta um sistema de controlo centralizado em edifícios, baseado num controlador lógico programável¹⁹ (PLC). Este modelo permite controlar o aquecimento, a iluminação, o sistema de segurança e o ar condicionado. Não obstante, este sistema permite ainda controlar dispositivos mais incomuns, como o caso da televisão via satélite, o rádio, e outros dispositivos multimídia de infravermelho ou de tecnologia IP²⁰. Um sistema de gestão descentralizada é apresentado em [59]. É usado a tecnologia *Power Line Communication*²¹ que é agregada aos contadores inteligentes, de modo a obter informações detalhadas. Com estas informações é possível identificar os perfis de consumo dos utilizadores e, ao mesmo tempo, controlar os equipamentos da habitação. Este sistema tem uma gestão descentralizada onde cada dispositivo instalado tem programas de controlo exclusivos, neste caso, cada dispositivo tem um controlador inteligente. No sistema desenvolvido na referência [60], as habitações dispõem de sensores e atuadores, sendo que cada equipamento tem o seu próprio controlo. O protocolo de comunicação KNX²² utilizado permite o controlo descentralizado de equipamentos de iluminação, de sistemas AVAC, de sistemas de segurança, entre outros. Em [61] é apresentado um método de controlo descentralizado para realizar o controlo ótimo dos sistemas AVAC. Neste sistema de controlo, cada unidade está equipada com um controlador, sendo o principal objetivo satisfazer os requisitos de conforto térmico, utilizando a energia de forma eficiente.

O modelo desenvolvido no âmbito desta dissertação representa um sistema de gestão de recursos energético centralizado, onde o operador do edifício é capaz de controlar todos os recursos, através de um único controlador central. O controlador central do edifício tem que

¹⁹ *Programmable Logic Controller*(PLC), na designação anglo-saxónica

²⁰ *Internet Protocol* (IP), na designação anglo-saxónica, representa um protocolo de comunicação usado entre todas as máquinas em rede para transporte de dados

²¹ *Power Line Communication*, na designação anglo-saxónica A tecnologia foi criada para permitir o transporte de dados através de uma das infraestruturas físicas mais disseminada no mundo: a rede de energia elétrica.

²² O protocolo KNX permite que os vários elementos que compõem o sistema de domótica de uma residência comuniquem entre si, numa linguagem única e universal.

gerir os seguintes recursos: unidades de PD; a energia proveniente dos fornecedores externos de energia; os sistemas de armazenamento e os VEs.

2.5. CONCLUSÕES

Melhorar a eficiência energética nos edifícios é uma questão crítica para a redução das emissões de CO₂. Quanto maior for a eficiência de um edifício, menor será o seu consumo energético, reduzindo drasticamente as necessidades de energia proveniente da rede elétrica, diminuindo diretamente as emissões. Por outro lado, a introdução das unidades de produção de energia com base em fontes renováveis nos edifícios, também tem um impacto direto na redução dos níveis de emissões de CO₂, já que o consumo poderá ser alimentado localmente, sem necessitar da energia proveniente da rede principal, esta que é produzida maioritariamente por centros de produção com fontes poluentes.

Num ponto de vista da sustentabilidade em edifícios, estes deverão ter a capacidade de gerir o seu consumo, assim como a sua produção, com o intuito de otimizar o uso dos seus recursos. A utilização de *smart meters* é já uma realidade em certos países, sendo que este dispositivo vão permitir a monitorização dos consumos elétricos em tempo real e a comunicação bidirecional entre o sistema de gestão do edifício e as entidades que operam a rede elétrica.

Os sistemas de gestão dos edifícios têm de permitir a monitorização e controle de diversos equipamentos, como o caso das cargas, as unidades de PD, os sistemas de armazenamento e os VEs. Estes sistemas devem ser dotados de comunicações entre os vários intervenientes do edifício, permitindo aceder aos dados reais dos vários recursos energéticos. Essa informação será processada e usada como um *input* ao sistema de gestão, que por sua vez vai determinar o escalonamento ótimo de cada recurso de energia, com o intuito de melhorar eficazmente a utilização da energia elétrica do edifício.

Esta dissertação apresenta uma metodologia para resolver o problema de gestão de recursos energéticos em edifícios, sendo o principal contributo o facto de esta metodologia ser capaz de modelar as incertezas associadas à produção de energia por fontes renováveis, por meio de uma otimização robusta. Como é possível verificar no estado de arte exposto anteriormente, existem já alguns modelos, no contexto dos edifícios, a utilizar a otimização robusta para modelar a incerteza. Todavia, a programação robusta é implementada através de um modelo matemático, que por sua vez é resolvido por interveniente de uma otimização

determinística. Contudo, em situações em que o número de variáveis é elevado, ou se pretende considerar uma maior gama de cenários representativos da incerteza, este método torna-se pesado e até mesmo inexecutável a nível computacional. O trabalho desenvolvido aplica o conceito de otimização robusta numa meta-heurística, nomeadamente o MOPSO, representando uma contribuição deste trabalho, face ao estado de arte atual.

3. METODOLOGIA DE OTIMIZAÇÃO

A metodologia apresentada nesta dissertação pretende realizar o escalonamento dos recursos energéticos do edifício para o dia seguinte, sendo o modelo proposto capaz de gerir diversos recursos num horizonte temporal de 24 horas, com uma granularidade de 1 hora. É considerada uma função multiobjectivo com dois objetivos conflitantes na gestão do edifício, a maximização dos lucros e minimização das emissões de CO₂. O problema é resolvido através de uma meta-heurística, o MOPSO, implementada em MATLAB. O principal contributo deste trabalho consiste na criação de uma ferramenta de otimização capaz de modelar a incerteza na previsão da produção de energia proveniente das fontes renováveis, através do uso da otimização robusta implementada numa meta-heurística.

A Figura 3 apresenta de forma esquematizada a metodologia desenvolvida no âmbito da gestão de recursos energéticos em edifícios. O algoritmo considera como dados de entrada, as previsões para o dia seguinte da produção e do consumo do edifício, juntamente com as previsões do comportamento dos VEs ao longo do dia. Não obstante, são ainda fornecidos dados de entrada como: os vários tipos de comercializadores de energia (preços para as diferentes horas e valores das emissões de CO₂) e os programas de DR pré acordados entre o agregador e o edifício. Os dados de entrada são encaminhados para o algoritmo de gestão

de recursos (MOPSO), obtendo-se como resultado final um repositório com as soluções robustas, em que cada uma delas contem o respetivo escalonamento, para cada hora do dia seguinte, de todos os recursos controláveis (VEs, fornecedores externos de energia, sistema de armazenamento).

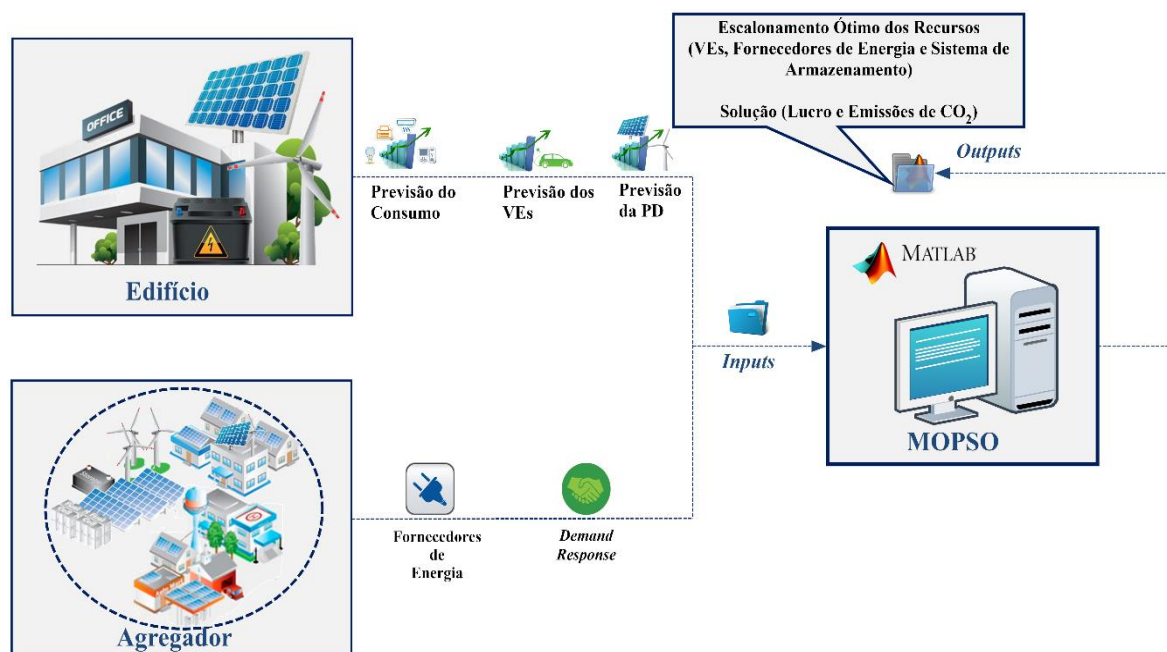


Figura 3 – Metodologia de gestão de recursos energéticos em edifícios

Na metodologia são ainda considerados modelos de negócio inovadores, como o caso do edifício poder em cada período comprar energia a diferentes comercializadores, o uso do V2B, onde o veículo pode fornecer energia ao edifício e programas de DR baseados na potência de pico. No modelo de negócio dos VEs considerado, o proprietário do VE recebe um valor monetário por permitir realizar o descarregamento da bateria do seu veículo. No caso em que o proprietário pretenda carregar o seu VE, este poderá fazê-lo pagando um valor pré acordado diretamente ao edifício. Estamos perante um modelo de negócio onde existe um acordo direto entre os proprietários dos VEs e o edifício, sem existir mais nenhum outro tipo de interveniente nas transações de compra e venda de energia no programa de V2B. Quanto à DR no controlo das cargas, esta é realizada de acordo com ordens externas provenientes do operador de sistema ou de agregadores [33], assim o escalonamento da DR nas cargas para o dia seguinte, do ponto de vista do edifício, terá que ser o *input* proveniente do agregador. Sendo a DR no controlo das cargas escalonada previamente pelo agregador e comunicada ao edifício, já não é necessário modelar este tipo de DR na otimização proposta, uma vez que não representa uma variável de decisão do edifício. De qualquer forma, foi

criado um modelo de negócio diferente do que é usado por outros autores, que poderá ser visto como um programa de DR. Basicamente propõe-se um escalão de custos associado ao valor de pico de potência requerida aos fornecedores externos, mais conhecido pelo custo da potência contratada. Atualmente este valor é fixo, previamente acordado e não tem em conta as variações dos valores de pico de consumo. No modelo proposto, este valor é considerado como um custo diário e irá sempre depender do valor de pico de potência obtido como resultado do escalonamento para o dia seguinte. Para minimizar este custo, o algoritmo de gestão do edifício procurará usar outros recursos energéticos capazes de reduzir esse valor, ou seja, terá que haver uma diminuição da energia solicitada aos fornecedores externos nessa hora de pico do edifício. Para tal, serão usados recursos como a descarga de veículos e do sistema de armazenamento. Para além disso, é oferecido um incentivo caso esse valor de potência de pico seja inferior ao dobro do valor médio de energia solicitada aos fornecedores externos.

3.1. TIPOS DE METODOLOGIAS DE OTIMIZAÇÃO

As metodologias de otimização podem ser classificadas como metodologias determinísticas ou metodologias estocásticas. A programação determinística determina a solução ótima sem necessitar de considerar a componente da aleatoriedade das variáveis associadas a cenários, enquanto a programação estocástica determina a solução ótima para um conjunto de cenários possíveis associados a uma medida probabilística de possibilidade de ocorrência.

As metodologias de otimização podem ainda ser classificadas nas seguintes categorias [62]:

- Programação linear: as variáveis são contínuas e apresentam um comportamento linear, tanto em relação às restrições como à função objetivo;
- Programação não linear: a função objetivo ou pelo menos uma das restrições não apresentam qualquer tipo de linearidade;
- Programação linear inteira mista (PLIM): a função objetivo e as restrições são lineares. As variáveis podem assumir valores discretos ou contínuos.
- Programação não linear inteira mista: a função objetivo ou pelo menos uma das restrições não apresentam qualquer tipo de linearidade. As variáveis podem assumir valores discretos ou contínuos.

3.1.1. PROGRAMAÇÃO ESTOCÁSTICA

A resolução de problemas que envolvem incertezas nos dados exige o recurso a técnicas de programação estocástica. Na formulação de programação estocástica, cada parâmetro incerto constitui uma variável aleatória, cujo valor evolui ao longo do tempo, representando um processo estocástico. Na programação estocástica, as variáveis aleatórias são geralmente representadas por um conjunto finito de cenários [63]. Por exemplo, uma variável aleatória x pode ser representada por uma série dada por x_i para $i=1, \dots, N$, em que i é o índice do cenário e N é o número de cenários considerados. Deste modo, a variável x pode ser representada pelo conjunto $x = \{x_1, \dots, x_N\}$. Para cada valor x_i (variável x do respetivo cenário i) estará associada uma probabilidade de acontecimento p_i .

A programação estocástica tem como objetivo encontrar soluções que sejam compatíveis com todos os acontecimentos possíveis, isto é, considera todos os cenários e as suas probabilidades de acontecimento [63].

3.1.2. PROGRAMAÇÃO ROBUSTA

O conceito da otimização robusta foi pela primeira vez introduzido pelo *Soyster* em 1973 [64]. Representa uma nova abordagem para resolver problemas de otimização afetados pela incerteza e cuja a sua modelização é feita através de intervalos de precisão, ou seja, este método permite alcançar uma solução que seja admissível para um intervalo de precisão.

Numa comparação direta, contrariamente à programação estocástica, onde a incerteza é modelada através de cenários, a programação robusta tem uma redução significativa das variáveis de decisão envolvidas no problema de otimização, tornando-a mais leve e rápida computacionalmente. Para além destas vantagens, neste tipo de otimização não é necessário determinar uma função de probabilidade subjacente aos parâmetros incertos e ainda é possível incorporar diferentes níveis de risco.

Na metodologia de *Soyster* todos os parâmetros sujeitos a incertezas são fixados nos respetivos valores que representam o pior caso, deste modo, em geral, os valores ótimos robustos são piores do que os valores ótimos do problema de otimização original. Para superar a limitação existente no modelo conservador referenciado anteriormente, *Ben-Tal* e *Nemirovski* publicaram no ano 2000 uma formulação robusta que permitia um equilíbrio

entre a robustez e o desempenho [65]. A desvantagem desta formulação resume-se à intratabilidade computacional, especialmente em problemas com variáveis discretas. Uma nova formulação foi apresentada por *Bertsimas* e *Sim* em meados de 2003 [66], [67]. Estes autores afirmam que é improvável as variáveis aleatórias coincidirem todas com os valores do caso mais pessimista, como o proposto por *Soyster*. Deste modo, os autores propõem um número máximo de variáveis aleatórias que podem assumir o valor do caso mais pessimista, denominado de *budget* de incerteza. O parâmetro é usado para controlar o grau de conservadorismo ou o nível de proteção da solução e ajustar a atitude do utilizador em relação ao risco.

3.1.3. PROGRAMAÇÃO MULTI-OBJECTIVO

Numa otimização multiobjectivo existem dois ou mais objetivos que precisam de ser otimizados, ou seja, pretende-se uma solução ótima para ambos. Quando um objetivo é melhorado e o segundo objetivo por sua vez também reage da mesma forma, o problema é bastante simples de resolver. Nesta situação é possível encontrar uma única solução ótima que garanta o melhor valor, em todos os aspetos de avaliação, para os dois objetivos. Porém, este não é o caso mais comum. A realidade é que, na maioria dos casos, os objetivos são opostos um do outro, onde a melhor solução que satisfaz um dos objetivos é a pior solução de um segundo objetivo. No caso em concreto apresentado nesta dissertação, o problema retratado tem dois objetivos conflitantes, a maximização dos lucros e minimização das emissões de CO₂. Para este problema, a otimização é capaz de obter uma série de soluções com dois limites, onde um limite representa a solução com maior lucro, mas também com maior nível de emissões de CO₂, enquanto o segundo limite representa a solução com menor lucro e menor número de emissões. As outras soluções encontradas pela otimização estarão entre essas duas soluções limite, sendo que nenhuma delas representa a melhor solução para ambos os objetivos. Com este conjunto de soluções será possível escolher aquela solução que representa um equilíbrio entre os dois objetivos, dependendo do peso que cada objetivo tem para o utilizador, ou seja, se este pretende uma solução com maior lucro, ou se prefere uma solução com menor valor de emissões.

Um problema de otimização multiobjectivo é caracterizado por encontrar dois tipos de soluções possíveis:

- Soluções que, quando comparadas às demais, apresentam um pior desempenho sob todos os objetivos simultaneamente considerados. Estas soluções designam-se de soluções dominadas, representando soluções que são descartadas;
- Soluções que, quando comparadas às demais, são melhores em um ou mais objetivos. Estas soluções designam-se de soluções não dominadas²³ (NDSs), sendo este conjunto de soluções usado para criar a frente de *Pareto* ótima.

Considerando um problema de minimização, um problema multiobjectivo tem a seguinte formulação:

$$\text{Minimizar } z = f(x) = [f_1(x), f_2(x), \dots, f_k(x)]^T \quad (1)$$

$$\text{Sujeito a: } g(x) = [g_1(x), g_2(x), \dots, g_m(x)]^T \leq 0 \quad (2)$$

$$h(x) = [h_1(x), h_2(x), \dots, h_p(x)]^T = 0 \quad (3)$$

$$x = [x_1, x_2, \dots, x_n]^T \in X$$

$$z = [z_1, z_2, \dots, z_k]^T \in Z$$

onde:

x	vetor das variáveis de decisão de dimensão n
$z, f(x)$	vetor das funções objetivo de dimensão k
$g(x)$	conjunto das restrições de desigualdade de dimensão m
$h(x)$	conjunto das restrições de igualdade de dimensão p

²³ *Non-dominated Solution* (NDS), na designação anglo-saxónica

No contexto de um problema de otimização multiobjectivo são necessárias as definições do ótimo de *Pareto* e da dominância de *Pareto*:

Definição 1. Dados dois vetores $x, y \in \mathbb{R}^k$, define-se $x \leq y$ se $x_i \leq y_i$ para $i = 1, \dots, k$, e que $x \prec y$ (lê-se x domina y) se $x \leq y$ e $x \neq y$.

Definição 2. Um vetor de variáveis de decisão no espaço de pesquisa $x \in X \subset \mathbb{R}^n$ é não dominado em relação a X , se não existe outro $x' \in X$, tal que $f(x') \prec f(x)$.

Definição 3. Um vetor de variáveis de decisão no espaço de busca $x^* \in F \subset \mathbb{R}^n$ (onde F é a região factível) é *Pareto* ótimo se ele é não dominado em relação à F .

Definição 4. O conjunto de *Pareto* ótimo P^* é definido por:

$$P^* = \{ x \in F \mid x \text{ é Pareto ótimo} \}.$$

Definição 5. A frente de *Pareto* PF^* é definida por:

$$PF^* = \{ f(x) \in \mathbb{R}^k \mid x \in P^* \}$$

A Figura 4 ilustra um caso em particular da relação de dominância num espaço com dois objetivos.

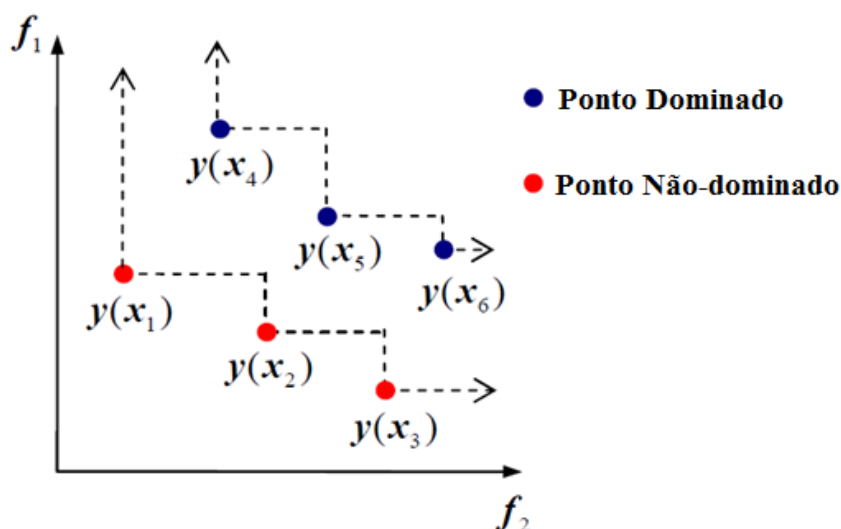


Figura 4 – Exemplo da relação de dominância

3.2. MODELO DE OTIMIZAÇÃO

Esta secção tem como principal objetivo dar a conhecer o modelo de otimização usado para solucionar o problema apresentado ao longo desta dissertação. Para além disso é ainda apresentado um modelo estocástico que foi usado para efeitos de comparação entre a otimização robusta e a programação estocástica.

3.2.1. MODELO USADO - MULTI-OBJECTIVE PARTICLE SWARM OPTIMIZATION

O *Particle Swarm Optimization* (PSO) é uma meta-heurística que usa uma técnica de pesquisa inspirada no comportamento e na dinâmica dos movimentos de um conjunto de aves, que visam encontrar comida, sendo considerado um algoritmo evolutivo [68]. Devido ao enorme sucesso do PSO, algoritmo utilizado para resolver problemas com um único objetivo, vários pesquisadores quiseram estender o uso desta técnica noutros campos de ação, sendo um deles os problemas de otimização multiobjectivo. O MOPSO é um algoritmo que foi introduzido para lidar com problemas com mais do que um objetivo. Este algoritmo foi proposto pela primeira vez por *Moore e Chapman* [69], representando uma meta-heurística onde a otimização pode ser executada considerando objetivos conflitantes em simultâneo. No MOPSO, em vez de se obter como resultado uma única solução, são obtidas um conjunto de soluções, também conhecido como frente de *Pareto*.

O MOPSO é um algoritmo de otimização avançada usado para resolver problemas com vários objetivos [70] e foi escolhido para lidar com o problema apresentado nesta dissertação. É reconhecido pela sua alta capacidade de convergência em termos de velocidade de execução, sendo este tipo de meta-heurística facilmente adotada em problemas de multiobjectivo. Como se trata de um algoritmo evolucionário, é adequado num esquema de classificação de *Pareto*. Na literatura é possível verificar que o MOPSO supera outros métodos, tais como o *Non-dominated Sorting Genetic Algorithms* (NSGA-II), *Pareto Archive Evolutionary Strategy* (PAES) e microGA, em vários problemas [70], [71]. O MOPSO usa um repositório externo, semelhante à rede adaptativa do PAES, e usa um operador de mutação com o objetivo de explorar toda a região do espaço de pesquisa e toda a gama dos valores de cada uma das variáveis de decisão. Também foi implementada a mutação dos parâmetros estratégicos (inercia, memória, cooperação), como é realizado no *Evolutionary PSO* [72], em vez dos parâmetros fixos usualmente utilizados no MOPSO original. Esta modificação melhorou o espetro das NDS resultantes na frente de *Pareto*,

conduzindo também a índices mais elevados das propriedades explorativas introduzidas no procedimento de pesquisa.

Considerando um espaço de pesquisa de dimensão d e n partículas, em que a partícula i está numa determinada posição $X_i(x_{i1}, x_{i2}, \dots, x_{id})$ e move-se com um velocidade $V_i(v_{i1}, v_{i2}, \dots, v_{id})$. Cada partícula mantém a informação das coordenadas associada à sua melhor solução individual ($pbest$), que é definida pelo seu melhor desempenho registado até então. A partícula também tem acesso à informação do melhor desempenho global do enxame ($gbest$). A ideia básica do PSO consiste em acelerar cada partícula na direção dos locais do $pbest$ e $gbest$. Cada partícula tenta modificar a sua posição utilizando a seguinte informação:

- Posição atual;
- Velocidade atual;
- Distância entre a posição atual e o $pbest$;
- Distância entre a posição atual e o $gbest$.

Como já foi dito anteriormente, o MOPSO apresentado neste trabalho considera três parâmetros estratégicos (W_i): peso de inércia; peso de memória; e peso da cooperação. No início do processo os valores destes três pesos são gerados aleatoriamente, num valor entre 0 e 1. Posteriormente, em cada iteração, esses parâmetros são alterados através do uso de uma mutação que segue uma distribuição Gaussiana, como é apresentado na equação (4).

$$W_i^{t+1} = W_i^t + \delta N(0,1) \quad (4)$$

onde

W_i^{t+1}	pesos após a mutação da partícula i na iteração $t+1$
W_i^t	pesos da partícula i na iteração t
δ	parâmetro de aprendizagem com uma variação ente 0 e 1

Um valor elevado de δ , significa que a mutação assume um papel mais importante, enquanto que $N(0,1)$ representa um número aleatório gerado na sequência de uma distribuição

normal, com média igual a 0 e variância igual a 1. Os parâmetros estratégicos estão limitados a valores entre 0 e 1 nesta fase.

O movimento de cada partícula i é orientado através da atualização do seu parâmetro de velocidade V_i e posição X_i . A equação (5) permite calcular a nova velocidade da partícula, sendo que esta vai depender da velocidade atual da partícula, da melhor posição encontrada por ela até então e da melhor posição do grupo.

$$V_i^{t+1} = W_{i(\text{inércia})}^t V_i^t + W_{i(\text{memória})}^t (x_{pbest} - X_i^t) + W_{i(\text{cooperação})}^t (x_{gbest} - X_i^t) \quad (5)$$

onde

$W_{i(\text{inércia})}^t$ peso de inércia da partícula i na iteração t

$W_{i(\text{memória})}^t$ peso de memória da partícula i na iteração t

$W_{i(\text{cooperação})}^t$ peso de cooperação da partícula i na iteração t

x_{pbest} melhor posição pessoal da partícula

x_{gbest} melhor posição global das partículas

X_i^t posição corrente da partícula i na iteração t

V_i^t velocidade corrente da partícula i na iteração t

A equação (6) apresenta a atualização da posição da partícula.

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (6)$$

A função de *fitness* (7) usada no MOPSO considera o lucro total e as emissões de CO₂.

$$\text{fitness} = [(C - R) + E] \quad (7)$$

Na realidade a função de *fitness* é um vetor de valores resultantes das diversas funções objetivo do problema multiobjectivo (neste caso 2 objetivos).

É importante salientar que o principal fator de inovação apresentado neste modelo é a modelação das incertezas, proveniente da produção dos painéis fotovoltaicos e da turbina eólica. Para modelizar estas incertezas é utilizada uma otimização robusta, baseada na referência [46], introduzida no MOSPO. O fluxograma da Figura 5 representa o algoritmo implementado para resolver o problema de gestão de recursos energéticos, usando a otimização robusta.

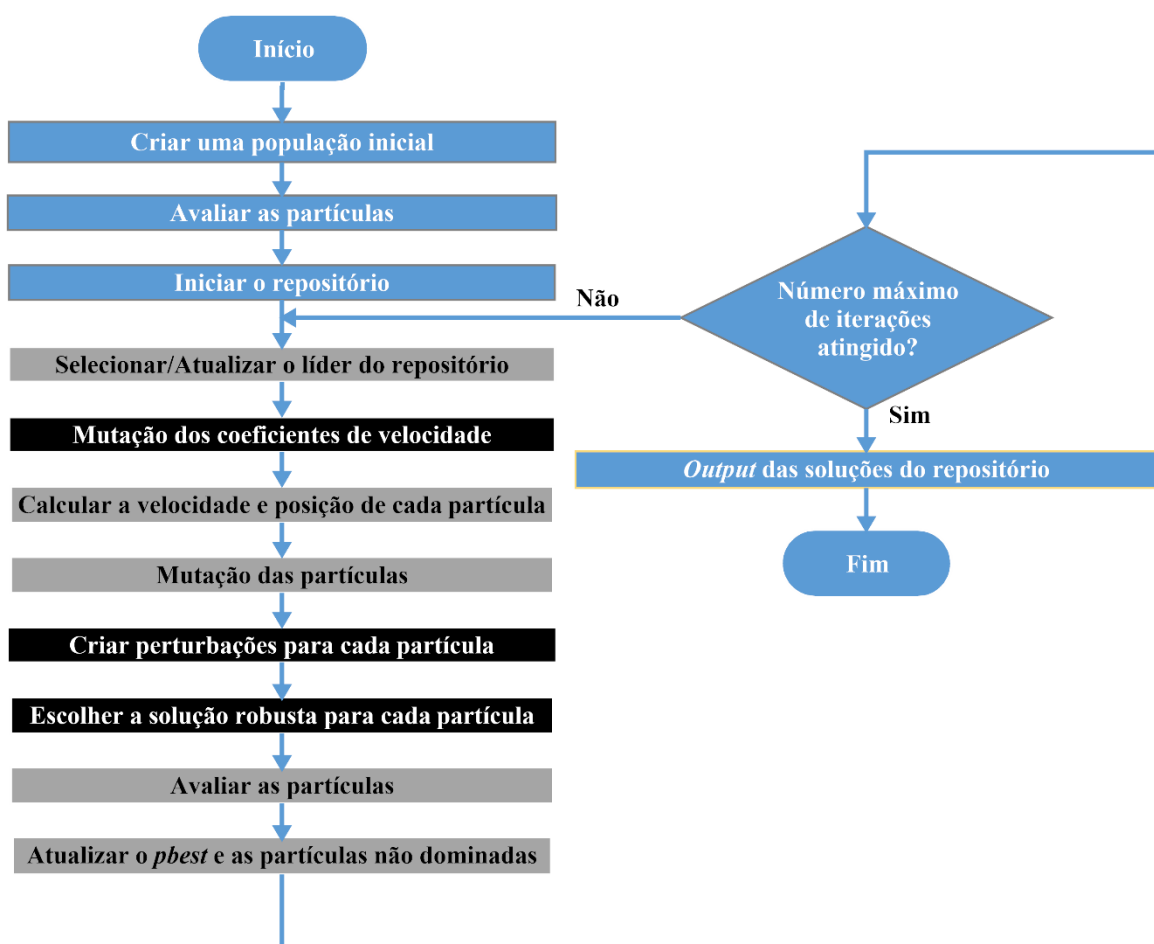


Figura 5 – Fluxograma do MOPSO desenvolvido

Primeiro são criadas N partículas iniciais (população inicial), sendo que cada uma delas contem as variáveis de decisão e as variáveis com incerteza. Após a criação da população inicial, cada partícula é avaliada, ou seja, são calculadas as soluções para cada partícula, sendo que as melhores partículas são memorizadas num repositório. O passo seguinte é identificar ou atualizar (no caso de não ser a primeira iteração) o líder do repositório (melhor solução global). Seguidamente é realizada a mutação dos coeficientes de velocidade através da equação (4). Posto isto, é realizado o calculo das novas velocidades e posições para cada

partícula, isto através da equação (5) e (6). A fase seguinte consiste na realização da mutação das partículas, através do cruzamento entre partículas, sendo apenas realizada na posição de algumas partículas (escolhidas aleatoriamente). Após serem realizados os passos típicos do MOPSO, para cada partícula, as variáveis com incerteza são perturbadas por um conjunto de cenários gerados pelo MC, isto tendo em conta um valor de erro de previsão (ver Algoritmo 2). Para cada perturbação é avaliada a solução na função objetivo, representada pela equação de *fitness* (7), e mediante de uma variável que decide qual o objetivo que o utilizador pretende dar maior relevância, é escolhida a solução que representa o pior caso, isto de forma a obter uma solução robusta, este processo é realizado para cada partícula da população inicial (ver Algoritmo 1). Após a seleção de todas as soluções robustas, para cada uma das partículas é realizada uma nova avaliação, sendo atualizada a melhor solução de cada partícula (*pbest*). Para além disso, as melhores partículas são ainda memorizadas no repositório, caso representem NDSs. Todo este ciclo descrito anteriormente irá repetir-se até ser atingido um número definido de iterações, sendo este tipo de configuração amplamente utilizada em outros algoritmos multiobjectivos baseados em meta-heurísticas.

No Algoritmo 1 é possível ver um pseudocódigo que representa um esboço do modelo de otimização robusta aplicado ao MOPSO.

Algoritmo 1 – Modelo de Otimização Robusta

```
1: nSamples {Definir o número de perturbações a criar}
2: errorForecast {Definir o erro de previsão}
3: objectivePriority ← 1(lucro), 2(emissões), 0(igualmente relevantes) {Definir o objetivo que se pretende dar prioridade}
4: Para it ← 1 até maxIterations {Para cada iteração}
5:     Para i ← 1 até nParticles {Para cada partícula}
6:         Perturbations ← createPerturbations() {Criar as perturbações em MC}
7:         Para n ← 1 até nSamples {Para cada perturbação}
8:             particlePert(n) ← fitnessFun() {Calcular a solução para a partícula perturbada}
9:         end {Fim do ciclo para o nSample}
10:        Se objectivePriority ← 0
11:            indexSolution ← getRand(particlePert) {Selecionar o índice de uma partícula perturbada aleatoriamente}
12:        Se objectivePriority ← 1
13:            indexSolution ← getMinProfit(particlePert) {Selecionar o índice de uma partícula perturbada que contem a solução com o valor mínimo de lucro}
14:        Se objectivePriority ← 2
15:            indexSolution ← getMaxEmissions(particlePert) {Selecionar o índice de uma partícula perturbada que contem a solução com o valor máximo de emissões}
```

```

17:         end {Fim das condições do objectivePriority}
18:     particle(i) ← particlePert(indexSolution) {Definir como partícula robusta a
partícula perturbada com o índice selecionado anteriormente}
19:     end {Fim do ciclo para o nParticles}
20: repository ← DetermineDomination(particle) {Identificar as partículas não dominadas
e gravar no repositório}
21: end {Fim do ciclo para o maxIterations}
    
```

No Algoritmo 2 é apresentado um extrato do código usado para criar as perturbações, baseado no método de MC.

Algoritmo 2 – Simulação de Monte Carlo (*createPerturbations*)

```

1: genTypeId ← find(caseStudyData) {Encontrar os índices das unidades PD com
incerteza}
2: meanForecas ← caseStudyData(genTypeId) {Definir o valor médio, representado pelo
valor da previsão de produção para o dia seguinte}
3: nGenTypeId ← length(genTypeId) {Identificar o número de unidades DG sujeitas a
incerteza}
4: Para j ← 1 até nGenTypeId {Para cada unidade de DG do tipo 1 (sujeita a incerteza)}
5:     Para t ← 1 até numPeriods {Para cada período de tempo}
6:         Perturbations ← randn(nSamples, errorForecast, meanForecast) {Criar as
perturbações com o uso do Monte Carlo, considerando uma distribuição
normal}
7:         end {Fim do ciclo para o numPeriods}
8:     end {Fim do ciclo para o nGenTypeId}
    
```

3.2.2. MODELO COMPARATIVO – PROGRAMAÇÃO ESTOCÁSTICA DE DOIS ESTÁGIOS

Esta subsecção apresenta o modelo de programação estocástica que foi implementado e usado como comparação com a metodologia robusta base desenvolvida nesta dissertação (MOPSO). Na programação estocástica, o problema de escalonamento de energia é formulado como um modelo estocástico de duas fases, sendo possível encontrar mais detalhes relativamente aos conceitos teóricos sobre os modelos de programação estocástica de dois estágios em [73]. A ideia é encontrar num primeiro estágio as soluções ótimas das variáveis sem incerteza para o dia seguinte, tendo em conta as variáveis com incerteza num segundo estágio, como a produção eólica e fotovoltaica. Nesta metodologia são gerados vários cenários de produção eólica e fotovoltaica pelo MC, considerando o mesmo erro de previsão usado no modelo de otimização robusta do MOPSO.

As decisões da primeira fase não mudam entre os cenários na segunda fase, ou seja, as variáveis sem incertezas permanecem as mesmas para todos os cenários. O problema apresentado é um PLIM, devido à presença de ambos variáveis contínuas e inteiro e

restrições lineares. O PLIM é implementado em TOMLAB [1], que é uma ferramenta de otimização avançada para MATLAB [1], usando CPLEX *solver*.

3.3. FORMULAÇÃO MATEMÁTICA

Nesta secção é apresentado o modelo matemático do problema multiobjectivo abordado nesta dissertação.

3.3.1. FUNÇÃO OBJETIVO

O problema proposto nesta dissertação representa um problema PLIM, devido à presença de ambos variáveis contínuas e inteiro e restrições lineares. Este problema contém dois objetivos conflitantes, sendo um deles a maximização dos lucros, e um outro a minimização das emissões de CO₂, como é demonstrado na equação (8). O lucro é representado pela diferença entre os custos e as receitas do edifício ($C-R$).

$$\text{Minimizar } Z = (C - R) + E \quad (8)$$

O edifício pode receber a sua receita (R) de duas formas diferentes, como é ilustrado em (9): a receita obtida no processo de carregamento dos VEs e o incentivo recebido por manter o seu valor de potência de pico solicitada aos fornecedores externos num valor pré acordado. Neste caso em concreto é considerado que o incentivo só é pago perante um valor da potência de pico inferior ao dobro do valor médio da potência solicitada aos fornecedores externos.

$$R = \sum_{t=1}^T \left[\left(\sum_{v=1}^{N_v} P_{\text{charg}}^v(t) \cdot c_{\text{charg}}^v(t) \right) \right] + r_{\text{peakPower}} \quad (9)$$

A equação (10) representa os custos ao encargo do edifício, sendo considerados quatro custos diferentes: o custo da energia fornecida pelos fornecedores de eletricidade (fornecedores externos), o custo da produção de energia pelas unidades de PD, o custo pago aos proprietários dos VEs por realizarem o descarregamento das baterias dos seus veículos e o custo do valor da potência de pico (potência contratada), que neste caso é igual ao valor máximo de potência solicitada aos fornecedores externos. Este custo é definido por escalões.

$$C = \sum_{t=1}^T \left[\left(\sum_{d=1}^{N_d} P_{\text{dg}}^d(t) \cdot c_{\text{dg}}^d(t) + \sum_{s=1}^{N_{sp}} P_{\text{sp}}^s(t) \cdot c_{\text{sp}}^s(t) + \sum_{v=1}^{N_v} P_{\text{disch}}^v(t) \cdot c_{\text{disch}}^v(t) \right) \right] + c_{\text{peakPower}} \quad (10)$$

A equação (11) representa a função objetivo para minimizar as emissões de CO₂:

$$E = \sum_{t=1}^T \left[\left(\sum_{d=1}^{\Omega_{dg}^d} P_{dg}^d(t) \cdot E_{dg}^d(t) + \sum_{s=1}^{\Omega_{sp}^s} P_{sp}^s(t) \times E_{sp}^s(t) \right) \right] \quad (11)$$

3.3.2. RESTRIÇÕES

Nesta subsecção são descritas as restrições usadas neste problema de otimização, englobando equações de multi-período, tais como, a equação de balanço entre a produção e o consumo total, o carregamento e descarga dos VEs e dos sistemas de armazenamento, a capacidade da bateria dos VEs e dos sistemas de armazenamento, o balanço considerado na previsão do consumo e localizações dos VEs, os limites técnicos dos sistemas de armazenamento, a capacidade da PD escalonável e os limites dos fornecedores externos.

3.3.2.1. BALANÇO

Em (12) é possível verificar a restrição do balanço. O total da energia produzida deverá ser igual ao consumo de energia, sendo esta condição válida e verificada em cada período t :

$$\begin{aligned} & \sum_{d \in \Omega_{dg}^d} P_{dg}^d(t) + \sum_{s=1}^{N_s} P_{sp}^s(t) + \sum_{d \in \Omega_{dg}^{nd}} P_{dg}^d(t) - \\ & \sum_{l=1}^{N_l} P_{load}^l(t) + \sum_{v=1}^{N_v} (P_{disch}^v(t) - P_{charg}^v(t)) + \\ & \sum_{st=1}^{N_{st}} (P_{disch}^{st}(t) - P_{charg}^{st}(t)) = 0 \quad \forall t \end{aligned} \quad (12)$$

3.3.2.2. PRODUÇÃO

A restrição seguinte impõe os limites máximos e mínimos de potência ativa em cada período t para as unidades de PD despacháveis. É usada uma variável binária para representar o estado de ligação dessas mesmas unidades. O valor 1 significa que a unidade está conectada, enquanto o valor zero significa que se encontra desligada:

$$X_{dg}^d(t) \cdot P_{dgMinLim}^d(t) \leq P_{dg}^d(t) \leq X_{dg}^d(t) \cdot P_{dgMaxLim}^d(t) \quad \forall t, \forall d \in \Omega_{dg}^d \quad (13)$$

onde

Variáveis

$X_{dg}^d(t)$ variável binária para o estado da unidade de PD d no período t

Parâmetros

$P_{dgMinLim}^d(t)$ potência ativa mínima da unidade de PD escalonável d no período t
(kW)

$P_{dgMaxLim}^d$ potência ativa máxima da unidade de PD escalonável d no período t
(kW)

O limite máximo e mínimo de potência ativa que pode ser fornecida por um fornecedor externo é expressa na seguinte expressão:

$$X_{sp}^s(t) \cdot P_{spMinLimit}^s(t) \leq P_{sp}^s(t) \leq X_{sp}^s(t) \cdot P_{spMaxLimit}^s \quad \forall t, \forall S \quad (14)$$

onde

Variáveis

$X_{sp}^s(t)$ variável binária de estado do fornecedor s no período t

Parâmetros

$P_{spMinLimit}^s$ potência ativa mínima do fornecedor s no período t (kW)

$P_{spMaxLimit}^s$ potência ativa máxima do fornecedor s no período t (kW)

3.3.2.3. SISTEMAS DE ARMAZENAMENTO DE ENERGIA

As restrições dos sistemas de armazenamento são descritas seguidamente. É importante referenciar que o carregamento e descarga dos sistemas de armazenamento não pode ser realizado simultaneamente, daí que sejam usadas duas variáveis binárias capazes de garantir esta condição para cada sistema de armazenamento:

$$X_{\text{storage}}^{st}(t) + Y_{\text{storage}}^{st}(t) \leq 1 \quad \forall t, \forall st \quad (15)$$

onde

Variáveis

$X_{\text{storage}}^{st}(t)$ variável binária que representa o estado de descarga do sistema de armazenamento st no período t

$Y_{\text{storage}}^{st}(t)$ variável binária que representa o estado de carregamento do sistema de armazenamento st no período t

O balanço da bateria máxima para cada sistema de armazenamento pode ser formulado da seguinte forma:

$$E_{\text{storage}}^{st}(t) = E_{\text{storage}}^{st}(t-1) + \eta_{\text{charg}}^{st} \cdot P_{\text{charg}}^{st}(t) \cdot \Delta t - \frac{1}{\eta_{\text{disch}}^{st}} \cdot P_{\text{disch}}^{st}(t) \cdot \Delta t \quad \forall t, \forall E \quad (16)$$

onde

Variáveis

$E_{\text{storage}}^{st}(t)$ energia armazenada no sistema de armazenamento st no período t (kWh)

Parâmetros

η_{charg}^{st} eficiência de carregamento do sistema de armazenamento st (%)

η_{disch}^{st} eficiência de descarga do sistema de armazenamento st (%)

O limite máximo de descarga de cada sistema de armazenamento pode ser expresso:

$$P_{\text{disch}}^{st}(t) \leq P_{\text{dischLimit}}^{st}(t) \cdot X_{\text{storage}}^{st}(t) \quad \forall t, \forall st \quad (17)$$

onde

Parâmetros

$P_{\text{dischLimit}}^{st}(t)$ limite máximo de descarga do sistema de armazenamento st no período t (kW)

O limite máximo de carregamento de cada sistema de armazenamento pode ser representado por:

$$P_{\text{charg}}^{st}(t) \leq P_{\text{chargLimit}}^{st}(t) \cdot Y_{\text{storage}}^{st}(t) \quad \forall t, \forall E \quad (18)$$

onde

Parâmetros

$P_{\text{chargLimit}}^{st}$ limite máximo de carregamento do sistema de armazenamento st no período t (kW)

A capacidade máxima da bateria de cada sistema de armazenamento pode ser representada por:

$$E_{\text{storage}}^{st}(t) \leq E_{\text{batCap}}^{st} \quad \forall t, \forall st \quad (19)$$

onde

Parâmetros

E_{batCap}^{st} capacidade máxima de armazenamento de energia permitida pelo sistema de armazenamento st (kWh)

O mínimo de energia armazenada a garantir no final de cada período t é expresso da seguinte forma:

$$E_{\text{storage}}^{st}(t) \leq E_{\text{minCharg}}^{st}(t) \quad \forall t, \forall st \quad (20)$$

onde

Parâmetros

$E_{\min\text{Charg}}^{st}$ energia armazenada mínima requerida pelo sistema de armazenamento
 st no período t (kWh)

3.3.2.4. VEÍCULOS ELÉTRICOS

O carregamento e descarga para cada VE não pode ser realizado de forma simultânea, existindo a necessidade da utilização de duas variáveis binárias para cada veículo, sendo esta restrição formulada da seguinte forma:

$$X_{EV}^v(t) + Y_{EV}^v(t) \leq 1 \quad \forall t, \forall v \quad (21)$$

onde

Variáveis

$X_{EV}^v(t)$ variável binária que representa o estado de carregamento do VE v no período t

$Y_{EV}^v(t)$ variável binária que representa o estado de descarga do VE v no período t

A expressão seguinte representa o balanço da bateria para cada VE. Têm de ser considerados o consumo de energia para a viagem do período t , a energia restante do período anterior armazenada na bateria e o valor de carga/descarga que ocorreu no período:

$$E_{EV\text{stored}}^v(t) = E_{EV\text{stored}}^v(t-1) + \eta_{\text{charg}}^v \cdot P_{\text{charg}}^v(t) \cdot \Delta t - \frac{1}{\eta_{\text{disch}}^v} \cdot P_{\text{disch}}^v(t) \cdot \Delta t \quad \forall t, \forall v \quad (22)$$

onde

Variáveis

$E_{EV\text{stored}}^v(t)$ energia armazenada no VE v no período t (kWh)

Parâmetros

η_{charg}^v	eficiência de carregamento do VE v (%)
η_{disch}^v	eficiência de descarregamento do VE v (%)
$E_{\text{EVtrip}}^v(t)$	energia prevista para a realização da viagem do VE v no período t (kWh)

Quando ligado à rede, o veículo não pode descarregar para a rede um valor superior à taxa admissível. O limite de descarga da bateria para cada VE pode ser formulado como:

$$P_{\text{disch}}^v(t) \leq P_{\text{dischLimit}}^v(t) \cdot X_{\text{EV}}^v(t) \quad \forall t, \forall v \quad (23)$$

onde

Parâmetros

$P_{\text{dischLimit}}^v(t)$ limite máximo de descarga do VE v no período t (kW)

Quando ligado à rede, o veículo não pode carregar um valor superior à taxa de segurança admissível. O limite de carga da bateria para cada VE pode ser formulado como:

$$P_{\text{charg}}^v(t) \leq P_{\text{chargLimit}}^v(t) \cdot Y_{\text{EV}}^v(t) \quad \forall t, \forall v \quad (24)$$

onde

Parâmetros

$P_{\text{chargLimit}}^v(t)$ limite máximo de carregamento do VE v no período t (kW)

Um outro aspeto importante é a energia armazenada mínima requerida no final do período t . Isto pode ser visto como uma reserva de energia (fixada pelos utilizadores dos VEs, ou estimada pelo operador) que pode ser utilizada para a realização de um percurso regular ou uma viagem inesperada em cada período t :

$$E_{\text{EVstored}}^v(t) \geq E_{\text{minCharg}}^v(t) \quad \forall t, \forall v \quad (25)$$

onde

Parâmetros

$E_{\min\text{Charg}}^v(t)$ energia armazenada mínima requerida pelo VE v no período t (kWh)

3.3.2.5. GESTÃO DA PROCURA

O custo da potência de pico ($c_{\text{peakPower}}$) é dado em função do valor de pico de potência (P_{peak}) obtido como resultado do escalonamento, sendo este valor de custo tabelado em função de diferentes escalões de potência. O P_{peak} consiste no valor de potência máxima solicitada ao fornecedor externo de energia durante o dia, sendo esse valor calculado pela seguinte expressão:

$$P_{\text{peak}} = \underset{T}{\text{máximo}} \left(\sum_{s=1}^{N_s} P_{sp}^s(t) \right) \quad (26)$$

onde

Variáveis

P_{peak} potência de pico proveniente do fornecedor externo de energia (kW)

O valor de custo da potência de pico ($c_{\text{peakPower}}$) é representado pela seguinte expressão:

$$c_{\text{peakPower}} = \left\{ \begin{array}{l} \text{se } \lim_{\min}(1) \leq P_{\text{peak}} \leq \lim_{\max}(1), p_{\text{escalão}}(1) \\ \text{se } \lim_{\min}(2) \leq P_{\text{peak}} \leq \lim_{\max}(2), p_{\text{escalão}}(2) \\ \vdots \\ \text{se } \lim_{\min}(n) \leq P_{\text{peak}} \leq \lim_{\max}(n), p_{\text{escalão}}(n) \end{array} \right\} \quad (27)$$

onde

Parâmetros

\lim_{\min} Limite mínimo de potência do respetivo escalão (kW)

\lim_{\max} Limite máximo de potência do respetivo escalão (kW)

$P_{\text{escalão}}$ Preço tabelado da potência de pico para o respetivo escalão (m.u.)

Além disso é pago um valor de incentivo ($r_{\text{peakPower}}$) caso o valor de potência de pico (P_{peak}) seja inferior ao dobro do valor médio de potência solicitada aos fornecedores externos (P_{mean}). O valor P_{mean} pode ser representada pela seguinte expressão:

$$P_{\text{mean}} = \underset{T}{\text{média}} \left(\sum_{s=1}^{N_s} P_{sp}^s(t) \right) \quad (28)$$

onde

Variáveis

P_{mean} potência média proveniente do fornecedor externo de energia (kW)

O valor de incentivo da potência de pico ($r_{\text{peakPower}}$) é calculado pela seguinte expressão:

$$r_{\text{peakPower}} = \begin{cases} \text{se } P_{\text{peak}} \leq 2 \times P_{\text{mean}}, & \frac{c_{\text{peak}}}{2} \\ \text{se } P_{\text{peak}} > 2 \times P_{\text{mean}}, & 0 \end{cases} \quad (29)$$

3.4. CONCLUSÕES

As incertezas associadas às condições climáticas provocam a existência de erros na previsão da produção, justificando a necessidade de uma complexa gestão dos recursos energéticos em edifícios capaz de modelar todo este comportamento incerto. Nesta metodologia são levadas em consideração as incertezas associadas à produção de energia fotovoltaica e eólica. Para modelar esta incerteza foi usada uma abordagem conhecida na literatura como otimização robusta. Este tipo de abordagem permite obter uma solução robusta para o dia seguinte, ou seja, temos uma proteção máxima da solução. Não obstante, esta solução é extremamente conservadora, refletindo-se numa solução mais adversa ao risco. Este tipo de metodologia permite abordar o problema de uma forma mais cautelosa, sendo que o resultado de escalonamento dos recursos considera um cenário mais pessimista, colocando o edifício mais preparado para lidar com os imprevistos.

A metodologia proposta é capaz de resolver o problema do escalonamento de recursos energéticos para o dia seguinte (escalonamento diário) sendo o modelo proposto capaz de gerir diversos recursos num horizonte temporal de 24 horas, com uma granularidade de 1 hora. O principal objetivo da metodologia é solucionar um problema multiobjectivo através da implementação de uma meta-heurística, o MOPSO. A função tem como dois objetivos conflitantes da gestão do edifício, a maximização dos lucros e minimização das emissões de CO₂.

Na metodologia são ainda considerados modelos de negócio que atualmente ainda não se encontram em vigor, como o caso do edifício poder em cada período comprar energia a diferentes comercializadores de energia, o uso do V2B e programas de DR baseados na potência de pico.

4. CASO DE ESTUDO

Para testar a viabilidade do método descrito na secção 3.2.1 foi considerado um caso de estudo de um edifício real de Portugal, localizado no Porto, a infraestrutura do GECAD. Tendo em conta os dados reais monitorizados pelo GECAD, foi desenvolvido um caso de estudo que pretende representar um edifício de escritórios em Portugal. A principal vantagem da utilização deste caso de estudo remonta para o facto de se poder usar dados reais, quer de consumo, quer de produção, recolhidos praticamente em tempo real e que se encontram armazenados numa base de dados em *SQL Server*. Este caso de estudo apresenta o escalonamento ótimo de recursos de um edifício, tendo dois objetivos conflitantes, a maximização dos lucros e a minimização das emissões de CO₂. Os dois objetivos são proporcionais, ou seja, quanto maior for o lucro, maior serão as emissões de CO₂ e quanto menor o lucro, menor serão as emissões de CO₂.

4.1. DESCRIÇÃO DO EDIFÍCIO

O GECAD, que inclui o laboratório *Intelligent Energy Systems Laboratory* (LASIE), está localizado no Instituto Superior de Engenharia do Instituto Politécnico do Porto (ISEP/IPP). A infraestrutura considerada engloba a supervisão e o controlo de microprodução (gerador eólico com 1,0 kW de capacidade máxima no edifício F, e mais um sistema fotovoltaico com 7,5 kW de capacidade máxima no edifício N) e de consumo (cargas reais dos edifícios N

com uma capacidade máxima de consumo superior a 7,0 kW). É importante salientar que o sistema de gestão do GECAD é responsável pela supervisão do consumo de outros edifícios. Contudo, neste caso de estudo foi apenas considerado o edifício N, uma vez que este é um edifício de menores dimensões (menor consumo) e com uma maior potência instalada em termos de produção, possibilitando deste modo situações em que este edifício é autossustentável, o que vai tornar o caso de estudo mais interessante do ponto de vista da otimização.

A infraestrutura do sistema de gestão do GECAD considerada incluiu dois edifícios de acordo com a Figura 6: o edifício F e o edifício N.

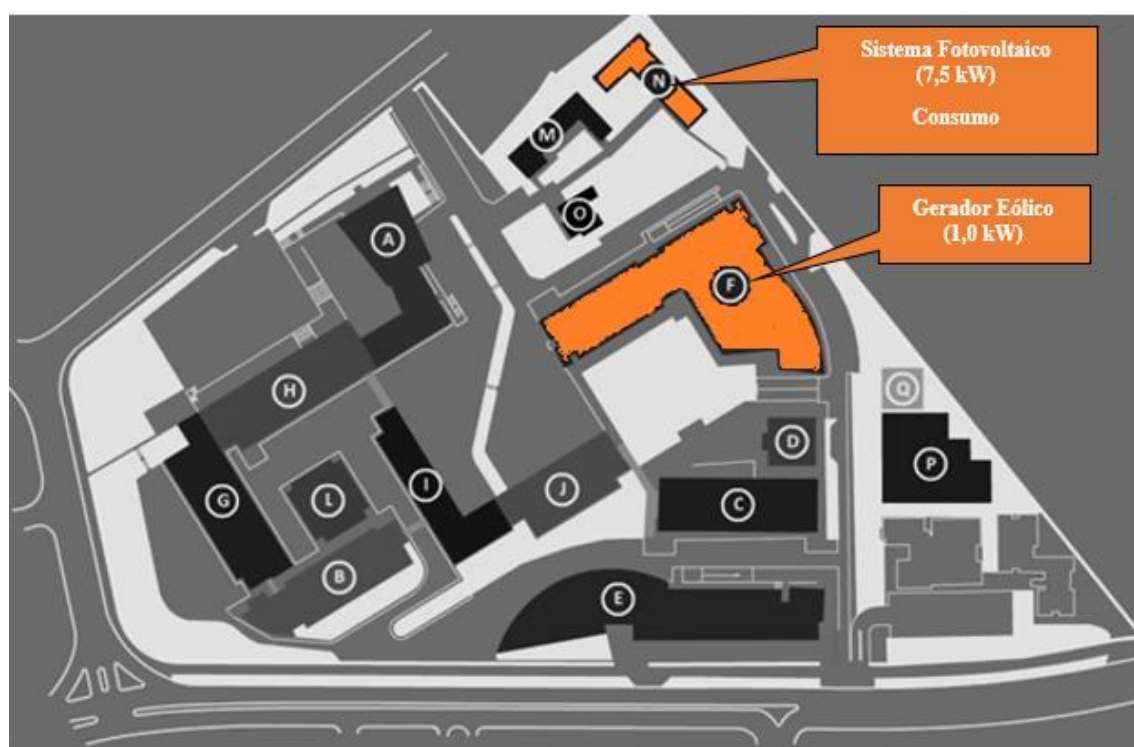


Figura 6 - Mapa dos edifícios do campus do ISEP

Através dos dados reais de consumo e produção foi criado um caso de estudo de um edifício de escritórios com os seguintes recursos de energia:

- 1 Sistema fotovoltaico;
- 1 Turbina eólica;
- 1 Sistema de armazenamento de energia;
- 4 Fornecedores externos de energia;
- 3 Veículos elétricos

4.2. DESCRIÇÃO DOS RECURSOS DO EDIFÍCIO

Esta subsecção tem como principal objetivo caracterizar os recursos considerados na gestão do edifício. Os dados usados para simular este caso de estudo do edifício de escritórios de Portugal são baseados em dados adquiridos pelo GECAD. A Tabela 2 apresenta a informação geral sobre os dados usados para simular este edifício.

Tabela 2 – Informação geral dos dados usados

Tipo de Recurso	Tipo	Informação
Consumo	Escritórios	Dados baseados nos consumos no edifício do GECAD (edifício N)
Produção	Fotovoltaica	Dados baseados no sistema fotovoltaico instalado no edifício do GECAD (edifício N)
	Eólica	Dados baseados no sistema eólico instalado no edifício do GECAD (edifício F)
VE	BEV (puramente elétrico)	Informação obtida através da ferramenta EVeSSi ²⁴
Sistema Armazenamento	Bateria	Adaptado dos inversores de baterias SMA (<i>Sunny Island 6.0H e 8.0H</i>) ²⁵

O edifício conta com os seguintes recursos: 2 unidades de PD; 4 fornecedores externos de energia; 1 sistema de armazenamento e 3 VEs. A Tabela 3 apresenta os dados dos recursos de energia, contendo informações de preço em unidades monetárias por kWh (m.u./kWh) e disponibilidade em kW.

Tabela 3 – Dados dos recursos de energia

Recursos de Energia	Disponibilidade (kW)		Preços (m.u./kWh)	Unidades
	mínima – máxima			
Fotovoltaico	0 – 7,50		0,00	1
Eólico	0 – 1,00		0,00	1
Fornecedor Externo	0 – 15,00		0,07 – 0,32	4
Armazenamento	Carregamento	0 – 10,00	0,00	1
	Descarregamento	0 – 10,00	0,00	
Veículos Elétricos	Carregamento	0 – 9,00	0,13	3
	Descarregamento	0 – 9,00	0,15	
Consumo	1,02 – 6,53		0,00	1

²⁴ EVeSSi – *Electric Vehicle Scenario Simulator*, na designação anglo-saxónica.

²⁵ *Sunny Island 6.0H e 8.0H*: <http://www.sma.de/en/products/battery-inverters/sunny-island-60h-80h.html>

Foram considerados quatro fornecedores externos de energia com diferentes taxas de emissão e preços de energia. A Tabela 4 apresenta os diferentes tipos de fornecedores externos utilizados neste caso de estudo, sendo estes baseados em comercializadores de energia reais de quatro países europeus diferentes (Portugal, Espanha, Alemanha e França) [74]–[77]. Para cada comercializador de energia foram escolhidos tipos de tarifa diferentes para tornar o caso de estudo mais interessante do ponto de vista da otimização. Para além disso, considerou-se diferentes níveis de emissões de CO₂ para cada um dos comercializadores, baseados nos valores reais registados para os diferentes países da europa [78].

Tabela 4 – Fornecedores de energia externos considerados no caso de estudo

País	Emissões de CO ₂ (kgCO ₂ /kWh)	Preços (m.u./kWh) min-máx	Tipo de Tarifa
Portugal	0,23	0,0927 – 0,3177	Tri-horária
Spain	0,25	0,0928 – 0,1092	Horária
France	0,07	0,1150 – 0,1636	Bi-horária
Germany	0,35	0,2013	Simple

No que se refere aos programas de DR, os escalões usados para o custo diário da potência de pico podem ser verificados na Tabela 5. Para além disso, é oferecido um incentivo caso esse valor de potência de pico seja inferior a duas vezes o valor médio diário de energia empregue ao edifício proveniente dos fornecedores externos. O incentivo é igual à metade do valor pago referente ao custo diário da potência de pico.

Tabela 5 – Tabela de preços da potência de pico

Escalão	Potência (kW)	Preço (m.u.)
1	1 - 3	0,05
2	4 - 6	0,06
3	7 - 9	0,07
4	10 - 12	0,08
5	13 - 15	0,09

Na Figura 7 é possível verificar a previsão de produção do sistema fotovoltaica e eólico usada neste caso de estudo. Verifica-se o pico de produção fotovoltaica entre as 12h e as 14h, correspondendo aos períodos de maior intensidade de irradiação solar. A produção eólica faz-se notar essencialmente nos períodos noturnos (19h-24h).

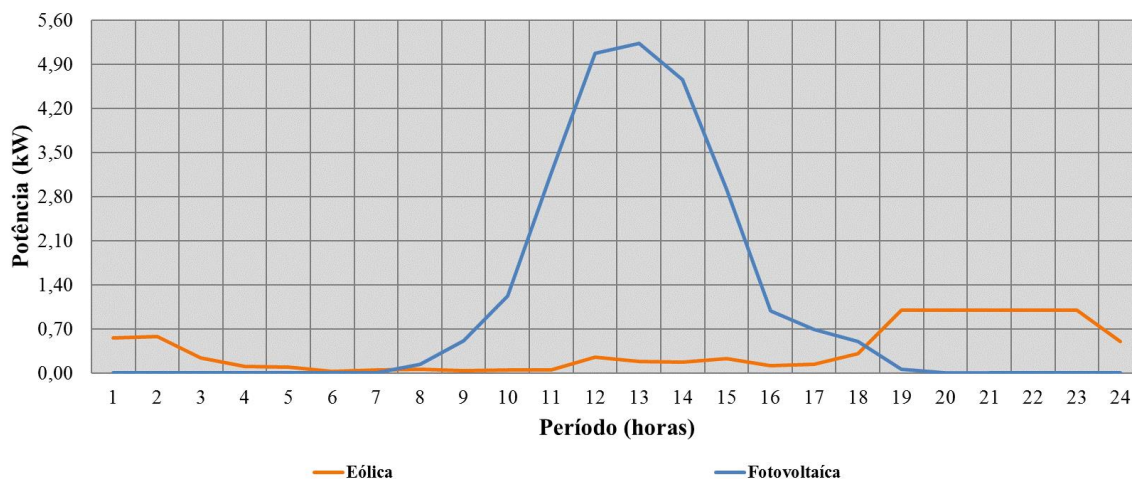


Figura 7 – Perfil de produção de energia do fotovoltaico e eólica

Estas unidades de PD de forma independente não são suficientes para alimentar todo o consumo do edifício (ver Figura 8), tornando-se assim necessário adquirir energia de fornecedores externos, mais conhecidos como comercializadores de energia. A Figura 8 apresenta o consumo típico por parte do edifício e a previsão do perfil de produção da PD usado neste caso de estudo.

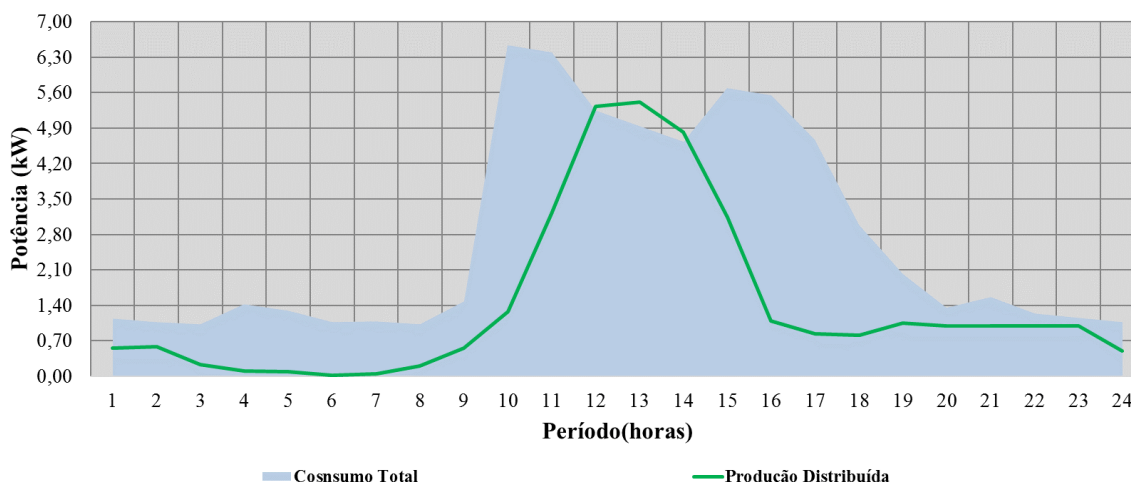


Figura 8 – Consumo versus PD total

Analisando a Figura 8, a produção total da PD não é suficiente para alimentar todo o consumo do edifício, salvo o período entre as 12h e as 14h, onde a produção da PD é superior ao consumo. Nos períodos onde não existe produção de PD suficiente, o edifício terá que comprar energia aos fornecedores externos. Poderão ainda ser usados outros recursos para suportar este consumo de energia, como é o caso da energia proveniente do descarregamento dos VEs e dos sistemas de armazenamento. O consumo de pico é descortinado no período

da manhã, entre as 9h e as 12h, existindo uma diminuição na hora de almoço (12h até as 14h). Posteriormente, o consumo volta a aumentar, contudo, a partir das 16h verifica-se uma nova diminuição gradual do consumo, justificada pelo facto de os funcionários estarem a abandonar o edifício nos períodos que se sucedem. Em suma, o consumo de maior relevo faz-se notar entre as 9h e as 20h, período esse que corresponde ao horário de expediente dos funcionários do edifício.

Na Figura 9 é possível visualizar os movimentos dos VEs (em viagem ou conectado ao edifício), bem como o consumo das suas viagens durante o dia. Estes movimentos e consumos dos VEs usados neste caso de estudo são obtidos através de uma ferramenta de simulação denominada de EVeSSI [79].




Figura 9 – Consumo das viagens e número de VEs ligados à rede e em viagem

Os VEs têm a capacidade de ligar à rede do edifício (V2B), sendo que o carregamento e descarga das suas baterias podem ser geridos pelo próprio edifício de uma forma inteligente. Os proprietários dos VEs ao aceitarem descarregar as suas baterias são recompensados monetariamente pelo edifício. Este processo pode trazer muitas vantagens para o edifício, como por exemplo, evitar o uso de recursos mais caros, como o caso do fornecedor externo, ou usar o excesso de produção de energia por parte dos sistemas fotovoltaicos e eólicos em outros períodos de tempo. Para além disso, caso os proprietários necessitem de carregar os seus veículos, estes poderão fazê-lo através do pagamento de uma tarifa ao edifício. Este foi o modelo de negócio utilizado neste caso de estudo, sendo que se trata de um modelo especulativo, uma vez que o carregamento em edifícios privado, bem como o processo V2G, ainda não se encontram atualmente aplicados.

4.2.1. SISTEMA FOTOVOLTAICO E EÓLICO

A descrição dos equipamentos do sistema fotovoltaico fixo ligado à rede (ver Figura 10 a) é seguidamente apresentada:

- 30 Módulos fotovoltaicos: AXITEC; Potência nominal: 7500W; Produção esperada para cada painel: 250W pico
- 1 Inversor: *Fronius* SYMO 6.0-3-M com MC4 PVKST4/6II

A descrição dos componentes do sistema eólico isolado (ver Figura 10 b) é a seguinte:

- 1 Turbina eólica: Potência nominal 1000W a 11.6 m/s; Produção esperada a 5.4 m/s: 200 kWh/mês
- 1 Inversor: *Steca Compact* C2600-24
- Sistema de baterias: *EXIDE Technologies* (12 módulos – 24V)
- 1 Regulator *Whisper* WHI 200



a) Sistema fotovoltaico do edifício N



b) Sistema eólico do edifício F

Figura 10 – Sistema de produção do GECAD

4.3. ESTRUTURA DOS TESTES REALIZADOS

Esta subsecção está relacionada com os diversos testes realizados para este caso de estudo. Foram desenvolvidos quatro testes diferentes: o primeiro teste considera uma otimização robusta dando importância ao critério do lucro; o segundo teste considera que ambos os critérios são igualmente relevantes; um terceiro teste em que a otimização robusta dá mais relevância ao critério das emissões de CO₂, e por último um teste que não considera as incertezas; ou seja, é considerada que a previsão para o dia seguinte é perfeita. Os testes realizados neste caso de estudo são apresentados de forma sumariada seguidamente:

- Otimização Robusta - Critério do Lucro (OR-CL);
- Otimização – Critérios Igualmente Relevantes (O-CIR);
- Otimização Robusta – Critério das Emissões de CO₂ (OR-CE);
- Otimização – Sem Incerteza (O-SI).

O período de amostragem considerado é de 1 hora, com um horizonte temporal de 24 horas, sendo este aspeto mantido em todos os testes realizados. A metodologia desenvolvida é capaz de obter, para o dia seguinte, o escalonamento ótimo dos recursos do edifício (ver Figura 11). O edifício pode suportar o consumo espectável através de recursos como as unidades de PD, fornecedores externos, descarga dos VEs e a descarga do sistema de armazenamento (bateria). Uma vez que se trata de um problema multiobjectivo, teremos como resultado um conjunto de pontos das NDSs obtidas, que são representados por uma frente de *Pareto*. No caso do OR-CL e OR-CE, onde é considerada a incerteza da PD (fotovoltaica e eólica), as soluções obtidas são sempre soluções robustas. Foi usado o MOPSO implementado no MATLAB para resolver este problema da gestão dos recursos do edifício descrito neste caso de estudo. O caso de estudo foi testado num computador com um processador *Intel® Xeon® E5-2620v2* - 2.10 GHz com 12 cores, uma memória *Random-Access-Memory* (RAM) de 16GB e com o sistema operativo *Windows 10 Education*.




Figura 11 – Estrutura do escalonamento para o dia seguinte

A Tabela 6 apresenta os parâmetros usados na meta-heurística (MOPSO), utilizada para solucionar o problema de escalonamento de recursos no edifício apresentado neste caso de estudo. É importante referenciar que estes parâmetros foram mantidos ao longo de todos os testes apresentados neste trabalho. Os parâmetros descritos foram obtidos por extensos ensaios experimentais e por recomendações na literatura como o caso da referência [70].

Tabela 6 – Parâmetros do MOPSO

Parâmetros		Descrição
Número de partículas		10
Tamanho do repositório		100
Pesos de inércia		Pesos de mutação Gaussiana (pesos iniciais gerados aleatoriamente entre 0 e 1)
Coeficiente de aceleração da melhor posição		
Coeficiente de cooperação		
Coeficiente de perturbação		
Parâmetro de mutação da aprendizagem (δ)		0.20
Número de divisões		30
População enxame inicial		Gerados aleatoriamente entre os limites superiores e inferiores das variáveis
Taxa de mutação de partículas		0.50
Dimensões de mutação		10% Dimensões aleatórias
Fator de travamento da velocidade (C_{factor})		1
Critério de paragem	Max.	2000 Iterações (ciclos)
Posição máxima (x_{max})		Igual aos limites superiores das variáveis
Posição mínima (x_{min})		Igual aos limites inferiores das variáveis
Velocidade máxima (v_{max})		$\frac{x_{max} - x_{min}}{2} \cdot C_{factor}$
Velocidade mínima (v_{min})		$-v_{max}$

No MOPSO primeiramente são criadas 10 partículas iniciais, sendo que cada uma delas contem as variáveis de decisão e as variáveis com incerteza (produção eólica e fotovoltaica), representado deste modo a população inicial. Nesta primeira fase, as variáveis com incerteza são definidas através de uma previsão de produção para o dia seguinte. Após a criação da população inicial, cada partícula é avaliada, ou seja, são calculadas as soluções para cada partícula, sendo que as melhores partículas são memorizadas no repositório. O passo seguinte é então identificar (ou atualizar, no caso de já não se tratar da população inicial) o líder do repositório (melhor solução global). Seguidamente é realizada a mutação dos coeficientes de velocidade (inercia, memória, cooperação). É importante referir que as variáveis com incerteza não vão sofrer qualquer tipo de alteração pelos parâmetros de mutação do MOPSO, uma vez que retratam variáveis não controláveis, pois é impossível controlar os valores das unidades de produção renovável. Posto isto, é realizado o cálculo das novas velocidades e posições para cada partícula. A fase seguinte consiste na mutação das partículas, através do cruzamento entre partículas, sendo esta apenas realizada na posição de algumas partículas (escolhidas aleatoriamente). Após serem realizados os passos típicos do MOPSO, para cada partícula, as variáveis com incerteza (produção eólica e fotovoltaica), que neste caso correspondem aos valores de previsão de produção para o dia seguinte, são perturbadas por um valor de erro de previsão, sendo criados 10 cenários diferentes de

produção fotovoltaica e 10 cenários de produção eólica. Estes cenários são gerados através da utilização do método de MC, seguindo uma distribuição normal e considerando um erro de previsão de 15%. Para cada perturbação é avaliada a função objetivo, e mediante de uma variável que decide qual o objetivo que o utilizador pretende dar maior relevância, é escolhida a solução que representa o pior caso. No OR-CL este pior caso consiste na solução que apresenta menor lucro, enquanto no OR-CE consiste na solução que apresenta pior valor de emissões de CO₂. No caso do O-CIR, onde os critérios são considerados igualmente relevantes, é selecionada uma solução aleatória nesta fase de seleção. No O-SI, como não são consideradas as perturbações existentes na produção, este processo de seleção não é realizado. É importante salientar que este processo de seleção das soluções é repetido para cada uma das partículas da população. Após a seleção das soluções robustas de cada uma das partículas é atualizada a melhor solução de cada partícula (*pbest*). Para além disso, as melhores partículas são ainda memorizadas no repositório, caso representem NDSs. Todo este ciclo descrito anteriormente irá repetir-se até ser atingido um número definido de iterações, no caso em concreto 2000 iterações. Pode-se concluir que são avaliados um total de 200 000 cenários diferentes de produção fotovoltaica e eólica, uma vez que são criados 10 cenários diferentes para cada uma das 10 partículas, sendo este processo repetido ao longo de 2000 iterações. Outra característica interessante deste caso de estudo é a presença de quatro fornecedores externos de energia com diferentes emissões de CO₂ e preços de energia. Para se encontrar um maior número de soluções que satisfaçam os dois objetivos de uma forma equilibrada, optou-se por uma abordagem aleatória na seleção do fornecedor externo a escalonar para os diferentes períodos. Como se trata de um problema multiobjectivo, seria bastante limitado, ao nível do espaço de pesquisa, escalonar sempre o mesmo fornecedor externo de energia, isto uma vez que existem fornecedores que apresenta menor preço da energia, mas contêm mais emissões, ou fornecedores que apresentam um preço mais elevado, mas com valores de emissão de CO₂ mais diminutos.

4.4. RESULTADOS E ANÁLISES

Esta subsecção apresenta os resultados e a análise de cada teste (OR-CL, O-CIR, OR-CE e O-SI) para este caso de estudo. No final é ainda descrita uma análise comparativa entre testes e as considerações finais.

4.4.1. OTIMIZAÇÃO ROBUSTA – CRITÉRIO DO LUCRO

Este caso de estudo considera 2 unidades de PD, 4 fornecedores externos, 1 bateria (sistema de armazenamento) e 3 VEs. Neste OR-CL é pressuposto que o objetivo para qual o utilizador pretende dar maior relevância é o lucro, logo o algoritmo na fase de avaliação da solução robusta irá escolher a solução que representa o pior caso, que neste caso corresponderá à solução que apresenta o pior lucro.

A Figura 12 apresenta a frente de *Pareto* obtida com a meta-heurística MOPSO para este OR-CL. Os marcadores da figura representam cada solução não dominada (NDS) do repositório do MOPSO. Os marcadores NDS-L e NDS-R representam os extremos das NDSs, sendo a NDS-L a solução com menor emissões de CO₂, e a NDS-R a solução com maior lucro. Pode-se verificar que como repositório final foram encontradas um total de 14 NDSs, sendo que o lucro tem uma variação entre os -6,275 m.u. e os -5,487 m.u., enquanto os valores de emissão têm uma variação entre 5,053 kgCO₂ e os 7,999 kgCO₂.

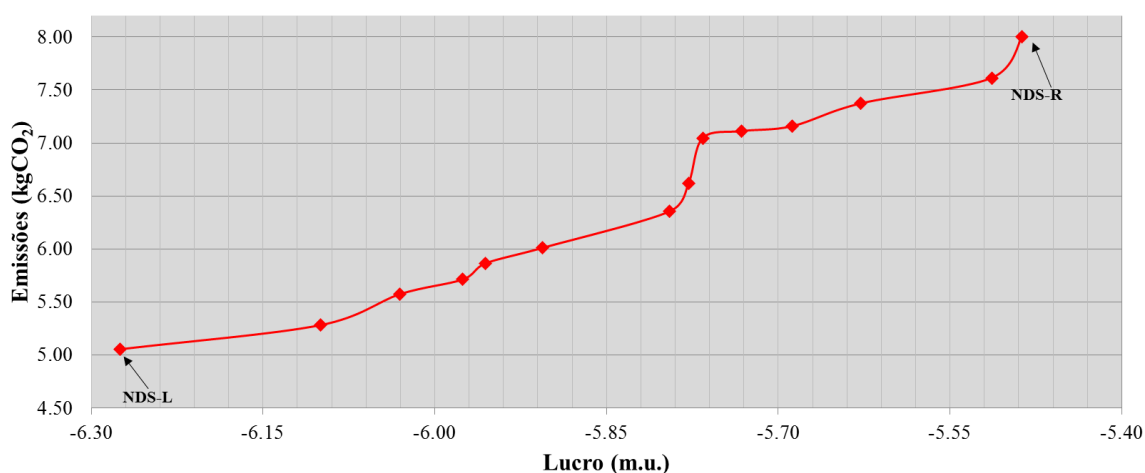


Figura 12 – Frente de Pareto do OR-CL

A Tabela 7 apresenta os resultados das soluções NDS-L e NDS-R obtidas na frente de *Pareto* no OR-CL.

Tabela 7 – Soluções não dominadas selecionadas do OR-CL

Solução	NDS-L	NDS-R
Lucro (m.u.)	-6,275	-5,487
Emissões (kgCO ₂)	5,053	7,999

A Figura 13 e a Figura 14 apresentam os resultados obtidos para o escalonamento de recursos de energia das soluções NDS-L e NDR-R, respetivamente.




Figura 13 – Escalonamento de recursos ótimo da NDS-L no OR-CL

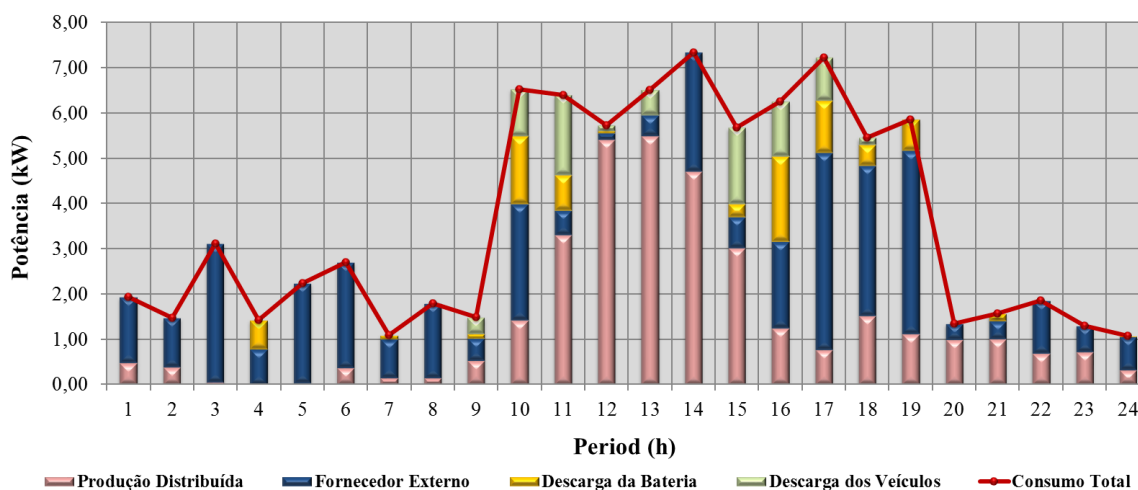


Figura 14 – Escalonamento de recursos ótimo da NDS-R no OR-CL

À primeira vista percebe-se logo que o escalonamento dos recursos das soluções obtidas são semelhantes. Isto acontece porque, uma vez que o algoritmo seleciona as soluções robusta, ou seja, soluções que apresentam pior lucro, as grandes diferenciações entre as soluções acontecem essencialmente devido ao fornecedor externo escalonado para os diferentes períodos. É possível verificar que em ambas as soluções foi usada a descarga de veículos e a descarga das baterias (sistema de armazenamento). Isto deve-se ao facto de, com o uso destes recursos, ser minimizado o uso da energia proveniente dos fornecedores externos, reduzindo as emissões de CO₂. Uma vez que o algoritmo está a seleccionar soluções robustas,

isto é, as melhores soluções considerando os cenários mais pessimistas de lucro, o uso da descarga de veículos é bastante evidente nas duas soluções, pois este recurso representa um custo adicional para o edifício, prejudicando o lucro total obtido. A grande percentagem de utilização da descarga da bateria é justificada pelo facto de se tratar de um recurso que não implica qualquer custo para o edifício, uma vez que esta unidade é considerada propriedade do mesmo. Com a utilização de quatro diferentes tipos de fornecedores externos, as grandes modificações a nível de lucro acontecem fundamentalmente devido ao fornecedor externo escalonado nos diferentes períodos de tempo. O facto de existirem fornecedores externos com menor preço de energia, mas com um maior valor de emissões, ou fornecedores externos com preço de energia mais elevado, mas com um valor de emissões mais baixo, origina as principais diferenças verificadas entre as duas soluções.

As percentagens de uso de cada recurso de produção, relativamente às soluções NDS-L e NDS-R, podem ser visualizadas na Figura 15 e na Figura 16. Nos resultados apresentados na Figura 15, referentes à solução NDS-L, a produção é dividida em: 43,09% para os fornecedores externos, 38,07% para a PD, 9,25% para a descarga da bateria e 9,59% para a descarga dos veículos. Nos resultados da Figura 16, referente à solução NDS-R, a produção está dividida em: 43,23% para os fornecedores externos, 38,82% para a PD, 8,94% para a descarga da bateria e 9,01% para a descarga dos veículos.




Figura 15 – Percentagem de uso dos recursos de produção da NDS-L no OR-CL




Figura 16 – Percentagem de uso dos recursos de produção da NDS-R no OR-CL

A Figura 17 e a Figura 18 apresentam os resultados obtidos para o consumo das soluções NDS-L e NDR-R, respetivamente. Tal como tinha acontecido no escalonamento da produção, uma vez mais os resultados obtidos foram praticamente iguais para as duas soluções. Em ambas as soluções os VEs são carregados essencialmente nos períodos ao final de tarde (16h–19h), isto de forma aos proprietários terem bateria suficiente para realizar a sua viagem de regresso a casa, após o término do seu horário de expediente. O carregamento da bateria é realizado de forma mais acentuada em períodos noturnos, uma vez que o preço da energia é mais baixo. É possível ainda verificar uma elevada taxa de carregamento da bateria no período entre as 13h-14h, justificada pela elevada penetração da PD registada.




Figura 17 – Escalonamento do consumo da NDS-L no OR-CL




Figura 18 – Escalonamento do consumo da NDS-R no OR-CL

A Figura 19 e a Figura 20 apresentam as percentagens do escalonamento do consumo, para as soluções NDS-L e NDS-R. Nos resultados apresentados na Figura 19, referentes à solução NDS-L, o consumo é dividido em: 74,98% para a carga, 12,56% para o carregamento dos veículos e 12,45% para o carregamento da bateria. Nos resultados da Figura 20, referente à solução NDS-R, o consumo é dividido em: 75,21% para a carga, 12,76% para o carregamento dos veículos e 12,03% para o carregamento da bateria.




Figura 19 – Percentagem dos recursos de consumo da NDS-L no OR-CL




Figura 20 – Percentagem dos recursos de consumo da NDS-R no OR-CL

Neste OR-CL é possível verificar uma diferença entre as soluções NDS-L e NDS-R, em termos de lucro, de um valor de -6,275 m.u. (NDS-L) para um valor de -5,487 m.u.(NDS-R), representado uma variação de 12,56%. Quanto às emissões de CO₂, na solução NDS-L o resultado foi de 5,053 kgCO₂, enquanto na NDL-R foi de 7,999 kgCO₂, representando um aumento de 58,30%. Estas diferenças devem-se essencialmente ao escalonamento da energia proveniente de fornecedores externos, e, de uma forma mais diminuta, devido ao uso da descarga de veículos.

Numa análise comparativa, pode-se verificar que a energia proveniente dos fornecedores externos é bastante idêntica para ambas as soluções. Em relação à PD, os resultados mostram um aumento de 1,65% na NDS-R face à solução NDS-L, verificando-se diferentes níveis de perturbações na produção. A descarga de veículos apresenta uma diminuição de 6,31% na solução NDS-R, isto que se deve ao facto de esta solução apresentar um lucro melhor. Para atingir essa melhoria foi necessário realizar uma redução no pagamento de incentivos para efeitos do uso da descarga de veículos. A descarga da bateria teve uma redução de 3,58% na solução NDS- R, comparativamente com a NDS-L. Em suma, houve uma diminuição da produção total de cerca de 0,30% na solução NDS-R, comparativamente ao resultado apresentado na solução NDS-L. No que diz respeito ao respeito ao consumo, verificou-se um aumento do carregamento de veículos em 1,36% na solução NDS-R. Quanto ao carregamento da bateria, na solução NDS-R este teve uma diminuição de 3,67%, quando

comparado à solução NDS-L. Estes resultados podem ser vistos de forma sumarizada na Tabela 8, onde a última coluna apresenta a variação da solução NDS-R face à solução NDS-L.

Tabela 8 – Comparação entre a solução NDS-L e NDS-R do OR-CL

Tipo de Recurso	NDS-L (kWh)	NDS-R (kWh)	Variação (%)
Produção			
Fornecedor Externo	37,74	37,76	+0,05
Produção Distribuída	33,35	33,90	+1,65
Descarga de Veículos	8,40	7,87	-6,31
Descarga da Bateria	8,10	7,81	-3,58
Produção Total	87,60	87,34	-0,30
Consumo			
Carga	65,68	65,68	0,00
Carregamento de Veículos	11,00	11,15	+1,36
Carregamento da Bateria	10,91	10,51	-3,67
Consumo Total	87,60	87,34	-0,30

4.4.2. OTIMIZAÇÃO – CRITÉRIOS IGUALMENTE RELEVANTES

Neste O-CIR o algoritmo na fase de avaliação da solução, irá selecionar, em vez da solução com pior lucro, uma solução aleatória, deixando assim de se aplicar o conceito de solução robusta. Para este teste são considerados os mesmos recursos energéticos referenciados no OR-CL.

A Figura 21 apresenta a frente de *Pareto* obtida com o uso da meta-heurística MOPSO para o O-CIR.

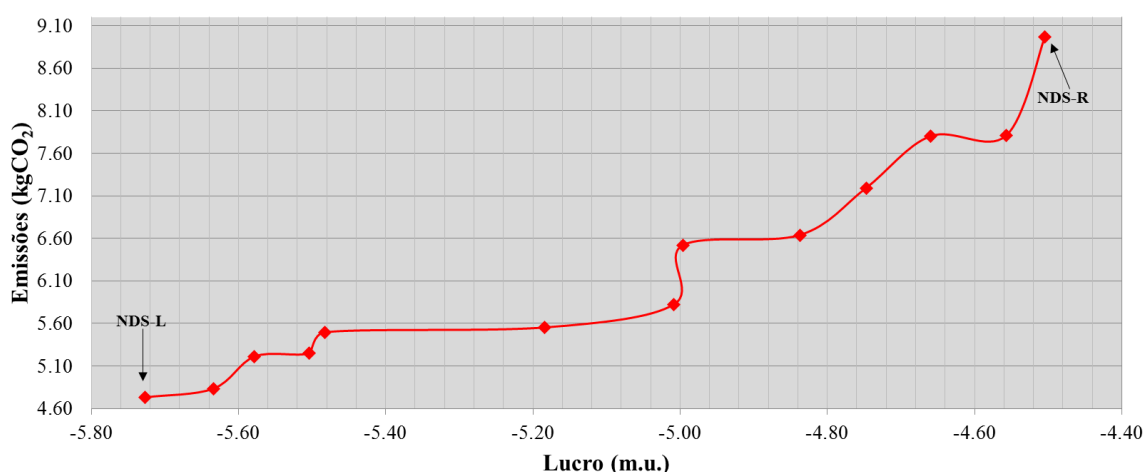


Figura 21 – Frente de Pareto do O-CIR

Os marcadores da Figura 21 representam cada NDS do repositório do MOPSO. Os marcadores NDS-L e NDS-R representam os extremos das NDSs, sendo a NDS-L a solução com menor emissões de CO₂, e a NDS-R a solução com maior lucro. Existem algumas regiões da frente de *Pareto* com maior número de marcadores, representando uma maior densidade de NDSs. O repositório final é composto por um total de 13 NDSs, sendo que o lucro tem uma variação entre os -5,727 m.u. e os -4,504 m.u., enquanto os valores de emissão têm uma variação entre 4,728 kgCO₂ e os 8,971 kgCO₂.

A Tabela 9 apresenta os resultados das soluções NDS-L e NDS-R obtidas na frente de *Pareto*.

Tabela 9 – Soluções não dominadas selecionadas do O-CIR

Solução	NDS-L	NDS-R
Lucro (m.u.)	-5,727	-4,504
Emissões (kgCO ₂)	4,728	8,971

A Figura 22 e a Figura 23 apresentam os resultados obtidos para o escalonamento dos recursos de energia das soluções NDS-L e NDR-R, respetivamente. Ao observar as duas soluções obtidas (NDS-L e NDS-R) para este O-CIR, é possível verificar que o escalonamento dos recursos de produção é bastante semelhante entre elas. Na solução NDS-R o valor de lucro e de emissões é superior, quando comparado aos valores obtidos na solução NDS-L. O principal recurso que causa estas diferenças é o tipo de fornecedor externo escalonado para os diferentes períodos. A descarga do sistema de armazenamento é um recurso usado em ambas as soluções. Isto acontece devido ao facto de se tratar de um recurso que não implica qualquer custo para o edifício, uma vez que as baterias são consideradas como propriedade do edifício. A descarga de veículos, onde o edifício tem que pagar um incentivo ao proprietário do veículo para usar esse recurso, é usada nos períodos em que é escalonado um fornecedor externo com um preço de energia superior ao valor que o edifício paga aos utilizadores dos VEs. Posto isto, recursos como a descarga dos veículos e descarga da bateria são usados com o objetivo diminuir a necessidade de uso da energia proveniente dos fornecedores externos, diminuindo diretamente o valor das emissões de CO₂. Como já foi dito anteriormente, o escalonamento obtido para as duas soluções (NDS-L e NDS-R) foi praticamente igual, sendo uma vez mais o escalonamento do fornecedor externo para cada período o principal o principal fator que provoca as diferenças entre as soluções. O facto de

existirem quatro comercializadores de energia com preços e emissões de CO₂ diferentes provoca as alterações verificadas.




Figura 22 – Escalonamento de recursos ótimo da NDS-L no O-CIR

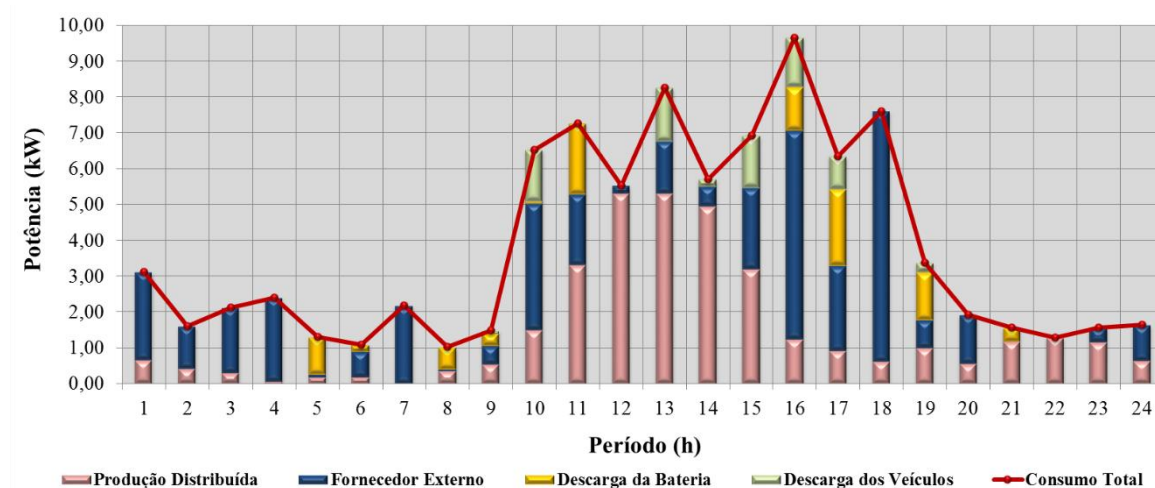


Figura 23 – Escalonamento de recursos ótimo da NDS-R no O-CIR

As percentagens de uso de cada recurso de produção, relativamente às soluções NDS-L e NDS-R, podem ser visualizadas na Figura 24 e na Figura 25. Nos resultados apresentados na Figura 24, referentes à solução NDS-L, a produção é dividida em: 42,58% para os fornecedores externos, 39,57% para a PD, 9,91% para a descarga da bateria e 7,95% para a descarga dos veículos. Nos resultados da Figura 25, referente à solução NDS-R, a produção está dividida em: 43,74% para os fornecedores externos, 38,24% para a PD, 10,15% para a descarga da bateria e 7,87% para a descarga dos veículos.




Figura 24 – Percentagem de uso dos recursos de produção da NDS-L no O-CIR

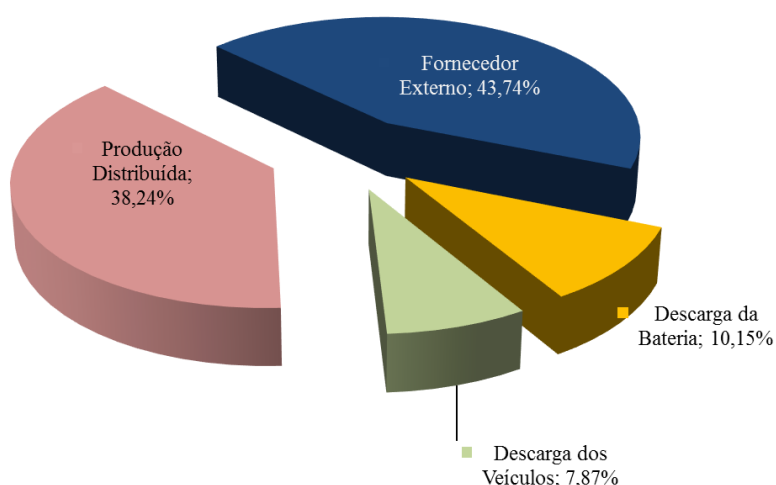


Figura 25 – Percentagem de uso dos recursos de produção da NDS-R no O-CIR

A Figura 26 e a Figura 27 apresentam os resultados obtidos para o consumo das soluções NDS-L e NDR-R, respetivamente. No escalonamento do consumo, os resultados obtidos nas duas soluções são muito idênticos. Os VEs são carregados maioritariamente nos períodos do final da tarde (16h–19h) de forma aos proprietários terem bateria suficiente para realizar a sua viagem de regresso a casa, após o término do seu horário de trabalho. Para além disso, o carregamento dos VEs é ainda realizado nos períodos de maior índice de produção da PD (11h-13h). A respeito do carregamento da bateria, este é realizado nos períodos em que o

edifício consegue comprar energia a um dos fornecedores externos por um preço mais baixo, correspondendo essencialmente a períodos noturnos (23h-4h), sendo o restante carregamento realizado nos períodos com maior produção de PD.




Figura 26 – Escalonamento do consumo da NDS-L no O-CIR




Figura 27 – Escalonamento do consumo da NDS-R no O-CIR

A Figura 28 e a Figura 29 apresentam as percentagens do escalonamento face ao consumo, para as soluções NDS-L e NDS-R. Nos resultados apresentados na Figura 28, referentes à solução NDS-L, o consumo é dividido em: 71,69% para a carga, 13,78% para o carregamento dos veículos e 14,52% para o carregamento da bateria. Nos resultados da Figura 29, referente à solução NDS-R, o consumo é dividido em: 71,88% para a carga, 13,76% para o carregamento dos veículos e 14,36% para o carregamento da bateria.




Figura 28 – Percentagem dos recursos de consumo da NDS-L no O-CIR

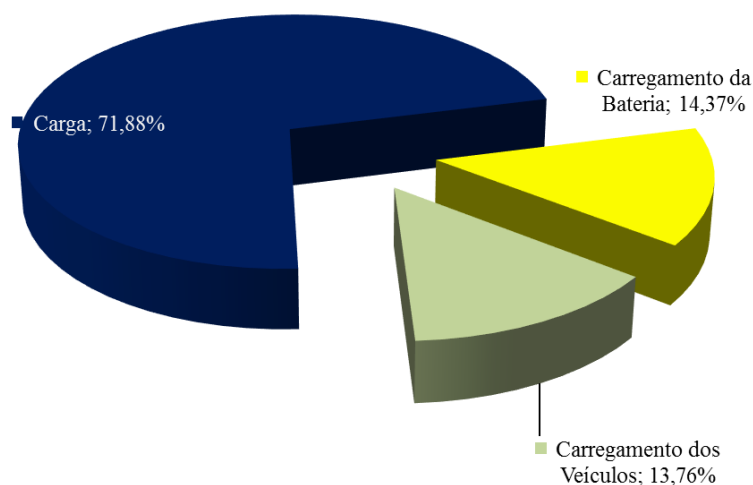


Figura 29 – Percentagem dos recursos de consumo da NDS-R no O-CIR

Neste teste (O-CIR) é possível verificar uma diferença entre as soluções NDS-L e NDS-R, em termos de lucro, de um valor de -5,727 m.u. (NDS-L) para um valor de -4,504 m.u.(NDS-R), representado uma variação de 21,34%. No que diz respeito às emissões de CO₂, na NDS-L obteve-se 4,728 kgCO₂, enquanto a NDL-R verificou-se um valor de 8,971 kgCO₂, representando um aumento de 89,74%. Estas diferenças devem-se essencialmente ao

escalonamento da energia proveniente de fornecedores externos, sendo que os valores de emissões têm uma maior variação que os valores de lucro.

A Tabela 10 apresenta uma comparação entre as soluções NDS-L e NDS-R, onde a última coluna apresenta a variação da solução NDS-R para a NDS-L.

Tabela 10 – Comparação entre a solução NDS-L e NDS-R do O-CIR

Tipo de Recurso	NDS-L (kWh)	NDS-R (kWh)	Variação (%)
Produção			
Fornecedor Externo	39,01	39,97	+2,46
Produção Distribuída	36,25	34,94	-3,61
Descarga de Veículos	7,28	7,19	-1,24
Descarga da Bateria	9,08	9,28	+2,20
Produção Total	91,62	91,38	-0,26
Consumo			
Carga	65,68	65,68	0,00
Carregamento de Veículos	12,63	12,57	-0,48
Carregamento da Bateria	13,30	13,13	-1,28
Consumo Total	91,62	91,38	-0,26

Realizando uma análise comparativa entre a solução NDS-L e NDS-R, pode-se concluir, como já tinha sido mencionado anteriormente, que as variações entre soluções são extremamente reduzidas. No que refere à energia proveniente dos fornecedores externos, é possível verificar um aumento de 2,46% na solução NDS-R. Quanto à PD, os resultados demonstram uma diminuição de 3,61% na NDS-R face à solução NDS-L, verificando-se diferentes perturbações de produção para ambos os testes. A descarga de veículos teve uma redução, em valores diminutos, de 1,24% na solução NDS-R, quando comparada à solução NDS-L. Na descarga da bateria (sistema de armazenamento) registou-se um aumento de 2,20% na solução NDS-R, comparativamente com a NDS-L. Em suma, houve uma ligeira diminuição de produção total de cerca de 0,26% na solução NDS-R face à solução NDS-L. Em relação ao consumo, verificou-se uma diminuição do uso de todas as variáveis na solução NDS-R. O carregamento de veículos e o carregamento da bateria tiveram uma diminuição de 0,48% e 1,28%, respetivamente, da solução NDS-L para a solução NDS-R.

Na Figura 30 é possível visualizar as frentes de Pareto obtidas no OR-CL e O-CIR. Realizando uma comparação entre o OR-CL e o O-CIR, ao usar uma abordagem em que se escolhe uma solução aleatória em detrimento da escolha do pior caso (solução robusta com pior lucro), é possível verificar desde logo, como era espectável, uma frente de *Pareto* onde as soluções são melhores quando comparadas com as soluções obtidas com a abordagem

robusta. Isto acontece porque, numa otimização robusta, as soluções obtidas na frente são as melhores soluções dentro soluções robustas encontradas, ou seja, as melhores das piores soluções, sendo estas soluções conservadoras. Nesta abordagem aleatória são obtidas as melhores soluções escolhidas aleatoriamente, o que do ponto de vista da modelação da incerteza, revela-se uma abordagem nada adversa ao risco, estando as soluções mais desprotegida das incertezas que afetam o problema. Na solução NDS-L, onde inicialmente o pior lucro era de -6,275 m.u. (OR-CL), nesta nova abordagem o pior lucro passou a ser de -5,727 m.u., representando uma melhoria percentual de 8,73%. Relativamente ao valor das emissões, registou-se uma variação de um valor mínimo de 5,053 kgCO₂ (OR-CL), para um valor de 4,728 kgCO₂, sendo a solução NDS-L do O-CIR cerca de 6,42% melhor. Na solução NDS-R, inicialmente no OR-CL o lucro máximo era de -5,487 m.u., obtendo-se um valor de -4.504 m.u no O-CIR, representando um melhoramento de 17,91%. Em relação ao valor das emissões, registou-se uma variação de um valor máximo de 7,999 kgCO₂ (OR-CL), para um valor de 8,971 kgCO₂ (O-CIR), representando uma solução 12,14% pior, no que diz respeito às emissões de CO₂. Em suma, pode-se concluir que com o uso de uma solução robusta estaremos a limitar o espaço de pesquisa, uma vez que apenas são consideradas as soluções que apresentam os piores lucros. Com uma abordagem aleatória foram encontradas melhores soluções, ou seja, soluções que conseguem apresentar um melhor lucro e ao mesmo tempo um menor valor de emissões de CO₂. Porém, as soluções obtidas não passam das melhores soluções aleatórias encontradas, representando uma abordagem pouco ortodoxa para efeitos da modelação da incerteza.

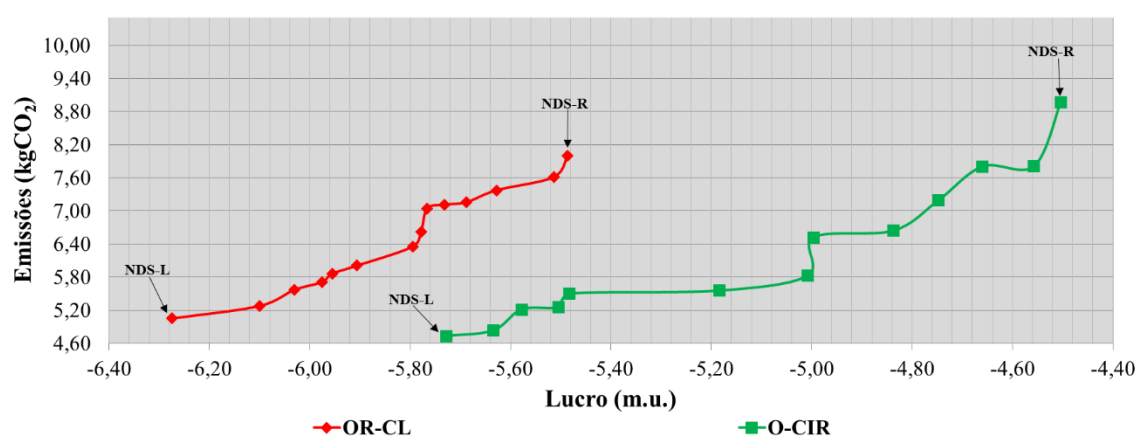


Figura 30 – Frentes de Pareto do O-CIR e OR-CL

Na Tabela 11 é possível ver detalhadamente uma comparação entre o escalonamento obtido para os recursos dos dois testes (OR-CL e O-CIR), onde as colunas com o termo “Variação” apresentam as variações das soluções (NDS-L e NDS-R) do O-CIR relativamente ao OR-CL. Fazendo uma análise comparativa entre os resultados do escalonamento de recursos dos dois testes realizados, pode-se verificar que na solução NDS-L do O-CIR, a energia proveniente dos fornecedores externos é superior, cerca de 3,37%, comparativamente com o OR-CL. A PD teve um aumento de 8,70% no O-CIR, quando comparada ao OR-CL. No caso em concreto da solução robusta (OR-CL), a amostragem com perturbação usada como solução da produção de PD revela índices de produção menores, quando comparado ao O-CIR. A descarga de veículos teve uma diminuição de 13,33% no O-CIR, comparativamente com o OR-CL. Por consequente a descarga da bateria tem um aumento de 12,1% no O-CIR. No somatório final é possível verificar um aumento da produção total de cerca de 4,59% na solução NDS-L do O-CIR face à solução NDS-L do OR-CL. A solução do O-CIR tem um lucro melhor comparativamente à solução do OR-CL, justificado pela menor utilização da descarga de veículos, que por sua vez permite a diminuição dos custos. Para suportar o consumo total, o O-CIR substitui a quantidade de energia proveniente da descarga de veículos resultante no OR-CL, pela descarga da bateria, retratando-se de um recurso sem encargos para o edifício. A maior utilização da descarga da bateria no O-CIR é possibilitada essencialmente pelo aumento que se verificou a nível da PD. Em relação às emissões de CO₂, os menores níveis verificados no O-CIR são justificados essencialmente pelo escalonamento de fornecedores externos com menor índices de emissões, quando comparados aos fornecedores escalonados na solução do OR-CL. Em relação ao consumo, o carregamento de veículos apresenta um aumento de 12,63% no O-CIR, quando comparado ao registado no OR-CL. Este aumento irá incrementar o valor da receita total do edifício, representando um outro recurso que permitiu a obtenção de melhor solução, em termos de lucro, no O-CIR. O maior aumento verificou-se no carregamento de baterias, aumento de cerca de 13,13%, na solução do O-CIR, justificado por uma maior utilização desta unidade para efeitos de descarga. No que diz respeito à solução NDS-R, fazendo uma comparação entre o O-CIR e o OR-CL, a energia proveniente dos fornecedores externos é 5,85% superior no O-CIR. Uma vez mais a PD teve um aumento de 3,07% no O-CIR, comparativamente com o OR-CL. Na descarga da bateria houve um aumento de 18,82% na solução NDS-R do O-CIR. Com o aumento da descarga da bateria, registou-se consequentemente uma diminuição na descarga de veículos do OR-CL para o O-CIR de 8,64%. No somatório final é possível verificar um

aumento da produção total de cerca de 4,63% na solução NDS-R do O-CIR face à solução NDS-R do OR-CL. Uma vez mais é possível identificar que a solução do O-CIR tem um lucro melhor comparativamente à solução do OR-CL. Uma vez que a descarga de veículos é menos utilizada no O-CIR, o custo pago para usar este recurso por sua vez também é reduzido. Por outro lado, a diminuição da descarga de veículos e o aumento da solicitação de energia aos fornecedores externos faz com que as emissões de CO₂ registadas na solução NDS-R do O-CIR sejam superiores às emissões do OR-CL. No que se refere ao consumo, verificou-se um aumento no carregamento de veículos num valor de 12,74% da NDS-R do O-CIR para a NDS-R do OR-CL. O valor do carregamento das baterias teve um aumento no O-CIR de 24,93%, isto comparativamente com a solução NDS-R do OR-CL.

Tabela 11 – Comparação entre as soluções do O-CIR e do OR-CL

Tipo de Recurso	NDS-L			NDS-R		
	OR-CL (kWh)	O-CIR (kWh)	Variação (%)	OR-CL (kWh)	O-CIR (kWh)	Variação (%)
Produção						
Fornecedor Externo	37,74	39,01	+3,37	37,76	39,97	+5,85
Produção Distribuída	33,35	36,25	+8,70	33,90	34,94	+3,07
Descarga de Veículos	8,40	7,28	-13,33	7,87	7,19	-8,64
Descarga da Bateria	8,10	9,08	+12,10	7,81	9,28	+18,82
Produção Total	87,60	91,62	+4,59	87,34	91,38	+4,63
Consumo						
Carga	65,68	65,68	0,00	65,68	65,68	0,00
Carregamento de Veículos	11,00	12,63	+14,82	11,15	12,57	+12,74
Carregamento da Bateria	10,91	13,13	+20,35	10,51	13,13	+24,93
Consumo Total	87,60	91,62	+4,59	87,34	91,38	+4,63

4.4.3. OTIMIZAÇÃO ROBUSTA – CRITÉRIO DAS EMISSÕES DE CO₂

Neste OR-CE é pressuposto que o objetivo para qual o utilizador pretende dar maior relevância é o critério das emissões de CO₂, logo o algoritmo na fase de avaliação da solução robusta irá selecionar, em vez da solução com pior lucro, uma solução que apresenta o pior valor de emissões de CO₂. Para este teste são considerados uma vez mais os recursos energéticos referenciados no OR-CL.

A Figura 31 apresenta a frente de *Pareto* resultante na meta-heurística MOPSO. Os marcadores da figura representam cada NDS obtida no repositório do MOPSO. Os marcadores NDS-L e NDS-R representam os extremos das NDSs, sendo a NDS-L a solução com menor emissões de CO₂, e a NDS-R a solução com maior lucro. O repositório final é composto por um total de 8 NDSs, sendo que o lucro tem uma variação entre os -5,699 m.u. e os -4,633 m.u., enquanto os valores de emissão têm uma variação entre 7,636 kgCO₂ e os 9,856 kgCO₂. A Tabela 12 apresenta os resultados das soluções NDS-L e NDS-R obtidas na frente de *Pareto*.

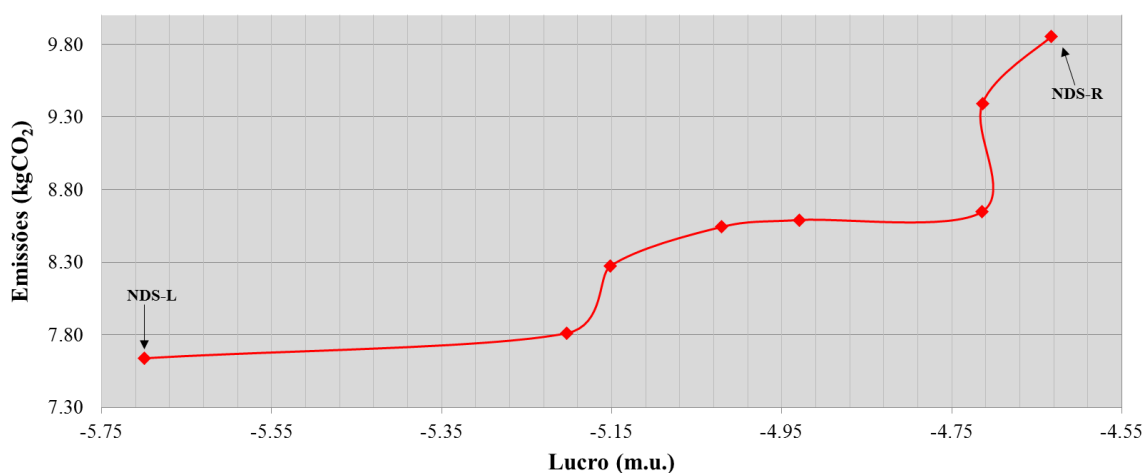


Figura 31 – Frente de *Pareto* do OR-CE

Tabela 12 – Soluções não dominadas selecionadas do OR-CE

Solução	NDS-L	NDS-R
Lucro (m.u.)	-5,699	-4,633
Emissões (kgCO ₂)	7,636	9,856

A Figura 32 e a Figura 33 apresentam os resultados obtidos para o escalonamento de recursos de energia das soluções NDS-L e NDR-R, respetivamente. Na solução NDS-R podemos verificar um valor superior de emissões de CO₂, quando comparado ao valor das emissões resultante na NDS-L. Este acontecimento é justificado por uma utilização mais acentuada da descarga dos VEs na solução NDS-L. O uso deste recurso irá reduzir as necessidades de comprar energia aos fornecedores externos, estes que são os responsáveis diretos pelas emissões de CO₂. Por outro lado, o uso da descarga de veículos tem um custo mais elevado, quando comparado ao preço da energia comprada aos fornecedores externos, daí que a solução NDS-R tenha um lucro superior, quando comparada com a solução NDS-L. A

descarga do sistema de armazenamento é um recurso usado em ambas as soluções, uma vez que representa um recurso que não implica qualquer custo para o edifício, pois as baterias são consideradas propriedade do mesmo. A descarga de veículos também é usada em ambas as soluções, contudo, contrariamente à descarga de baterias, este recurso implica um custo para o edifício. Posto isto, é possível verificar que a descarga de baterias, dentro dos recursos controláveis, e excluindo os fornecedores externos, é o recurso mais usado. O seu principal objetivo é alimentar o consumo, diminuindo as necessidades de energia proveniente dos fornecedores externos, causando uma diminuição direta das emissões de CO₂. Os principais recursos responsáveis pelas as diferenças registadas entre as soluções obtidas (NDS-L e NDS-R) são: o fornecedor externo escalonado para cada período, uma vez que existem quatro fornecedores com preços e emissões diferentes, e a descargas dos VEs e da bateria




Figura 32 – Escalonamento de recursos ótimo da NDS-L no OR-CE




Figura 33 – Escalonamento de recursos ótimo da NDS-R no OR-CE

As percentagens de uso de cada recurso de produção, para as soluções NDS-L e NDS-R, podem ser visualizadas na Figura 34 e na Figura 35. Nos resultados apresentados na Figura 34, referentes à solução NDS-L, a produção é dividida em: 45,20% para os fornecedores externos, 45,20% para a PD, 8,63% para a descarga da bateria, 8,63% para a descarga da bateria e 4,99% para a descarga dos veículos. Nos resultados da Figura 35, referente à solução NDS-R, a produção está dividida em: 47,04% para os fornecedores externos, 41,13% para a PD, 7,36% para a descarga da bateria e 4,13% para a descarga dos veículos.




Figura 34 – Percentagem de uso dos recursos de produção da NDS-L no OR-CE




Figura 35 – Percentagem de uso dos recursos de produção da NDS-R no OR-CE

A Figura 36 e a Figura 37 apresentam os resultados obtidos para o escalonamento do consumo das soluções NDS-L e NDR-R, respetivamente. Os resultados obtidos nas duas soluções são muito idênticos. Os VEs são carregados essencialmente nos períodos onde existe maior produção proveniente da PD (12h–13h). Para além disso, os VEs são ainda carregados no final da tarde, de forma aos proprietários dos veículos terem bateria suficiente para realizar a sua viagem de regresso a casa, após o término do seu horário de expediente. Relativamente ao carregamento da bateria, este é realizado nos períodos noturnos, uma vez que o preço da energia é mais barato. Um outro pico de carregamento da bateria é verificado no período das 14h, justificado pela elevada penetração da PD, mais precisamente, a produção fotovoltaica.




Figura 36 – Escalonamento do consumo da NDS-L no OR-CE




Figura 37 – Escalonamento do consumo da NDS-R no OR-CE

A Figura 38 e a Figura 39 apresentam as percentagens do escalonamento face ao consumo, para as soluções NDS-L e NDS-R. Nos resultados apresentados na Figura 38, referentes à solução NDS-L, o consumo é dividido em: 84,28% para a carga, 4,16% para o carregamento dos veículos e 11,56% para o carregamento da bateria. Nos resultados da Figura 39, referente à solução NDS-R, o consumo é dividido em: 79,08% para a carga, 7,77% para o carregamento dos veículos e 13,15% para o carregamento da bateria.




Figura 38 – Percentagem dos recursos de consumo da NDS-L no OR-CE




Figura 39 – Percentagem dos recursos de consumo da NDS-R no OR-CE

No OR-CE é possível verificar uma diferença entre a solução NDS-L e NDS-R, em termos de lucro, num valor de -5,699 m.u. (NDS-L) para um valor de -4,633 m.u., representado um incremento de 18,71%. Quanto às emissões de CO₂, na NDS-L obteve-se 7,636 kgCO₂, enquanto na NDL-R verifica-se um valor de 9,856 kgCO₂, representando um aumento de 29,07%. Estas diferenças devem-se a fatores como: as diferenças existentes na produção da PD; o escalonamento da descarga dos VEs e da bateria; e o escalonamento da energia proveniente de fornecedores externos. A PD representa um recurso que, para além de minimizar as emissões de CO₂, melhora o lucro. Uma vez que PD é considerada propriedade do edifício e a energia produzida é proveniente de fontes naturais, esta não implica qualquer tipo de custo para o edifício. Não obstante, como são de origem renovável não produzem qualquer tipo de emissões de CO₂. A descarga de veículos retrata um recurso que diminui as emissões de CO₂, no entanto, apresenta-se maioritariamente como um recurso mais caro, quando comparado com os preços aplicados pelos fornecedores externos, afetando negativamente o lucro. Com a existência de quatro fornecedores externos, onde cada um deles aplica diferentes tipos de tarifas de energia e valores de emissões de CO₂, estes apresentam-se como grandes influenciadores, tanto a nível da solução do lucro, como a nível das emissões, uma vez que representam um recurso com uma elevada penetração no edifício.

Realizando-se uma comparação direta entre as soluções NDS-L e NDS-R deste OR-CE, verifica-se que a energia proveniente dos fornecedores externos tem um aumento de 21,71% na solução NDS-R, quando comparada com a solução NDS-L. Relativamente à PD, os resultados mostram uma diminuição de 2,51% na NDS-R face à solução NDS-L, verificando-se diferentes previsões de produção para ambas as soluções. A descarga de veículos também teve uma diminuição de 9,21% na solução NDS-R. A descarga da bateria (sistema de armazenamento) teve uma diminuição de 11,83% na solução NDS-R. Em suma, houve um aumento na produção total em cerca de 6,57% na solução NDS-R face à solução NDS-L. Com esta comparação de resultados é possível verificar que a solução NDS-R teve um lucro melhor, comparativamente com a NDS-L, essencialmente devido à diminuição do uso da descarga de veículos. Por outro lado, esta solução obteve um pior valor de emissões, justificado por uma maior solicitação de energia proveniente dos fornecedores externos. Este aumento da energia solicitada a fornecedores externos é originado pela menor produção registada nas unidades de PD, e por um menor uso da descarga de veículos e da descarga da bateria, isto comparativamente com a solução NDS-L. No que diz respeito ao consumo, verificou-se um aumento em todos recursos na solução NDS-R. O carregamento de veículos

e o carregamento da bateria tiveram um aumento de 99,38% e 10,92%, respetivamente, na solução NDS-R, face à solução NDS-L. Estes resultados podem ser vistos de forma sumariada na Tabela 13, onde a última coluna apresenta a variação da solução NDS-R para a NDS-L.

Tabela 13 – Comparação entre a solução NDS-L e NDS-R do OR-CE

Tipo de Recurso	NDS-L (kWh)	NDS-R (kWh)	Variação (%)
Produção			
Fornecedor Externo	32,10	39,07	+21,71
Produção Distribuída	35,23	34,45	-2,21
Descarga de Veículos	3,89	3,43	-11,83
Descarga da Bateria	6,73	6,11	-9,21
Produção Total	77,94	83,06	+6,57
Consumo			
Carga	65,68	65,68	0,00
Carregamento de Veículos	3,24	6,46	+99,38
Carregamento da Bateria	9,01	10,92	+21,20
Consumo Total	77,94	83,06	+6,57

Na Figura 40 é possível visualizar as frentes de Pareto obtidas no OR-CL e OR-CE. Realizando uma comparação entre o OR-CL e o OR-CE, ao usar uma abordagem em que se escolhe uma solução com pior valor de emissões, em detrimento da escolha da solução com pior lucro, é possível verificar desde logo, como era espectável, uma frente de *Pareto* onde as soluções têm um valor superior, quer a nível do lucro, quer a nível do valor das emissões de CO₂. Isto acontece porque, na fase de seleção, são escolhidas as soluções com maior valor de emissões de CO₂, que por sua vez irão corresponder a soluções com um lucro melhor. Na solução NDS-L, onde inicialmente o pior lucro era de -6,275 m.u. (OR-CL), neste OR-CE o menor lucro passou a ser de -5,699 m.u., representando uma melhoria de 9,18% face ao valor de lucro obtido no OR-CL. A respeito do valor das emissões de CO₂, registou-se uma variação de um valor máximo de 5,063 kgCO₂ (OR-CL), para um valor de 7,636 kgCO₂ (OR-CE), sendo a solução NDS-L do OR-CL cerca de 50,82% melhor que a solução do OR-CE. Na solução NDS-R, o OR-CL tem como resultado um lucro de -5,487 m.u., enquanto o OR-CE obteve -4,633 m.u de lucro, representando uma melhoria de 15,56%. Quanto ao valor das emissões, registou-se uma variação de um valor mínimo de 7,999 kgCO₂ (OR-CL), para um valor de 9,856 kgCO₂ (OR-CE), representando uma solução 23,22 % pior, a nível das emissões de CO₂. Em suma, com o uso de uma otimização robusta estaremos a limitar o espaço de pesquisa, uma vez que no OR-CL apenas são consideradas as melhores soluções dentro das soluções com piores lucros, enquanto no OR-CE são consideradas as melhores

soluções dentro das soluções que apresentam as piores emissões. A junção de ambas as frentes de *Pareto* obtidas (OR-CL e OR-CE) permitem constituir um conjunto de soluções robustas com um gama de soluções bem mais alargada.




Figura 40 – Frentes de *Pareto* do OR-CE e OR-CL

Na Tabela 14 é possível ver detalhadamente uma comparação entre o escalonamento obtido para os recursos dos dois testes (OR-CL e OR-CE), onde as colunas com o termo “Variação” apresentam a variação das soluções do OR-CE relativamente ao OR-CL. Fazendo uma análise comparativa entre os recursos escalonados para os dois testes, na solução NDS-L, a energia proveniente dos fornecedores externos é 14,94% inferior no OR-CE, comparativamente com o OR-CL. Esta variação é devida essencialmente ao facto de a PD ser 5,64% superior no OR-CE, uma vez que quanto maior for o valor de energia produzida pela PD, menor será a necessidade de comprar energia aos fornecedores externos. No caso em concreto do OR-CL, a amostragem com perturbação usada como solução da produção de PD corresponde a uma solução com índices de produção menores, comparativamente com o OR-CE. Uma vez que a solução NDS-L do OR-CL tem uma maior necessidade de comprar energia aos fornecedores externos, o lucro desta solução é pior quando comparado à solução do OR-CE. A descarga de veículos no OR-CE tem uma diminuição de 53,69%, ou seja, mais de metade do registado na solução NDS-L do OR-CL. Este recurso vai influenciar o lucro, tornando-o pior na solução do OR-CL, sendo que os níveis de emissões são reduzidos simultaneamente. A descarga da bateria teve uma diminuição de 16,91% na solução do OR-CE. No somatório final é possível verificar uma diminuição da produção total de cerca de 11,03% na solução NDS-L do OR-CE face à solução NDS-L do OR-CL. No que diz respeito ao consumo, no carregamento de veículos verificou-se uma grande diminuição (70,55%) no

OR-CE, face à solução obtida no OR-CL, justificada pelo menor uso da descarga de veículos registada nesta solução. O carregamento de baterias teve um decréscimo de 17,42%, no OR-CE, quando comparado à solução NDS-L do OR-CL. Na solução NDS-R, fazendo uma comparação entre o OR-CE e o OR-CL, a energia proveniente dos fornecedores externos é 3,47% superior no OR-CE. A PD teve um aumento em 1,62% no OR-CE, comparativamente com o OR-CL. Na descarga de veículos do OR-CE registou-se uma diminuição de 56,42% face à solução do OR-CL. Pode-se então identificar este recurso como o principal influenciador das variações existentes, tanto a nível de lucro, como a nível de emissões de CO₂. Quanto maior é o uso da descarga de veículos, pior é o lucro, contudo, os níveis de emissões por sua vez são diminuídos, como é possível verificar na solução do OR-CL. Na descarga da bateria houve uma diminuição de 21,77% na solução NDS-R do OR-CE, comparativamente com a do OR-CL. No somatório final é possível verificar uma diminuição da produção total de cerca de 4,90% na solução NDS-R do OR-CE face à solução NDS-R do OR-CL. Em termos de consumo, no carregamento de veículos registou-se, uma vez mais justificado pelo maior valor da descarga de veículos na solução do OR-CL, uma diminuição no OR-CE de 42,06%. O valor do carregamento da bateria teve um aumento de 3,90% no OR-CE, em comparação ao valor atribuído na solução NDS-R do OR-CL.

Tabela 14 – Comparação entre as soluções do OR-CE e do OR-CL

Tipo de Recurso	NDS-L			NDS-R		
	OR-CL (kWh)	OR-CE (kWh)	Variação (%)	OR-CL (kWh)	OR-CE (kWh)	Variação (%)
Produção						
Fornecedor Externo	37,74	32,10	-14,94	37,76	39,07	+3,47
Produção Distribuída	33,35	35,23	+5,64	33,90	34,45	+1,62
Descarga de Veículos	8,40	3,89	-53,69	7,87	3,43	-56,42
Descarga da Bateria	8,10	6,73	-16,91	7,81	6,11	-21,77
Produção Total	87,60	77,94	-11,03	87,34	83,06	-4,90
Consumo						
Carga	65,68	65,68	0,00	65,68	65,68	0,00
Carregamento de Veículos	11,00	3,24	-70,55	11,15	6,46	-42,06
Carregamento da Bateria	10,91	9,01	-17,42	10,51	10,92	+3,90
Consumo Total	87,60	77,94	-11,03	87,34	83,06	-4,90

4.4.4. OTIMIZAÇÃO – SEM INCERTEZA

No O-SI não são consideradas as incertezas na produção eólica e fotovoltaica; ou seja, é considerada que a previsão para o dia seguinte é perfeita. É considerado exclusivamente um cenário representativo da previsão da produção da PD renovável para o dia seguinte. Sem a componente da incerteza não faz qualquer sentido utilizar uma modelização robusta, logo é considerado um MOPSO convencional neste teste. Para este O-SI são considerados os recursos energéticos presentes no OR-CL.

A Figura 41 apresenta a frente de *Pareto* obtida com a meta-heurística MOPSO. Os marcadores da figura representam cada NDS do repositório resultante do MOPSO. Os marcadores NDS-L e NDS-R representam os extremos das NDSs, sendo a NDS-L a solução com menor valor de emissões de CO₂, e a NDS-R a solução com maior valor de lucro. Como repositório final foram obtidas um total de 10 NDSs, sendo que o lucro tem uma variação entre os -6,644 m.u. e os -4,497 m.u., enquanto os valores de emissão têm uma variação entre 5,245 kgCO₂ e os 10,984 kgCO₂.

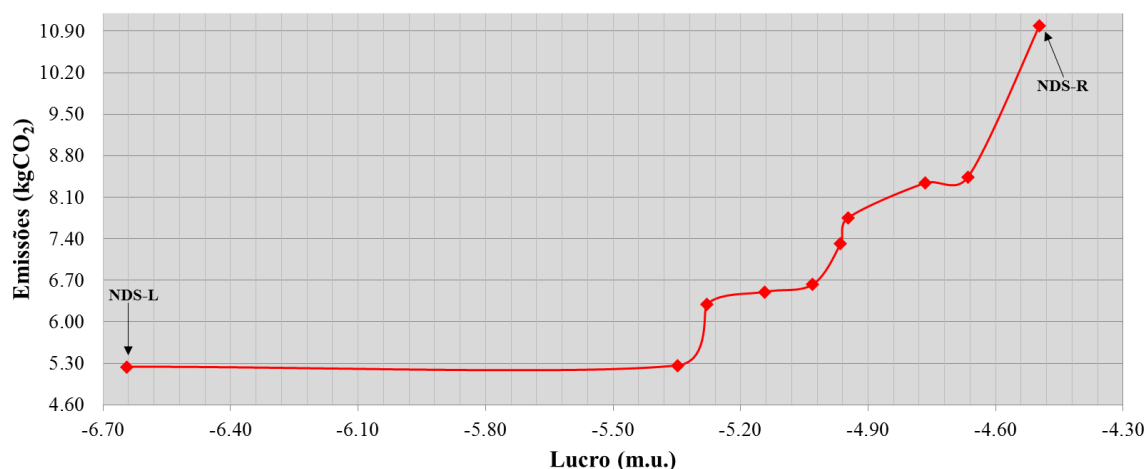


Figura 41 – Frente de *Pareto* do O-SI

A Tabela 15 apresenta os resultados das soluções NDS-L e NDS-R obtidas na frente de *Pareto*.

Tabela 15 – Soluções não dominadas selecionadas do O-SI

Solução	NDS-L	NDS-R
Lucro (m.u.)	-6,644	-4,497
Emissões (kgCO ₂)	5,241	10,984

A Figura 42 e a Figura 43 apresentam os resultados obtidos para o escalonamento de recursos de energia das soluções NDS-L e NDR-R, respetivamente.




Figura 42 – Escalonamento de recursos ótimo da NDS-L no O-SI




Figura 43 – Escalonamento de recursos ótimo da NDS-R no O-SI

Em ambas as soluções foram usadas a descarga de veículos e a descarga das baterias (sistema de armazenamento). Com a utilização destes recursos é minimizado o uso da energia proveniente dos fornecedores externos, reduzindo de forma direta as emissões de CO₂. A descarga de veículos apresenta uma percentagem de uso de maior relevo na solução NDS-L, permitindo uma redução nas emissões de CO₂. Em contrapartida o lucro tem tendência a piorar, uma vez que este recurso apresenta um custo maioritariamente mais elevado, quando comparado ao custo da energia proveniente da maioria dos fornecedores externos. Verifica-se uma grande utilização da descarga da bateria, isto uma vez que se trata de um recurso que

não implica qualquer custo para o edifício. Com a utilização de quatro diferentes tipos de fornecedores externos, pode-se concluir que as grandes variações do valor de lucro acontecem fundamentalmente devido ao fornecedor externo escalonado para os diferentes períodos. As percentagens de uso de cada recurso de produção, relativamente às soluções NDS-L e NDS-R, podem ser visualizadas na Figura 44 e Figura 45




Figura 44 – Percentagem de uso dos recursos de produção da NDS-L no O-SI




Figura 45 – Percentagem de uso dos recursos de produção da NDS-R no O-SI

Nos resultados apresentados na Figura 44, referentes à solução NDS-L, a produção é dividida em: 49,09% para os fornecedores externos, 36,71% para a PD, 4,74% para a descarga da bateria e 9,46% para a descarga dos veículos. Nos resultados da Figura 45, referente à solução NDS-R, a produção é dividida em: 48,85% para os fornecedores externos, 36,60% para a PD, 8,61% para a descarga da bateria e 5,94% para a descarga dos veículos.

A Figura 46 e Figura 47 apresentam os resultados obtidos para o escalonamento dos recursos de consumo das soluções NDS-L e NDR-R, respetivamente.




Figura 46 – Escalonamento do consumo da NDS-L no O-SI




Figura 47 – Escalonamento do consumo da NDS-R no O-SI

Para o escalonamento do consumo as soluções NDS-L e NDS-R são bastante idênticas. Uma vez que existe um grande uso da descarga de veículos, os VEs são carregados em diversos períodos, contudo a grande proporção de carregamento encontra-se alocada ao fim da tarde,

de forma aos proprietários dos veículos terem bateria suficiente para realizar a sua viagem de regresso a casa. Em relação ao carregamento da bateria, este é realizado nos períodos noturnos, uma vez que o preço da energia é mais barato, podendo-se ainda verificar uma grande taxa de carregamento no período entre as 11h-14h, onde a penetração da PD é mais elevada. As Figura 48 e a Figura 49 apresentam as percentagens do escalonamento dos recursos de consumo, para as soluções NDS-L e NDS-R.




Figura 48 – Percentagem dos recursos de consumo da NDS-L no O-SI




Figura 49 – Percentagem dos recursos de consumo da NDS-R no O-SI

Nos resultados apresentados na Figura 48, referentes à solução NDS-L, o consumo é dividido em: 71,16% para a carga, 15,25% para o carregamento dos veículos e 13,59% para o carregamento da bateria. Nos resultados da Figura 49, referente à solução NDS-R, o consumo é dividido em: 70,95% para a carga, 16,83% para o carregamento dos veículos e 12,22% para o carregamento da bateria.

Neste teste é possível verificar uma diferença entre a solução NDS-L e NDS-R, em termos de lucro, de um valor de -6,644 m.u. (NDS-L) para um valor de -4,497 m.u (NDS-R), representado um aumento de lucro de 32,31%. No que se refere às emissões de CO₂, na NDS-L obteve-se 5,241 kgCO₂, enquanto na NDL-R registou-se um valor de 10,984 kgCO₂, representando um aumento de 109,59%. Estas diferenças devem-se essencialmente ao escalonamento da energia proveniente dos fornecedores externos, bem como do uso da descarga de veículos.

A Tabela 16 apresenta uma comparação entre as soluções NDS-L e NDS-R, onde a última coluna apresenta a variação da solução NDS-R para a NDS-L.

Tabela 16 – Comparação entre a solução NDS-L e NDS-R do O-SI

Tipo de Recurso	NDS-L (kWh)	NDS-R (kWh)	Variação (%)
Produção			
Fornecedor Externo	45,32	45,22	-0,22
Produção Distribuída	33,88	33,88	0,00
Descarga de Veículos	8,73	5,50	-37,00
Descarga da Bateria	4,37	7,97	+82,38
Produção Total	92,30	92,57	+0,29
Consumo			
Carga	65,68	65,68	0,00
Carregamento de Veículos	14,08	15,58	+10,65
Carregamento da Bateria	12,54	11,31	-9,81
Consumo Total	92,30	92,57	+0,29

Numa análise comparativa, pode-se verificar que em ambas as soluções a energia proveniente dos fornecedores externos têm resultados praticamente similares, havendo uma ligeira diminuição de 0,22% da NDS-L para a NDS-R. Relativamente à PD, os resultados obtido obviamente que são os para as duas soluções, uma vez que não foi considerada a incerteza, logo é usado um único cenário representativo da produção durante todo o processo do algoritmo, que neste caso consiste na previsão de produção para o dia seguinte (ver subsecção 4.2, Figura 7). A descarga de veículos apresenta uma diminuição de 37,00% na solução NDS-R. O facto de a solução NDS-R apresentar um lucro melhor justifica essa

diminuição na descarga de veículos, uma vez que para atingir um maior lucro foi necessário realizar uma redução do pagamento de incentivos para o uso deste recurso. A descarga da bateria teve um aumento de 82,38% na solução NDS-R, comparativamente com a NDS-L. Em suma, houve um ligeiro aumento na produção total de cerca de 0,29% na solução NDS-R face à solução NDS-L. Quanto ao consumo, verificou-se um aumento do carregamento de veículos em 10,65% na solução NDS-R. Por consequente, o carregamento da bateria teve, na solução NDS-R, uma diminuição de 9,81%, quando comparada à solução NDS-L.

Na Figura 50 é possível visualizar as frentes de Pareto obtidas no OR-CL e O-SI. Realizando uma comparação entre os dois testes, ao usar uma abordagem sem considerar as incertezas em detrimento da abordagem robusta, é possível verificar desde logo, como era espectável, uma frente de *Pareto* onde as soluções são melhores quando comparadas com as soluções do OR-CL. Para além disso, o espectro de soluções obtidas na abordagem do O-SI é bem mais alargado, comparativamente à frente de *Pareto* obtida no OR-CL. Na otimização robusta as soluções obtidas na frente são as melhores soluções dentro soluções robustas encontradas, ou seja, as melhores das piores soluções, logo o espectro de soluções encontradas é bem mais limitado, uma vez que as soluções robustas apresentadas no OR-CL são as melhores dentro das soluções com pior lucro, logo são descartadas muitas soluções com lucros melhores.




Figura 50 – Frentes de *Pareto* do O-SI e OR-CL

Na solução NDS-L, onde inicialmente o pior lucro era de -6,275 m.u. (OR-CL), nesta nova abordagem o pior lucro passou a ser de -6,644 m.u. (O-SI), representando um lucro 5,73% pior que lucro resultante no OR-CL. Em relação ao valor das emissões, registou-se uma variação de um valor mínimo de 5,053 kgCO₂ (OR-CL), para um valor de 5,241 kgCO₂ (O-

SI), sendo a solução NDS-L do O-SI cerca de 3,72% pior, em termos de emissões de CO₂. Nesta solução NDS-L podemos concluir que a abordagem robusta encontrou uma solução capaz de obter um nível de emissões mais reduzido (-3,72%), bem como um valor de lucro superior (+5,73%), isto comparativamente com a solução NDS-L do O-SI, onde não foram consideradas incertezas. Na solução NDS-R, inicialmente o lucro máximo no OR-CL era de -5,487 m.u., sendo obtido um valor de -4.497 m.u no O-SI, representando um melhoramento de 18,03%. No que diz respeito ao valor das emissões, registou-se uma variação de um valor máximo de 7,999 kgCO₂ (OR-CL), para um valor de 10,984 kgCO₂ (O-SI), representando uma solução 37,31% pior, em termos de emissões de CO₂. Em suma, pode-se concluir que com o uso de uma solução robusta (OR-CL) estaremos a limitar o espaço de pesquisa, uma vez que apenas são consideradas as soluções que apresentam os piores lucros. A frente de *Pareto* obtida com a abordagem sem robustez (O-SI) apresente uma maior gama de soluções, e soluções maioritariamente melhores, ou seja, soluções que conseguem apresentar um melhor lucro e ao mesmo tempo um menor valor de emissões de CO₂, contudo estas soluções não estão protegidas da incerteza. A produção da energia eólica e fotovoltaica pode mudar significativamente após a otimização ser realizada, pondo em causa a solução do escalonamento obtido, sendo que com o uso de um modelo robusto esse risco é diminuído. Perante uma otimização feita para o dia seguinte que não modele eficazmente a incerteza, a produção real no próprio dia poderá ser pior que a prevista, obrigando á realização de um reescalonamento em tempo real, o que levaria a penalizações e custos excessivos para cumprir determinadas restrições. Outro aspeto a salientar, é que apesar de esta abordagem do O-SI apresentar melhores soluções, a abordagem robusta (OR-CL) obteve uma melhor solução extremo (NDS-L), comprovando que, numa abordagem onde não são consideradas as incertezas, as soluções são extremamente limitadas.

Numa comparação entre estes dois testes (OR-CL e O-SI), pode-se verificar que para a solução NDS-L do O-SI, a energia proveniente dos fornecedores externos é bastante superior, cerca de 20,08%, comparativamente com o OR-CL. A PD teve um aumento de 1,59% no O-SI. A descarga de veículos teve um aumento de 3,93% no O-SI, comparativamente com o OR-CL. A descarga da bateria teve uma diminuição de 46,05% na solução NDS-L do O-SI, quando comparada ao OR-CL. No somatório final é possível verificar um aumento da produção total de cerca de 5,37% na solução NDS-L do O-SI face à solução NDS-L do OR-CL. O melhor lucro verificado na solução do OR-CL, quando comparado ao lucro obtido na solução do O-SI, é justificado pela menor utilização da

descarga de veículos, mas também essencialmente pela menor utilização dos fornecedores externos. A forte diminuição da utilização de energia proveniente dos fornecedores externos para além de diminuir os custos (aumentando o lucro), provoca uma grande diminuição dos valores de emissões de CO₂, tornando a solução NDS-L do OR-CL melhor que a solução NDS-L do O-SI. Para suportar o consumo total, o OR-CL substitui a quantidade de energia proveniente dos fornecedores externos (O-SI) pela descarga da bateria, retratando-se de um recurso sem encargos para o edifício e sem emissões. Em relação ao consumo, o carregamento de veículos apresenta um aumento de 28,00% no O-SI, devido a uma maior utilização deste recurso para efeitos de descarga. O carregamento da bateria teve um aumento de cerca de 14,94% na solução do O-SI, este aumento que acontece perante uma maior produção de PD registada. Quanto à solução NDS-R, fazendo uma comparação entre o O-SI e o OR-CL, a energia proveniente dos fornecedores externos é 19,76% superior no O-SI. A PD teve uma diminuição de 0,06% no O-SI, comparativamente com o OR-CL, comprovando que no OR-CL a amostragem com perturbação usada como solução de previsão da produção de PD corresponderá a uma solução com um maior índice de produção. Na descarga da bateria houve um aumento de 2,05% na solução NDS-R do O-SI, comparativamente com a solução do OR-CL. Com o aumento da descarga da bateria, registou-se consequentemente uma diminuição na descarga de veículos do OR-CL para o O-SI de 30,11%. No somatório final é possível verificar um aumento da produção total de cerca de 5,99% na solução NDS-R do O-SI face à solução NDS-R do OR-CL. É possível concluir que a solução NDS-R do O-SI tem um lucro melhor, quando comparada à solução do OR-CL, fundamentado por uma menor utilização da descarga de veículos, permitindo que os custos sejam diminuídos. Por outro lado, a diminuição da descarga de veículos e o aumento da energia solicitada aos fornecedores externos resultam em emissões mais elevadas na solução NDS-R do O-SI, comparativamente aos valores registados na solução do OR-CL. Em relação de consumo, verificou-se um aumento de 39,73% no carregamento de veículos da NDS-R do O-SI para a NDS-R do OR-CL. Por sua vez, o valor do carregamento das baterias também teve um aumento de 7,61% no O-SI. Toda a informação dos resultados referenciados anteriormente pode ser analisada na Tabela 17, onde é possível ver detalhadamente uma comparação entre o escalonamento obtido para os recursos do teste OR-CL e o O-SI, onde as colunas com o termo “Variação” apresentam a variação percentual, para os diferentes tipos de recurso, da solução NDS-L do O-SI face ao OR-CL (1º coluna

com o termo “Variação”) e da solução NDS-R do O-SI face ao OR-CL (2ª coluna com o termo “Variação”).

Tabela 17 – Comparação entre as soluções do O-SI e o OR-CL

Tipo de Recurso	NDS-L			NDS-R		
	OR-CL (kWh)	O-SI (kWh)	Variação (%)	OR-CL (kWh)	O-SI (kWh)	Variação (%)
Produção						
Fornecedor Externo	37,74	45,32	+20,08	37,76	45,22	+19,76
Produção Distribuída	33,35	33,88	+1,59	33,90	33,88	-0,06
Descarga de Veículos	8,40	8,73	+3,93	7,87	5,50	-30,11
Descarga da Bateria	8,10	4,37	-46,05	7,81	7,97	+2,05
Produção Total	87,60	92,30	+5,37	87,34	92,57	+5,99
Consumo						
Carga	65,68	65,68	0,00	65,68	65,68	0,00
Carregamento de Veículos	11,00	14,08	+28,00	11,15	15,58	+39,73
Carregamento da Bateria	10,91	12,54	+14,94	10,51	11,31	+7,61
Consumo Total	87,60	92,30	+5,37	87,34	92,57	+5,99

4.4.5. COMPARAÇÃO DE TESTES

Nesta última subsecção é apresentada uma comparação dos resultados obtidos para todos os testes analisados anteriormente e as considerações finais para este caso de estudo. A Figura 51 apresenta as várias frentes de Pareto obtidas para os diferentes testes (OR-CL, O-CIR, OR-CE e O-SI).

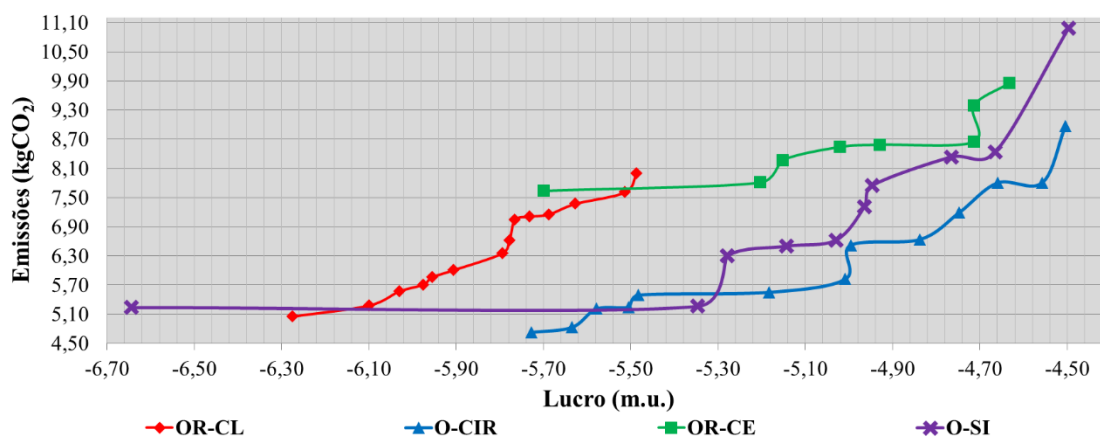


Figura 51 – Frentes de Pareto obtidas para todos os testes

É possível verificar que a frente que obteve um melhor conjunto de soluções foi a frente de *Pareto* do O-CIR, porém, as soluções obtidas não passam das melhores soluções aleatórias encontradas, representando uma abordagem pouco ortodoxa para efeitos da modelação da incerteza. Esta abordagem apresenta melhores resultados que as abordagens robustas (OR-CL e OR-CE) pois o espaço de pesquisa não fica limitado às melhores das piores soluções encontradas. Nesta abordagem aleatória são obtidas as melhores soluções escolhidas aleatoriamente, o que do ponto de vista da modelação da incerteza, revela-se uma abordagem nada adversa ao risco, estando as soluções mais desprotegida das incertezas que afetam o problema. A frente obtida pela abordagem que não considera a incerteza (O-SI) revela-se também maioritariamente melhor que as frentes das abordagens robustas. Todavia, estas soluções não estão protegidas da incerteza. Perante uma otimização feita para o dia seguinte que não modele eficazmente a incerteza, a produção real no próprio dia poderá ser pior que a prevista, obrigando á realização de um reescalonamento em tempo real, o que levaria a penalizações e custos excessivos para cumprir determinadas restrições. A frente do (O-SI), quando comparada com a frente na abordagem aleatória que considera incertezas (O-CIR), apresenta resultados maioritariamente piores. Isto deve-se ao facto de nas soluções do O-SI a previsão de produção PD considerada, ser sempre a mesma amostra para todas as soluções, não considerando deste modo o erro de previsão da produção, que como se pode verificar nas soluções do O-CIR, vão limitar de forma acentuada as soluções. Em suma, nenhuma das abordagens permite uma frente com soluções 100% certas de acontecimento, ou seja, sem incerteza no resultado. Contudo, com a abordagem robusta existe uma modelação da incerteza, permitindo abordar o problema de uma forma mais cautelosa e preparando o escalonamento dos recursos para o dia seguinte de uma forma mais adversa ao risco.

A Tabela 18 apresenta as soluções NDS-L e NDS-R obtidas para os quatro testes, e o tempo de execução para a abordagem de cada teste. É possível verificar que a abordagem que conseguiu encontrar um melhor lucro (solução NDS-R) foi a abordagem que não considerou a incerteza (O-SI), com um lucro de -4,497. Por outro lado, a abordagem que encontrou a solução com menores níveis de emissão de CO₂ foi a abordagem aleatória que considera incertezas (O-CIR), com um total de emissões de 4,728 kgCO₂. A maior diferença entre a NDS-R e NDS-L, para as emissões de CO₂, foi obtida na abordagem sem incerteza (O-SI), com uma diferença de 5,743 kgCO₂, enquanto a menor diferença foi alcançada na abordagem robusta que da mais relevância ao critério das emissões de CO₂ (OR-CE). No que se refere ao lucro, a maior diferença registou-se uma vez mais na abordagem do O-SI, com uma

diferença de 2,147 m.u., enquanto a menor diferença foi alcançada na abordagem robusta que dá maior relevância ao critério dos lucros (OR-CL). Como era espectável, a frente de *Pareto* com a abordagem robusta do OR-CL tem um menor espectro de soluções, a nível de lucro, uma vez que são selecionados piores lucros na fase de seleção. Por outro lado, a frente robusta do OR-CE tende a ter um menor espectro de soluções, a nível dos valores de emissões de CO₂, pois são selecionadas as soluções com pior valor de emissões de CO₂. Em relação ao tempo de execução, a realidade é que com a adição da componente da incerteza (diferentes cenários de produção) o tempo de processamento do algoritmo aumenta exponencialmente, devido ao facto de originar um incremento ao número de vezes que as soluções passam a ser avaliadas. Pode-se concluir que quanto maior for o número de cenários de produção considerados, maior será o tempo de execução do algoritmo.

Tabela 18 – Soluções NDS-L e NDS-R e tempo de execução para todos os testes

Teste	OR-CL		O-CIR		OR-CE		O-SI	
	NDS-L	NDS-R	NDS-L	NDS-R	NDS-L	NDS-R	NDS-L	NDS-R
Lucro (m.u.)	-6,275	-5,487	-5,727	-4,504	-5,699	-4,633	-6,644	-4,497
Emissões (kgCO ₂)	5,053	7,999	4,728	8,971	7,636	9,856	5,241	10,984
Tempo (s)	1775,711		1959,909		1849,314		239,418	

4.5. VERIFICAÇÃO DA VARIABILIDADE DO MÉTODO

Para confirmar a validade da meta-heurística desenvolvida (MOPSO), foi realizada uma verificação do grau de variabilidade do método. Esta avaliação é necessária pois sempre que se executa o algoritmo são obtidas soluções ligeiramente diferentes, isto devido a se tratar de um método de pesquisa não exata (aleatoriedade existente nos processos de pesquisa), logo através deste teste é possível verificar a credibilidade das soluções obtidas pelo algoritmo. Cada algoritmo foi executado 10 vezes (10 frentes de *Pareto*), com o intuito de confirmar se a variabilidade dos resultados obtidos é baixa. A Figura 52 apresenta as frentes de *Pareto*, em duas perspetivas diferentes: a) em 3D e b) em 2D, obtidas pelo método de otimização robusta apresentado no OR-CL (critério do lucro). Neste teste da variabilidade do método são demonstrados os resultados obtidos para o OR-CL, uma vez que esta abordagem utiliza o conceito de otimização robusta para modelar a incerteza, que neste caso representa a grande contribuição desta dissertação. Para além disso, foram os resultados obtidos neste OR-CL que serviram de comparação com os restantes testes (O-CIR, OR-CE e O-SI).

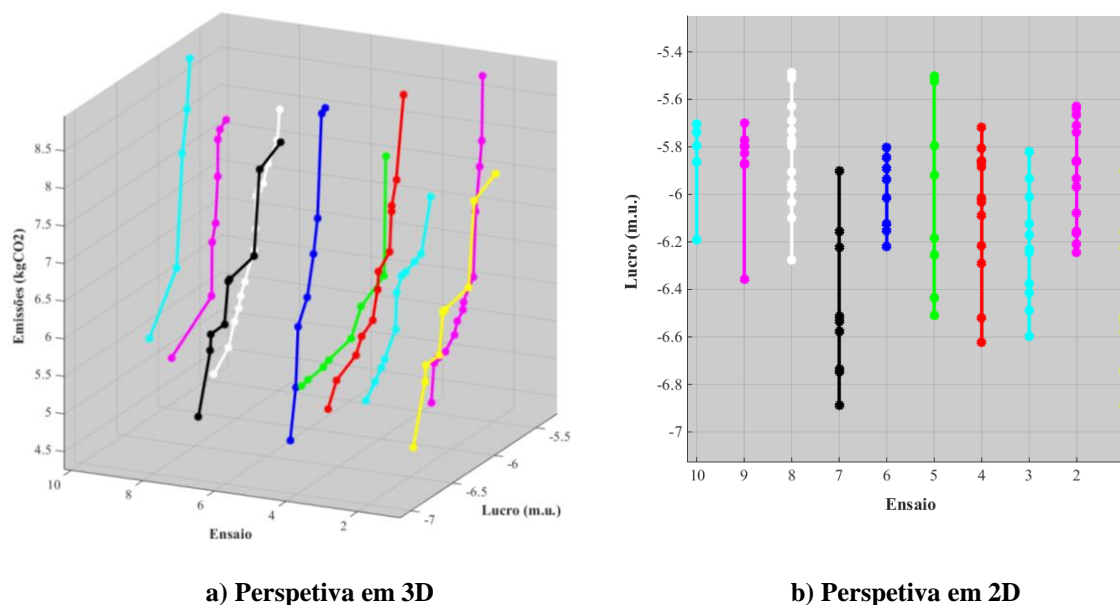


Figura 52 – Variabilidade da frente de *Pareto* obtida no método do OR-CL

A Tabela 19 apresenta os desvios padrão e os valores médios obtidos para as duas soluções limite das frentes de *Pareto* (NDS-L e NDS-R), para o lucro e para as emissões. Para além disso, pode-se ainda verificar o valor do erro percentual absoluto médio²⁶ (MAPE) entre as soluções limites. Ao analisar os resultados obtidos é possível verificar que na solução NDS-L existe uma variabilidade de 3,42% e 3,90%, para o lucro e as emissões, respetivamente. Para a solução NDS-R, verifica-se uma variabilidade de 3,19% e 6,14%, para o lucro e as emissões, respetivamente. Pode-se então concluir que os resultados apresentam um grau de variabilidade moderadamente aceitável, isto tendo em conta, não só o a natureza estocástica do MOPSO, mas também o facto de ser considerado um problema multiobjectivo e, ao mesmo tempo a incerteza na produção fotovoltaica e eólica. Como é descrito na secção 4.4.1, o algoritmo opta em cada período por selecionar um fornecedor externo de uma forma aleatória, sendo este mais um fator que provoca uma maior variabilidade do método. Existem vários fatores que poderiam influenciar diretamente a variabilidade do método, como por exemplo, realizar um aumento do número de iterações, não realizar a seleção do fornecedor externo de forma aleatória, considerar menos perturbações na produção, contudo todos

²⁶ Mean Absolute Percentage Error (MAPE), na designação anglo-saxónica.

levariam a um degradingamento da performance do algoritmo. Ao aumentar-se o número de iterações, o tempo de execução do método irá aumentar exponencialmente, sendo necessário promover uma otimização ao código do algoritmo. Se a seleção do fornecedor externo consistir sempre no que apresenta menor preço de energia, o espaço de pesquisa de soluções seria extremamente reduzido, uma vez que não seriam escalonados fornecedores com menores níveis de emissões, caso estes apresentassem um preço de energia mais elevado. Ao considerar-se um menor número de perturbações, estaríamos a testar uma menor gama de incerteza, logo esta não seria modelada corretamente. Em suma, tendo em conta que os valores percentuais de variabilidade foram minimamente satisfatórios, não foi realizado qualquer alteração face aos parâmetros iniciais de execução do algoritmo.

Tabela 19 – Métricas para a medição da variabilidade do MOPSO

Solução		Desvio Padrão	Média	MAPE (%)
Lucro (m.u.)	NDS-L	0,266	-6,480	3,417
	NDS-R	0,296	-5,777	3,186
Emissões (kgCO ₂)	NDS-L	0,307	5,066	3,897
	NDS-R	0,676	7,959	6,135

4.6. COMPARAÇÃO DE MÉTODOS

Nesta subsecção foi realizada uma comparação de performance entre a otimização robusta implementada no MOPSO e a programação estocástica implementada em TOMLAB [1], que é uma ferramenta de otimização avançada para MATLAB [1], usando CPLEX *solver*. É importante referenciar que para este teste considerou-se o mesmo caso de estudo usado em todas as abordagens anteriormente descritas. Devido a algumas limitações na implementação de variáveis não lineares no CPLEX, não foi possível a implementação do programa de DR desenvolvido na metodologia apresentada neste trabalho, ou seja, não foram considerados na função objetivo o custo do preço diário da potência de pico ($C_{peakPower}$), nem o incentivo para a minimizar ($r_{peakPower}$). Deste modo, para uma análise entre métodos justa, o MOPSO e o CPLEX foram testados sem a inserção destes programas de DR na função objetivo.

Para a abordagem estocástica, resolvida em CPLEX, foram apenas geradas 2000 amostras diferentes de produção de eólica e vento (usando o valor de erro de previsão de 15%) uma vez que, a nível de processamento computacional, este programa é bastante mais pesado, devido ao facto de utilizar uma abordagem determinística baseada no *Branch-and-Cut*. O

número de cenários avaliados por esta abordagem é bastante mais reduzido (2000 cenários), quando comparado aos 200 000 cenários de produção considerados pela otimização robusta.

A Figura 53 apresenta as duas frentes de *Pareto* obtidas para a otimização robusta (MOPSO com o critério do lucro) e a programação estocástica (CPLEX).




Figura 53 – Frentes de *Pareto* obtidas para a abordagem robusta e estocástica

Realizando uma comparação entre a otimização robusta (critério do lucro) e a programação estocástica, é possível verificar desde logo, como era espectável, uma frente de *Pareto* onde as soluções da programação estocástica são relativamente melhores, quando comparadas com as soluções da otimização robusta, sendo que o espectro de soluções obtidas nesta abordagem estocástica também é bem mais amplo. Na otimização robusta as soluções obtidas na frente de *Pareto* são as melhores soluções dentro das soluções robustas encontradas, ou seja, as melhores soluções dentro das piores soluções de lucro (soluções robustas). Nesta abordagem são descartadas muitas soluções com melhores lucros, que correspondem a soluções com níveis de emissões superiores, justificando então a obtenção de uma frente de *Pareto* pior que a obtida através da programação estocástica.

A Tabela 20 apresenta as soluções NDS-L e NDS-R obtidas e o tempo de execução para ambas as programações, robusta e estocástica. Na solução NDS-L, a otimização robusta obteve um lucro de -4,793 m.u., enquanto a abordagem estocástica teve um lucro de -6,712 m.u., representando um lucro 40,04% pior. Quanto ao valor das emissões, registou-se uma variação de um valor mínimo de 2,299 kgCO₂ (robusta), para um valor de 1,058 kgCO₂ (estocástica), sendo a solução NDS-L da programação estocástica cerca de 53,98% melhor,

a nível das emissões de CO₂. Nesta solução NDS-L podemos concluir que a abordagem robusta encontrou uma solução capaz de obter um nível de lucro 40,04% melhor. Não obstante, essa mesma solução é 53,98% pior, isto relativamente aos níveis de emissão de CO₂. Esta solução revela-se melhor no caso do operador do edifício pretender dar mais relevância à obtenção do melhor lucro. Na solução NDS-R, na otimização robusta o lucro máximo foi de -2,973 m.u., enquanto na programação estocástica obteve-se um valor de -2,103 m.u, representando uma melhoria de 29,26%. No que se refere ao valor das emissões, registou-se uma variação de um valor máximo de 11,211 kgCO₂ (robusta), para um valor de 18,567 kgCO₂ (estocástica), representando uma solução 65,61% pior, em termos de emissões de CO₂. Nesta solução NDS-L podemos concluir que a abordagem robusta encontrou uma solução com um lucro 29,26% pior. Contudo, essa mesma solução é 65,61% melhor no que diz respeito aos níveis de emissão de CO₂. Esta solução revela-se melhor no caso do operador do edifício pretender dar maior relevância à obtenção de níveis de emissões de CO₂ mais reduzidos. Em relação ao tempo de execução, a abordagem robusta além de considerar 200 000 cenários de produção diferentes, número bem mais elevado quando comparado com os 2000 cenários considerados na abordagem estocástica, apresenta um tempo de execução bastante mais rápido que a programação estocástica. A otimização robusta obteve um tempo de execução de 1806,763 segundos (cerca de 30 minutos), enquanto a programação estocástica demorou 15397,446 segundos (cerca de 4 horas e 15 minutos).

Tabela 20 – Comparação de resultados entre a abordagem robusta e estocástica

Tipo de Programação	Robusta		Estocástica	
	NDS-L	NDS-R	NDS-L	NDS-R
Lucro (m.u.)	-4,793	-2,973	-6,712	-2,103
Emissões (kgCO ₂)	2,299	11,211	1,058	18,567
Tempo (s)	1806,763		15397,446	

Em suma, pode-se concluir que com o uso de uma solução robusta estaremos a limitar o espaço de pesquisa, uma vez que apenas são consideradas as melhores soluções dentro das soluções que representam o pior caso, contrariamente à frente de *Pareto* obtida com a abordagem estocástica que apresenta um maior espectro de soluções. Para além disso, as soluções obtidas pela programação estocástica são maioritariamente melhores, ou seja, soluções que conseguem apresentar um melhor lucro e ao mesmo tempo um menor valor de emissões de CO₂. No que diz respeito à solução robusta, é importante referenciar que esta pode não representar a melhor solução, mas representa uma solução capaz de salvaguardar o operador do edifício. Trata-se de uma abordagem que indica escalonamento dos recursos

energéticos para o dia seguinte, considerando o pior caso de acontecimentos, representando uma abordagem bastante adversa ao risco e conservadora. A abordagem robusta apresenta um tempo de processamento bastante razoável, revelando-se um método bastante útil para obter uma solução para o dia seguinte de uma forma rápida.

É importante ter em consideração que a comparação entre os dois tipos de abordagens (robusta e estocástica) é pouco equitativa, isto uma vez que as ideologias de ambas as metodologias são bastante diferentes. Na otimização robusta obtém-se as melhores soluções do conjunto das piores soluções selecionadas (pior caso), enquanto na programação estocástica são obtidas soluções baseadas em probabilidades de acontecimento.

5. CONCLUSÕES

Este capítulo apresenta as principais conclusões relativas ao trabalho desenvolvido, tendo em conta os objetivos alcançados, identificando ainda algumas perspetivas de desenvolvimento para trabalho futuro.

5.1. PRINCIPAIS CONCLUSÕES E CONTRIBUIÇÕES

As previsões são bastante importantes para a maioria dos sistemas de gestão dos recursos de energia. No entanto, os modelos preditivos constituem informação imperfeita, isto devido a erros de previsão. Certos parâmetros de entrada não são determinísticos, como por exemplo a produção eólica e fotovoltaica, e podem mudar significativamente após a otimização ser realizada, pondo em causa a solução obtida. Isto é particularmente verdade nas previsões para o dia seguinte, contendo um horizonte de tempo maior. Esta dissertação teve como principal objetivo o desenvolvimento de um modelo capaz de gerir diversos tipos de recursos energéticos num horizonte temporal de 24 horas, com uma granularidade de 1 hora, integrando recursos como as PDs, os sistemas de armazenamento e os VEs. O problema apresentado da gestão do edifício tem como dois objetivos conflitantes, a maximização dos lucros e minimização das emissões de CO₂. Para resolver este problema multiobjetivo da gestão dos recursos do edifício foi usado o MOPSO. O MOPSO desenvolvido é usado para solucionar um problema de escalonamento para o dia seguinte, daí a importância de ser

associado a esta meta-heurística uma otimização robusta para modelar as incertezas na produção de energia fotovoltaica e eólica. A implementação de um modelo de otimização robusto a uma meta-heurística é justificada pelo facto de esta requerer menos recursos computacionais, permitir obter uma solução mais rapidamente e apresentar maior simplicidade de implementação, quando comparada ao modelo matemático da programação robusta. O principal contributo deste trabalho consiste na modelação da incerteza de previsão da produção renovável para o dia seguinte, através do uso da otimização robusta implementada numa meta-heurística. O modelo desenvolvido considera como dados de entrada, as previsões para o dia seguinte da produção e do consumo do edifício, juntamente com as previsões do comportamento dos VEs ao longo do dia. Não obstante, são ainda fornecidos dados de entrada como: os vários tipos de comercializadores de energia (preços para as diferentes horas e emissões de CO₂) e os programas de DR pré acordados entre o agregador e o edifício. Os dados de entrada são encaminhados para o algoritmo de gestão de recursos (MOPSO), obtendo-se como resultado final um repositório com as soluções robustas, em que cada uma delas contem o respetivo escalonamento, para cada hora do dia seguinte, de todos os recursos controláveis (VEs, fornecedores externos de energia, sistema de armazenamento). Na metodologia são ainda considerados modelos de negócio, nomeadamente, o facto do operador do edifício poder em cada período comprar energia a diferentes comercializadores de energia e o uso do V2B, onde o veículo pode fornecer energia ao edifício. Adicionalmente, foi proposto um modelo inovador de DR, que considera o preço diário da potência de pico e um incentivo para a minimizar.

Nesta dissertação é apresentado um caso de estudo de um edifício real de Portugal, a infraestrutura do GECAD. A infraestrutura engloba a supervisão e o controlo da microprodução (um sistema eólico com uma capacidade máxima de 1,0 kW e um sistema fotovoltaico com uma capacidade máxima de 7,5 kW) e o consumo existente no edifício. Foram ainda integrados no caso de estudo um sistema de armazenamento de energia e quatro VEs. Este caso de estudo foi usado para comprovar a metodologia desenvolvida, sendo considerados quatro testes diferentes: o primeiro teste considera uma otimização robusta dando importância ao critério do lucro (OR-CL); o segundo teste onde ambos os critérios são igualmente relevantes (O-CIR); um terceiro teste em que a otimização robusta dá mais relevância ao critério das emissões de CO₂ (OR-CE); e por último um teste sem incertezas (O-SI), ou seja, é considerada que a previsão para o dia seguinte é perfeita.

Analisando os resultados obtidos para os diversos testes, pode-se concluir que as soluções que apresentam menores valores de emissão de CO₂ utilizam uma percentagem maior da descarga de veículos, isto acontece, pois, com o uso deste recurso é minimizada a necessidade de energia proveniente dos fornecedores externos. Em contrapartida, o lucro tem tendência a piorar devido ao facto de se tratar de um recurso maioritariamente mais caro. O facto de haver períodos em que alguns fornecedores externos têm um preço mais elevado que o aplicado á descarga de veículos incentiva que este recurso seja usado, em menor escala, mesmo em soluções em que se obtém um maior lucro. Em todas as soluções existe uma grande utilização da descarga do sistema de armazenamento, uma vez que este recurso não implica qualquer custo para o edifício, pois a bateria é considerada propriedade do mesmo. Com a utilização de quatro diferentes tipos de fornecedores externos, pode-se verificar que as grandes alterações, a nível de lucro e emissões, acontecem fundamentalmente devido ao fornecedor externo escalonado para os diferentes períodos, uma vez que existem fornecedores externos com menor preço de energia, mas com um maior valor de emissões, ou fornecedores externos com preço de energia mais elevado, mas com um valor de emissões baixo. O elevado uso da descarga de veículos leva a que os VEs sejam carregados em diversos períodos. A grande proporção de carregamento encontra-se alocada ao fim da tarde, de forma aos proprietários terem bateria suficiente para realizar a sua viagem de regresso a casa, após o término do seu horário de trabalho. Quanto ao carregamento do sistema de armazenamento, este é realizado maioritariamente nos períodos noturnos, uma vez que o preço da energia é mais barato, podendo-se ainda verificar o carregamento nos períodos onde existe maior penetração da PD, mais concretamente, da produção fotovoltaica. Relativamente ao programa de DR considerado, o algoritmo de gestão do edifício procura usar outros recursos energéticos capazes de reduzir o valor da energia solicitada aos fornecedores externos, representando este um outro fator que leva a uma maior utilização da descarga de veículos e do sistema de armazenamento.

Para comprovar a eficácia do método foi realizada uma comparação de performance entre o método MOPSO com otimização robusta desenvolvido e a programação estocástica. A frente de *Pareto* da programação estocástica obteve melhores soluções do que a otimização robusta, podendo-se ainda verificar um espectro de soluções obtido nesta abordagem estocástica bem mais alargado. Em contrapartida, a otimização robusta é menos pesada computacionalmente, permitindo introduzir no problema um maior número de cenários gerados em MC a serem testados, aumentando deste modo a veracidade do método em

termos da modelação da incerteza. Para além disso, apresenta um tempo de execução bastante mais rápido que a programação estocástica. É importante referenciar que a comparação entre estes dois tipos de programação acaba por não ser completamente justa, isto uma vez que são metodologias baseadas em ideais diferentes, onde na otimização robusta obtém-se as melhores soluções dentro das piores, enquanto na solução estocástica são obtidas soluções baseadas em probabilidades de acontecimento.

Como conclusão, a otimização robusta pode não conseguir obter a melhor solução, porém, representa uma solução capaz salvaguardar a operação do edifício. A produção da energia eólica e fotovoltaica pode mudar significativamente após a otimização ser realizada, pondo em causa a solução do escalonamento obtido, sendo que com o uso de um modelo robusto esse risco é diminuído. Perante uma otimização feita para o dia seguinte que não modele eficazmente a incerteza, a produção real no próprio dia poderá ser pior que a prevista, obrigando á realização de um reescalonamento em tempo real, o que levaria a penalizações e custos excessivos para cumprir determinadas restrições. Por outro lado, a abordagem robusta permite obter o escalonamento dos recursos para o dia seguinte considerando sempre os piores cenários de acontecimento. Na abordagem robusta temos uma solução bastante adversa ao risco, diminuindo a possibilidade de soluções reais piores que a prevista, salvaguardando o operador do edifício. Levando em conta o seu tempo de processamento e tendo em conta que os valores percentuais de variabilidade do método foram minimamente satisfatórios, o modelo de otimização robusta desenvolvida nesta dissertação poderá ser um método bastante útil para obter uma solução para o dia seguinte de uma forma rápida, permitindo ao operador abordar o problema de uma forma mais conservadora.

Enumerando agora algumas limitações da metodologia robusta desenvolvida, verifica-se que o grau de variabilidade do método, que apesar de aceitável, poderá ser melhorado. Uma segunda limitação é a velocidade de processamento do método, que apesar de ser bastante mais rápido que o tempo de execução da programação estocástica, poderia ser melhorado através de uma otimização de código.

5.2. SUGESTÕES PARA TRABALHO FUTURO

Ao longo do desenvolvimento deste trabalho, algumas áreas não foram abordadas e que poderão vir a ser benéficas na evolução do presente trabalho. O contínuo desenvolvimento deste trabalho estão internamente ligadas a novos projetos europeus que foram recentemente aprovados, e que

vêm dar continuidade aos projetos já mencionados no capítulo introdutório, nomeadamente os seguintes:

- **AVIGAE** - Assistente Virtual Inteligente para a Gestão Ativa da Energia em Edifícios, P2020 003401;
- **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-2014; projeto nº 641794;

O desenvolvimento e avanços realizados ao longo deste trabalho permitem abrir caminho para desenvolvimentos adicionais, dos quais se referem os seguintes:

- Melhorar a performance do método através de uma otimização do código do algoritmo desenvolvido, diminuindo o tempo de execução do mesmo;
- Tornar o método mais robusto no que diz respeito à variabilidade dos resultados obtidos na execução do algoritmo, sendo que este ponto estará sempre dependente do primeiro;
- Introduzir a modelação de outras incertezas, como o caso da incerteza associada à utilização das cargas e VEs;
- Resolver o mesmo problema apresentado nesta dissertação através da utilização da programação robusta implementada numa abordagem determinística;
- Adaptar o algoritmo desenvolvido para solucionar problemas na gestão de recursos energéticos, a nível dos agregadores de energia ou operadores de rede;
- Aplicar o conceito de otimização robusta a outras meta-heurísticas, comparando-as entre si.

Referências Documentais

- [1] MathWorks, “MATLAB - The Language Of Technical Computing.” [Online]. Available: <http://www.mathworks.com/products/matlab/>.
- [2] Y.-K. Juan, P. Gao, and J. Wang, “A hybrid decision support system for sustainable office building renovation and energy performance improvement,” *Energy Build.*, vol. 42, no. 3, pp. 290–297, Mar. 2010.
- [3] H. Zhao and F. Magoulès, “A review on the prediction of building energy consumption,” *Renew. Sustain. Energy Rev.*, vol. 16, no. 6, pp. 3586–3592, Aug. 2012.
- [4] C. Fernandes, P. Frías, and J. M. Latorre, “Impact of vehicle-to-grid on power system operation costs: The Spanish case study,” *Appl. Energy*, vol. 96, no. 0, pp. 194–202, 2012.
- [5] T. Sousa, H. Morais, R. Castro, and Z. Vale, “Evaluation of different initial solution algorithms to be used in the heuristics optimization to solve the energy resource scheduling in smart grids,” *Appl. Soft Comput.*, vol. 48, pp. 491–506, 2016.
- [6] G. K. Venayagamoorthy, “Dynamic, Stochastic, Computational and Scalable Technologies for Smart Grids,” *IEEE Comput. Intell. Mag.*, vol. 6, no. 3, pp. 22–35, 2011.
- [7] P. Faria, J. Spinola, and Z. Vale, “Aggregation and Remuneration of Electricity Consumers and Producers for the Definition of Demand-Response Programs,” *IEEE Trans. Ind. Informatics*, vol. 12, no. 3, pp. 952–961, Jun. 2016.
- [8] B. Biao Sun, P. B. Luh, Q.-S. Qing-Shan Jia, Z. Ziyang Jiang, F. Fulin Wang, and C. Chen Song, “Building Energy Management: Integrated Control of Active and Passive Heating, Cooling, Lighting, Shading, and Ventilation Systems,” *IEEE Trans. Autom. Sci. Eng.*, vol. 10, no. 3, pp. 588–602, Jul. 2013.
- [9] G. P. J. Verbong, S. Beemsterboer, and F. Sengers, “Smart grids or smart users?”

- Involving users in developing a low carbon electricity economy,” *Energy Policy*, vol. 52, pp. 117–125, Jan. 2013.
- [10] M. Welsch, M. Bazilian, M. Howells, D. Divan, D. Elzinga, G. Strbac, L. Jones, A. Keane, D. Gielen, V. S. K. M. Balijepalli, A. Brew-Hammond, and K. Yumkella, “Smart and Just Grids for sub-Saharan Africa: Exploring options,” *Renew. Sustain. Energy Rev.*, vol. 20, pp. 336–352, Apr. 2013.
- [11] K. G. Di Santo, E. Kanashiro, S. G. Di Santo, and M. A. Saidel, “A review on smart grids and experiences in Brazil,” *Renew. Sustain. Energy Rev.*, vol. 52, pp. 1072–1082, Dec. 2015.
- [12] I. Colak, R. Bayindir, G. Fulli, I. Tekin, K. Demirtas, and C.-F. Covrig, “Smart grid opportunities and applications in Turkey,” *Renew. Sustain. Energy Rev.*, vol. 33, pp. 344–352, May 2014.
- [13] S. Erlinghagen and J. Markard, “Smart grids and the transformation of the electricity sector: ICT firms as potential catalysts for sectoral change,” *Energy Policy*, vol. 51, pp. 895–906, Dec. 2012.
- [14] V. C. Gungor, D. Sahin, T. Kocak, S. Ergut, C. Buccella, C. Cecati, and G. P. Hancke, “Smart Grid Technologies: Communication Technologies and Standards,” *IEEE Trans. Ind. Informatics*, vol. 7, no. 4, pp. 529–539, Nov. 2011.
- [15] M. Carvalho, C. Perez, and A. Granados, “An adaptive multi-agent-based approach to smart grids control and optimization,” *Energy Syst.*, vol. 3, no. 1, pp. 61–76, Feb. 2012.
- [16] A. Baziar and A. Kavousi-Fard, “Considering uncertainty in the optimal energy management of renewable micro-grids including storage devices,” *Renew. Energy*, vol. 59, pp. 158–166, Nov. 2013.
- [17] Jong-Yul Kim, Jin-Hong Jeon, Seul-Ki Kim, Changhee Cho, June Ho Park, Hak-Man Kim, and Kee-Young Nam, “Cooperative Control Strategy of Energy Storage System and Microsources for Stabilizing the Microgrid during Islanded Operation,” *IEEE Trans. Power Electron.*, vol. 25, no. 12, pp. 3037–3048, Dec. 2010.

- [18] D. E. Olivares, A. Mehrizi-Sani, A. H. Etemadi, C. A. Canizares, R. Iravani, M. Kazerani, A. H. Hajimiragha, O. Gomis-Bellmunt, M. Saeedifard, R. Palma-Behnke, G. A. Jimenez-Estevez, and N. D. Hatziargyriou, “Trends in Microgrid Control,” *IEEE Trans. Smart Grid*, vol. 5, no. 4, pp. 1905–1919, Jul. 2014.
- [19] S. Mohammadi, B. Mozafari, S. Solimani, and T. Niknam, “An Adaptive Modified Firefly Optimisation Algorithm based on Hong’s Point Estimate Method to optimal operation management in a microgrid with consideration of uncertainties,” *Energy*, vol. 51, pp. 339–348, Mar. 2013.
- [20] H. Jiayi, J. Chuanwen, and X. Rong, “A review on distributed energy resources and MicroGrid,” *Renew. Sustain. Energy Rev.*, vol. 12, no. 9, pp. 2472–2483, Dec. 2008.
- [21] F. Fernandes, H. Morais, Z. Vale, and C. Ramos, “Dynamic load management in a smart home to participate in demand response events,” *Energy Build.*, vol. 82, pp. 592–606, 2014.
- [22] L. C. De Silva, C. Morikawa, and I. M. Petra, “State of the art of smart homes,” *Eng. Appl. Artif. Intell.*, vol. 25, no. 7, pp. 1313–1321, Oct. 2012.
- [23] B. Jiang and Y. Fei, “Dynamic Residential Demand Response and Distributed Generation Management in Smart Microgrid with Hierarchical Agents,” *Energy Procedia*, vol. 12, pp. 76–90, 2011.
- [24] J. Yan, Y. Liu, S. Han, Y. Wang, and S. Feng, “Reviews on uncertainty analysis of wind power forecasting,” *Renew. Sustain. Energy Rev.*, vol. 52, pp. 1322–1330, Dec. 2015.
- [25] I. Maity and S. Rao, “Simulation and Pricing Mechanism Analysis of a Solar-Powered Electrical Microgrid,” *IEEE Syst. J.*, vol. 4, no. 3, pp. 275–284, Sep. 2010.
- [26] R. Caldon, A. R. Patria, and R. Turri, “Universities Power Engineering Conference, 2004. UPEC 2004. 39th International,” *Universities Power Engineering Conference, 2004. UPEC 2004. 39th International*, vol. 3, pp. 1058–1062 vol. 2, 2004.
- [27] E. Niesten and F. Alkemade, “How is value created and captured in smart grids? A review of the literature and an analysis of pilot projects,” *Renew. Sustain. Energy*

- Rev.*, vol. 53, pp. 629–638, Jan. 2016.
- [28] P. Faria, T. Soares, Z. Vale, and H. Morais, “Distributed generation and demand response dispatch for a virtual power player energy and reserve provision,” *Renew. Energy*, vol. 66, pp. 686–695, 2014.
- [29] A. Soares, A. Gomes, and C. H. Antunes, “Domestic load characterization for demand-responsive energy management systems,” in *2012 IEEE International Symposium on Sustainable Systems and Technology (ISSST)*, 2012, pp. 1–6.
- [30] P. Faria, Z. Vale, and J. Baptista, “Demand Response Programs Design and Use Considering Intensive Penetration of Distributed Generation,” *Energies*, vol. 8, no. 6, pp. 6230–6246, Jun. 2015.
- [31] P. Palensky and D. Dietrich, “Demand Side Management: Demand Response, Intelligent Energy Systems, and Smart Loads,” *IEEE Trans. Ind. Informatics*, vol. 7, no. 3, pp. 381–388, Aug. 2011.
- [32] F. Shariatzadeh, P. Mandal, and A. K. Srivastava, “Demand response for sustainable energy systems: A review, application and implementation strategy,” *Renew. Sustain. Energy Rev.*, vol. 45, pp. 343–350, May 2015.
- [33] M. Kuzlu, M. Pipattanasomporn, and S. Rahman, “Hardware Demonstration of a Home Energy Management System for Demand Response Applications,” *IEEE Trans. Smart Grid*, vol. 3, no. 4, pp. 1704–1711, Dec. 2012.
- [34] A. Emadi and K. Rajashekara, “Power Electronics and Motor Drives in Electric, Hybrid Electric, and Plug-In Hybrid Electric Vehicles,” *IEEE Trans. Ind. Electron.*, vol. 55, no. 6, pp. 2237–2245, Jun. 2008.
- [35] D. B. Richardson, “Electric vehicles and the electric grid: A review of modeling approaches, Impacts, and renewable energy integration,” *Renew. Sustain. Energy Rev.*, vol. 19, pp. 247–254, 2013.
- [36] T. Sousa, T. Soares, H. Morais, R. Castro, and Z. Vale, “Simulated annealing to handle energy and ancillary services joint management considering electric vehicles,” *Electr. Power Syst. Res.*, vol. 136, pp. 383–397, 2016.

- [37] H. Morais, T. Sousa, J. Soares, P. Faria, and Z. Vale, “Distributed energy resources management using plug-in hybrid electric vehicles as a fuel-shifting demand response resource,” *Energy Convers. Manag.*, vol. 97, no. June 2015, pp. 79–93, 2015.
- [38] W. Jian, L. Zhizhen, W. Kuihua, W. Feng, and Z. Yi, “Impact of plug-in hybrid electric vehicles on power distribution networks,” in *2011 4th International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT)*, 2011, pp. 1618–1622.
- [39] C. Wang, Y. Zhou, B. Jiao, Y. Wang, W. Liu, and D. Wang, “Robust optimization for load scheduling of a smart home with photovoltaic system,” *Energy Convers. Manag.*, vol. 102, pp. 247–257, Sep. 2015.
- [40] Y. Zhou, C. Wang, B. Jiao, and Y. Wang, “Robust Load Scheduling in a Smart Home with Photovoltaic System,” *Energy Procedia*, vol. 61, pp. 772–776, 2014.
- [41] Z. Chen, L. Wu, and Y. Fu, “Real-Time Price-Based Demand Response Management for Residential Appliances via Stochastic Optimization and Robust Optimization,” *IEEE Trans. Smart Grid*, vol. 3, no. 4, pp. 1822–1831, Dec. 2012.
- [42] A. T. Rezvan, N. S. Gharneh, and G. B. Gharehpetian, “Robust optimization of distributed generation investment in buildings,” *Energy*, vol. 48, no. 1, pp. 455–463, Dec. 2012.
- [43] K. Akbari, M. M. Nasiri, F. Jolai, and S. F. Ghaderi, “Optimal investment and unit sizing of distributed energy systems under uncertainty: A robust optimization approach,” *Energy Build.*, vol. 85, pp. 275–286, Dec. 2014.
- [44] E. Kuznetsova, C. Ruiz, Y.-F. Li, and E. Zio, “Analysis of robust optimization for decentralized microgrid energy management under uncertainty,” *Int. J. Electr. Power Energy Syst.*, vol. 64, pp. 815–832, Jan. 2015.
- [45] Y. Zhang, N. Gatsis, and G. B. Giannakis, “Robust Energy Management for Microgrids With High-Penetration Renewables,” *IEEE Trans. Sustain. Energy*, vol. 4, no. 4, pp. 944–953, Oct. 2013.
- [46] R. Marijt, "Multi-objective Robust Optimization Algorithms for Improving Energy

- Consumption and Thermal Comfort of Buildings." *Diss. Technical University of Eindhoven*, 2009.
- [47] H. Keko and V. Miranda, "Impact of clustering-based scenario reduction on the perception of risk in unit commitment problem," in *2015 18th International Conference on Intelligent System Application to Power Systems (ISAP)*, 2015, pp. 1–6.
- [48] A. Conejo, M. Carrión, and J. Morales, "Decision making under uncertainty in electricity markets", *New York: Springer*, vol. 1., 2010.
- [49] S. Zhang, P. Huang, and Y. Sun, "A multi-criterion renewable energy system design optimization for net zero energy buildings under uncertainties," *Energy*, vol. 94, pp. 654–665, Jan. 2016.
- [50] S. Kim, J. Koo, C. J. Lee, and E. S. Yoon, "Optimization of Korean energy planning for sustainability considering uncertainties in learning rates and external factors," *Energy*, vol. 44, no. 1, pp. 126–134, Aug. 2012.
- [51] W. Su, J. Wang, and J. Roh, "Stochastic Energy Scheduling in Microgrids With Intermittent Renewable Energy Resources," *IEEE Trans. Smart Grid*, vol. 5, no. 4, pp. 1876–1883, Jul. 2014.
- [52] M. Gonzalez Vaya and G. Andersson, "Optimal Bidding Strategy of a Plug-In Electric Vehicle Aggregator in Day-Ahead Electricity Markets Under Uncertainty," *IEEE Trans. Power Syst.*, vol. 30, no. 5, pp. 2375–2385, 2015.
- [53] N. Mehboob, C. Canizares, and C. Rosenberg, "Day-ahead dispatch of distribution feeders considering temporal uncertainties of PEVs," in *2015 IEEE Eindhoven PowerTech*, 2015, pp. 1–6.
- [54] M. F. Shaaban, Y. M. Atwa, and E. F. El-Saadany, "PEVs Modeling and Impacts Mitigation in Distribution Networks," *IEEE Trans. Power Syst.*, vol. 28, no. 2, pp. 1122–1131, 2013.
- [55] F. J. Soares, J. A. Pecas Lopes, and P. M. Rocha Almeida, "A Monte Carlo method to evaluate electric vehicles impacts in distribution networks," in *2010 IEEE*

- Conference on Innovative Technologies for an Efficient and Reliable Electricity Supply*, 2010, pp. 365–372.
- [56] D. Kullmann, A. Thavlov, O. Gehrke, and H. W. Bindner, “Active load management in an intelligent building using model predictive control strategy,” in *2011 IEEE Trondheim PowerTech*, 2011, pp. 1–6.
- [57] J. Ye, Q. Xie, Y. Xiahou, and C. Wang, “The research of an adaptive smart home system,” in *2012 7th International Conference on Computer Science & Education (ICCSE)*, 2012, pp. 882–887.
- [58] T. Sysala, M. Pospichal, and P. Neumann, “Monitoring and control system for a smart family house controlled via programmable controller,” in *2016 17th International Carpathian Control Conference (ICCC)*, 2016, pp. 706–710.
- [59] Y. Son, T. Pulkkinen, K. Moon, and C. Kim, “Home energy management system based on power line communication,” *IEEE Trans. Consum. Electron.*, vol. 56, no. 3, pp. 1380–1386, Aug. 2010.
- [60] I.-V. Sita and P. Dobra, “KNX Building Automations Interaction with City Resources Management System,” *Procedia Technol.*, vol. 12, pp. 212–219, 2014.
- [61] Y. Dai, Z. Jiang, Q. Shen, P. Chen, S. Wang, and Y. Jiang, “A decentralized algorithm for optimal distribution in HVAC systems,” *Build. Environ.*, vol. 95, pp. 21–31, 2016.
- [62] S. Burer and A. N. Letchford, “Non-convex mixed-integer nonlinear programming: A survey,” *Surv. Oper. Res. Manag. Sci.*, vol. 17, no. 2, pp. 97–106, Jul. 2012.
- [63] J. R. Birge and F. Louveaux, “Introduction to Stochastic Programming”, *Springer Science & Business Media*, 2011.
- [64] A. Soroudi and T. Amraee, “Decision making under uncertainty in energy systems: State of the art,” *Renew. Sustain. Energy Rev.*, vol. 28, pp. 376–384, Dec. 2013.
- [65] A. Ben-Tal and A. Nemirovski, “Robust solutions of Linear Programming problems contaminated with uncertain data,” *Math. Program.*, vol. 88, no. 3, pp. 411–424, Sep. 2000.

- [66] D. Bertsimas and M. Sim, “Robust discrete optimization and network flows,” *Math. Program.*, vol. 98, no. 1–3, pp. 49–71, Sep. 2003.
- [67] D. Bertsimas, D. Pachamanova, and M. Sim, “Robust linear optimization under general norms,” *Oper. Res. Lett.*, vol. 32, no. 6, pp. 510–516, Nov. 2004.
- [68] J. Soares, M. A. Fotouhi Ghazvini, M. Silva, and Z. Vale, “Multi-dimensional signaling method for population-based metaheuristics: Solving the large-scale scheduling problem in smart grids,” *Swarm Evol. Comput.*, Mar. 2016.
- [69] J. Moore and R. Chapman, “Application Of Particle Swarm To Multiobjective Optimization.” *Department of Computer Science and Software Engineering, Auburn University* 32, 1999.
- [70] C. A. C. Coello, G. T. Pulido, and M. S. Lechuga, “Handling multiple objectives with particle swarm optimization,” *Evol. Comput. IEEE Trans.*, vol. 8, no. 3, pp. 256–279, 2004.
- [71] P. K. Tripathi, S. Bandyopadhyay, and S. K. Pal, “Multi-Objective Particle Swarm Optimization with time variant inertia and acceleration coefficients,” *Inf. Sci. (Ny)*, vol. 177, no. 22, pp. 5033–5049, 2007.
- [72] V. Miranda, H. Keko, and A. Jaramillo, “EPSO: Evolutionary particle swarms,” *Stud. Comput. Intell.*, vol. 66, pp. 139–167, 2007.
- [73] J. R. Birge and F. Louveaux, "Introduction to stochastic programming." *Springer Science & Business Media*, 2011.
- [74] Red Eléctrica de España, “Active Energy Invoicing Price.” [Online]. Available: <https://www.esios.ree.es/es>.
- [75] ERSE, “Preços de referência no mercado liberalizado de energia elétrica e gás natural em portugal continental.” [Online]. Available: <http://www.erse.pt/>
- [76] E.ON, “Finden Sie Ihr optimales Stromprodukt.” [Online]. Available: <https://www.eon.de/gk/de/strom/tarifberater.html>.
- [77] EDF, “Grilles tarifaires de l’offre de fourniture d’électricité.” [Online]. Available:

<https://particulier.edf.fr/>

- [78] P. P. Capros, A. De Vita, N. Tasios, D. Papadopoulos, P. Siskos, E. Apostolaki, M. Zampara, L. Paroussos, K. Fragiadakis, N. Kouvaritakis, L. Höglund-Isaksson, W. Winiwarter, P. Purohit, H. Böttcher, S. Frank, P. Havlík, M. Gusti, and H. P. Witzke, “EU Energy, Transport and GHG Emissions - Trends to 2050,” 2013.

- [79] J. Soares, B. Canizes, C. Lobo, Z. Vale, and H. Morais, “Electric Vehicle Scenario Simulator Tool for Smart Grid Operators,” *Energies*, vol. 5, no. 12, pp. 1881–1899, Jun. 2012.

Anexo A. Características dos Veículos Elétricos

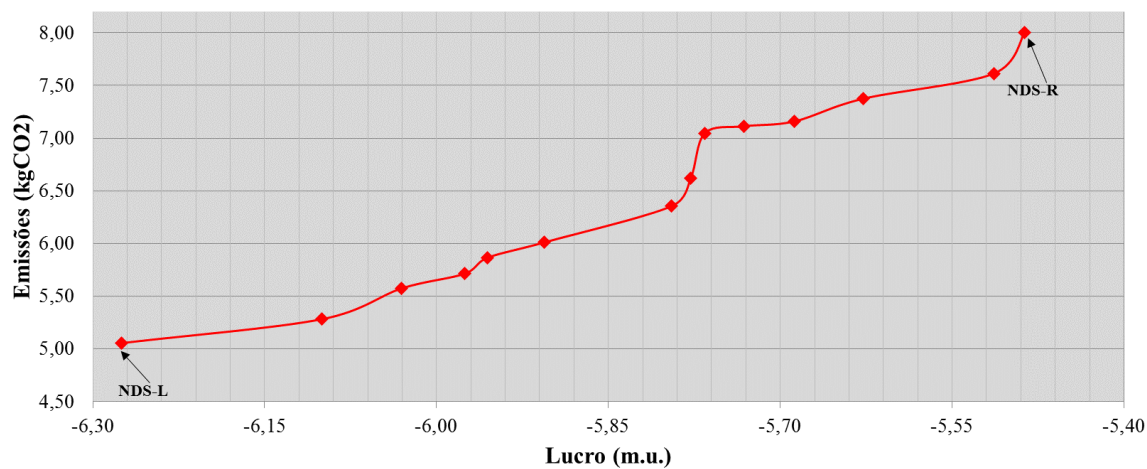
Neste anexo são descritas as características dos VEs usados no caso de estudo apresentado na secção 4.

ID	1	2	3
Marca	BMW	Nissan	Renault
Modelo	i3 2013	Leaf	Zoe 2013
Tipo de Veículo	BEV	BEV	BEV
Classe do Veículo	M1	M1	M1
Massa (kg)	1195	1525	1468
Coefficiente Aerodinâmico Cd	0,30	0,28	0,29
Área Frontal (m ²)	1,98	2,19	2,43
Capacidade da Bateria (kW)	18,8	24	22
Min SOC	20	20	20
Max SOC	100	100	100
Max Carregamento Lento (kWh)	2,4	6,6	3
Max Carregamento Rápido (kWh)	50	44	43
Modo VE Combinado	0,18	0,17	0,146
Modo VE Cidade	-	0,15	-
Modo VE Autoestrada	-	0,30	-
Autonomia (km)	130	120	210

Anexo B. Soluções do OR-CL

Neste anexo são apresentadas as soluções NDS encontradas pelo o MOPSO no OR-CL.


ID	Lucro (m.u.)	Emissões (kgCO ₂)
1	-5,778	6,620
2	-5,956	5,863
3	-6,100	5,281
4	-5,732	7,110
5	-5,687	7,157
6	-6,031	5,572
7	-5,514	7,611
8	-5,976	5,711
9	-5,766	7,046
10	-5,906	6,009
11	-6,275	5,053
12	-5,795	6,353
13	-5,628	7,372
14	-5,487	7,999



Anexo C. Soluções do O-CIR

Neste anexo são apresentadas as soluções NDS encontradas pelo o MOPSO no O-CIR.


ID	Lucro (m.u.)	Emissões (kgCO ₂)
1	-5,634	4,832
2	-4,837	6,639
3	-5,008	5,822
4	-4,504	8,971
5	-4,660	7,804
6	-5,184	5,552
7	-5,482	5,495
8	-5,727	4,728
9	-5,504	5,248
10	-5,578	5,212
11	-4,557	7,807
12	-4,747	7,192
13	-4,996	6,519



Anexo D. Soluções do OR-CE

Neste anexo são apresentadas as soluções NDS encontradas pelo o MOPSO no OR-CE.


ID	Lucro (m.u.)	Emissões (kgCO ₂)
1	-5,203	7,809
2	-4,714	8,646
3	-4,633	9,856
4	-5,699	7,637
5	-4,929	8,590
6	-5,021	8,542
7	-5,152	8,272
8	-4,714	9,393



Anexo E. Soluções do O-SI

Neste anexo são apresentadas as soluções NDS encontradas pelo o MOPSO no O-SI.

ID	Lucro (m.u.)	Emissões (kgCO ₂)
1	-6,644	5,241
2	-5,143	6,504
3	-4,497	10,984
4	-5,030	6,627
5	-4,965	7,315
6	-4,947	7,754
7	-5,279	6,298
8	-4,665	8,439
9	-5,348	5,265
10	-4,766	8,338



Anexo F. Soluções da Programação Estocástica

Neste anexo são apresentadas as soluções NDS encontradas pelo o CPLEX usadas na subsecção 4.6.

ID	Lucro (m.u.)	Emissões (kgCO ₂)	ID	Lucro (m.u.)	Emissões (kgCO ₂)	ID	Lucro (m.u.)	Emissões (kgCO ₂)
2	-6,712	1,058	45	-4,950	1,147	84	-3,130	7,256
3	-5,081	1,077	46	-4,950	1,147	85	-3,112	7,350
7	-5,078	1,078	47	-4,951	1,146	86	-3,100	7,423
8	-5,070	1,078	48	-4,950	1,147	87	-3,089	7,494
9	-5,068	1,078	49	-4,950	1,147	88	-2,897	8,867
10	-5,062	1,079	50	-4,950	1,147	89	-2,884	8,969
11	-5,059	1,079	51	-4,950	1,147	90	-2,705	10,509
12	-5,056	1,080	52	-4,950	1,147	91	-2,471	12,658
14	-5,055	1,080	53	-4,950	1,147	92	-2,324	14,201
15	-5,055	1,080	54	-4,950	1,147	93	-2,312	14,346
16	-5,053	1,080	55	-4,950	1,147	94	-2,290	14,669
17	-5,052	1,080	56	-4,950	1,147	95	-2,225	15,791
18	-5,051	1,080	57	-4,950	1,147	96	-2,148	17,286
19	-5,050	1,081	58	-4,950	1,147	97	-2,104	18,508
20	-5,049	1,081	60	-4,950	1,148	98	-2,104	18,530
21	-5,046	1,081	61	-4,950	1,148	99	-2,103	18,549
22	-5,044	1,082	62	-4,949	1,148	100	-2,103	18,567
23	-5,042	1,083	63	-4,949	1,148			
24	-5,039	1,083	64	-4,949	1,148			
25	-5,039	1,084	65	-4,543	1,880			
26	-5,038	1,084	66	-4,523	1,917			
27	-5,037	1,084	67	-4,513	1,937			
28	-5,037	1,084	68	-4,507	1,949			
29	-5,036	1,084	69	-4,501	1,962			
30	-5,036	1,085	70	-4,497	1,971			
31	-5,036	1,085	71	-4,493	1,981			
32	-5,035	1,085	72	-4,489	1,989			
33	-5,034	1,085	73	-4,365	2,319			
34	-5,033	1,086	74	-4,336	2,398			
36	-5,032	1,087	75	-4,183	2,847			
37	-5,030	1,087	76	-4,124	3,027			
38	-5,029	1,088	77	-3,959	3,563			
39	-5,028	1,089	78	-3,935	3,645			
40	-5,026	1,090	79	-3,915	3,719			
41	-5,023	1,092	80	-3,874	3,875			
42	-5,020	1,094	81	-3,677	4,682			
43	-5,016	1,097	82	-3,635	4,862			
44	-4,951	1,147	83	-3,231	6,761			

Anexo G. Soluções da Programação Robusta

Neste anexo são apresentadas as soluções NDS encontradas pelo o MOPSO usadas na subsecção 4.6.

ID	Lucro (m.u.)	Emissões (kgCO₂)
1	-3,815	7,391
2	-3,019	10,484
3	-3,039	10,368
4	-2,991	10,613
5	-3,157	9,555
6	-2,973	11,211
7	-3,236	9,116
8	-3,199	9,461
9	-4,793	2,315
10	-3,170	9,547
11	-3,095	10,110
12	-4,397	5,619
13	-3,098	9,635
14	-4,310	6,493
15	-3,289	8,891
16	-4,715	2,316
17	-4,638	2,418
18	-3,214	9,176
19	-3,273	8,929
20	-4,793	2,299
21	-4,079	6,538
22	-3,313	8,732
23	-3,367	8,278
24	-3,240	9,096
25	-3,366	8,471
26	-3,063	10,220

