




ISEL
INSTITUTO SUPERIOR DE
ENGENHARIA DE LISBOA

INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA

Área Departamental de Engenharia Eletrotécnica Energia e Automação



Otimização Estocástica para a Exploração de Centrais de Concentração Solar considerando Incerteza e Risco

João André Ribeiro Esteves
(Licenciado)

Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica

Orientadores:

Doutor Victor Manuel Fernandes Mendes
Doutor Hugo Miguel Inácio Pousinho

Júri:

Presidente:

Doutora Maria da Graça Vieira Brito Almeida

Vogais:

Doutor Victor Manuel Fernandes Mendes
Doutor Carlos Manuel Pereira Cabrita

Novembro de 2015

Dissertação realizada em regime de coorientação sob orientação do

Professor Doutor Victor Manuel Fernandes Mendes

e do

Doutor Hugo Miguel Inácio Pousinho

Respetivamente, Professor coordenador c/Agregação do
Área Departamental de Engenharia Eletrotécnica Energia e Automação do

INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA

e

Investigador do Centro de Sistemas Inteligentes do

Instituto de Engenharia Mecânica da

UNIVERSIDADE DE LISBOA

Ao meu Avô...

Resumo

Esta dissertação aborda o problema de planejamento de curto prazo em sistemas de aproveitamento de energia solar realizado através de centrais de concentração solar térmica. O objetivo desta dissertação consiste em propor uma nova metodologia de otimização estocástica baseada em programação linear inteira mista considerando a gestão de risco para resolver o problema de planejamento de curto prazo, de forma a maximizar o lucro esperado inerente à exploração da central de concentração solar térmica que atuam em ambiente de mercado. Um algoritmo de redução de cenários é também utilizado não só para mitigar a redundância de cenários, mas também para melhorar o desempenho computacional da metodologia proposta. Com o intuito de melhorar a produtividade operacional de centrais de concentração solar térmica durante períodos de ausência de radiação solar foi analisada a utilidade de sistemas de armazenamento de energia para aumentar a eficiência destas centrais. O problema de planejamento de curto prazo é formulado recorrendo ao uso de variáveis binárias, que permitem modelizar os estados discretos de funcionamento da central de concentração solar. São consideradas duas incertezas inerentes ao problema: i) Preço de energia elétrica em mercado diário; ii) Radiação solar direta, convertida em potência térmica no campo solar. A medida de risco CVaR é utilizada para o suporte à tomada de decisão do produtor, considerando o seu perfil de aversão ao risco. Para comprovar a proficiência da metodologia proposta são utilizados casos de estudo realísticos para concluir sobre o desempenho da nova metodologia.

Palavras-chave

Concentração solar térmica

Energia solar

Otimização estocástica

Programação linear inteira mista

Sistema de armazenamento de energia

Gestão de Risco

Abstract

This dissertation addresses the problem of short-term planning of systems for exploitation of solar energy by a concentrating solar power plant. The objective of this dissertation is to propose a new methodology based on mixed integer linear programming and stochastic optimization with risk management to solve the problem of short-term planning in order to maximize the profit inherent to the operation of a concentration solar power plant in a day-ahead electricity market environment. A scenario reduction algorithm is also used not only to mitigate redundancy of scenarios, but also to improve the computational performance of the proposed methodology. To improve the operational productivity of the concentration solar power plant during the periods of no solar radiation, energy storage system is considered in order to solve the problem. The problem of short-term planning is formulated using binary variables, which allow modelling the discrete status of the plant. Two uncertainties were considered in this problem: i) Electricity price in the day ahead electricity market; ii) Solar irradiation (converted to thermal power in the solar field). The risk measure CVaR is used to take into consideration the level of aversion to risk of the producer. To prove the proficiency of the proposed methodology realistic case studies are presented to conclude about the performance of the new methodology.

Keywords

Concentrated solar power

Solar energy

Stochastic optimization

Mixed-integer linear programming

Thermal storage system

Risk Management

Agradecimentos

Ao Doutor Victor Manuel Fernandes Mendes, Professor Coordenador c/Agregação da Área Departamental de Engenharia Eletrotécnica Energia e Automação do Instituto Superior de Engenharia de Lisboa, responsável como orientador em regime de coorientação científica, desejo expressar o meu agradecimento sincero pela sua disponibilidade, pelas suas palavras de apoio e incentivo que foram essenciais durante o decorrer desta dissertação.

Ao Doutor Hugo Miguel Inácio Pousinho, Investigador no Centro de Sistemas Inteligentes do Instituto de Engenharia Mecânica da Universidade de Lisboa, responsável como orientador em regime de coorientação científica, desejo expressar o meu agradecimento pela excelente orientação prestada, pela sua opinião honesta e critica que me levou mais além nesta dissertação.

Ainda, ao Doutor Victor Manuel Fernandes Mendes e Doutor Hugo Miguel Inácio Pousinho, um sincero bem-haja pelas oportunidades que me proporcionaram e que enriqueceram tanto o meu percurso académico como pessoal.

Ao Instituto Superior de Engenharia de Lisboa e a todos os docentes que à sua maneira me passaram o seu conhecimento e que fizeram parte do meu crescimento na vida académica, o meu sincero obrigado.

Uma palavra de agradecimento também para toda a minha família, em especial para os meus Pais, Ana Paula das Neves Ribeiro Esteves e João Manuel Louro Esteves, pelo incentivo, pelo apoio e compreensão durante todo este processo de aprendizagem que, sem eles, não teria sido possível.

Um agradecimento especial ao meu Pai pela paciência que teve em me fornecer todo o material que utilizei ao longo da Licenciatura e Mestrado, que sem o qual não teria sido o mesmo. Muito obrigado.

Aos meus amigos de sempre Vitor Alemão, David Reis, Ricardo Régio, e muitos mais que me tem acompanhado, desejo expressar o meu agradecimento pelo apoio e amizade e compreensão.

Ao meu colega e amigo Pedro Miguel Mendes Freire que me acompanhou em todo o meu percurso académico e, sem a sua amizade e apoio, não teria o resultado que consegui alcançar. Agradeço de coração.

Ao Ângelo Pereira que me auxiliou e me ajudou nos primeiros tempos do meu percurso académico um bem-haja pela amizade, paciência e ajuda prestada que, sem ela teria sido impossível chegar onde cheguei.

Ao Sr. Abraão Ribeiro Neto, meu avô, que não pôde ver o neto a terminar esta etapa da sua vida mas que com certeza ficará contente com o resultado que alcancei. A minha nota final de Mestrado é para ti avô, como prometi...

Á minha companheira, Ana Lúcia Gomes Rebelo, um profundo obrigado pela compreensão e apoio em todas as largas horas e dias que estive ausente para poder alcançar mais um percurso académico. Sem o seu apoio e motivação não teria a mesma vontade e garra com que ataquei a vida académica. Agradeço de coração.

A todos aqueles que não foram mencionados e que em diversas ocasiões e por diferentes motivos me acompanharam e motivaram durante este percurso académico.

A todos, o meu profundo agradecimento.

Índice

1. Introdução.....	1
1.1. Enquadramento	2
1.2. Motivação.....	12
1.3. Estado da arte	15
1.4. Organização do texto.....	24
1.5. Notação	26
2. Energia Solar Térmica.....	27
2.1. Energia Solar	28
2.2. Tecnologia de Concentração Solar	31
2.3. Central de Concentração Solar Térmica com SAE.....	41
3. Metodologia de Otimização Estocástica.....	47
3.1. Caracterização da Incerteza.....	48
3.2. Técnica de Redução de Cenários	51
3.3. Otimização Estocástica	56
3.4. Gestão de Risco.....	60
4. Formulação do Problema	68
4.1. Problema de exploração de CCST com SAE.....	69
4.2. Variáveis de uma CCST com SAE	72
4.3. Função Objetivo: Lucro Esperado	74
4.4. Restrições Associadas à Exploração de CCST com SAE.....	76
4.5. Formulação do Problema	87

5. Casos de Estudo	90
5.1. Casos de Estudo	91
5.2. Caso de estudo 1.....	93
5.3. Caso de estudo 2.....	97
5.4. Caso de estudo 3.....	100
5.5. Análise de Resultados	106
6. Conclusão	108
6.1. Contribuições	109
6.2. Direções de Investigação.....	110
Referências Bibliográficas	111
Anexos.....	121

Lista de Figuras

Figura 1.1 – Comparação entre diversos países [1].	3
Figura 1.2 – Projeção da concentração de CO ₂ [1].	3
Figura 1.3 – Potência instalada de energias renováveis em Portugal [5].	5
Figura 1.4 – Classificação dos Países da EU na integração de FER [5].	6
Figura 1.5 – Fases de aproveitamento das energias renováveis [6].	6
Figura 1.6 – Disponibilidade de radiação solar na Europa [7].	7
Figura 1.7 – Disponibilidade de radiação solar em Portugal [7].	8
Figura 1.8 – Países que mais investem na instalação de CCST [12].	9
Figura 1.9 – Potência associada com a radiação solar, Évora 2009 [13].	13
Figura 1.10 – Alexandre Edmond Becquerel	15
Figura 1.11 – Concentradores solares térmicos [18].	15
Figura 2.1 – Captação da radiação solar pelo coletor solar [13].	29
Figura 2.2 – Concentrador de disco parabólico [17].	32
Figura 2.3 – Esquema típico de uma CCST de recetor central de torre [62].	34
Figura 2.4 – Recetor central de torre em Sevilha (GEMASOLAR) [61].	35
Figura 2.5 – Concentrador linear com refletor do tipo <i>Fresnel</i> [17].	36
Figura 2.6 – Acompanhamento da posição solar pelo refletor <i>Fresnel</i> [60].	36
Figura 2.7 – Concentrador cilíndrico com refletor parabólico [24].	38
Figura 2.8 – Pormenor da concentração solar no tubo contendo o FTC [62].	39
Figura 2.9 – Esquema representativo de uma CCST com SAE [17].	41
Figura 2.10 – SAE da CCST ANDASOL 1 situada em Espanha [61].	44
Figura 2.11 – Funcionamento típico de uma CCST com SAE.	45
Figura 3.1 – Árvore de cenários de três estados.	49
Figura 3.2 – Árvore de cenários.	50
Figura 3.3 – Redução de cenários: Preço da energia elétrica.	54
Figura 3.4 – Redução de cenários: Potência térmica disponível no CS.	55

Figura 3.5 – Conjunto de cenários e probabilidades.	56
Figura 3.6 – Metodologia de otimização estocástica com técnica de redução de cenários.	57
Figura 3.7 – Curva da fronteira eficiente.	63
Figura 3.8 – Metodologia de otimização estocástica considerando a gestão de risco e a técnica de redução de cenários.	64
Figura 4.1 – Caracterização do horizonte temporal de curto prazo [78].	70
Figura 4.2 – Esquema exemplificativo da metodologia aplicada.	71
Figura 4.3 – Esquema de uma CCST com SAE por blocos.	72
Figura 4.4 – Restrição de rampas do SAE.	79
Figura 4.5 – Restrição de curva de ofertas em mercado.	85
Figura 5.1 – Caso de estudo 1: Preço da energia elétrica.	93
Figura 5.2 – Caso de estudo 1: Potência térmica no CS.	93
Figura 5.3 – Caso de estudo 1: Perfil de potência elétrica na CCST com SAE.	94
Figura 5.4 – Caso de estudo 1: Potência elétrica a vender em mercado diário.	95
Figura 5.5 – Caso de estudo 1: Potência térmica no CS na CCST com SAE.	95
Figura 5.6 – Caso de estudo 1: Energia no SAE e potência para o mercado.	96
Figura 5.7 – Caso de estudo 2: Lucro esperado e tempo de computação	98
Figura 5.8 – Caso de estudo 3: Cenários para preço da energia elétrica.	100
Figura 5.9 – Caso de estudo 3: Cenários para a potência térmica no CS.	100
Figura 5.10 – Caso de estudo 3: Lucro esperado vs. desvio padrão do lucro.	102
Figura 5.11 – Caso de estudo 3: Curvas de oferta horárias.	104
Figura 5.12 – Caso de estudo 3: Energia total a vender em mercado diário.	105

Lista de Tabelas

Tabela 2.1 – Comparação de tecnologia de concentração solar	40
Tabela 4.1 – Estados da variável binária $u_{\omega,t}$	77
Tabela 4.2 – Estados da variável binária $e_{\omega,t}$	80
Tabela 4.3 – Situações possíveis para a restrição de funcionamento do SAE	80
Tabela 4.4 - Estados da variável binária $y_{\omega,t}$ e $z_{\omega,t}$	81
Tabela 5.1 – Características da CCST com SAE	91
Tabela 5.2 – Caso de estudo 2: Lucro esperado e tempo de computação	98
Tabela 5.3 – Caso de estudo 2: VSS para diferentes números de cenários	99
Tabela 5.4 – Caso de estudo 3: Número de variáveis e restrições	101
Tabela 5.5 – Caso de estudo 3: Análise do lucro esperado	103

Lista de Siglas

ARIAE	Associação ibero-americana de entidades reguladoras de energia
CCST	Central de Concentração Solar Térmica
CF	Centrais Fotovoltaicas
CS	Campo Solar
CVaR	Valor em Risco Condicional
ES	<i>Expected shortfall</i>
ETSAP	<i>Energy Technology Systems Analysis Program</i>
EUA	Estados Unidos da América
EVPI	<i>Expected value of perfect information</i>
FER	Fontes de Energia Renováveis
FTC	Fluído de Transferência de Calor
GEE	Gases de Efeito de Estufa
IRENA	<i>International Renewable Energy Agency</i>
MIT	<i>Massachusetts Institute of Technology</i>
PB	Módulo de produção de energia elétrica
PIB	Produto Interno Bruto
PLIM	Programação Linear Inteira Mista
SAE	Sistema de Armazenamento de Energia
SEGS	<i>Solar Energy Generating Systems</i>
SP	<i>Shortfall probability</i>
UE	União Europeia
VaR	Valor em Risco
VSS	Valor da Solução Estocástica

Lista de Símbolos

Índices

t	Índice de períodos horários
ω	Índice de cenário
k	Índice auxiliar representativo dos períodos horários

Conjuntos

T	Conjunto de períodos horários
Ω	Conjunto de cenários
Ω_S	Conjunto de cenários selecionados pelo algoritmo de redução de cenários
Ω_J	Conjunto de cenários não selecionados pelo algoritmo de redução de cenários
Ω_S^*	Conjunto final de cenários selecionados pelo algoritmo de redução de cenários
X	Conjunto de variáveis de decisão que correspondem ao primeiro estado
Y	Conjunto de variáveis de decisão que correspondem ao segundo estado

Parâmetros

$E_{\omega,t}$	Potência térmica do campo solar (radiação solar) para o cenário ω na hora t
$\lambda_{\omega,t}$	Preço da energia elétrica no mercado diário para o cenário ω na hora t
$\pi_{t,\omega}$	Probabilidade de ocorrência do cenário ω na hora t

β	Nível de aversão ao risco considerado para o produtor
α	Nível de confiança para a medida de risco CVAR
η_1	Rendimento do campo solar
η_2	Eficiência da rede de tubagens entre o campo solar e os tanques de armazenamento
η_3	Rendimento dos tanques de armazenamento
R^{up}	Limite da rampa a subir para o sistema de armazenamento
R^{dn}	Limite da rampa a descer para o sistema de armazenamento
TMF	Tempo mínimo de funcionamento da central de concentração solar térmica
TMP	Tempo mínimo de paragem da central de concentração solar térmica
K_0^{on}	Número de períodos horários em que a central funcionou antes do início do horizonte temporal
K_0^{off}	Número de períodos horários em que a central parou antes do início do horizonte temporal
R	Constante suficientemente grande
Q_{min}^E	Potência térmica mínima do módulo de produção
Q_{max}^E	Potência térmica máxima do módulo de produção
P_{min}^S	Potência elétrica mínima do módulo de produção
P_{max}^S	Potência elétrica máxima do módulo de produção
Q_{min}^S	Potência térmica mínima do sistema de armazenamento de energia
Q_{max}^S	Potência térmica máxima do sistema de armazenamento de energia

Variáveis contínuas

$P_{\omega,t}^{FE}$	Potência elétrica proveniente do campo solar no cenário ω na hora t
$P_{\omega,t}^{SE}$	Potência elétrica proveniente do sistema de armazenamento no cenário ω na hora t

$P_{\omega,t}^{FS}$	Potência elétrica proveniente do campo solar para o armazenamento no cenário ω na hora t
$P_{\omega,t}^S$	Potência elétrica associada com a energia vendida ao mercado diário no cenário ω na hora t
$Q_{\omega,t}^{FE}$	Potência térmica para a energia proveniente do campo solar no cenário ω na hora t
$Q_{\omega,t}^{SE}$	Potência térmica para a energia proveniente do sistema de armazenamento no cenário ω na hora t
$Q_{\omega,t}^{FS}$	Potência térmica proveniente do campo solar para o armazenamento no cenário ω na hora t
$Q_{\omega,t}^S$	Potência térmica armazenada no cenário ω na hora t
$x_{\omega,t}$	Número de horas de funcionamento da central para o cenário ω no final da hora t
L_{ω}	Variável auxiliar tempo mínimo de funcionamento para o cenário ω
M_{ω}	Variável auxiliar tempo mínimo de paragem para o cenário ω
η	Variável para o valor em risco, VAR
s_{ω}	Variável auxiliar medida de risco CVAR

Variáveis binárias

$u_{\omega,t}$	Igual a 1 se a central de concentração solar térmica se encontra em conversão de energia no cenário ω na hora t
$y_{\omega,t}$	Igual a 1 se a central de concentração solar térmica arrancou no cenário ω na hora t
$z_{\omega,t}$	Igual a 1 se a central de concentração solar térmica parou no cenário ω na hora t
$e_{\omega,t}$	Igual a 1 se o sistema de armazenamento de energia está a carregar.

Vetores e matrizes

c	Vetor dos coeficientes da função objetivo associado às variáveis de primeiro estado
A	Matriz dos coeficientes determinísticos
b	Vetor que contém os limites para as restrições associadas às variáveis de primeiro estado
x	Vetor que contém as variáveis de decisão que correspondem ao primeiro estado
y_{ω}	Vetor das variáveis de decisão correspondentes ao segundo estado
q_{ω}	Vetor dos coeficientes da função objetivo associado às variáveis de segundo estado
T_{ω}	Matriz dos coeficientes associado às variáveis de primeiro estado
W_{ω}	Matriz dos coeficientes associado às variáveis de segundo estado
h_{ω}	Vetor limite de restrições associadas às variáveis de segundo estado

Funções

$v(\omega, \omega')$	Função de custo aplicada no algoritmo de redução de cenários
$D_k(Q, Q')$	Função definição da distância de <i>Kantorovich</i>
d_{ω}	Função de distância de <i>Kantorovich</i> aplicada no algoritmo de redução de cenários
$j(\omega')$	Função auxiliar para cálculo da probabilidade no algoritmo de redução de cenários
$J(\omega)$	Função auxiliar para cálculo da probabilidade ótima no algoritmo de redução de cenários

Capítulo 1

Introdução

Neste capítulo é apresentada uma introdução ao tema da otimização estocástica para a exploração de centrais de concentração solar considerando incerteza e risco. É apresentado o enquadramento da investigação, a motivação para abordar o tema e o estado da arte. Ainda, é descrita a forma como o texto está organizado e a notação utilizada.

1.1. Enquadramento

O setor energético contribui de forma determinante para potenciar o crescimento económico e tem contribuindo para sustentabilidade ambiental. A crescente consciencialização da sinergia entre economia e sustentabilidade ambiental é uma oportunidade que se revela com um imenso potencial a explorar, colocando desafios ambiciosos à investigação e desenvolvimento, quer a âmbito nacional, quer internacional. Ao nível da definição de uma política energética nacional cabe diversificar a oferta de fontes de energia alternativas aos recursos de origem fóssil, razão pela qual internacionalmente se promove a questão do potencial de exploração das fontes de energia renováveis.

O cenário conjeturado sobre o crescimento da população a nível mundial e o conseqüente aumento da procura de energia elétrica representam um problema relevante para garantir a sustentabilidade energética das nações. Neste problema a utilização de combustíveis fósseis cuja fonte é finita tende a ser substituída em parte pela introdução das fontes de energia renováveis (FER), as quais contribuem para mitigar as emissões antropogénicas de gases de efeitos de estufa (GEE) para a atmosfera.

O problema do aquecimento global que vem afetando o planeta constitui uma preocupação mundial que não pode ser ignorada. O principal recurso que contribui para a produção de energia elétrica é o combustível fóssil, emitindo para a atmosfera elevadas quantidades de dióxido de carbono e de outros gases poluentes prejudiciais à saúde e a toda a vida no planeta.

A percentagem da população, do produto interno bruto (PIB), do consumo de energia e das emissões de dióxido de carbono de diversos países emergentes é apresentada na Figura 1.1.

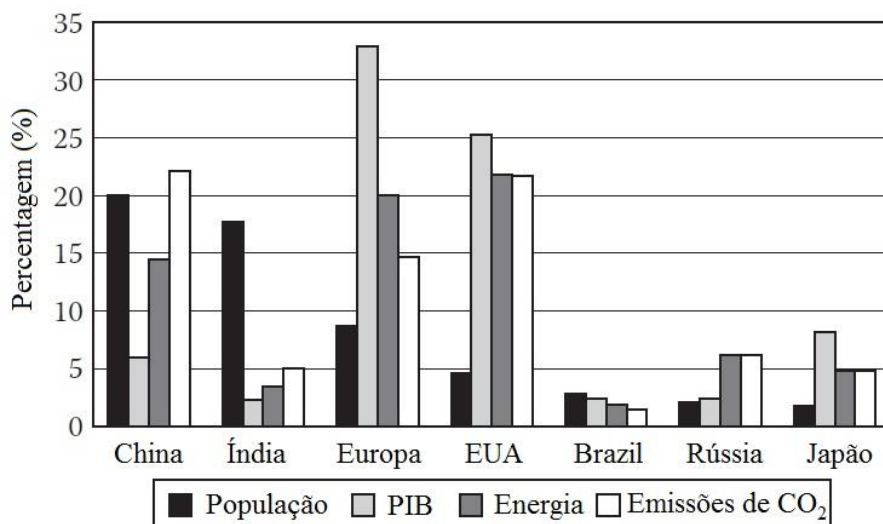


Figura 1.1 – Comparação entre diversos países [1].

A Figura 1.1 mostra que a China e os Estados Unidos da América (EUA) são os países que mais contribuem para a emissão de dióxido de carbono na atmosfera comparativamente com os restantes países identificados na figura.

A projeção da concentração de dióxido de carbono na atmosfera, baseada no crescimento constante da energia consumida é apresentada na Figura 1.2.

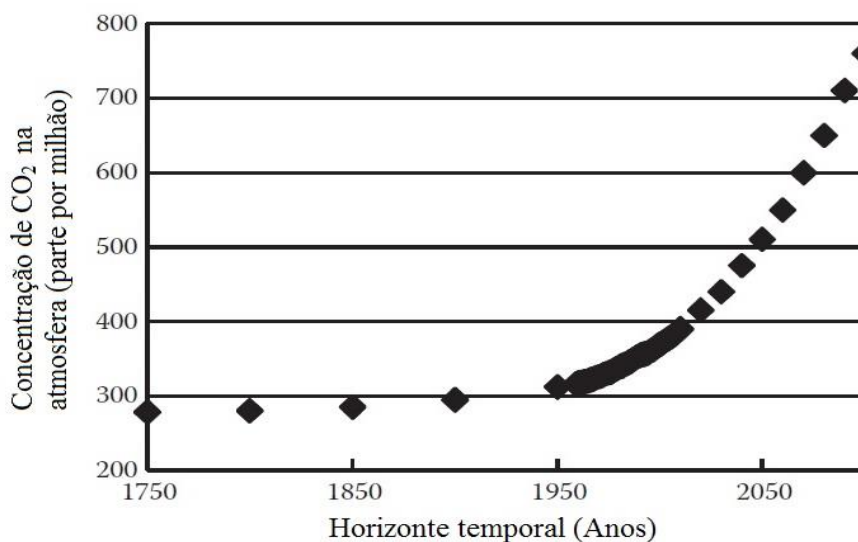


Figura 1.2 – Projeção da concentração de CO₂ [1].

A Figura 1.2 mostra que a concentração de dióxido de carbono tem vindo a aumentar exponencialmente, sendo espectável que no ano de 2050 a concentração de dióxido de carbono duplique em relação ao ano de 1950.

Uma das primeiras iniciativas a nível internacional concretizadas para estabelecer metas de emissões de GEE para a atmosfera foi a Conferência de Quioto, realizada em 11 de Dezembro de 1997, onde os países signatários se comprometeram a reformar os setores da energia e transportes, a promover a utilização de FER e a mitigar a emissão de gases antropogénica de GEE em 8% entre 2008 e 2012 relativamente a 1990 [2].

As alterações climáticas constituem uma preocupação preponderante devido ao aumento dos GEE na atmosfera ocasionar aumento no valor médio da temperatura terrestre. Em 2100 é espectável que o nível médio da água do mar aumente entre 0,2 a 1,0 metro [1]. Um melhor aproveitamento das FER constitui um interesse estratégico que deve ser explorado, não só por investigadores, desenvolvendo tecnologia inovadora para o aproveitamento de FER, mas também por promotores, aproveitando esta tecnologia em parques electroprodutores convenientemente localizados. Ainda, é relevante que órgãos governamentais estabeleçam políticas fiscais atrativas que promovam a diversificação da matriz energética de carácter renovável para que a pretensão sobre a sustentabilidade energética possa ser concretizada sem comprometer o ambiente. A União Europeia tem proactivamente promovido a adoção de políticas energéticas no âmbito da iniciativa Energia – 2020 [3]. Esta iniciativa, tendo como referência o ano 1990, estabelece até 2020 alcançar os objetivos de:

- Reduzir a emissão antropogénica de GEE em 20%;
- Reduzir o consumo energético através de 20% de eficiência energética;
- Assegurar 20% das necessidades energéticas a partir de FER.

No que respeita a Portugal, novas medidas estratégicas foram delineadas para o sistema energético com a aprovação da resolução do Conselho de Ministros 29/2010, de 15 de Abril, que estabeleceu a Estratégia Nacional para a Energia 2020 (ENE 2020) [4]. Com a aplicação da ENE 2020 é esperado alcançar os resultados que a seguir se identificam:

- Reduzir a dependência energética externa para 74% em 2020;
- Cumprir os compromissos assumidos para 2020, relativos ao combate às alterações climáticas, de:
 - 31% da energia final proveniente de recursos renováveis;
 - 20% de redução do consumo de energia final.
- Reduzir em 25% o saldo importador energético, com a energia produzida a partir de fontes endógenas.

A ENE 2020 têm permitido uma intensificação e diversificação da matriz energética nacional com recurso a FER, como é apresentado na Figura 1.3.




Figura 1.3 – Potência instalada de energias renováveis em Portugal [5].

A Figura 1.3 mostra que a potência instalada de energias renováveis tem vindo a aumentar progressivamente, sendo de salientar o contributo da potência instalada nas centrais hidroelétricas e nos parques eólicos. Em 2012, Portugal foi o quarto país da União Europeia com maior integração de energias renováveis como é apresentado na Figura 1.4.




Figura 1.4 – Classificação dos Países da EU na integração de FER [5].

As fases de aproveitamento das energias renováveis em Portugal são apresentadas na Figura 1.5.

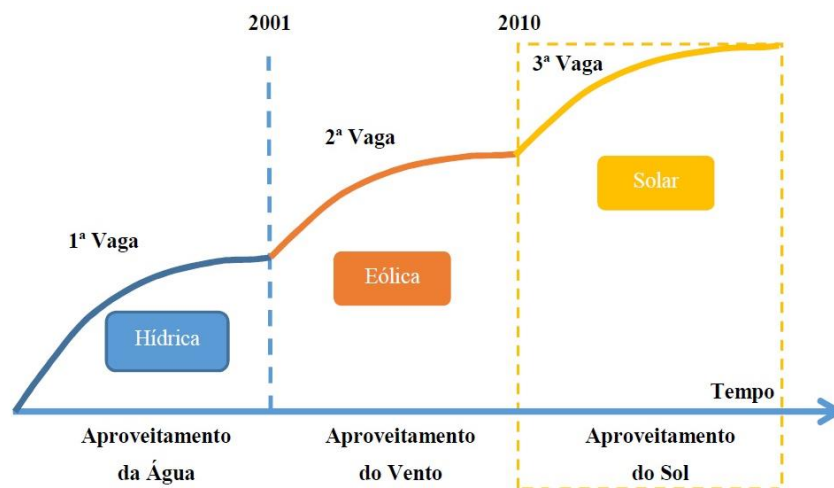


Figura 1.5 – Fases de aproveitamento das energias renováveis [6].

Apesar de se verificar um aumento da integração de energias renováveis em Portugal, o seu aproveitamento tem vindo a ocorrer de forma faseada o que justifica o ainda escasso aproveitamento de energia solar. A primeira fase, promovida pelo Plano Nacional de Barragens de Elevado Potencial Hidroelétrico,

privilegiou a exploração e reforço de potência de infraestruturas hidroelétricas para assegurar a complementaridade com os recursos eólicos. A segunda fase privilegiou o aproveitamento da energia eólica. Finalmente, a terceira fase deve privilegiar a energia solar dada a elevada disponibilidade do recurso solar em Portugal.

A disponibilidade de radiação solar incidente na Europa e só para Portugal é apresentada na Figura 1.6 e na Figura 1.7, respetivamente.

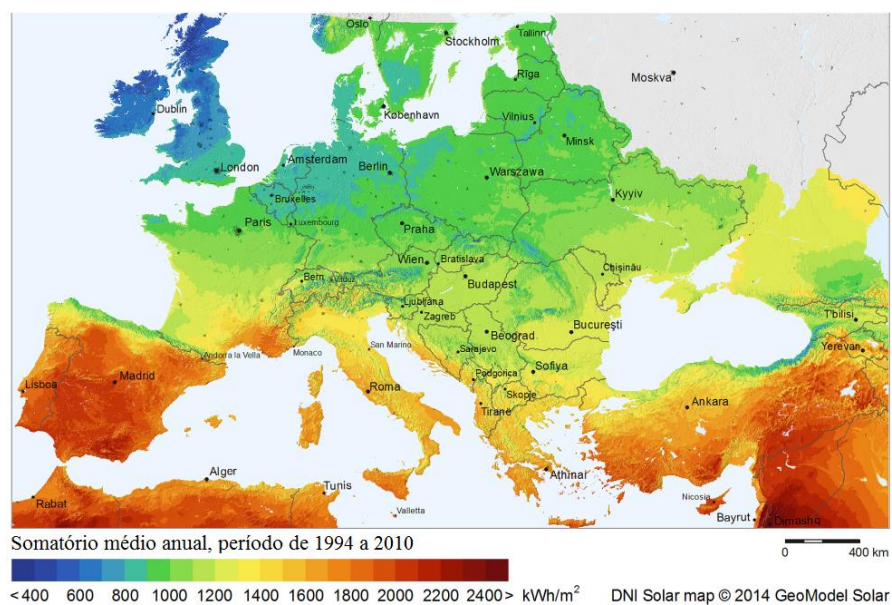


Figura 1.6 – Disponibilidade de radiação solar na Europa [7].

A Figura 1.6 mostram que Portugal é um dos países da Europa que recebe índices mais elevados de radiação solar por unidade de superfície, facto que resulta da sua posição subtropical. A elevada disponibilidade de radiação solar em Portugal continental e a constante evolução tecnológica permitem antever enormes potencialidades para o aproveitamento deste recurso energético, o que permitirá alcançar uma maior independência energética para o país.

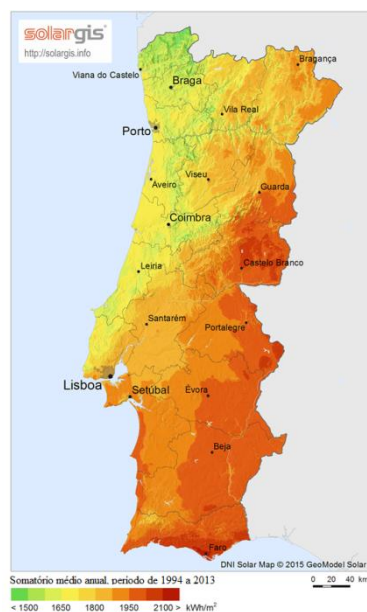


Figura 1.7 – Disponibilidade de radiação solar em Portugal [7].

O aproveitamento da energia proveniente da radiação solar pode ser efetuado através de centrais fotovoltaicas (CF) e através de centrais de concentração solar térmica (CCST), sendo esta última o foco desta dissertação.

Em Portugal existe produção de energia elétrica a partir de CF, no entanto, as CCST são mais flexíveis, visto que, podem facilmente incorporar sistemas de armazenamento de energia (SAE) o que permite atenuar o efeito intermitente e variável deste recurso renovável.

O avanço constante e significativo da tecnologia de conversores de energia solar para a forma de energia elétrica tem permitido não só reduzir o preço da instalação das infraestruturas de forma notável, mas também os custos de manutenção e exploração [8]. Assim, as recentes melhorias na tecnologia de produção de energia solar, CF e CCST, têm despertado o interesse por parte das empresas produtoras de energia elétrica. Contudo, a energia elétrica produzida a partir das CCST tem ganho interesse, visto que, o valor de investimento em relação às CF é inferior.

A nível mundial, a aposta nas CCST tem assumido destaque. Um estudo realizado nos EUA apurou que em 2013 existia aproximadamente 3,8 GW de potência

instalada em CCST, tendo em 2014 esta capacidade aumentado cerca de 60% [9]. Ainda, em [10] foi estimado que até 2020 seria alcançada uma potência instalada em CCST de aproximadamente 20 GW.

A exploração de CCST tem surgido predominantemente em Espanha e nos EUA, sendo Espanha o maior produtor de energia elétrica proveniente de CCST. Em 2010, estes dois países detinham cerca de 90% da capacidade total instalada em CCST [11]. Em Portugal, começam a ser dados os primeiros passos na implementação de CCST, como é o caso da instalação piloto localizada em Évora.




Figura 1.8 – Países que mais investem na instalação de CCST [12].

Numa sociedade moderna, a principal prioridade para um agente de decisão é uma medida de proveito que decorre da ação de decisão. Neste âmbito, para tornar um investimento em energias renováveis mais aliciente e vantajoso é proposto o desenvolvimento de um sistema de apoio à decisão que recorre a uma metodologia de otimização estocástica, tendo como objetivo maximizar o proveito de um produtor de energia elétrica detentor de uma CSST com SAE.

Esta dissertação incide sobre o estudo de uma metodologia de otimização estocástica para a exploração de CCST com SAE no horizonte temporal de curto prazo. A incerteza da potência térmica produzida pelo campo solar e a incerteza nos preços da energia elétrica em mercado diário é modelizada através de um

conjunto de cenários. Adicionalmente, a gestão de risco é considerada na metodologia de otimização, permitindo dotar o produtor de um portfólio de soluções ótimas cuja escolha da melhor solução é determinada de acordo com o nível de aversão ao risco. Este estudo representa uma contribuição original desta dissertação, visto que, não se encontrou na bibliografia uma referência ao seu uso.

O desenvolvimento de novas metodologias de otimização, sustentadas em ferramentas de programação matemática, desempenham um papel relevante na operação de sistemas de energia solar, conduzindo a decisões acertadas. Deste modo, a escolha acertada da metodologia de otimização a aplicar ao problema da exploração de curto prazo de CCST com SAE poderá conduzir a resultados mais realísticos.

Para resolver o problema da exploração de curto prazo de CCST com SAE é utilizado, nesta dissertação, métodos de programação matemática baseados em programação linear inteira mista (PLIM) e otimização estocástica com aplicação da gestão de risco.

Assim, a utilização da PLIM com a otimização estocástica com aplicação da gestão de risco permitirá abrir uma nova área de investigação no que respeita à resolução do problema da exploração de curto prazo de CCST com SAE.

A nova metodologia de otimização estocástica baseada em PLIM considerando a incerteza e risco permitirá obter uma exploração de curto prazo de CCST com SAE mais realística, na medida em que para além das restrições operacionais inseridas na PLIM, são incluídas as contribuições seguintes:

- Restrições de rampa;
- Incerteza na potência térmica disponível no campo solar;
- Incerteza no preço da energia elétrica em mercado diário;
- Medida de risco *conditional value-at-risk* (CVaR).

Nesta dissertação, a abordagem ao problema da exploração de curto prazo de CCST com SAE será feita considerando os seguintes casos de estudo:

- Caso de estudo 1: otimização determinística para a exploração de CCST com SAE;
- Caso de estudo 2: otimização estocástica para a exploração de CCST com SAE;
- Caso de estudo 3: otimização estocástica para a exploração de CCST com SAE considerado o risco.

No final são analisados os resultados e feita uma comparação entre os diferentes casos de estudo. Os resultados obtidos nestes casos de estudo permitirão, por um lado, evidenciar como se mostra atrativa a utilização da metodologia proposta e, por outro lado, tornar claros alguns aspetos relativos à formulação dos modelos matemáticos de decisão e às respetivas implicações nas formas de resolução.

1.2. Motivação

Esta dissertação tem como motivação dar um contributo para promover a utilização de FER, com especial enfoque nas CCST, permitindo aumentar a diversificação da matriz energética em Portugal. A constante preocupação e emergente criação de novas políticas energéticas que visam a sustentabilidade ambiental, económica e social são um contributo para diversificar o parque electroprodutor nacional. A tecnologia de concentração solar apresenta um rápido crescimento e o seu aproveitamento a partir de CCST está a ser disseminado em todo o mundo. No entanto, novos desafios tecnológicos e económicos necessitam de resposta.

Para tornar mais aliciante o investimento em CCST é necessário fazer uma correta exploração do recurso solar, conferindo ao produtor detentor de CCST uma maior competitividade para participar nos mercados de energia elétrica. A incerteza dos preços da energia elétrica em mercado e a incerteza inerente à disponibilidade da radiação solar devem ser tidas em conta para que a tomada de decisão por parte do produtor da CCST seja o mais eficiente possível.

As FER são caracterizadas pela sua intermitência e variabilidade o que confere ao seu aproveitamento, neste caso específico das CCST, uma característica não despachável. A consideração da incerteza associada a esta FER vem atenuar essa característica não despachável [13]. Um perfil de potência associado com radiação solar verificado em Évora (38,5°N, 7,9°W), mostrando a previsibilidade limitada da radiação solar no ano de 2009 é apresentada na Figura 1.9.

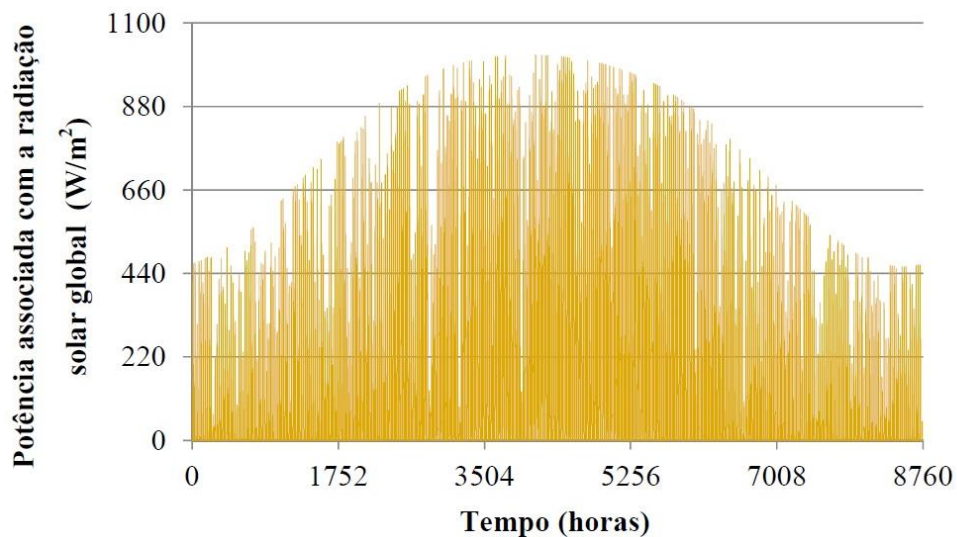


Figura 1.9 – Potência associada com a radiação solar, Évora 2009 [13].

A característica não despachável da CCST pode ser atenuada utilizando um SAE, possibilitando uma melhor gestão da energia disponível na central [14]. Os SAE permitem aumentar o lucro das CCST através da redução em tempo real da variabilidade da produção, devido ao facto de se dispor de energia térmica armazenada para ser comercializada em períodos de baixa ou nula radiação solar [15]. Além disso, dependendo da CCST e das características do local da instalação, um SAE pode contribuir para a redução dos custos, devido a uma utilização mais intensiva do módulo de produção [11, 16].

A otimização da exploração de CCST é importante para as empresas de produção de energia elétrica, pelo valor económico que pode acrescentar, podendo representar volumosas poupanças quando resolvido de forma ótima. Existe, assim, um grande interesse pelo desenvolvimento de ferramentas computacionais que permitam convergir para a tomada de decisões ótimas.

A complexidade subjacente ao problema da exploração de curto prazo de CCST com SAE leva a que ferramentas matemáticas e computacionais intervenham.

A motivação para o estudo do tema da dissertação é reforçada pelos seguintes fatores:

- A necessidade de intensificar a pesquisa por melhores resultados no suporte das decisões, resultando num melhor aproveitamento do recurso solar existente, por parte das empresas produtoras de energia elétrica;
- A vantagem da grande evolução tecnológica na área computacional que permite às metodologias de otimização maior facilidade de resolução de problemas.

Como tal, surge a necessidade de construção de modelos matemáticos de decisão que contribuem para uma clarificação e uma sistematização do problema a resolver.

Assim, nesta dissertação, a nova metodologia de otimização estocástica, baseada em PLIM, considera não só as restrições de rampa, mas também a incerteza nos preços da energia elétrica em mercado diário, a incerteza da potência térmica disponível no campo solar (CS) e ainda a medida de risco CVaR, concebendo ao planeamento um maior nível de realidade não desprezando aspetos importantes para a obtenção de resultados realistas com o intuito final de gerar melhores decisões.

1.3. Estado da arte

O efeito fotovoltaico foi observado pela primeira vez pelo físico francês Alexandre Edmond Becquerel em 1839, que na verdade o confunde com o efeito fotoelétrico. Mais tarde também Heinrich Hertz, em 1887, e Albert Einstein, em 1905, estudam este efeito. Esta observação e os consequentes estudos desencadearam a utilização e desenvolvimento de nova tecnologia e instalações, tendo estas começado nos finais da década de 90. Esta nova tecnologia rapidamente se dividiu em duas categorias: a fotovoltaica e a solar térmica.



Figura 1.10 – Alexandre Edmond Becquerel

Em [17,19] é apresentada a tecnologia solar térmica, dando destaque ao concentrador cilíndrico com refletor parabólico, ao concentrador linear com refletor do tipo Fresnel, ao concentrador de disco parabólico e ao recetor central de torre. Uma representação esquemática associada a cada um destes concentradores é apresentada na Figura 1.11.




Figura 1.11 – Concentradores solares térmicos [18].

Em [20] é verificado que as centrais solares térmicas compostas por concentradores cilíndricos com refletores parabólicos predominam a nível mundial, representado cerca de 90% de quase toda a tecnologia solar instaladas, devido à existência de esquemas de incentivos que permitiram alcançar um elevado grau de maturidade.

Em [21] é verificado que os esquemas de incentivos Europeus, baseados em subsídios verdes, estimulam a competitividade das CCST em relação às centrais de combustíveis fósseis, visto que, permitem reduzir os custos de produção de energia elétrica. Uma vez que os esquemas de incentivo têm contribuído para o aumento da instalação das CCST em larga escala, [22] realiza uma avaliação técnico-económica para permitir a integração das CCST na rede elétrica com segurança.

Em [19] é verificado que a integração das CCST na rede elétrica é condicionada pela variabilidade não controlável e previsibilidade limitada da radiação solar, sendo a nebulosidade um fator revelante que torna a previsão uma tarefa difícil.

Na literatura especializada, várias aplicações para a previsão da radiação solar têm sido propostas, com vista a minimizar os erros inerentes aos resultados da previsão. Dois tipos de modelos aplicados à previsão de radiação solar são largamente utilizados, estes são os modelos físicos e os modelos estatísticos.

Em [57] é afirmado que os modelos físicos utilizam informações físicas e meteorológicas para atingir as melhores estimativas da radiação solar, num local, podendo posteriormente utilizar modelos estatísticos para minimizar os erros remanescentes.

Em [59] é referido que os modelos físicos apresentam uma certa complexidade matemática devido à utilização de equações que traduzem as leis físicas que regem o comportamento dinâmico da atmosfera. Como consequência, estes modelos

físicos, requerem a utilização de computadores suficientemente rápidos para conseguir obter resultados antes que a previsão deixe de ser útil para o intervalo de tempo desejável. As desvantagens apontadas, na literatura especializada, para os modelos físicos, consistem no facto de estes serem modelos que requerem um esforço computacional excessivo, apresentarem erros consideráveis quando existem mudanças de tempo inesperadas e o facto de não serem eficazes para previsões no horizonte temporal a curto prazo.

Em [59] é feita uma comparação entre vários modelos físicos para avaliar os erros de previsão da radiação solar obtidos para uma dada região de Espanha. A média dos erros de previsão horária varia entre 20,8% e 31,7% para o primeiro dia de previsão, 21,3% e 36,8% para o segundo dia de previsão e 22,4% e 40,9% para o terceiro dia de previsão.

Em [67] é afirmado que os modelos estatísticos são menos complexos em relação aos modelos físicos, devido ao facto de apenas utilizarem bases de dados radiométricos. Este facto reduz a exigência computacional requerida pelo modelo para obter previsões da radiação solar no horizonte temporal de curto prazo.

Os modelos estatísticos convencionais são modelos baseados em séries temporais [68], como o modelo de persistência, o modelo autorregressivo e o modelo autorregressivo integrado de média móvel [69]. O modelo de persistência é considerado o mais simples das séries temporais. Este tem uma melhor aplicabilidade para previsões de muito curto prazo.

Em [31] é feita a análise da geração de cenários aplicados à otimização estocástica e apresentado um algoritmo para geração de cenários com base em modelos ARIMA.

Modelos de previsão são considerados para suprirem dificuldades e conduzirem à obtenção de boas previsões. Esses modelos envolvem as seguintes linhas de

investigação: as redes neuronais [70, 71, 72], a lógica difusa [73], os algoritmos evolucionários [74], e os modelos híbridos [67, 79].

A difícil implementação dos modelos baseados em redes neuronais, dos modelos baseados na lógica difusa, dos modelos baseados nos algoritmos evolucionários e dos modelos híbridos tem como causa o facto de cada modelo assumir um comportamento próprio devido a sua característica construtiva. No entanto, é afirmado que os modelos baseados em técnicas de inteligência artificial superam os modelos baseados em séries temporais para a previsão da radiação solar a curto prazo [19].

Em [59, 60] é proposto modelos estatísticos baseados em técnicas de inteligência artificial para prever a radiação solar em Espanha e zonas Mediterrânicas, constituindo potenciais soluções para atenuar a variabilidade não controlável da radiação solar e conseqüentemente a não despachabilidade das CCST.

Por forma a atenuar os efeitos da variabilidade e intermitência das FER os SAE protagonizam um papel de elevada importância. Em [27] é utilizado SAE e ar comprimido para melhorar o planeamento dos sistemas eólicos. Em [28] é analisado o desempenho de baterias acopladas a uma CF de modo a reduzir a não despachabilidade destas centrais. Ambos os estudos demonstram que os SAE tendem a garantir a estabilidade no fornecimento de energia. Em [29] são obtidos resultados mais satisfatórios ao introduzir o SAE por ar comprimido num parque eólico.

A constante e progressiva evolução tecnológica permite que as instalações e projetos de implementação de CCST se tornem mais aliciantes para os investidores. Redução no custo de produção de energia elétrica para o mesmo nível de produção permite a um produtor detentor de uma CCST melhorar o lucro. Pelo que, a adoção de nova tecnologia e de meios de suporte à decisão são relevantes contribuições.

Em [23, 24] é realizado um estudo intensivo acerca de como a evolução tecnológica permitirá reduções pertinentes no custo da energia elétrica produzida a partir de CCST. Melhorias na concepção das centrais, avanços tecnológicos nos recetores e concentradores solares, inovações emergentes no que respeita a SAE, fluido de transferência de calor (FTC) e planeamentos mais eficazes são temas abordados. Em [23] é afirmado que as CCST que utilizam a tecnologia de coletores cilindro-parabólicos apresentam a maior redução no custo de energia elétrica produzida no futuro.

Em [25, 26] é feito um estudo e análise aos diversos FTC aplicados em CCST e como este desenvolvimento tecnológico e novas diversidades de FTC vem colaborar na redução do custo da energia elétrica produzida pelas CCST.

A incerteza faz parte dos problemas de decisão nos mercados de energia elétrica. Como consequência esta incerteza afeta os preços e a procura de energia elétrica. Um destes problemas de decisão concerne no tema abordado nesta dissertação, a oferta em mercado por parte de um produtor de energia elétrica.

A otimização estocástica proporciona uma modelização adequada a partir da qual os problemas de decisão contendo incerteza são devidamente formulados [30]. Em [31] é feita uma abordagem ao tema da incerteza e da programação estocástica aplicada aos mercados de energia elétrica, tanto do ponto de vista do produtor como do consumidor. No entanto, na literatura especializada, as primeiras técnicas de otimização desenvolvidas para resolver o problema de planeamento de curto prazo de sistemas de energia elétrica foram técnicas baseadas em metodologias determinísticas.

Em [32] é proposta uma metodologia determinística, baseada PLIM, para analisar o desempenho económico de uma CCST com SAE, sendo avaliado o impacto sobre os lucros obtidos no mercado diário.

Em [33] é proposta uma metodologia determinística para maximizar os lucros de uma CCST com SAE, situada em Espanha, considerando os preços da energia elétrica no mercado diário.

Em [15, 34] é proposta uma metodologia determinística, baseada PLIM, com objetivo de determinar o valor de capacidade das CCST com e sem SAE. Os resultados obtidos mostram que para o caso de CCST sem SAE os valores variam entre 60% e 86% da capacidade máxima da CCST, enquanto com SAE esses valores variam entre 79% e 92% da capacidade máxima da CCST.

Em [35, 42] é proposta uma metodologia determinística, baseada em PLIM, com o objetivo de avaliar a coordenação de CCST com SAE com uma central eólica, mostrando que o SAE tem um papel importantíssimo ao armazenar a energia em horas cujo preço se encontra mais baixo, passando-a para horas com preços mais atrativos.

Estas abordagens determinísticas perderam o interesse pois não consideram a incerteza associada com diversos parâmetros associados ao problema de decisão. Em contrapartida as metodologias baseadas em programação estocástica têm sido amplamente utilizadas para modelizar a incerteza através de um conjunto de cenários [36].

Em [37, 38] é apresentada uma metodologia de otimização estocástica aplicada a problemas sujeitos a diversas fontes de incerteza. Em [39] é ainda abordado o tema de decomposição estocástica para resolução de problemas complexos que de outra forma necessitariam de um requisito computacional muito elevado.

Em [40] é aplicada uma metodologia de otimização estocástica ao problema de planeamento de curto prazo de uma CCST com SAE considerando um conjunto de cenários para a radiação solar. No entanto, a incerteza dos preços da energia elétrica no mercado diário e a análise de risco não são considerados nesta metodologia.

Em [41] é feita uma análise sobre as diferentes metodologias de otimização aplicadas à determinação das ofertas ótimas a submeter em mercado diário por parte dos produtores de energia elétrica.

Na otimização estocástica a incerteza é modelizada através de um conjunto de cenários para determinados parâmetros. Quanto maior o número da amostra mais precisos e realista são os resultados obtidos, no entanto, amostras com elevado número de dados acarretam tempos de computação pouco aceitáveis. Neste sentido, algoritmos de redução de cenário foram desenvolvidos para, mantendo as características estatísticas e estocásticas da amostra, reduzir para um número aceitável estas amostras.

Em [43] são aplicados dois algoritmos diferentes de redução de cenários, *backward reduction* e *forward reduction*, a um conjunto de dados do consumo de energia elétrica, sendo concluído que mesmo após uma redução de 50% no número de cenários a precisão relativa da árvore inicial foi mantida nos 90%.

Resultados empíricos reportados em [44, 45] apuram que os conjuntos que são reduzidos através de técnicas de redução de cenários resultam, em casos práticos, em bons resultados.

Em [45] é apresentado um novo algoritmo para redução de cenários que demonstra ser mais eficiente na escolha dos cenários, acarretando apenas um tempo de computação superior relativamente a outros algoritmos.

Uma temática com bastante importância em qualquer análise e que vem emergindo na área da energia elétrica e conseqüentemente no planeamento de centrais e na venda em mercado de energia elétrica é a gestão de risco. Neste tipo de problemas é realizada a maximização ou minimização da função objetivo mas, no entanto, o nível de risco que o agente está disposto a correr na sua decisão é também levado em conta. Esta gestão de risco é feita através de medidas de risco [31], tais como:

i) Variância; ii) *Shortfall Probability* (SP); iii) *Expected Shortage* (ES); iv) *Value-at-Risk* (VaR); v) CVaR.

Em [46] é apresentado um estudo enunciando as propriedades matemáticas necessárias para que uma medida de risco seja considerada coerente, i.e., para que a sua aplicabilidade aos problemas seja maximizada em termos de funcionalidade.

Em [55] é feito um estudo acerca da aplicabilidade das medidas SP e ES em problemas estocásticos baseados em PLIM, resultados válidos são obtidos dentro de um tempo de computação aceitável.

As medidas de risco podem ser introduzidas na metodologia de programação através da função objetivo, como especificado em [47, 48], ou com a adição de restrições ao problema. Em [31] ambos os métodos são abordados.

Em [49] é feito um estudo acerca da medida de risco CVaR e VaR onde se conclui que o CVaR pode ser minimizado recorrendo a programação linear e esta minimização tem implicações no VaR, reduzindo o seu valor. Resultados válidos são obtidos e em [50] é aprofundado ainda mais o estudo sobre o CVaR.

Mais recentemente surgiu, em alternativa às medidas de risco, a aplicação da gestão de risco através do Domínio Estocástico. Este tema é abordado em [51, 52, 54] para um Domínio Estocástico de primeira ordem e em [55] para um Domínio Estocástico de segunda ordem.

Em [56] é realizado um estudo que aplica a gestão de risco ao problema de planeamento de curto prazo para um sistema electroprodutor onde é aplicada uma metodologia de otimização estocástica considerando incerteza. Neste estudo é destacado contributo que a gestão de risco, nomeadamente utilizando o CVaR, acrescenta à metodologia de otimização e consequentes resultados.

Nesta dissertação uma nova metodologia de otimização estocástica baseada em PLIM considerando incerteza e risco é proposta para resolver o problema da exploração de curto prazo de CCST com SAE. Em suma, a metodologia apresentada nesta dissertação reúne os seguintes atributos:

- Otimização estocástica;
- Consideração da incerteza dos preços da energia elétrica no mercado diário;
- Consideração da incerteza da potência térmica disponível no campo solar, i.e., a radiação solar;
- Algoritmo de redução de cenários baseado no método *Fast Forward Selection*;
- Consideração da medida de risco CVaR.

1.4. Organização do texto

Esta dissertação está organizada em seis capítulos distintos. No capítulo 2 são apresentadas diferentes implementações tecnológicas para o aproveitamento de energia solar através da sua concentração e também é feita uma breve introdução acerca das energias renováveis. No capítulo 3 é apresentada a metodologia de otimização estocástica aplicada ao problema de planeamento de curto prazo de sistemas de energia solar. No capítulo 4 é declarada a formulação do problema em estudo, enunciando a função objetivo e respetivas restrições bem como explicadas todas as variáveis a estas associadas. No capítulo 5 são descritos os casos de estudo para os quais foi aplicada a metodologia de otimização e são apresentados os respetivos resultados, sendo efetuada uma análise comparativa entre eles. No capítulo 6 a dissertação são apresentadas as conclusões e possíveis direções de investigação. Seguidamente é apresentada uma descrição mais pormenorizada do conteúdo de cada capítulo.

No capítulo 2 é abordado o tema da energia solar, elaborando acerca da sua utilização e dos conceitos inerentes à radiação solar. São apresentadas diferentes tipos de tecnologia utilizadas para a concentração da radiação solar, as suas vantagens e desvantagens. É descrito o funcionamento de uma CCST com SAE com especial ênfase na utilização de concentradores cilíndricos com refletor parabólico

No capítulo 3 é apresentada a metodologia de otimização aplicada para o suporte de decisões do problema da exploração de curto prazo de CCST com SAE. Para a resolução do problema, este estudo assenta numa metodologia de otimização estocástica baseada em PLIM. São ainda identificadas as fontes de incerteza do problema modelizadas através de uma árvore de cenários e apresentado o algoritmo de redução de cenários desenvolvido e a medida de risco CVaR utilizada para controlar a variabilidade do lucro esperado.

No capítulo 4 é descrito o problema de exploração de CCST com SAE considerando incerteza e risco. São apresentadas as variáveis inerentes a uma CCST com SAE no que respeita à potência térmica, elétrica e energia armazenada. É apresentada a função objetivo e as restrições associadas ao problema.

No capítulo 5 são apresentados 3 casos de estudo com vista a resolver o problema de exploração de CCST com SAE. O primeiro caso de estudo consiste numa otimização determinística, o segundo caso de estudo numa otimização estocástica considerando incerteza e o terceiro caso de estudo consiste numa otimização estocástica considerando a incerteza e o risco. É aplicado um algoritmo de redução de cenários para aplicação na metodologia de otimização estocástica considerando incerteza. É ainda apresentada a análise de resultados.

Por fim, no capítulo 6 é enunciada uma síntese do trabalho e apresentada as principais conclusões que se extraíram da investigação desenvolvida para a resolução do problema da exploração de CCST com SAE. Ainda, são apontadas algumas direções em que pode ser desenvolvida investigação de interesse relevante para a solução do problema.

1.5. Notação

Em cada um dos capítulos desta dissertação é utilizada a notação mais usual na literatura especializada, harmonizando, sempre que possível, aspectos comuns a todos os capítulos. Contudo, quando necessário, em cada um dos capítulos é utilizada uma notação apropriada. As expressões matemáticas, figuras e tabelas são identificadas com referência ao capítulo em que são apresentadas e são numeradas de forma sequencial no capítulo respectivo, sendo a numeração reiniciada quando se transita para o capítulo seguinte. A identificação de expressões matemáticas é efetuada através de informação numérica por ordem crescente entre parênteses curvos () e a identificação de referências bibliográficas é efetuada através de parênteses retos [].

Capítulo 2

Energia Solar Térmica

Neste capítulo é abordado o tema da energia solar, elaborando acerca da sua utilização e dos conceitos inerentes à radiação solar. São apresentados diferentes tipos tecnologia utilizados para a concentração da radiação solar, as suas vantagens e desvantagens. É descrito o funcionamento de uma CCST com SAE com especial ênfase na utilização de concentradores cilíndricos com refletor parabólico.

2.1. Energia Solar

A energia solar é a fonte de energia que possibilita aos seres vivos a vida no planeta Terra. É uma das opções para concretizar o desejo de que futuramente todas as sociedades possam usufruir de fontes de energia limpa e sustentáveis. É através de reação nuclear que ocorre no núcleo do Sol a fusão de núcleos de Hidrogénio em Hélio, que origina a conversão da diferença no balanço de massa em energia, denominada de energia solar. O planeta Terra funciona como um grande coletor solar que recebe, através de ondas eletromagnéticas, a energia solar que origina manifestações de diversas formas no planeta Terra. A fotossíntese das plantas, o aquecimento de camadas de ar que originam o vento e o ciclo da água são exemplos de manifestações da energia solar na Terra [58].

O Sol juntamente com o vento, marés, biomassa, ondas e o calor emitido pelo planeta Terra são considerados as principais fontes de energia renováveis. A energia solar é considerada como sendo uma fonte renovável pois estará disponível enquanto o Sol continuar a brilhar. O Sol, sendo uma estrela, inevitavelmente atingirá o seu fim. No entanto, este fim é estimado que seja entre 4 a 5 biliões de anos a se concretizar [58].

Os combustíveis fósseis estão disponíveis em reservas no Planeta que por prospeção vão contribuindo para as necessidades energéticas da civilização. No entanto, estas reservas são finitas. Com o nível de consumo energético mundial em crescimento estas reservas garantem as necessidades energéticas da civilização sociedades em pleno durante algumas décadas, mas dependendo do recurso fóssil em questão [58]. Assim, a necessidade da introdução de uma maior quantidade de energias renováveis na matriz energética mundial tem uma especial atenção por parte dos órgãos governamentais a nível mundial.

A integração de sistemas electroprodutores renováveis na rede elétrica obedece a projetos cada vez mais ambiciosos, visando o desenvolvimento sustentado e as questões ambientais associadas ao uso de fontes de energia não renováveis, sendo de salientar que a eficiência energética e a redução das emissões poluentes representam uma das prioridades da iniciativa europeia Energia – 2020 [66].

A energia radiante emitida pelo Sol, também denominada por radiação solar, é aproveitada em diversas aplicações da engenharia com destaque para o aquecimento de água e obtenção de energia elétrica. As CCST são uma forma de obtenção de energia elétrica, a partir da energia térmica captada do Sol. Estas centrais utilizam lentes e/ou espelhos que podem estar associados a mecanismos de seguimento do Sol, para focar grandes áreas de radiação solar em pequenos feixes. Esta radiação é concentrada pelos coletores solares no CS, como representado na Figura 2.1, e posteriormente utilizada como fonte de calor para as CCST [13].




Figura 2.1 – Captação da radiação solar pelo coletor solar [13].

O valor da intensidade radiação solar apresenta incerteza devido à sua característica intermitente e à sua previsibilidade limitada. No que respeita à gestão de uma CCST esta incerteza é considerada com o intuito de atenuar a sua característica não despachável para que se possa assegurar compromissos futuros

de fornecimento de energia elétrica, previamente estabelecidos através de contratos bilaterais ou no mercado diário [66].

Os métodos de previsão de radiação solar contribuem na atenuação da variabilidade não controlável desta fonte de energia. Na literatura especializada a previsão de radiação solar diverge entre os modelos físicos e os modelos estatísticos. Nos modelos físicos são utilizados dados físicos e meteorológicos para a previsão de radiação solar [57], nos modelos estatísticos são analisadas séries temporais de dados [59].

A investigação no campo da previsão de radiação solar recorre às áreas das redes neuronais, como apresentado em [70, 71, 72], da lógica difusa [73], dos algoritmos evolucionários [74] e dos modelos híbridos [67,75].

No caso particular de uma CCST a utilização de SAE vem, em conjunto com a previsão de radiação solar, dar um contributo na atenuação da variabilidade não controlável desta fonte de energia. Permite armazenar a energia térmica proveniente da radiação solar para fazer face a períodos de menor radiação e permite também uma redução nos custos através de uma utilização mais intensiva do módulo de produção [66].

Nas CCST a energia solar é utilizada pela captação da radiação solar no CS que pode ser feita através de diversa tecnologia de concentração solar, dando destaque nesta dissertação ao concentrador cilíndrico com refletor parabólico, ao concentrador linear com refletor do tipo Fresnel, ao recetor central de torre e ao concentrador de disco parabólico.

2.2. Tecnologia de Concentração Solar

Nas CCST a radiação solar é utilizada para aquecer um FTC que, uma vez aquecido, será utilizado para gerar vapor de alta temperatura cuja energia é convertida em energia elétrica através de um gerador acoplado a uma turbina de vapor [17].

As superfícies de captação dos coletores solares são compostos por espelhos ou lentes onde a radiação solar é direcionada especificamente para um ponto ou superfície com menores dimensões denominada de superfície de aquecimento. Esta superfície consiste na tubagem onde circula um FTC que vai aumentando de temperatura por ação da concentração solar.

O principal tipo de tecnologia de aproveitamento solar é o concentrador cilíndrico com refletor parabólico, o concentrador linear com refletor do tipo Fresnel, o recetor central de torre e o concentrador de disco parabólico. A tecnologia de aproveitamento solar térmico com maior utilização em mercado é o concentrador cilíndrico com refletor parabólico cujos primeiros projetos comerciais remontam os anos 80 nos EUA [13].

A tecnologia de concentração solar está dividida em dois grupos, as que possuem um sistema de foco em linha e as que possuem um sistema de foco num ponto. O concentrador linear com refletor do tipo Fresnel e concentrador cilíndrico com refletor parabólico possuem um sistema de foco em linha onde utilizam um sistema de controlo de apenas um eixo. O recetor central de torre e o concentrador de disco parabólico possuem um sistema de foco num ponto utilizando um sistema de controlo de dois eixos para concentrar a radiação solar [11].

2.2.1. Concentrador de Disco Parabólico

O concentrador de disco parabólico consiste num refletor em forma de parábola projetado para focalizar a radiação solar num único ponto, como é apresentado na Figura 2.2.



Figura 2.2 – Concentrador de disco parabólico [17].

A radiação solar é concentrada num recetor, que aquece um fluido, convertendo energia solar em energia elétrica. O recetor, que é associado a um gerador elétrico, pode ser uma microturbina ou um motor de *Stirling* [11]. Este conjunto é denominado de unidade de conversão de energia e produz diretamente energia elétrica que, posteriormente é entregue à rede.

O recetor funciona como interface entre o disco parabólico e o gerador elétrico. No caso do motor de *Stirling*, este pode ser de dois tipos, de pistão livre ou cinemático. O motor cinemático funciona com hidrogénio e o motor de pistão livre funciona com hélio. O motor de pistão livre, ao contrário do cinemático, não produz fricção o que leva a uma redução na sua manutenção [11].

O concentrador de disco parabólico pode alcançar a máxima eficiência teórica de um motor termodinâmico, denominada da eficiência de *Carnot*. Assim, esta

tecnologia de aproveitamento solar, possui a maior potencialidade de conversão de energia térmica em energia elétrica [17]. O facto do concentrador de disco parabólico ser uma tecnologia modular, permite-lhe ser aplicado em instalações de geração distribuída [11].

As grandes desvantagens do concentrador de disco parabólico devem-se ao facto de cada módulo desta tecnologia de aproveitamento solar térmico necessitar de um motor próprio, o que se traduz em um acréscimo de custo de investimento e de custo de operação e manutenção, e o facto de não existir uma solução prática e simples para o armazenamento térmico no concentrador solar de disco parabólico. Este tipo de tecnologia de aproveitamento solar térmico tem sido testada com sucesso, no entanto, tem crescido comercialmente com grandes limitações [11].

2.2.2. Recetor Central de Torre

O recetor central de torre solar utiliza um campo circular ou semicircular de espelhos, ao quais se denominam de helióstatos, que refletem e concentram a radiação solar num recetor instalado no cima de uma torre, como é apresentado na Figura 2.3.




Figura 2.3 – Esquema típico de uma CCST de recetor central de torre [62].

Os Helióstatos são controlados computacionalmente para efetuarem o seguimento do sol através de um sistemas de dois eixos. O recetor central de torre utiliza vapor, água ou sal fundido como FTC no entanto, o sal fundido é mais comum nas instalações em funcionamento atualmente [11].

O recetor central de torre é a tecnologia de aproveitamento solar térmico que atinge maiores temperaturas no coletor da radiação, situado no cimo da torre central, podendo operar entre os 250°C e os 565°C nas centrais com utilização de sal fundido como FCT [17].

Esta tecnologia de aproveitamento solar necessita de mais instalações para que se assumam como comercialmente viáveis e venham a ser instaladas em larga escala. No entanto várias instalações comerciais piloto são implementadas, exemplo disso é a central GEMASOLAR de 19,9 MW em Sevilha, como é apresentado na Figura 2.4.



Figura 2.4 – Recetor central de torre em Sevilha (GEMASOLAR) [61].

2.2.3. Concentrador Linear com Refletor do Tipo *Fresnel*

O concentrador linear com refletor do tipo *Fresnel*, como apresentado na Figura 2.5, consiste na utilização de diversos espelhos refletores planos, ou ligeiramente curvos, dispostos com diferentes ângulos de modo a concentrar a radiação solar no recetor central situado a uma cota mais elevada [17].



Figura 2.5 – Concentrador linear com refletor do tipo *Fresnel* [17]

Os espelhos refletores da radiação solar possuem um sistema de controlo de posição de um eixo e são otimizados individualmente para garantir que a radiação solar é concentrada no recetor central durante as várias posições do Sol durante o decorrer dia, como apresentado na Figura 2.6. O recetor central consiste num tubo de absorção contendo no seu interior um FTC [11].




Figura 2.6 – Acompanhamento da posição solar pelo refletor *Fresnel* [60].

O concentrador linear com refletor do tipo *Fresnel* permite a utilização de água como FTC para a produção de vapor o que permite evitar a utilização de permutadores de calor. O vapor produzido nos tubos de absorção serve para acionar uma turbina, com vista à produção de energia elétrica através de um gerador. O vapor será depois condensado, retornando aos tubos de absorção, para a repetição do processo [13].

O concentrador linear com refletor do tipo *Fresnel* é uma tecnologia de aproveitamento solar térmico similar ao concentrador cilíndrico com refletor parabólico, podendo ambos ter a possibilidade de incorporação de um SAE. No entanto o concentrador linear com refletor do tipo *Fresnel* tem a vantagem de possuir um custo de investimento e um custo de operação e manutenção mais reduzido, devido a utilizar componentes mais baratos. Possui também, devido à sua estrutura, um menor efeito negativo provocado pelo efeito do vento, o que reduz as perdas óticas e os danos nos espelhos refletores [11].

2.2.4. Concentrador Cilíndrico com Refletor Parabólico

O concentrador cilíndrico com refletor parabólico é constituído por espelhos refletores em forma de parábola que concentram a radiação solar num recetor central posicionado ao longo da linha de refletores focais [11], como é apresentado na Figura 2.7.



Figura 2.7 – Concentrador cilíndrico com refletor parabólico [24].

Esta tecnologia de aproveitamento solar térmico utiliza um sistema de posição de um eixo para orientar os espelhos refletores e o recetor central por forma a efetuar um seguimento otimizado da posição do Sol ao longo do dia. Os espelhos refletores em forma de parábola chegam a atingir uma distância de 100 metros e sua curvatura ronda os 5 a 6 metros [11].

O tubo recetor central, onde a radiação solar é concentrada através dos espelhos parabólicos refletores, como apresentado na Figura 2.8, contém um FTC que converte a radiação solar em energia térmica para, através da obtenção de vapor de alta temperatura, obter por conversão energia elétrica para entregar à rede. Na maioria das implementações de concentradores cilíndricos de refletor parabólico é utilizado óleo sintético como FTC, no entanto, novos projetos em construção utilizam sal fundido como FTC possibilitando um acréscimo da temperatura na ordem de 100°C [11].




Figura 2.8 – Pormenor da concentração solar no tubo contendo o FTC [62].

Os concentradores cilíndricos com refletor parabólico, para maximizar o aproveitamento da radiação solar, são projetados para serem instalados segundo um eixo Norte-Sul e efetuarem o seguimento do Sol segundo a direção Este-Oeste [11].

Esta tecnologia de aproveitamento solar térmico é a mais utilizada comercialmente e conseqüentemente é a que tem uma maior maturidade comercial. Os primeiros projetos de implementação de concentradores cilíndricos de refletor parabólico remontam aos anos 80, nos EUA, onde foram instaladas centrais denominadas de *Solar Energy Genarating Systems* (SEGS) [17].

Através dos incentivos governamentais às instalações de centrais com recurso a FER rapidamente as implementações de novas centrais, nomeadamente de CCST, aumentaram por todo o mundo. Assim, os concentradores cilíndricos com refletor parabólico, utilizados como tecnologia de aproveitamento solar térmico em CCST, dominaram o mercado. Em 2013 mais de 90% das instalações de CCST a nível mundial utilizam esta tecnologia de aproveitamento solar térmico, sendo que os EUA e Espanha lideram nas instalações deste tipo de CCST [24].

2.2.5. Tecnologia de Concentração Solar

Após uma descrição da tecnologia de concentração solar, importa resumir os aspetos que as caracterizam para ser possível um estudo comparativo. Na tabela 2.1 é apresentado e comparado identificando as diferenças para a tecnologia de concentração solar.

Tabela 2.1 – Comparação de tecnologia de concentração solar

	Refletor parabólico	Recetor central de torre	Refletor do tipo <i>Fresnel</i>	Disco Parabólico
Maturidade da tecnologia	Provada comercialmente	Projetos piloto comerciais	Projetos piloto	Projetos de demonstração
Custos	Moderado	Elevado	Baixo	Muito elevado
Risco associado	Baixo	Médio	Médio	Médio
Espaço ocupado	Elevado	Médio	Médio	Baixo
Eficiência termodinâmica	11-16	7-20	13	12-25
Uso de água (L/MWh)	3000	2000	3000	0
Margem para evolução	Limitada	Muito significativa	Significativa	Significativa

Os concentradores cilíndricos com refletor parabólico são a tecnologia de aproveitamento solar térmico que apresenta um grau de maturidade mais elevado, fazendo com que o valor de investimento e os custos de operação e manutenção estejam bem definidos. Esta tecnologia tem também, conduzido com sucesso, estudos e implementações práticas de SAE, o que lhe confere uma vantagem competitiva relativamente à restante tecnologia de concentração solar.

No âmbito desta dissertação é dado especial enfoque ao concentrador cilíndrico com refletor parabólico aplicado a uma CCST com SAE.

2.3. Central de Concentração Solar Térmica com SAE

A CCST é uma central termoelétrica que produz energia elétrica através da utilização da radiação solar para aquecer um FTC, utilizado para gerar vapor, que aciona uma turbina acoplada a um gerador elétrico [17]. Um esquema representativo de uma CCST com SAE é apresentado na Figura 2.9.

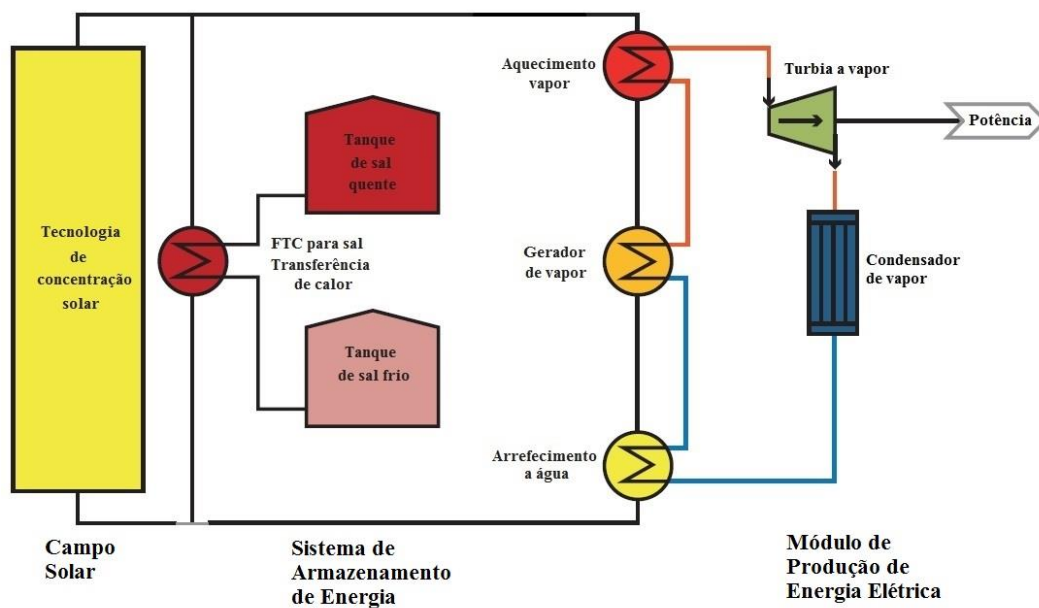


Figura 2.9 – Esquema representativo de uma CCST com SAE [17].

Na Figura 2.9 é possível verificar os principais componentes da CCST, o CS onde se utiliza uma tecnologia de aproveitamento solar térmico, o SAE, onde é realizado o armazenamento de energia térmica e o módulo de produção de energia elétrica onde é convertida a energia térmica em energia elétrica.

A CCST utiliza espelhos refletores, através do CS, para concentrar a radiação solar num coletor contendo um FTC. No subcapítulo anterior é apresentada uma análise de quatro tipos de tecnologia de concentração solar de possível utilização no CS. O concentrador cilíndrico com refletor parabólico é a tecnologia mais utilizada e que tem maior destaque nesta dissertação.

O FTC é aquecido, através da concentração da radiação solar, produzindo energia térmica que pode ser utilizada para gerar vapor e produzir energia elétrica, através do módulo de produção de energia, ou ser armazenada no SAE.

O SAE permite armazenar a energia térmica proveniente do CS para poder ser utilizada quando necessário contribuindo para um melhor planeamento da CCST [17]. A incorporação de SAE numa CCST melhora a eficiência da central, utilizando de forma mais intensiva o módulo de produção de energia elétrica, e atenua a característica não previsível e intermitente da FER utilizada.

O módulo de produção de energia elétrica consiste numa turbina de vapor de alta temperatura acoplada a um gerador de energia elétrica que fornece à rede a energia produzida pela CCST. Assim, a energia produzida pode provir de duas situações: i) diretamente do CS, ii) do SAE.

No âmbito desta dissertação será considerada uma CCST com SAE, como representado na Figura 2.9, utilizando sal fundido como FTC e considerando que no CS é implementado concentradores cilíndricos com refletor parabólico.

2.3.1. Fluido de Transferência de Calor

O FTC é a substância utilizada pelas CCST para efetuar trocas de calor entre os componentes do seu sistema. Existem diversos tipos de FTC e a sua utilização na indústria é muito mais antiga do que a utilização para aplicações em tecnologia de concentração solar. Os mais utilizados neste caso são os óleos sintéticos, os sais fundidos e a água [63].

Os óleos sintéticos foram os primeiros fluidos a serem usados nesta tecnologia e, conseqüentemente é o fluido com maior maturidade e experiência no mercado. No entanto, têm a desvantagem de possuir uma temperatura máxima de 400 °C que pode comprometer a eficiência do ciclo a vapor [25]. O óleo sintético é inflamável, tóxico e, quando a CCST está provida de SAE, passam a existir 3 ciclos de troca de calor, nomeadamente óleo, vapor e o armazenamento, levando a uma diminuição da eficiência global da central [63].

Os sais fundidos conseguem suportar temperaturas mais elevadas, mantendo-se estáveis até 550 °C, o que leva a uma melhor eficiência da CCST. Uma outra vantagem é o facto de ser mais fácil de integrar com o SAE utilizando tanques de armazenamento de sais fundidos. O inconveniente dos sais fundidos consiste no facto de estes congelarem a temperaturas inferiores a 100 °C levando a que exista um consumo de energia durante a noite para poder manter o fluido a uma temperatura aceitável de funcionamento [63].

A utilização de água como um FTC é vantajoso pois é simples e pode ser usado diretamente no ciclo de vapor, no entanto, este FTC está ainda em fase de investigação e levará o seu tempo até atingir maturidade comercial [63].

Para além destes FTC surgem hoje em dia estudos e investigações para a utilização de ar comprimido, de químicos e, na vanguarda do estado da arte, a utilização de nanotecnologia [26].

2.3.2. Sistema de Armazenamento Térmico

A CCST tem a possibilidade de incorporar um SAE tendo em conta que a radiação solar é concentrada para gerar energia térmica. No caso específico dos concentradores cilíndricos com refletor parabólico a implementação de SAE nas CCST tem já diversas aplicações comerciais, exemplo desta aplicação é a central Espanhola ANDASOL 1 [76], como apresentado na Figura 2.10.



Figura 2.10 – SAE da CCST ANDASOL 1 situada em Espanha [61].

A utilização de SAE permite efetuar um planeamento dos sistemas de energia solar térmica de modo a que o produtor possa maximizar o seu lucro [32]. As CSST, utilizando a energia solar como fonte primária, apresentam as mesmas características das centrais termoelétricas convencionais, cuja agregação de um SAE lhe confere uma elevada capacidade de predição e desfasamento da produção de energia elétrica. Esta mais valia representa uma enorme vantagem na ligação à rede elétrica [76].

O SAE permite armazenar energia ao longo do dia, em dois casos específicos: i) caso radiação solar disponível seja superior à que se pretende utilizar para gerar energia elétrica, ii) caso o preço da energia elétrica em mercado não seja atrativo, utilizando esta energia armazenada para produzir e vender energia elétrica em horas com um preço de energia elétrica mais competitivo ou com menor

radiação solar disponível. Na Figura 2.11 é representado o funcionamento típico de uma CCST com SAE.

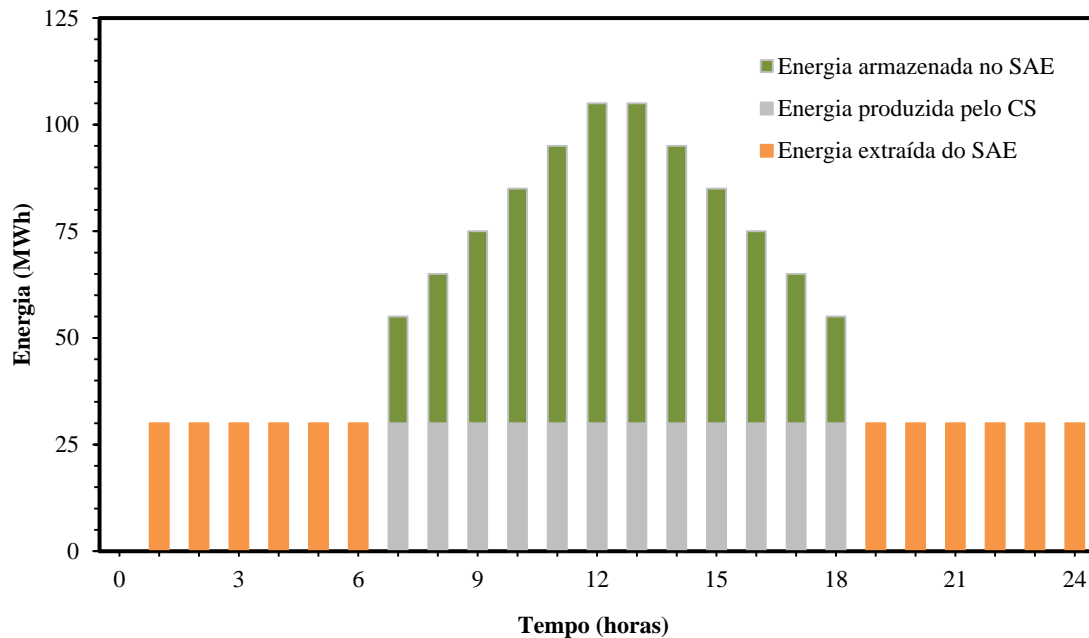


Figura 2.11 – Funcionamento típico de uma CCST com SAE.

A influência do SAE no planeamento é verificada na Figura 2.11, este fornece a energia térmica necessária para a produção de energia elétrica durante os períodos de baixa ou nenhuma radiação solar, a laranja, e armazena a energia em períodos cuja radiação solar é elevada, a verde. Nos períodos em que a radiação solar é abundante a produção de energia elétrica é assegurada diretamente pelo campo solar, a cinzento.

A configuração típica deste sistema de armazenamento consiste na combinação de dois tanques a diferente temperatura. O material de preenchimento dos tanques mais utilizado, considerando as temperaturas típicas de funcionamento das CCST, que variam entre os 300°C e os 600°C, consiste em sais fundidos, sendo a mistura mais utilizada constituída por 60% de nitrato de sódio (NaNO_3) e 40% de nitrato de potássio (KNO_3) [76].

Nos últimos anos, têm-se apostado na investigação de sistemas com geração direta de vapor. Esta solução apresenta como vantagens a eliminação de permutadores de calor entre o circuito de recolha de energia térmica e o circuito de armazenamento, a diminuição dos custos das CCST e o aumento do rendimento da central. No entanto, esta solução apresenta como desvantagem o aumento da pressão no circuito hidráulico e no circuito recetor, o que provoca uma maior necessidade de controlo de operação da central [76].

Capítulo 3

Metodologia de Otimização

Estocástica

Neste capítulo é apresentada a metodologia de otimização aplicada para o suporte de decisões do problema da exploração de curto prazo de CCST com SAE. Para a resolução do problema, este estudo assenta numa metodologia de otimização estocástica baseada em PLIM. São ainda identificadas as fontes de incerteza do problema modelizadas através de uma árvore de cenários. Finalmente, é apresentado o algoritmo de redução de cenários desenvolvido e a medida de risco CVaR utilizada para controlar a variabilidade do lucro esperado.

3.1. Caracterização da Incerteza

A incerteza é um fator que tem que ser considerado na tomada de decisão racional, visto que, a ausência da sua consideração pode perturbar os proveitos provenientes do aproveitamento do recurso solar. A maior parte das decisões são tomadas com base em previsões, o que, por si só, origina uma dificuldade acrescida. Mesmo que o problema de decisão não exija previsão, outra condicionante é a insuficiência de informação que representa um acréscimo de dificuldade. Pelo que, é importante fazer uma avaliação do grau de incerteza existente no processo de decisão, i.e., introduzir uma estimativa do risco envolvido.

O preço da energia elétrica no fecho do mercado diário, a quantidade de energia, a radiação solar e a velocidade do vento são exemplos de parâmetros incertos que coexistem nos problemas reais no âmbito da exploração de sistemas de energia elétrica.

Os dois parâmetros incertos relevantes para um produtor detentor de CCST são a radiação solar e os preços da energia elétrica. Por um lado, a volatilidade dos preços da energia elétrica reflete o comportamento dinâmico do mercado de eletricidade. Por outro lado, a intermitência da radiação solar, derivada da flutuação desta FER, dificulta a capacidade de decidir quando e quanta energia produzir, visto que, um produtor está dependente do nível de radiação solar direta para cada período de tempo.

Do ponto de vista computacional a incerteza pode ser modelizada através de cenários, que representam um possível desfecho ou valor para um conjunto de parâmetros de entrada [31]. Os possíveis desfechos, i.e. cenários, desse parâmetro de entrada constituem um conjunto finito de valores cuja representação é feita na forma de uma árvore de cenários, como é apresentado na Figura 3.1.

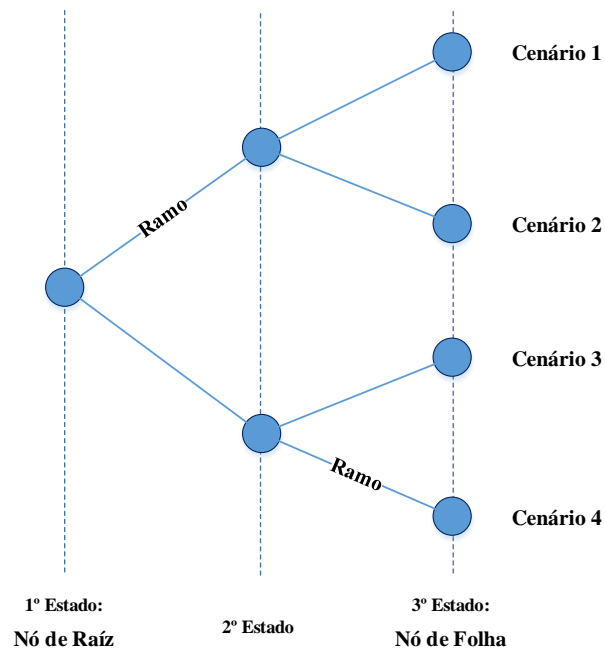


Figura 3.1 – Árvore de cenários de três estados.

A árvore de cenários é composta pela raiz, nós e ramos como é apresentado na Figura 3.1. A raiz ou nó de raiz consiste no início do horizonte de planeamento, os nós consistem num ponto específico no tempo onde as decisões são tomadas e os ramos representam um possível desfecho para uma dada variável. Os nós do último estado são também conhecidos como nós de folha e o caminho entre a raiz e um nó de folha representa um cenário. As tomadas de decisão são representadas, na árvore de cenários, pelos diferentes estados [31].

No âmbito desta dissertação são considerados dois parâmetros incertos para a metodologia de otimização estocástica, nomeadamente o preço da energia elétrica em mercado diário e a radiação solar na forma de potência térmica disponível no CS. Assim, em cada hora do horizonte temporal, existe uma combinação de preços de energia elétrica em mercado diário e potência térmica disponível no campo solar que dá origem ao número total de cenários. Esta combinação é apresentada na Figura 3.2.

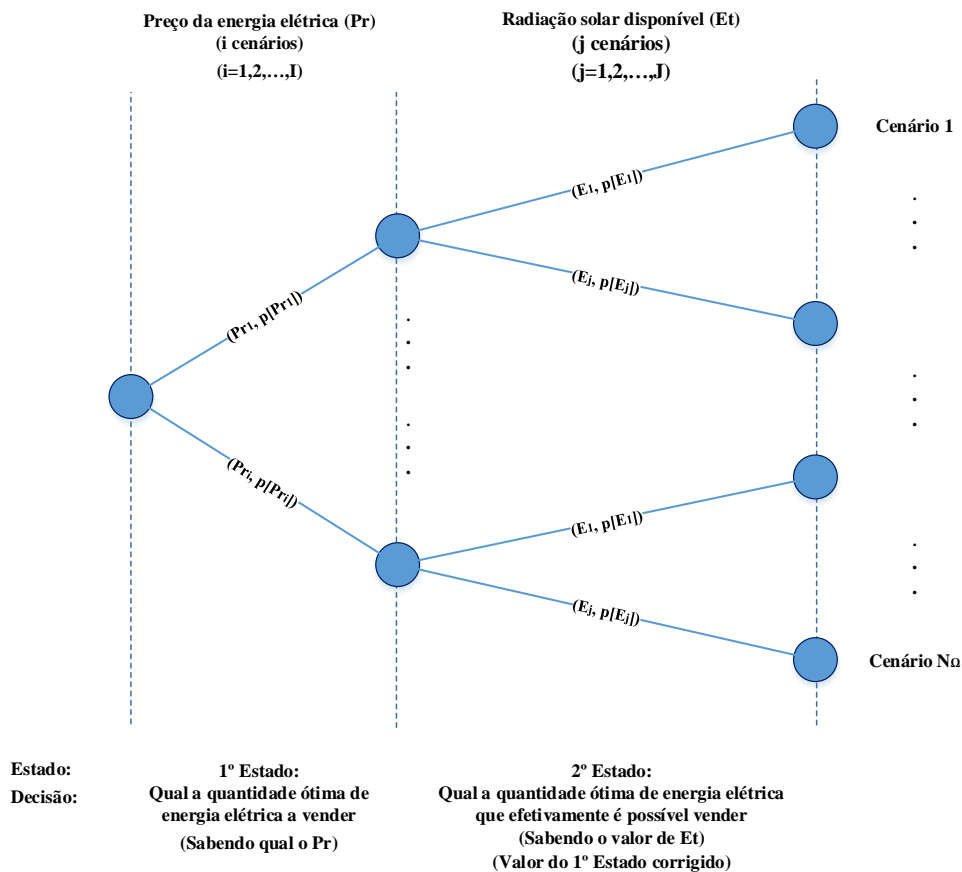


Figura 3.2 – Árvore de cenários.

A Figura 3.2 mostra que uma probabilidade de ocorrência é atribuída ao preço de energia elétrica no mercado diário e à potência térmica disponível no CS. A probabilidade do cenário é obtida através do produto das probabilidades de cada parâmetro incerto, sendo que no final a soma das probabilidades de todos os cenários totalizará o valor 1.

No primeiro estado é revelado a incerteza relacionada com o preço de energia elétrica dando origem a um valor ótimo de energia a ser vendida em mercado diário. Contudo, no segundo estado, é revelada a incerteza da potência térmica disponível no CS que irá limitar o valor de produção de energia. Assim, é obtido o valor final ótimo de energia a vender em mercado diário, sendo que a cada hora do horizonte temporal, esta metodologia é repetida percorrendo todos os cenários.

3.2. Técnica de Redução de Cenários

A utilização de técnicas de redução de cenários visa diminuir o tamanho do conjunto de dados mantendo a representatividade da informação estocástica original. O objetivo de um algoritmo de redução de cenários consiste em permitir a obtenção de uma solução que se aproxime da solução ótima considerando o conjunto de dados originais [31].

Nesta dissertação foi elaborado um algoritmo de redução de cenários com base numa distância probabilística, definida entre duas distribuições de probabilidades, denominada de *Kantorovich Distance* [31].

A seguinte notação permite definir o algoritmo de redução de cenários desenvolvido no âmbito desta dissertação:

- Índice do cenário: $\omega, \omega = 1,2,3,\dots, N_{\Omega}$
- Conjunto de cenários: Ω
- Número de cenários: N_{Ω}
- Probabilidade do cenário: π_{ω}
- Conjunto de Cenários selecionados: Ω_S
- Conjunto de Cenários não selecionados: Ω_J
- Conjunto final de Cenários selecionados: Ω_S^*
- Número de iterações: i
- Número de cenários pretendidos: N_{Ω_S}

A técnica de redução de cenários assenta na minimização de uma função de custo, baseada na norma da diferença entre pares de vetores aleatórios [31]:

$$v(\omega, \omega') = \|\lambda_{\omega} - \lambda_{\omega'}\| \quad (3.1)$$

onde $v(\omega, \omega')$ é uma função simétrica não negativa e contínua; λ é um processo estocástico caracterizado por um número inicial de cenários λ_ω , para todo $\omega \in \Omega$, i.e., $\lambda = \{\lambda_\omega, \omega = 1, 2, \dots, N_\Omega\}$.

Assim, a distância de *Kantorovich* é formulada da seguinte forma [31]:

$$D_1(Q, Q') = \sum_{\omega \in \Omega \setminus \Omega_S} \pi_\omega \min_{\omega' \in \Omega_S} v(\omega, \omega') \quad (3.2)$$

onde Q representa uma distribuição de probabilidades.

Com base nesta formulação é possível desenvolver dois tipos de algoritmos para a redução de cenários, o *Backward Reduction* e o *Forward Reduction*. No primeiro caso os cenários ótimos são obtidos através da eliminação de cenários do conjunto original e no segundo são obtidos através da seleção de cenários. O algoritmo utilizado no âmbito desta dissertação é o *Forward Reduction* devido a possuir uma melhor aplicabilidade nos problemas que envolvem mercados de energia elétrica [31].

A inicialização do algoritmo é feita através de um conjunto vazio, onde são colocados, no decorrer das iterações, os cenários selecionados.

$$\Omega_S^{[k=0]} = \emptyset \quad (3.3)$$

Adicionalmente é criado um conjunto de cenários não escolhidos, sendo que na sua inicialização este é igual ao conjunto original de cenários.

$$\Omega_J^{[k=0]} = \Omega \quad (3.4)$$

O número de iterações será tal quanto o número de cenários finais pretendidos pelo operador do algoritmo.

$$i = 0, 1, 2, \dots, N_{\Omega_S} + 1 \quad (3.5)$$

Em cada iteração, do conjunto original $\Omega \setminus \Omega_S$, o cenário que minimizar a distância de *Kantorovich* entre o conjunto dos cenários original e o conjunto dos cenários selecionados, é adicionado ao conjunto Ω_S . Seguidamente são apresentados os passos inerentes a este algoritmo [31, 77].

Passo 0 (inicialização):

- Criação da função de custo $v(\omega, \omega')$ para todos os pares de cenários ω e ω' pertencentes ao conjunto de cenários Ω .

Passo 1:

- Criação da função da distância de *Kantorovich*:

$$d_\omega = \sum_{\substack{\omega'=1 \\ \omega' \neq \omega}}^{N_\Omega} \pi_{\omega'} v(\omega, \omega'), \quad \forall \omega \in \Omega \quad (3.6)$$

- Selecionar $\omega_1 \in \arg \left\{ \min_{\omega \in \Omega} d_\omega \right\}$;
- Retirar o cenário escolhido do conjunto $\Omega_j^{[1]} = \{1, \dots, N_\Omega\} \setminus \omega_1$.

Passo i:

- Atualização da distância de *Kantorovich*:

$$v^{[i]}(\omega, \omega') = \min \{ v^{[i-1]}(\omega, \omega'), v^{[i-1]}(\omega, \omega_{i-1}) \}, \quad \forall \omega, \omega' \in \Omega_j^{[i-1]} \quad (3.7)$$

$$d_\omega^{[i]} = \sum_{\omega' \in \Omega_j^{[i-1]} \setminus \omega}^{N_\Omega} \pi_{\omega'} v^{[i]}(\omega', \omega), \quad \forall \omega \in \Omega_j^{[i-1]} \quad (3.8)$$

- Selecionar $\omega_i \in \arg \left\{ \min_{\omega \in \Omega_j^{[i-1]}} d_\omega^{[i]} \right\}$;

- Conjunto $\Omega_j^{[i]} = \Omega_j^{[i-1]} \setminus \omega_i$;

Passo $N_{\Omega_S^*} + 1$:

- Definição do conjunto final de cenários não selecionados:

$$\Omega_J^* = \Omega_J^{[N_{\Omega_J^*}]} \quad (3.9)$$

- Definição do conjunto final de cenários selecionados:

$$\Omega_S^* = \Omega \setminus \Omega_J^* \quad (3.10)$$

- Definição das probabilidades dos cenários selecionados $\omega \in \Omega_S^*$:

$$\pi_\omega^* = \pi_\omega + \sum_{\omega' \in J(\omega)} \pi_{\omega'}^*, \quad \forall \omega \in \Omega_S^* \quad (3.11)$$

$$J(\omega) = \{\omega' \in \Omega_J^* | \omega = j(\omega')\}, \quad j(\omega') \in \arg \left\{ \min_{\omega'' \in \Omega_S^*} v(\omega'', \omega') \right\} \quad (3.12)$$

O resultado computacional da aplicação do algoritmo de redução de cenários para o preço da energia elétrica e para a potência térmica disponível no CS é apresentado na Figura 3.3 e na Figura 3.4.

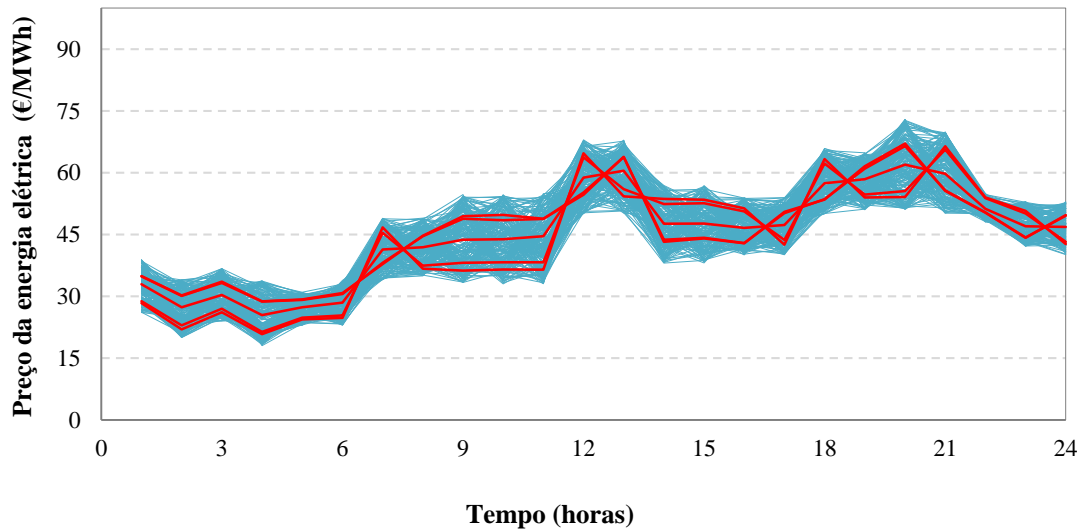


Figura 3.3 – Redução de cenários: Preço da energia elétrica.

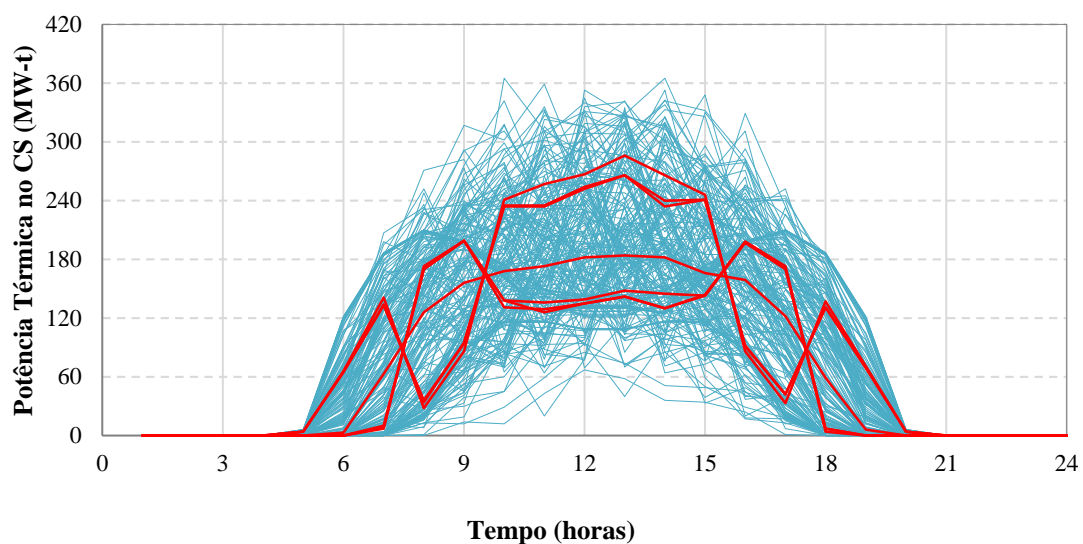


Figura 3.4 – Redução de cenários: Potência térmica disponível no CS.

Os cenários do conjunto original de dados são representados a azul enquanto os cenários escolhidos pelo algoritmo são representados a vermelho como é apresentado na Figura 3.3 e Figura 3.4. Esta aplicação partiu de uma amostra original constituída por 200 cenários, tendo sido escolhidos pelo algoritmo, neste exemplo, 5 cenários.

3.3. Otimização Estocástica

A resolução de problemas que envolvem a incerteza nos dados, diferentemente da programação determinística, onde se supõe que os parâmetros do problema são conhecidos sem incerteza, exige o recurso a técnicas de programação estocástica. Para modelizar um problema de programação estocástica, cuja incerteza é representada por uma árvore de cenários, devem ser conhecidas as realizações futuras de todas as variáveis aleatórias envolvidas no problema, ou então, gerar cenários de forma sistemática.

Na formulação da programação estocástica, cada parâmetro incerto constitui uma variável aleatória. Uma variável aleatória cujo valor evolui ao longo do tempo é conhecida como um processo estocástico. Cada parâmetro incerto pode ser caracterizado através de uma distribuição de probabilidade. A partir da distribuição de probabilidade descreve cada parâmetro incerto é possível gerar um número plausível cenários com uma probabilidade de ocorrência associada, como é apresentado na Figura 3.5.

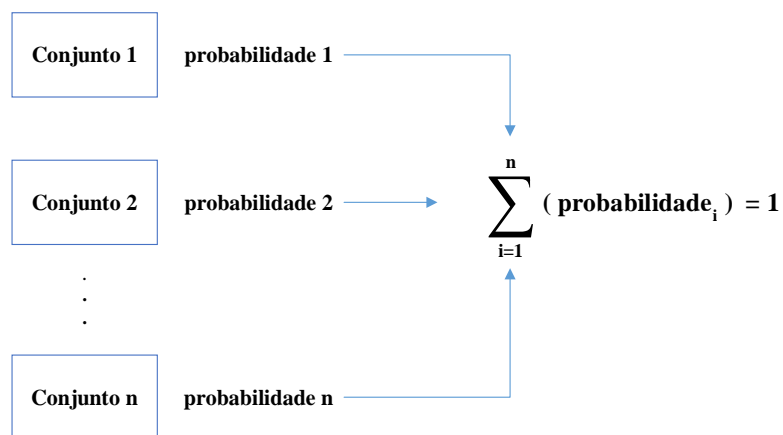


Figura 3.5 – Conjunto de cenários e probabilidades.

Assim, na otimização estocástica, um cenário representa a realização de um processo estocástico que para ser bem representado é necessário que exista um número suficientemente grande de cenários [31].

A aplicação de técnicas de redução de cenários permite reduzir significativamente a cardinalidade do conjunto original de dados mantendo, dentro de um certo erro, as características estatísticas da amostra. Esta operação permite reduzir significativamente o tempo de computação necessário para a resolução do problema de decisão contendo incerteza.

Um esquema exemplificativo da metodologia de otimização estocástica, aplicada no âmbito desta dissertação, com recurso à técnica de redução de cenários é apresentado na Figura 3.6.

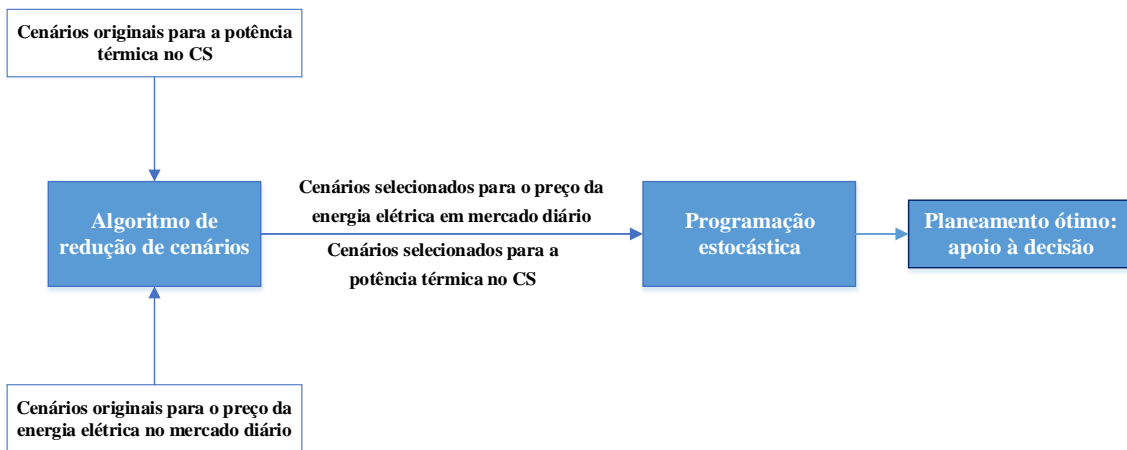


Figura 3.6 – Metodologia de otimização estocástica com técnica de redução de cenários.

O problema parte de dois conjuntos de dados para a potência térmica disponível no CS e para o preço da energia elétrica em mercado diário cujo algoritmo de redução de cenários reduz para o número pretendido pelo utilizador, como é representado na Figura 3.6. Esta redução permite diminuir significativamente o tempo de computação necessário para a resolução do problema. Seguidamente, os conjuntos reduzidos são dados de entrada para a metodologia de otimização estocástica que apresentará o planeamento ótimo com vista a ser utilizado como suporte à decisão para um produtor detentor de uma CCST com SAE.

3.3.1. Problema Estocástico de Dois Estados

Os problemas de programação estocástica de dois estados têm como objetivo maximizar o lucro esperado. No entanto, estes problemas são abordados pressupondo que um produtor de energia elétrica é neutro ao risco, i.e., o agente de decisão apenas foca o seu interesse no valor esperado do lucro, z , ignorando os restantes parâmetros que caracterizam a distribuição do lucro. O problema estocástico de dois estados referente a um produtor de energia elétrica neutro ao risco é dado por:

$$\max_{x, y_\omega} z = c^T x + \sum_{\omega \in \Omega} \pi_\omega q_\omega^T y_\omega \quad (3.13)$$

sujeito a:

$$Ax = b \quad (3.14)$$

$$T_\omega x + W_\omega y_\omega = h_\omega, \forall \omega \in \Omega \quad (3.15)$$

$$x \in X, y_\omega \in Y, \forall \omega \in \Omega \quad (3.16)$$

onde x e y_ω representam o conjunto de variáveis de decisão de primeiro e segundo estado respetivamente, c , q_ω , b , h_ω , A , T_ω e W_ω são vetores e matrizes representativos dos coeficientes e limites das restrições do problema. Ainda, ω representa o índice do cenário, sendo que $\omega = 1, 2, 3, \dots, N_\Omega$, onde N_Ω representa o número total de cenários presentes no conjunto de cenários Ω .

A função objetivo é dada por (3.13) onde se maximiza o lucro esperado do produtor detentor de uma CCST com SAE. As equações (3.14) a (3.16) garantem que os limites técnicos e restrições do problema seja respeitadas.

3.3.2. Medidas de Avaliação da Solução Estocástica

Em [31] são apresentadas medidas para avaliar a qualidade da metodologia de otimização estocástica. Estas medidas de qualidade visam justificar a utilização de uma metodologia estocástica em relação a uma metodologia determinística. Dessas medidas de avaliação destacam-se:

- *Expected value of perfect information (EVPI);*
- *Value of stochastic solution (VSS);*
- *Método Out-of-sample.*

No âmbito desta dissertação é aplicada a medida VSS para quantificar o ganho que se obtém resolver o problema de decisão aplicando uma metodologia de otimização estocástica face a uma metodologia determinística.

Nesta medida são substituídos os parâmetros incertos pelos seus valores esperados, ficando assim com um problema determinístico. A medida de VSS é formulada da seguinte forma [31]:

$$VSS = z^{S^*} - z^{D^*} \quad (3.17)$$

onde z^{S^*} representa a solução ótima do problema estocástico e z^{D^*} representa a solução ótima do problema determinístico onde é efetuada a troca dos parâmetros incertos pelos seus valores esperados.

3.4. Gestão de Risco

A otimização estocástica permite efetuar uma gestão de risco associada a cada cenário em simultâneo com a otimização da função objetivo associada a um dado problema. O agente decisor, com o intuito de maximizar um determinado objetivo, possui um certo limite de risco a que se propõem sujeitar e a metodologia de otimização estocástica pode simultaneamente maximizar o seu objetivo e limitar o risco.

Cabe ao agente decisor definir previamente qual o nível de risco que está disposto a suportar nas suas tomadas de decisão, cujo valor afetará o portfólio de soluções ótimas. Quanto maior for a aversão ao risco por parte do agente decisor menor será o resultado ótimo que obtém para o seu objetivo, a ponderação correta é a chave para um bom resultado. Tomando como exemplo o problema abordado nesta dissertação, qualquer decisão que envolva incerteza requer um compromisso entre o lucro esperado e o risco que o produtor detentor de uma CCST com SAE está disposto a assumir [56].

A gestão de risco atenua propriedades indesejadas na distribuição da função objetivo, que tomando como exemplo o lucro obtido pela venda de energia elétrica em mercado diário por parte de um produtor detentor de uma CCST com SAE, seria a obtenção de um lucro reduzido para um determinado cenário.

A forma mais usual de se efetuar a gestão de risco numa metodologia de otimização estocástica consiste em incluir na formulação do problema um termo que contabilize o risco associado com a distribuição da função objetivo. Esta contabilização do risco é efetuada através de medidas de risco [31]:

- Variância;
- *Shortfall Probability* (SP);

- *Expected Shortage (ES)*;
- *Value-at-Risk (VaR)*;
- *Conditional Value-at-Risk (CVaR)*.

Mais recentemente tem sido também explorada e aplicada a gestão de risco, numa metodologia de otimização estocástica, utilizando o domínio estocástico onde a gestão de risco é feita utilizando somente restrições adicionais no problema [31].

3.4.1. Problema Estocástico de Dois Estados Considerando a Gestão de Risco

Na secção 3.3.1 é apresentada a formulação de um problema estocástico de dois estados em que não é considerada a gestão de risco, ou seja, o agente decisor é neutro ao risco. Considerando a gestão de risco, é possível formular o problema estocástico de dois estados através do seu equivalente determinístico [31]:

$$\max_{x, y(\omega)} z = (1-\beta) \left(c^T x + \sum_{\omega \in \Omega} \pi_{\omega} q_{\omega}^T y_{\omega} \right) - \beta(r_{\omega}) \quad (3.18)$$

sujeito a:

$$Ax = b \quad (3.19)$$

$$T_{\omega}x + W_{\omega}y_{\omega} = h_{\omega}, \forall \omega \in \Omega \quad (3.20)$$

$$x \in X, y_{\omega} \in Y, \forall \omega \in \Omega \quad (3.21)$$

em que r_{ω} representa a medida de risco aplicada e o parâmetro β o nível de aversão ao risco que o agente decisor pretende assumir, sendo a seu intervalo de valores definido por:

- $\beta = 0$ —————> Decisor é neutro ao risco;
- $\beta \in [0,1]$ —————> Decisor com um certo nível de aversão ao risco;
- $\beta = 1$ —————> Decisor com total aversão ao risco.

Assim, a solução ótima depende do valor do parâmetro β e esta define uma solução específica apresentada pela metodologia de otimização estocástica. O lucro de um produtor detentor de uma CCST com SAE face ao nível de risco que está disposto a tomar é apresentado na Figura 3.9.

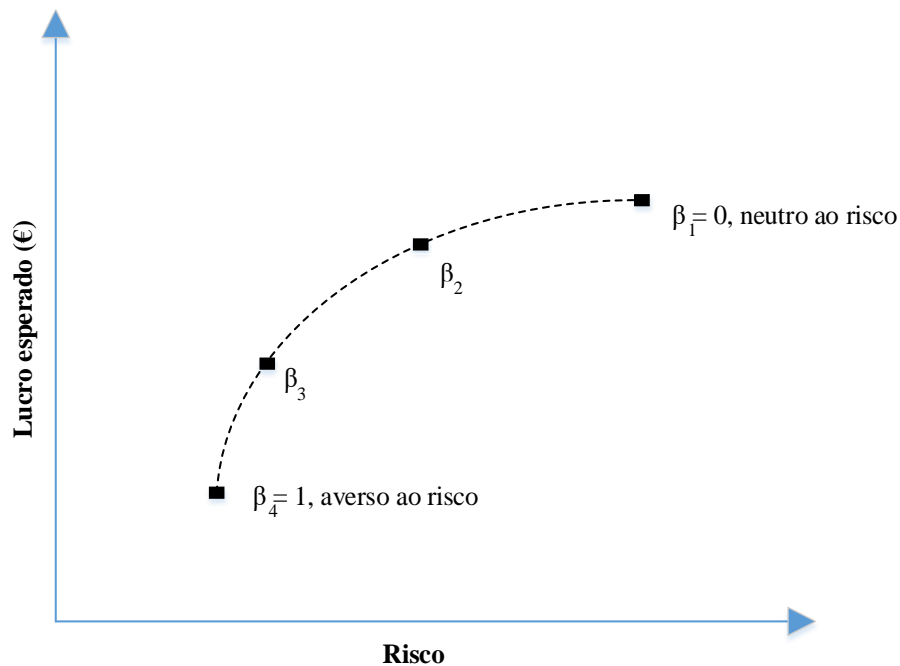


Figura 3.7 – Curva da fronteira eficiente.

A Figura 3.7 mostra que quanto maior for a aversão ao risco por parte do produtor detentor de uma CCST com SAE menor será o lucro esperado e vice-versa. O conjunto de soluções ótimas obtidas através da variação do parâmetro β define a fronteira eficiente. A fronteira eficiente é uma curva formada pelos pares (lucro esperado, risco), de tal forma que é impossível encontrar um conjunto de variáveis de decisão que gerem, simultaneamente, um maior lucro esperado e um menor risco. Desta forma, uma solução com maior lucro esperado face a um ponto eficiente só pode ser obtida à custa de um risco mais elevado, e vice-versa [56].

O esquema representativo da metodologia de otimização estocástica com gestão de risco e aplicação de um algoritmo de redução de cenários, no âmbito desta dissertação, é apresentado na Figura 3.8.

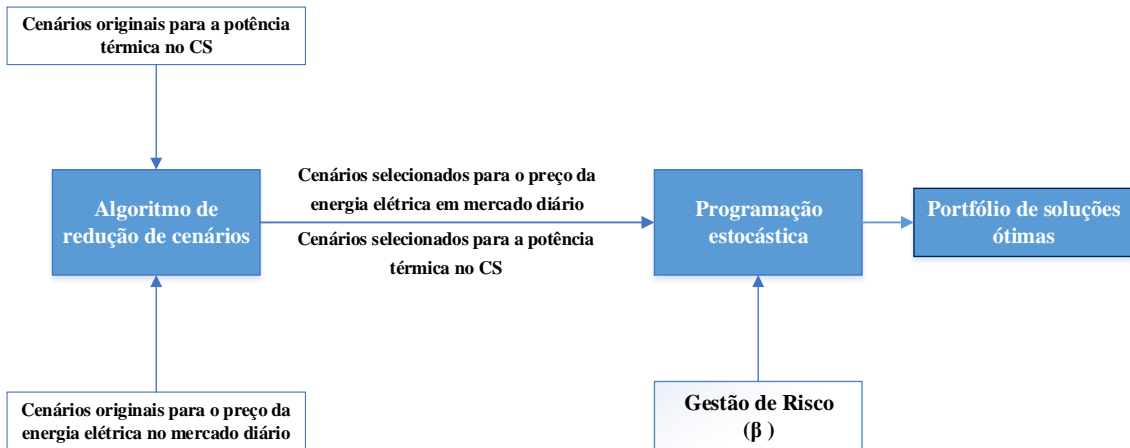


Figura 3.8 – Metodologia de otimização estocástica considerando a gestão de risco e a técnica de redução de cenários.

Nesta dissertação será aplicada a gestão de risco, na metodologia de otimização estocástica, através da medida de risco CVaR, proporcionando a um produtor detentor de uma CCST com SAE um portfólio de soluções ótimas que possam apoiar a sua tomada de decisão.

3.4.2. Valor em Risco Condicional - CVaR

Para um dado nível de confiança $\alpha \in \{0,1\}$, o $CVaR_\alpha$ é definido como sendo a média dos quantis dos piores cenários, por outras palavras, se todos os cenários forem equiprováveis, $CVaR_\alpha(x)$ é computado como sendo o valor esperado do lucro em $(1-\alpha)100\%$ dos piores cenários. Assim, se o nível de confiança for de $\alpha = 0,6$ significa que, $CVaR_\alpha(x)$ representa 60% dos piores cenários [31].

A medida de risco CVaR é considerada uma medida de risco coerente cumprindo as 4 propriedades definidas em [46]. Sendo estas a Invariância à translação, a subaditividade, a homogeneidade e a monotonicidade. Assim, o CVaR, cumprindo as propriedades mencionadas, favorece a diversificação do portfólio de soluções apresentado pela metodologia de otimização estocástica. Estas condições permitem ainda que o CVaR seja descrito através de uma formulação linear [56].

O $CVaR_\alpha$, para uma distribuição discreta, é definido matematicamente da seguinte forma [31, 49, 50]:

$$CVaR_\alpha(x) = \max \left\{ \eta - \frac{1}{1-\alpha} E \left\{ \max \{ \eta - f(x,\omega), 0 \} \right\} \right\}, \quad \forall \alpha \in \{0,1\} \quad (3.22)$$

onde a função objetivo é representada por $f(x,\omega)$ e η é uma variável que dependerá do valor de $f(x,\omega)$ em cada cenário. A formulação do $CVaR_\alpha$ pode ser ainda simplificada, adicionando a variável s_ω [56]:

$$CVaR_\alpha(x) = \eta - \frac{1}{1-\alpha} \sum_{\omega \in \Omega} \pi_\omega s_\omega \quad (3.23)$$

onde

$$s_{\omega} = \max \{ \eta - f(x, \omega), 0 \} \quad (3.24)$$

$$s_{\omega} \geq 0 \quad (3.25)$$

Assim, a formulação estocástica de dois estados com gestão de risco apresentada na secção 3.4.1, equações (3.18) a (3.21), é completada com a medida de risco CVaR introduzindo a equação (3.23) na parcela da função objetivo respeitante à medida de risco e introduzindo como restrições no problema as equações (3.24) e (3.25).

3.4.3. Problema Estocástico de Dois Estados Considerando o CVaR

O CVaR pode ser incluído no problema de otimização estocástica indicado de (3.18) a (3.21), passando a ser dado por:

$$\max_{x, y(\omega), \eta, s(\omega)} z = (1 - \beta) \left\{ c^T x + \sum_{\omega \in \Omega} \pi_{\omega} q_{\omega}^T y_{\omega} \right\} + \beta \left\{ \eta - \frac{1}{1-\alpha} \sum_{\omega \in \Omega} \pi_{\omega} s_{\omega} \right\} \quad (3.26)$$

sujeito a:

$$Ax = b \quad (3.27)$$

$$T_{\omega}x + W_{\omega}y_{\omega} = h_{\omega}, \forall \omega \in \Omega \quad (3.28)$$

$$\eta - (c^T x + q_{\omega}^T y_{\omega}) \leq s_{\omega}, \forall \omega \in \Omega \quad (3.29)$$

$$s_{\omega} \geq 0, \forall \omega \in \Omega \quad (3.30)$$

$$x \in X, y_{\omega} \in Y, \forall \omega \in \Omega \quad (3.31)$$

A função objetivo indicada em (3.26) é composta por dois termos. O primeiro termo corresponde ao lucro esperado, enquanto o segundo termo é diretamente proporcional ao CVaR através do parâmetro β não negativo.

As restrições (3.29) e (3.30) impõem condições para o cálculo das variáveis auxiliares da medida de risco CVaR.

Capítulo 4

Formulação do Problema

Neste capítulo é descrito o problema de exploração de CCST com SAE considerando incerteza e risco. São apresentadas as variáveis inerentes a uma CCST com SAE no que respeita à potência térmica, elétrica e energia armazenada. Por fim, é apresentada a função objetivo e as restrições associadas ao problema.

4.1. Problema de exploração de CCST com SAE

A metodologia de otimização estocástica proposta para resolução do problema de exploração de CCST com SAE considerando incerteza e risco é matematicamente formulada como sendo um problema de maximização de um objetivo, sujeito a um conjunto de restrições. No capítulo 3 desta dissertação é introduzida a programação estocástica, sendo esta uma metodologia de programação matemática utilizada para resolver problemas que envolvam incerteza nos dados [56].

Nesta dissertação é utilizada uma metodologia de programação estocástica para modelizar o processo de decisão de um produtor detentor de uma CCST com SAE que participa no mercado diário. A estocacidade introduzida na metodologia de otimização advém dos efeitos da incerteza que resultam do ambiente de mercado competitivo, o que se reflete no preço da energia elétrica em mercado, e da invariabilidade e intermitência da energia solar, que se reflete na potência térmica disponível no CS. Adicionalmente, a metodologia de otimização proposta inclui a medida de risco CVaR na função objetivo para controlar a variabilidade do lucro esperado.

O planeamento operacional de sistemas de energia solar passa por estabelecer uma série de decisões admissíveis num número finito de etapas, i.e., um escalonamento temporal. No âmbito do planeamento de sistemas de energia a curto prazo, são considerados dois casos atendendo ao número de períodos horários, como apresentado na Figura 4.1.

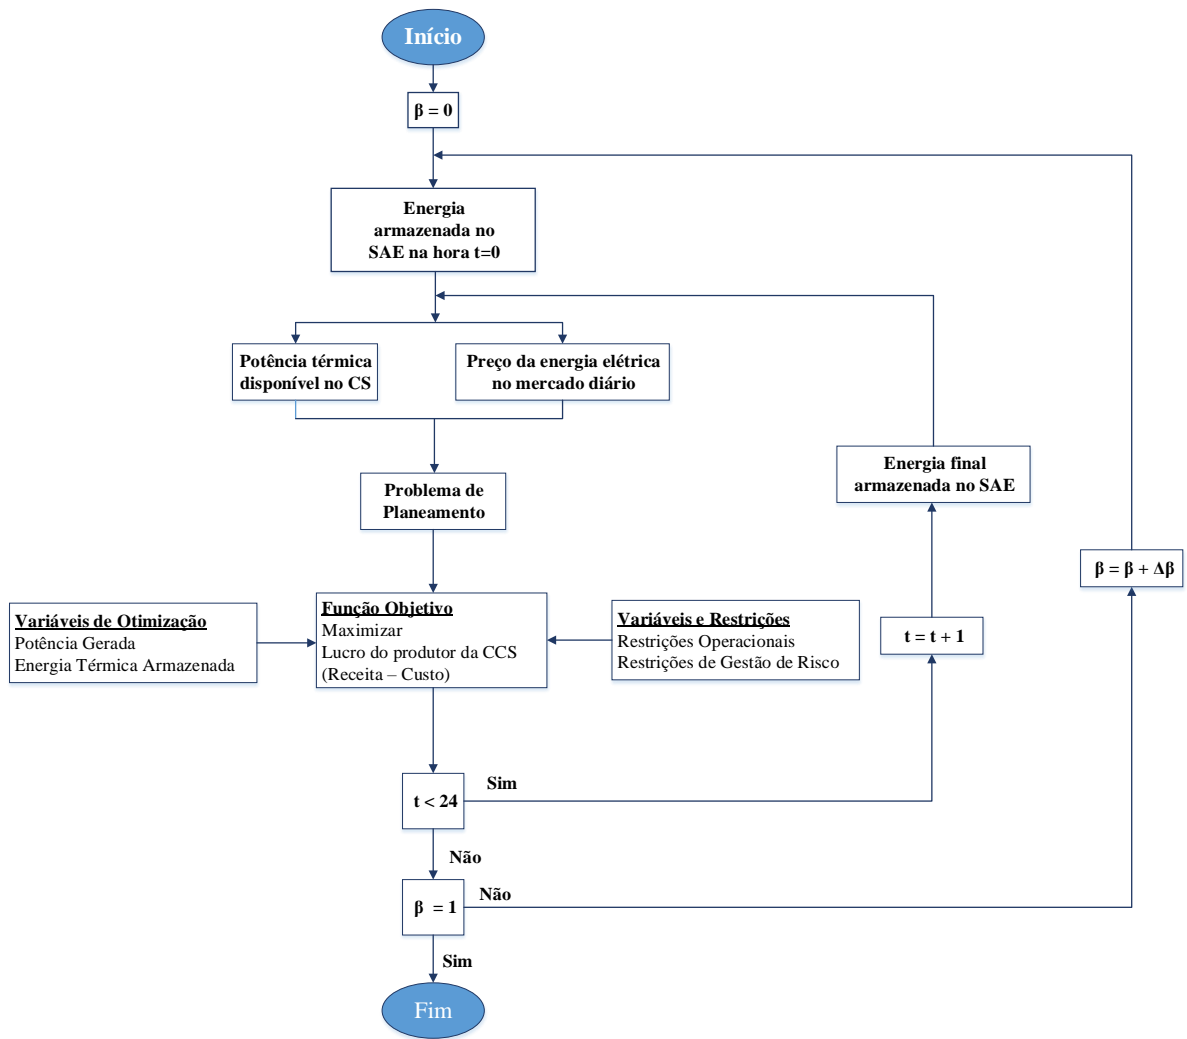


Figura 4.2 – Esquema exemplificativo da metodologia aplicada

4.2. Variáveis de uma CCST com SAE

Um esquema exemplificativo de uma CCST com SAE é apresentado na Figura 4.3, onde é possível analisar as variáveis e parâmetros intervenientes no problema de planeamento de curto prazo abordado nesta dissertação.

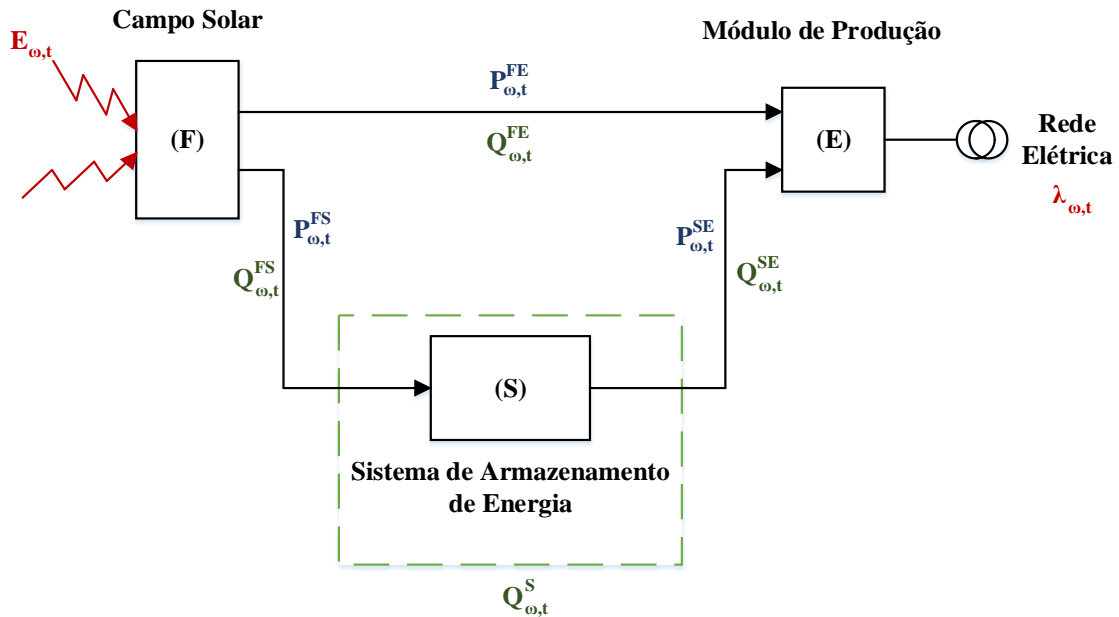


Figura 4.3 – Esquema de uma CCST com SAE por blocos.

Como abordado no capítulo 2, a CCST com SAE pode ser caracterizada por três componentes base, o CS que consiste nos concentradores cilíndricos com refletor parabólico que concentram a radiação solar, o SAE que permite armazenar energia térmica para ser utilizada de modo a otimizar a utilização da central e o módulo de produção que possibilita a conversão de energia térmica em energia elétrica através de uma turbina de vapor de alta temperatura acoplada a um gerador.

As variáveis apresentadas na Figura 4.3 representam as potências elétrica e térmica que circulam na CCST com SAE. Cada variável possui como expoente duas siglas, a primeira sigla representa a sua origem, ou seja, de qual dos três componentes a

potência é proveniente. A segunda sigla representa qual o destino que a potência terá, ou seja, em qual dos três componentes a potência será utilizada. Essas siglas são as seguintes:

- F – CS;
- E – Módulo de produção de energia;
- S – SAE;
- s – Rede elétrica (energia a vender).

A energia armazenada no SAE tem apenas um expoente representando o componente respectivo, ou seja, o SAE.

Os índices ω , t representam respectivamente o cenário ω na hora t , o que significa que para cada hora do horizonte temporal, T , existe um conjunto de cenários Ω . Na Figura 4.3 verifica-se ainda a existência de parâmetros endógenos ao sistema, nomeadamente:

- $E_{\omega,t}$ que representa, abusando da linguagem, a potência térmica solar. Isto é, o valor de potência que o CS gera para uma determinada radiação solar. Esta potência é tal para o cenário ω na hora t ;
- $\lambda_{\omega,t}$ que representa o preço da energia elétrica no mercado diário para o cenário ω na hora t .

4.3. Função Objetivo: Lucro Esperado

O objetivo do pacote de otimização é de efetivamente maximizar o lucro esperado do produtor de uma CCST com SAE, utilizando para isso a central de uma forma adequada. Sendo assim a função objetivo é formalizada da seguinte forma:

$$\text{Lucro} = \text{Receita} - \text{Custo} \quad (4.1)$$

No âmbito desta dissertação os custos do funcionamento da central são considerados desprezáveis para o problema, com isso, a formulação do lucro é a seguinte:

$$\text{Lucro} = \Pi = \sum_{\omega=1}^{\Omega} \sum_{t=1}^T (\pi_{\omega,t} \lambda_{\omega,t} P_{\omega,t}^s) \quad (4.2)$$

onde $T=1, 2, \dots, 24$ horas e $\lambda_{t,\omega}$ representa o preço da energia elétrica em mercado diário no cenário ω para a hora t . O número de cenários é dado por ω onde $\omega \in \Omega$. Sendo Ω o conjunto total de cenários considerados no problema. A cada cenário, como verificado em detalhe no capítulo 3, está associada uma probabilidade $\pi_{\omega,t}$.

No entanto, a equação (4.2) é apenas o primeiro termo da função objetivo. Para se efetuar a gestão de risco com auxílio da medida de risco CVaR é introduzido um segundo termo na função objetivo, como apresentado no capítulo 3. Assim, a função objetivo é formulada da seguinte forma:

$$z = (1 - \beta) \left(\sum_{\omega=1}^{\Omega} \sum_{t=1}^T (\pi_{\omega,t} \lambda_{\omega,t} P_{\omega,t}^s) \right) + \beta \left(\eta - \frac{1}{1-\alpha} \sum_{\omega=1}^{\Omega} (\pi_{\omega,t} s_{\omega}) \right) \quad (4.3)$$

onde o parâmetro β representa o nível de aversão ao risco que o produtor detentor de uma CCST com SAE pretende assumir. Assim existe um compromisso entre o lucro esperado e o risco associado às decisões.

Estando a função objetivo definida o próximo passo consiste em identificar e formalizar as restrições inerentes à exploração de CCST com SAE, originando o seguinte problema de otimização:

$$\max \quad (1 - \beta) \left(\sum_{\omega=1}^{\Omega} \sum_{t=1}^T (\pi_{\omega,t} \lambda_{\omega,t} P_{\omega,t}^s) \right) + \beta \left(\eta - \frac{1}{1-\alpha} \sum_{\omega=1}^{\Omega} (\pi_{\omega,t} s_{\omega}) \right) \quad (4.4)$$

sujeito a:

Restrições associadas à exploração de CCST com SAE

onde as restrições associadas à exploração de CCST com SAE consistem nas restrições operacionais, restrições de lógica binária, restrições de tempo mínimo de funcionamento (TMF) e de tempo mínimo de paragem (TMP), restrição de ofertas em mercado e por fim, a restrição inerente à gestão de risco utilizando a medida de risco CVaR.

4.4. Restrições Associadas à Exploração de CCST com SAE

Como verificado no subcapítulo 4.1, o intervalo de tempo T considerado será de 24 horas e para cada hora existem Ω cenários. Os parâmetros de estocacidade considerados nesta dissertação são o preço da energia elétrica em mercado diário e a potência térmica disponível no CS. As variáveis associadas à exploração de CCST com SAE são abordadas no subcapítulo 4.2.

4.4.1. Restrições Operacionais

As restrições operacionais consistem nas regras de funcionamento da central, incluindo as eficiências térmicas e elétricas e a relação que existe entre os diversos componentes base da CCST com SAE.

O balanço elétrico no módulo de produção é dado pelo somatório da potência elétrica que provem do CS com a potência elétrica que provem do SAE. Esta restrição é dada por:

$$P_{\omega,t}^s = P_{\omega,t}^{FE} + P_{\omega,t}^{SE} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.5)$$

Numa CCST com SAE é utilizada energia térmica como energia intermédia antes da conversão final para energia elétrica, como resultado desta conversão são consideradas as suas perdas através da seguinte formulação:

$$P_{\omega,t}^{FE} = \eta_1 Q_{\omega,t}^{FE} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.6)$$

$$P_{\omega,t}^{SE} = \eta_3 Q_{\omega,t}^{SE} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.7)$$

onde o η_1 representa o rendimento do CS e o η_3 o rendimento dos tanques de armazenamento do SAE.

A energia térmica produzida pela concentração solar no CS pode ser utilizada para produzir energia no módulo de produção e para ser armazenada no SAE, possuindo como limite a energia térmica disponível no CS e é dada por:

$$Q_{\omega,t}^{FE} + Q_{\omega,t}^{FS} = E_{\omega,t} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.8)$$

no entanto esta relação não tem em consideração as perdas. Isto é, desde a radiação solar que é concentrada ao aquecimento do FTC e à consequente utilização dessa energia para armazenamento ou para conversão, vai existir dissipação térmica. Assim, a restrição formulada em (4.8) é dada por:

$$Q_{\omega,t}^{FE} + Q_{\omega,t}^{FS} \leq E_{\omega,t} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.9)$$

O módulo de produção é composto por uma turbina de vapor a alta temperatura e um gerador elétrico. Assim, tem as suas limitações em termos de energia térmica, i.e., possui um limite mínimo e máximo de funcionamento para o qual está dimensionado pelo respetivo fabricante. Estes limites são formulados por:

$$Q_{\min}^E \leq Q_{\omega,t}^{FE} + Q_{\omega,t}^{SE} \leq Q_{\max}^E \quad \forall \omega \in \Omega, \forall t \in T \quad (4.10)$$

no entanto, ao se utilizar PLIM, é acrescentada a variável binária $u_{\omega,t}$ que representa o funcionamento do módulo de produção. Os estados desta variável são descritos na Tabela 4.1.

Tabela 4.1 – Estados da variável binária $u_{\omega,t}$

Variável	Estados
$u_{\omega,t}$	0 – Módulo de produção não se encontra em funcionamento
	1 – Módulo de produção encontra-se em funcionamento

Com a introdução da variável binária $u_{\omega,t}$, os limites térmicos do módulo de produção definidos em (4.10) são dados por:

$$Q_{\min}^E u_{\omega,t} \leq Q_{\omega,t}^{FE} + Q_{\omega,t}^{SE} \leq Q_{\max}^E u_{\omega,t} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.11)$$

$$u_{\omega,t} \in \{0,1\} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.12)$$

Tal com os limites térmicos, o módulo de produção possui limites elétricos que são definidos pelas suas características de fábrica e são dados por:

$$P_{\min}^S \leq P_{\omega,t}^S \leq P_{\max}^S \quad \forall \omega \in \Omega, \forall t \in T \quad (4.13)$$

mais uma vez, a restrição (4.13) apenas se aplica caso o módulo de produção esteja em funcionamento:

$$P_{\min}^S u_{\omega,t} \leq P_{\omega,t}^S \leq P_{\max}^S u_{\omega,t} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.14)$$

A energia térmica armazenada no SAE é dada pela energia armazenada na hora t-1 mais a energia armazenada através do CS na hora t, menos a energia que é utilizada pelo módulo de produção proveniente do SAE. Este balanço térmico no SAE é dado por:

$$Q_{\omega,t}^S = Q_{\omega,t-1}^S + (\eta_2 Q_{\omega,t}^{FS}) - Q_{\omega,t}^{SE} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.15)$$

onde o parâmetro η_2 corresponde à eficiência das tubagens onde circula o FTC.

O SAE é projetado para certos limites de energia armazenada pelo fabricante, esta restrição é dada por:

$$Q_{\min}^S \leq Q_{\omega,t}^S \leq Q_{\max}^S \quad \forall \omega \in \Omega, \forall t=0,1,\dots,T \quad (4.16)$$

Construtivamente o SAE possui também limites máximos de subida e descida da potência térmica armazenada, como é apresentado na Figura 4.4.




Figura 4.4 – Restrição de rampas do SAE.

A Figura 4.4 ilustra a restrição de rampa mínima e máxima para o SAE e estas são dadas por:

$$P_{\omega,t}^{\text{FS}} - P_{\omega,t-1}^{\text{FS}} \leq R^{\text{up}} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.17)$$

$$P_{\omega,t-1}^{\text{SE}} - P_{\omega,t}^{\text{SE}} \leq R^{\text{dn}} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.18)$$

A restrição de rampa de descida em (4.17) envolve a potência que sai do SAE para ser utilizada pelo módulo de produção, o que limita a quantidade de energia que é possível de colocar em uma determinada hora. A restrição de rampa de subida está relacionada com a capacidade que o SAE tem para armazenar energia que depende do CS, assim, a equação (4.18) pode ser formulada em função da energia térmica:

$$\eta_2 \left(Q_{\omega,t}^{\text{FS}} - Q_{\omega,t-1}^{\text{FS}} \right) \leq R^{\text{up}} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.19)$$

Uma restrição adicional necessária ao funcionamento do SAE consiste no facto de este não poder, simultaneamente, armazenar e descarregar energia. Ou seja, para o mesmo instante t o SAE apenas pode estar a armazenar, recebendo a energia

térmica proveniente do CS, ou a descarregar, enviando a energia térmica para o módulo de produção. Esta restrição é dada por [35]:

$$P_{\omega,t}^{SE} \leq R e_{\omega,t} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.20)$$

$$Q_{\omega,t}^{FS} \leq R (1 - e_{\omega,t}) \quad \forall \omega \in \Omega, \forall t \in T \quad (4.21)$$

$$e_{\omega,t} \in \{0,1\} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.22)$$

onde R é uma constante suficientemente grande, nomeadamente $R \geq P_{\max}^s$. A variável binária $e_{\omega,t}$ representa os dois estados de funcionamento do SAE, como é apresentado na Tabela 4.2, e a sua influencia nas restantes variáveis é apresentada na Tabela 4.3.

Tabela 4.2 – Estados da variável binária $e_{\omega,t}$

Variável	Estados
$e_{\omega,t}$	0 – SAE está a carregar
	1 – SAE está a descarregar

Tabela 4.3 – Situações possíveis para a restrição de funcionamento do SAE

Situações possíveis		$e_{\omega,t}$	Consequência
$P_{\omega,t}^{SE} > 0$	SAE a descarregar	1	$Q_{\omega,t}^{FS} = 0$
$Q_{\omega,t}^{FS} > 0$	SAE a carregar	0	$P_{\omega,t}^{SE} = 0$
$P_{\omega,t}^{SE} = Q_{\omega,t}^{FS} = 0$	SAE não carrega nem descarrega	0 ou 1	-

Por fim temos que todas as variáveis de potência térmica e elétrica presentes na exploração de CCST com SAE são positivas, formuladas por:

$$P_{\omega,t}^{FE}, P_{\omega,t}^{SE}, P_{\omega,t}^{FS}, P_{\omega,t}^s, Q_{\omega,t}^{FE}, Q_{\omega,t}^{SE}, Q_{\omega,t}^{FS}, Q_{\omega,t}^s \geq 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.23)$$

4.4.2. Restrições de Lógica Binária

Através das variáveis binárias, descritas na Tabela 4.4, são introduzidas restrições com o intuito de garantir que a CCST com SAE não arranque e pare simultaneamente. Estas restrições de arranque e paragem são dadas por:

$$y_{\omega,t} - z_{\omega,t} = u_{\omega,t} - u_{\omega,t-1} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.24)$$

$$y_{\omega,t} + z_{\omega,t} \leq 1 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.25)$$

onde as variáveis binárias, $y_{\omega,t}, z_{\omega,t} \in \{0,1\}$, representam o arranque e a paragem da CCST com SAE, respetivamente.

Tabela 4.4 - Estados da variável binária $y_{\omega,t}$ e $z_{\omega,t}$

Variável	Estados
$y_{\omega,t}$	0 – Central arrancou na hora t
	1 – Central não arrancou na hora t
$z_{\omega,t}$	0 – Central parou na hora t
	1 – Central não parou na hora t

4.4.3. Restrições de Tempo Mínimo de Funcionamento e Paragem

A restrição de TMF pretende garantir que a central funcione efetivamente durante o TMF obrigatório, que advém do tipo de tecnologia implementada. O mesmo sucede para o TMP obrigatório. Estas restrições podem ser formuladas da seguinte forma [13]:

$$(x_{\omega,t} - \text{TMF})(u_{\omega,t-1} - u_{\omega,t}) \geq 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.26)$$

$$(x_{\omega,t} - \text{TMP})(u_{\omega,t} - u_{\omega,t-1}) \geq 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.27)$$

Onde $x_{\omega,t}$ representa o número de horas que a central funcionou ou esteve parada no cenário ω , no final da hora t . TMF e TMP representam o número de horas obrigatórias de funcionamento e de paragem, respetivamente.

No entanto esta formulação é feita com base em equações não lineares, (4.26) e (4.27). Assim, para evitar não linearidades na formulação, utiliza-se a linearização proposta em [64] e [65], seguidamente apresentada.

A formulação do TMF inicia-se com o parâmetro L_{ω} que representa o número de horas que faltam para respeitar o tempo mínimo de funcionamento caso a central esteja em funcionamento na hora 0, ou seja, no início do horizonte temporal. Este parâmetro é dado por:

$$L_{\omega} = \min\{T, (\text{TMF} - K_0^{\text{on}})u_{\omega,t=0}\} \quad \forall \omega \in \Omega \quad (4.28)$$

onde K_0^{on} representa o número de períodos de tempo em que a central esteve a funcionar antes do início do horizonte temporal. O parâmetro L_{ω} é utilizado para formular as restantes equações que definem a restrição de TMF.

$$\sum_{t=1}^L (1 - u_{\omega,t}) = 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.29)$$

A equação (4.29) garante que o TMF seja respeitado caso a central esteja inicialmente em funcionamento. Caso contrário, ou caso $TMF \leq K_0^{on}$, esta restrição não é sequer considerada na formulação.

$$\sum_{t=k}^{k+TMF-1} u_{\omega,t} \geq TMF(u_{\omega,k} - u_{\omega,k-1}) \quad \forall \omega \in \Omega, \forall k=L+1, \dots, T-TMF+1 \quad (4.30)$$

A equação (4.30) garante que para $t \geq 0$ se verifique o tempo mínimo de funcionamento para quaisquer conjuntos de horas consecutivas de tamanho igual a TMF. Caso $L_{\omega}+1 > T-TMF+1$ esta equação não é considerada na formulação. O índice k é no fundo o mesmo que o índice t , ou seja, representa passos dentro do vetor $t=1,2,3,\dots, T$.

$$\sum_{t=k}^T u_{\omega,t} \geq \sum_{t=k}^T (u_{\omega,k} - u_{\omega,k-1}) \quad \forall \omega \in \Omega, \forall k = T-TMF+2, \dots, T \quad (4.31)$$

Por fim, com a equação (4.31) garante-se que o TMF é respeitado nas últimas TMF-1 horas do horizonte temporal. Ou seja, caso a central arranque numa dessas horas esta restrição garante que permanece ligada até à última hora do horizonte temporal, sendo esta restrição apenas considerada caso $TMF \geq 2$.

A formulação do TMP é feita de forma análoga, esta é iniciada com o parâmetro M_{ω} que representa o número de períodos de tempo em que a central esteve parada antes do início do horizonte temporal. O parâmetro M_{ω} é dado por:

$$M_{\omega} = \min\{T, (TMP - K_0^{off})(1 - u_{\omega,t=0})\} \quad \forall \omega \in \Omega \quad (4.32)$$

onde K_0^{off} representa o número de períodos de tempo em que a central esteve parada antes do início do horizonte temporal.

$$\sum_{t=1}^M u_{\omega,t} = 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.33)$$

A equação (4.33) obriga que o TMP seja respeitado caso a central esteja inicialmente parada e não tenha ainda completado o tempo mínimo de paragem. Caso contrário, ou caso $\text{TMP} \leq K_0^{\text{on}}$, esta restrição não é considerada na formulação.

$$\sum_{t=k}^{k+\text{TMP}-1} (1 - u_{\omega,t}) \geq \text{TMP}(u_{\omega,k-1} - u_{\omega,k}) \quad \forall \omega \in \Omega, \forall k=M+1, \dots, T-\text{TMP}+1 \quad (4.34)$$

A equação (4.34) garante que para $t \geq 0$ se verifique o TMP para quaisquer conjuntos de horas consecutivas de tamanho igual a TMP. Caso $M_{\omega} + 1 > T - \text{TMP} + 1$ esta equação não é considerada na formulação.

$$\sum_{t=k}^T (1 - u_{\omega,t}) \geq \sum_{t=k}^T (u_{\omega,k-1} - u_{\omega,k}) \quad \forall \omega \in \Omega, \forall k=T-\text{TMP}+2, \dots, T \quad (4.35)$$

Por fim, com a equação (4.31) garante-se o cumprimento do TMP para as últimas TMP-1 horas do horizonte temporal. Ou seja, caso a central pare numa dessas horas esta restrição garante que permanece parada até à última hora do horizonte temporal, sendo apenas considerada esta restrição caso $\text{TMP} \geq 2$.

4.4.4. Restrição de Ofertas em Mercado

A restrição de ofertas em mercado pretende garantir que as curvas de oferta em mercado sejam monotonamente decrescentes, ou seja, se o preço da energia elétrica no mercado diário não decrescer, a quantidade de energia oferecida não pode também decrescer. Esta restrição é representada na Figura 4.5.

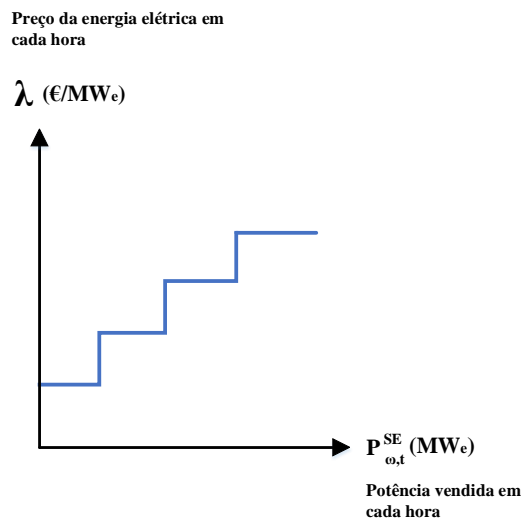


Figura 4.5 – Restrição de curva de ofertas em mercado.

Assim, a restrição de ofertas em mercado como representado na Figura 4.5 é dada por [16]:

$$(\lambda_{\omega,t} - \lambda_{\omega,t-1})(P_{\omega,t}^s - P_{\omega,t-1}^s) \geq 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.36)$$

4.4.5. Restrição de Gestão de Risco

A restrição de gestão de risco, como apresentado no capítulo 3 desta dissertação, representa um complemento na formulação do problema de otimização estocástica com gestão de risco sendo dada por [31]:

$$\eta - \left(\sum_{t=1}^T \lambda_{t,\omega} P_{\omega,t}^s \right) \leq s_{\omega} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.37)$$

Onde η é uma variável auxiliar, $s(\omega)$ é uma variável contínua não negativa que é igual à maximização de $\eta - (c^T x + q(\omega)^T y(\omega))$ e zero:

$$s_{\omega} \geq 0 \quad \forall \omega \in \Omega \quad (4.38)$$

4.5. Formulação do Problema

A formulação do problema de exploração de CCST com SAE considerando incerteza e risco é obtida através da função objetivo apresentada no subcapítulo 4.3 com a adição das restrições expostas no subcapítulo 4.4. A formulação é apresentada seguidamente.

$$\begin{aligned} \max \quad & (1 - \beta) \left(\sum_{\omega=1}^{\Omega} \sum_{t=1}^T (\pi_{\omega,t} \times \lambda_{\omega,t} \times P_{\omega,t}^s) \right) \\ & + \beta \left(\eta - \frac{1}{1-\alpha} \sum_{\omega=1}^{\Omega} (\pi_{\omega,t} s_{\omega}) \right) \end{aligned} \quad (4.39)$$

sujeito a:

$$P_{\omega,t}^s = P_{\omega,t}^{FE} + P_{\omega,t}^{SE} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.40)$$

$$P_{\omega,t}^{FE} = \eta_1 Q_{\omega,t}^{FE} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.41)$$

$$P_{\omega,t}^{SE} = \eta_3 Q_{\omega,t}^{SE} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.42)$$

$$Q_{\omega,t}^{FE} + Q_{\omega,t}^{FS} \leq E_{\omega,s} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.43)$$

$$Q_{\min}^E u_{\omega,t} \leq Q_{\omega,t}^{FE} + Q_{\omega,t}^{SE} \leq Q_{\max}^E u_{\omega,t} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.44)$$

$$P_{\min}^s u_{\omega,t} \leq P_{\omega,t}^s \leq P_{\max}^s u_{\omega,t} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.45)$$

$$Q_{\omega,t}^S = Q_{\omega,t-1}^S + (\eta_2 Q_{\omega,t}^{FS}) - Q_{\omega,t}^{SE} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.46)$$

$$Q_{\min}^S \leq Q_{\omega,t}^S \leq Q_{\max}^S \quad \forall \omega \in \Omega, \forall t=0,1,\dots,T \quad (4.47)$$

$$\eta_2 (Q_{\omega,t}^{FS} - Q_{\omega,t-1}^{FS}) \leq R^{up} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.48)$$

$$P_{\omega,t-1}^{SE} - P_{\omega,t}^{SE} \leq R^{dn} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.49)$$

$$P_{\omega,t}^{FE}, P_{\omega,t}^{SE}, P_{\omega,t}^{FS}, P_{\omega,t}^s, Q_{\omega,t}^{FE}, Q_{\omega,t}^{SE}, Q_{\omega,t}^{FS}, Q_{\omega,t}^S \geq 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.50)$$

$$y_{\omega,t} - z_{\omega,t} = u_{\omega,t} - u_{\omega,t-1} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.51)$$

$$y_{\omega,t} + z_{\omega,t} \leq 1 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.52)$$

$$u_{\omega,t} \in \{0,1\} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.53)$$

$$y_{\omega,t} \in \{0,1\} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.54)$$

$$z_{\omega,t} \in \{0,1\} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.55)$$

$$\sum_{t=1}^L (1 - u_{\omega,t}) = 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.56)$$

$$\sum_{t=k}^{k+TMF-1} u_{\omega,t} \geq TMF(u_{\omega,k} - u_{\omega,k-1})$$

$$\forall \omega \in \Omega, \forall k=L+1, \dots, T-TMF+1 \quad (4.57)$$

$$\sum_{t=k}^T u_{\omega,t} \geq \sum_{t=k}^T (u_{\omega,k} - u_{\omega,k-1}) \quad \forall \omega \in \Omega, \forall k = T-TMF+2, \dots, T \quad (4.58)$$

$$\text{Onde: } L_{\omega} = \min\{T, (TMF - K_0^{\text{on}})u_{\omega,t=0}\} \quad \forall \omega \in \Omega \quad (4.59)$$

$$\sum_{t=1}^M u_{\omega,t} = 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.60)$$

$$\sum_{t=k}^{k+TMP-1} (1 - u_{\omega,t}) \geq TMP(u_{\omega,k-1} - u_{\omega,k})$$

$$\forall \omega \in \Omega, \forall k=M+1, \dots, T-TMP+1 \quad (4.61)$$

$$\sum_{t=k}^T (1 - u_{\omega,t}) \geq \sum_{t=k}^T (u_{\omega,k-1} - u_{\omega,k})$$

$$\forall \omega \in \Omega, \forall k=T-TMP+2, \dots, T \quad (4.62)$$

$$\text{Onde: } M_\omega = \min\{T, (TMP - K_0^{\text{off}})(1 - u_{\omega,t=0})\} \quad \forall \omega \in \Omega \quad (4.63)$$

$$P_{\omega,t}^{\text{SE}} \leq R \times e_{\omega,t} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.64)$$

$$Q_{\omega,t}^{\text{FS}} \leq R \times (1 - e_{\omega,t}) \quad \forall \omega \in \Omega, \forall t \in T \quad (4.65)$$

$$R \geq P_{\max}^s \rightarrow \text{Constante suficientemente grande} \quad (4.66)$$

$$e_{\omega,t} \in \{0,1\} \quad \forall \omega \in \Omega, \forall t \in T \quad (4.67)$$

$$(\lambda_{\omega,t} - \lambda_{\omega,t-1})(P_{\omega,t}^s - P_{\omega,t-1}^s) \geq 0 \quad \forall \omega \in \Omega, \forall t \in T \quad (4.68)$$

$$\eta - \left(\sum_{t=1}^T \lambda_{\omega,t} P_{\omega,t}^s \right) \leq s_\omega \quad \forall \omega \in \Omega, \forall t \in T \quad (4.69)$$

$$s_\omega \geq 0 \quad \forall \omega \in \Omega \quad (4.70)$$

Capítulo 5

Casos de Estudo

Neste capítulo são apresentados três casos de estudo com vista a resolver o problema de exploração de CCST com SAE. O primeiro caso de estudo consiste numa otimização determinística, o segundo caso de estudo numa otimização estocástica considerando incerteza e o terceiro caso de estudo consiste numa otimização estocástica considerando a incerteza e o risco. É aplicado um algoritmo de redução de cenários para aplicação na metodologia de otimização estocástica considerando incerteza. Por fim, é apresentado a análise de resultados.

5.1. Casos de Estudo

Com o intuito de ilustrar o desempenho da metodologia estocástica com consideração de risco modelizada por PLIM são apresentados nesta dissertação três casos de estudo baseados num produtor detentor de uma CCST com SAE:

- Caso de estudo 1: otimização determinística para simulação da exploração de CCST com SAE;
- Caso de estudo 2: otimização estocástica para simulação da exploração de CCST com SAE;
- Caso de estudo 3: otimização estocástica para simulação da exploração de CCST com SAE considerando o risco.

A CCST possui um CS constituído por concentradores cilíndricos com refletor parabólico com um rendimento $\eta_1=0,40$, um SAE com um rendimento $\eta_3=0,35$ possuindo dois tanques de sal fundido com rendimento $\eta_2=0,80$. As características da CCST com SAE utilizadas na metodologia de otimização estocástica são apresentadas na Tabela 5.1.

Tabela 5.1 – Características da CCST com SAE

Q_{\min}^E/Q_{\max}^E (MW-t)	P_{\min}^S/P_{\max}^S (MW-e)	$Q_{\min}^{FE}/Q_{\max}^{FE}$ (MW-t)	R^{dn} por hora (MW-e)	R^{up} por hora (MW-e)
50/125	0/50	0/150	35	80

Q_{\min}^S/Q_{\max}^S (MWh-t)	Q_0^S (MWh-t)	R (MW-e)	TMF (h)	TMP (h)
45/700	350	150	2	2

K_0^{on} (h)	K_0^{off} (h)	u_0	y_0	z_0
1	1	0	1	0

Os casos de estudo apresentados foram simulados com recurso ao *solver* CPLEX 12.2.0.0 [79] em GAMS [80], implementados num processador Intel® Core™ i3-4000M CPU @ 2.40GHz com uma memória RAM de 8,00 GB num sistema operativo a 64-bit (Windows 10 Pro).

O *software* MATLAB foi utilizado na construção do algoritmo de redução de cenários e para controlar e processar os casos de estudo fazendo a ligação com o *software* GAMS [82] e com o *software* Microsoft Excel [83].

O conjunto de cenários de preços para a energia elétrica no mercado diário a ser processado pelo algoritmo de redução de cenários foi construído através dos dados disponíveis em [84]. Estes dados são composto por 300 cenários equiprováveis. O conjunto de cenários de potência térmica disponível no CS foi construído através de dados da central experimental de Évora, Universidade de Évora, sendo composto por 200 cenários equiprováveis.

5.2. Caso de estudo 1

Neste caso de estudo é considerado o planeamento determinístico da CCST com SAE, utilizando os valores esperados para as incertezas do preço da energia elétrica e potência térmica disponível no CS, apresentados nas Figura 5.1 e 5.2.

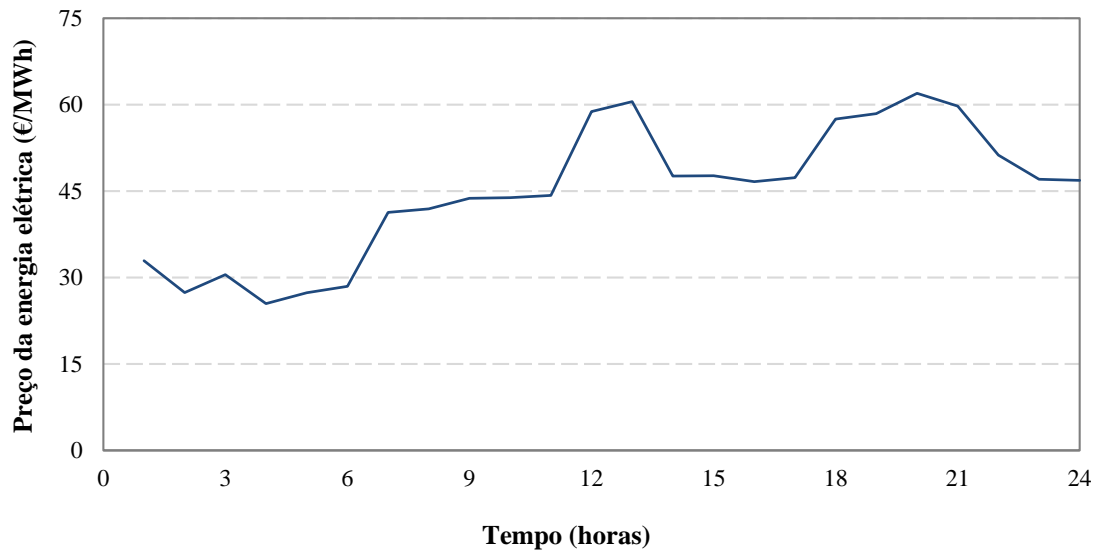


Figura 5.1 – Caso de estudo 1: Preço da energia elétrica.




Figura 5.2 – Caso de estudo 1: Potência térmica no CS.

O problema de exploração de CCST com SAE é simulado como sendo determinístico, usando os valores esperados do preço de energia elétrica e potência térmica no CS, representados na Figura 5.1 e Figura 5.2, i.e., apenas tem um cenário possível de acontecer. Na Figura 5.3 é apresentado a solução ótima para o perfil de potência elétrica na CCST com SAE.




Figura 5.3 – Caso de estudo 1: Perfil de potência elétrica na CCST com SAE.

Na Figura 5.3 é observado que nas horas de maior radiação o módulo de produção de energia elétrica recebe potência diretamente do CS, a azul, sendo que nestas horas o SAE armazena energia, a vermelho. No final do dia o perfil de preços de energia elétrica é ainda atrativo, no entanto a radiação solar é praticamente nula. Assim, no final do dia o módulo de produção de energia elétrica recebe potência através do SAE, a verde, que foi armazenada durante as horas de maior radiação. Este perfil de potências permite que seja vendida energia elétrica em mercado diário, representado na Figura 5.4.

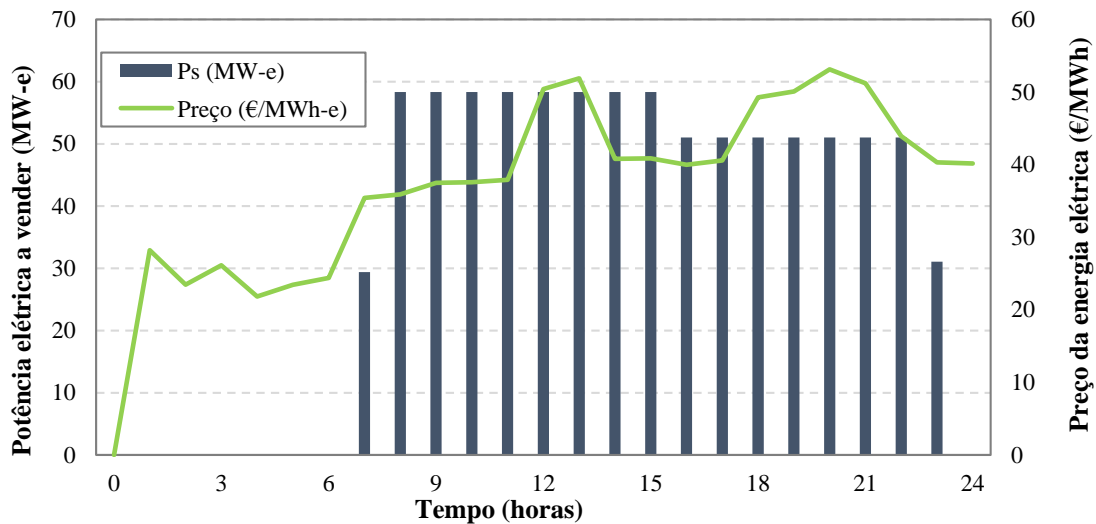


Figura 5.4 – Caso de estudo 1: Potência elétrica a vender em mercado diário.

Na Figura 5.4 é observada a potência associada com a energia elétrica a vender em mercado diário em cada hora, a azul, resultante da aplicação da metodologia de otimização determinística. Ainda, é observado o preço da energia elétrica ao longo do horizonte temporal, a verde. A energia total vendida para este planeamento da CCST com SAE, nas 24 horas do horizonte temporal, é de 758,08 MWh, originando um lucro de 38 460,44 €. Na Figura 5.5 e 5.6 é apresentado o efeito da potência térmica no CS no perfil de potência elétrica na CCST com SAE e a energia no SAE ao longo do horizonte temporal, respetivamente.




Figura 5.5 – Caso de estudo 1: Potência térmica no CS na CCST com SAE.

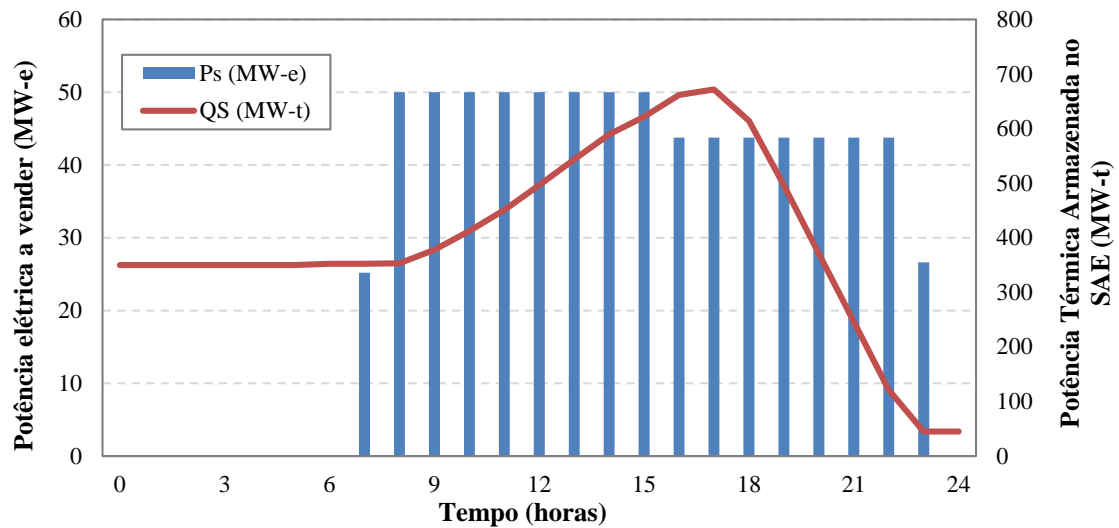


Figura 5.6 – Caso de estudo 1: Energia no SAE e potência para o mercado.

Na Figura 5.5 é observado que até à hora 7 não existe radiação solar disponível e consequentemente a CCST não está em captação de energia. Assim que existe radiação solar disponível é obtida energia elétrica para vender em mercado diário e para armazenar energia térmica no SAE, como é apresentado na Figura 5.6. Nas horas 8 a 15 o limite de produção de energia elétrica é atingido no módulo de produção. Assim, a restante radiação solar disponível é utilizada para armazenar energia térmica no SAE. A partir da hora 16 a radiação solar começa a decrescer e o SAE começa a contribuir também para a potência a associada com a energia a vender em mercado. É de notar que a partir das 20 horas a potência a associada com a energia a vender em mercado passa a ser apenas obtida diretamente do SAE, como é apresentado na Figura 5.5.

5.3. Caso de estudo 2

Na otimização estocástica a incerteza é considerada através de cenários, como apresentado no capítulo 3. Neste caso de estudo é aplicada a metodologia de otimização estocástica para diferentes números de cenários com o intuito de se retirar conclusões acerca da sua influência no resultado da metodologia de otimização estocástica. Assim, a metodologia é aplicada tendo em consideração a seguinte quantificação de cenários:

- 10 Cenários;
- 100 Cenários;
- 200 Cenários;
- 300 Cenários;
- 600 Cenários;
- 900 Cenários;
- 1200 Cenários;
- 1800 Cenários.

O objetivo da aplicação da metodologia de otimização estocástica consiste na maximização do valor do lucro esperado para o produtor detentor de CCST com SAE. Ainda, o tempo de computação necessário para a simulação da metodologia de otimização estocástica é relevante para a aceitação da sua utilização prática, visto que, um tempo de computação muito elevado pode não levar a uma aceitação da metodologia.

Os valores de lucro esperado e tempo de computação para a quantificação do número de cenários, apresentada anteriormente, aplicado à metodologia de otimização estocástica para um produtor detentor de CCST com SAE são apresentados na Tabela 5.2, sendo que para o caso específico de apenas ser considerado um cenário, i.e. corresponde a um caso análogo ao caso determinístico apresentado no subcapítulo 5.2.

Tabela 5.2 – Caso de estudo 2: Lucro esperado e tempo de computação

Cenários (#)	Lucro Esperado (€)	Tempo de Computação (m:s)
1	38 460	0:4
10	41 119	0:11
100	42 278	0:37
200	43 782	2:22
300	44 014	17:18
600	44 105	23:26
900	44 124	31:26
1200	44 204	41:22
1800	44 337	57:46

Na Tabela 5.2 é observado que a introdução da incerteza resulta em melhores valores para o lucro esperado comparativamente ao caso determinístico. No entanto, com o aumento do número de cenários o ganho que se obtém no lucro esperado é cada vez menos significativo, sendo o tempo de computação cada vez maior. A análise da evolução do tempo de computação e da sua relação com o lucro esperado é apresentado na Figura 5.7.




Figura 5.7 – Caso de estudo 2: Lucro esperado e tempo de computação

Na Figura 5.7 é observado que o lucro esperado aumenta inicialmente com o número de cenários. No entanto, tende a estagnar à medida que o número de

cenários é incrementado. Portanto, a partir de um certo número de cenários o uso de recursos computacionais para obter a solução poderá não ser apelativo tendo em consideração o acréscimo no lucro esperado.

A contribuição da otimização estocástica face à otimização determinística é analisada, usando a medida de qualidade VSS apresentada no capítulo 3, sendo os valores VSS apresentados na Tabela 5.3.

Tabela 5.3 – Caso de estudo 2: VSS para diferentes números de cenários

Cenários (#)	VSS (€)
10	2659
100	3818
200	5322
300	5554
600	5645
900	5664
1200	5743
1800	5876

Na Tabela 5.3 é observado o valor de VSS que apresenta um comportamento algo similar ao que acontece com o valor do lucro esperado. Assim, a partir de um certo número de cenários o ganho que se obtém ao utilizar uma otimização estocástica face a uma otimização determinística tende a não ser significativo. Pelo que a aplicabilidade prática no que respeita aos resultados da otimização estocástica pode ser discutível comparativamente com a otimização determinística.

5.4. Caso de estudo 3

Neste caso de estudo é aplicada a metodologia de otimização estocástica para a exploração de CCST com SAE considerando o risco, sendo o preço da energia elétrica e a potência térmica disponível no CS dados do problema. Com base no algoritmo de redução de cenário abordado no capítulo 3 são utilizados 250 cenários compostos por 25 cenários de preço da energia elétrica e 10 cenários de potência térmica disponível no CS, representados na Figura 5.8 e 5.9 respetivamente.




Figura 5.8 – Caso de estudo 3: Cenários para preço da energia elétrica.




Figura 5.9 – Caso de estudo 3: Cenários para a potência térmica no CS.

Os conjuntos originais de cenários de preço da energia elétrica de potência térmica disponível do CS são considerados com cenários equiprováveis, sendo que após a

redução feita pelo algoritmo de redução de cenários, o conjunto de cenários selecionado não é necessariamente constituído por cenários equiprováveis. O número de variáveis contínuas, variáveis binárias e restrições neste caso de estudo é apresentado na Tabela 5.

Tabela 5.4 – Caso de estudo 3: Número de variáveis e restrições

Variáveis contínuas	Variáveis binárias	Restrições
54 002	24 000	162 000

Na tabela 5.4, o número total de variáveis contínuas é igual à soma: do produto do número de horas, 24, pelo número total de decisões descritas por variáveis contínuas, 9, e pelo número total de cenários, 250; mais as variáveis da gestão de risco s_{ω} e η . O número total de variáveis binárias é igual ao produto do número de horas, pelo número de decisões descritas por variáveis binárias, 4, e pelo número total de cenários. O número total de restrições é igual ao produto do número de horas, número total de cenários e número de restrições, 27.

Os resultados obtidos para o problema de otimização estocástica para exploração de CCST com SAE são obtidos tendo em consideração diferentes valores para o nível de aversão ao risco β , variando entre 0 e 1 com passo igual a 0,2. O nível de confiança considerado é de $\alpha = 0,95$. Os resultados obtidos para os diferentes valores de ponderação de risco permitem determinar a curva da fronteira eficiente para este caso de estudo.

A curva da fronteira eficiente representa o lucro esperado versus o desvio padrão do lucro, são considerados seis valores diferentes de β como é apresentado na Figura 5.10.




Figura 5.10 – Caso de estudo 3: Lucro esperado vs. desvio padrão do lucro.

Na Figura 5.10, a curva da fronteira eficiente apresenta o portfólio de soluções eficientes com o lucro máximo esperado para cada nível de aversão ao risco. O produtor detentor de CCST com SAE se optar por ser neutro ao risco $\beta = 0$, terá uma previsão de lucro esperado de 42 110 €, sendo o desvio padrão de 2 978 €; se optar por ser avesso ao risco $\beta = 1$, terá uma previsão de lucro esperado de 41 072 €, sendo o desvio padrão de 2 301 €. Os desvios padrão entre a opção de neutro ao risco e avesso ao risco sofrem um decréscimo de 676 €.

As soluções que envolvam um risco reduzido, desvio padrão baixo, estão associados a menores lucros esperados, ou seja, o lucro esperado do produtor detentor de CCST com SAE aumenta à medida que o seu desvio padrão aumenta. Com recurso à curva da fronteira eficiente o produtor pode escolher o seu portfólio ótimo de acordo com o seu nível de aversão ao risco.

O comportamento do produtor detentor de CCST com SAE vai influenciar a oferta que fará no mercado de eletricidade e consequentemente o lucro esperado. Uma comparação tendo em consideração diferentes níveis de aversão ao risco, β , e os correspondentes desvios padrões, lucros esperados e percentagens de aumento do lucro esperado é apresentado na Tabela 5.5.

Tabela 5.5 – Caso de estudo 3: Análise do lucro esperado

β	Desvio padrão (€)	Lucro esperado (€)	% Aumento
1	2301	41072	-
0,8	2293	41097	0,06
0,6	2292	41097	0,06
0,4	2410	41525	1,10
0,2	2718	41975	2,20
0	2978	42110	2,53

Na Tabela 5.5, o lucro mais elevado é obtido para um nível de aversão ao risco correspondente a $\beta = 0$, produtor neutro ao risco, este lucro apresenta um aumento do valor de 2,53 % face ao caso de produtor avesso ao risco, $\beta = 1$.

As curvas de ofertas horárias referentes à CCST com SAE considerada no caso de estudo para um produtor neutro ao risco e para um produtor avesso ao risco são representadas na Figura 5.11.

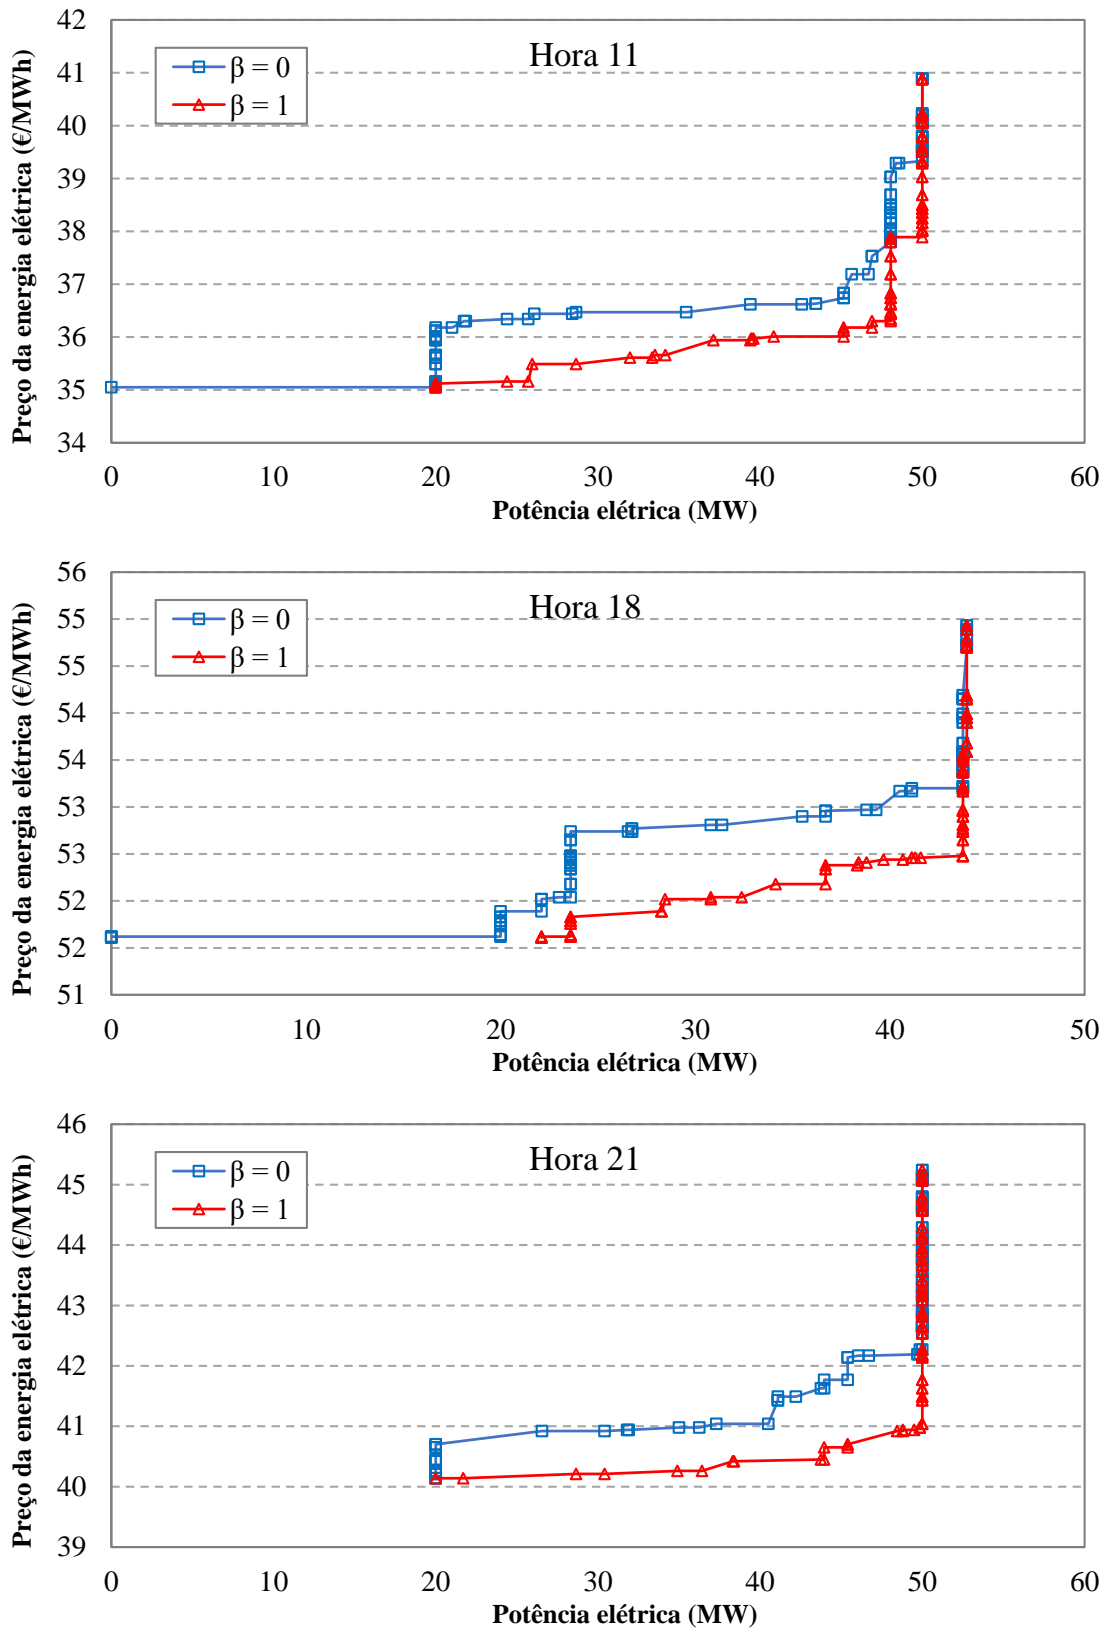


Figura 5.11 – Caso de estudo 3: Curvas de oferta horárias.

Na Figura 5.11, os níveis de aversão ao risco por parte do produtor detentor de CCST com SAE $\beta = 0$ e $\beta = 1$, as curvas de oferta apresentam perfis diferentes condicionados pela incerteza presente neste caso de estudo. Esta diferença vai originar um lucro esperado diferente como é observado na curva da fronteira eficiente. Esta diferença é devida ao facto da energia a vender em mercado para a totalidade do horizonte temporal, 24 horas, ser diferente, como é apresentado na Figura 5.12.




Figura 5.12 – Caso de estudo 3: Energia total a vender em mercado diário.

Na Figura 5.12, o aumento do nível de aversão ao risco por parte do produtor de CCST com SAE está associada uma diminuição da energia total a vender em mercado para o horizonte temporal, que resulta num lucro esperado menor. Assim, é evitada a licitação em mercado para cenários com risco maior.

5.5. Análise de Resultados

A competitividade no setor elétrico é um incentivo para o desenvolvimento de novas metodologias e aperfeiçoamento das já existentes para que a exploração de um sistema electroprodutor possa conduzir a um melhor aproveitamento económico da operação. No caso das FER esta necessidade é ainda justificada para que seja atenuada a característica imprevisível e intermitente da sua fonte de energia primária. Nesta dissertação é realizada uma contribuição para CCST com SAE que utilizando uma metodologia estocástica considerando o risco, visando não só mitigar a incerteza mas também considerar o risco no mercado diário.

A incerteza inerente ao mercado de eletricidade, da disponibilidade da radiação solar e o risco foram tomados em consideração no problema de otimização da exploração de CCST com SAE, considerando as restrições associadas à sua exploração. A função objetivo caracterizada no problema permite maximizar o valor de uma função determinada por uma soma do lucro com um termo que define uma medida de risco que controla a variabilidade do lucro, o CVaR.

A exploração de curto prazo de CCST com SAE, objeto desta dissertação, apresenta como principal conclusão que as curvas de oferta permitem ao produtor detentor de CCST com SAE dispor de um suporte para que nas decisões de ofertas em mercado diário considerem a incerteza do próprio mercado de eletricidade e da disponibilidade da radiação solar. A incerteza inerente ao mercado diário está associada aos preços da energia elétrica em cada hora e a incerteza da radiação solar está associada à potência térmica disponível no CS.

Na metodologia de otimização estocástica apresentada nesta dissertação: i) a incerteza do preço da energia elétrica em mercado e da potência térmica disponível no CS são modelizados através de um conjunto de cenários resultado da aplicação de um algoritmo de redução de cenários; ii) a gestão de risco é modelizada através

de um parâmetro que define o nível de aversão ao risco que o produtor está disposto a tomar.

A metodologia de otimização estocástica considerando incerteza e risco permite apresentar a curva da fronteira eficiente, representando o lucro esperado versus desvio padrão. A curva da fronteira eficiente é importante para a tomada de decisões no mercado diário pois disponibiliza um portfólio de soluções ótimas para vários níveis de aversão ao risco. Na dissertação são apresentados resultados para os valores extremos de aversão ao risco a fim de exemplificar a influência que o risco tem sobre a incerteza dos cenários e na respectiva tomada de decisão.

A metodologia proposta mostra ainda que é possível a implementação adequada e fidedigna com um número de cenários que não leve a um requisito computacional que possa não permitir a aceitabilidade da metodologia nas aplicações práticas por excessivo uso de requisitos computacionais. Assim, é verificado que a partir de um número de cenários superior a 300, é possível afirmar que a incerteza se encontra devidamente modelizada dado que o aumento do número de cenários origina um incremento do lucro esperado não significativo para o produtor.

Capítulo 6

Conclusão

Neste capítulo é enunciada a síntese do trabalho e apresentada as principais conclusões que se extraíram da investigação desenvolvida para a resolução do problema da exploração de CCST com SAE. São, ainda, apontadas algumas direções em que pode ser desenvolvida investigação de interesse relevante para a solução do problema.

6.1. Contribuições

A dissertação aborda e propõe a utilização do método de otimização estocástica para otimizar a exploração de curto prazo de uma CCST com SAE. A modelização da CCST com SAE recorre ao uso de variáveis inteiras para descrever restrições associadas com a descrição do funcionamento CCST.

A incerteza nos preços da energia elétrica em mercado diário e da potência térmica disponível no CS, que resulta da imprevisibilidade da radiação solar, são consideradas através de árvore de cenários. A consideração da incerteza na metodologia de otimização estocástica vem atenuar os efeitos imprevisíveis, devido a característica renovável da fonte primária deste tipo de central, e a sua característica não despachável. Um algoritmo de redução de cenários é aplicado com sucesso aos conjuntos de cenários originais, reduzindo a sua cardinalidade.

Neste trabalho, são propostas contribuições para que o produtor detentor de uma CCST com SAE possa ter as ferramentas necessárias para que a tomada de decisão seja feita de forma racional. Para isso, nesta dissertação, é realizada a gestão de risco recorrendo à medida de risco CVaR, dando à metodologia de otimização estocástica uma característica mais realista na tomada de decisões.

Com uma metodologia de otimização estocástica considerando a incerteza e o risco o produtor detentor de CCST com SAE pode efetuar a sua tomada de decisão de acordo com o nível de risco que está disposto a tomar. Assim, na curva de fronteira eficiente o produtor pode efetuar a sua tomada de decisão assumindo um compromisso entre lucro esperado e risco associado.

Os resultados obtidos mostram que a metodologia é computacionalmente apropriada para a exploração de CCST com SAE apresentando, um aceitável tempo de computação e bom desempenho, na medida em que todos os casos de estudo apresentaram convergência nas simulações.

6.2. Direções de Investigação

É possível estabelecer um conjunto de direções de investigações, quer no âmbito desta dissertação, visto que, a mesma não esgota os assuntos nela abordados, quer no que concerne a novas perspectivas que a própria dissertação deixa antever como direções para futuras investigações e desenvolvimento.

As direções de investigação identificadas são as seguintes:

- Aplicação e comparação de diferentes medidas de risco ao problema, incluindo o domínio estocástico, na perspectiva de retirar conclusões pertinentes acerca dos requisitos computacionais e melhorias nos resultados;
- Aplicação de técnicas de previsão de radiação solar e algoritmos de geração de cenários com o intuito de se dar um contributo positivo na mitigação da incerteza envolvente à radiação solar;
- Aplicação da metodologia estocástica considerando incerteza e risco a uma CCST com SAE híbrida, considerando as devidas restrições referentes ao sistema de *backup*;
- Aplicação da metodologia de otimização estocástica considerando incerteza e risco integrando a CCST com SAE com uma central de produção eólica, introduzindo a incerteza referente ao vento e as restrições associadas à rede de interligação dos dois sistemas electroprodutores e de distribuição à rede de energia eléctrica;
- Aplicação da metodologia de otimização estocástica considerando incerteza e risco para um produtor detentor de CST com SAE que participa no mercado diário e realiza contrato bilaterais. Inclusão das repercussões inerentes ao não cumprimento de contratos.

Referências Bibliográficas

- [1] Vaughn Nelson, “Energy and the Environment: Introduction to Renewable Energy”, CRC Press Taylor & Francis Group, 2011.
- [2] Kyoto Protocol to the United Nations Framework Convention on Climate Change, 1997. Disponível em: <http://europa.eu>.
- [3] Energy 2020 – A strategy for competitive, sustainable and secure energy, 2011. Disponível em: <http://europa.eu>.
- [4] Estratégia Nacional para a Energia 2020, 2014. Disponível em: <http://www.apren.pt/>.
- [5] Direção Geral de Energia e Geologia – “Estatísticas Rápidas – nº125 – Março de 2015”, Março de 2015.
- [6] Direção Geral de Energia e Geologia – “Energia em Portugal – Principais Números – Janeiro 2013”, Janeiro de 2013.
- [7] GeoModel Solar, 2015. Disponível em: <http://solargis.info>.
- [8] KIC InnoEnergy, “Future Renewable Energy Costs: Solar-Thermal Electricity”, 2015.
- [9] Solar Power International, “The Power of Solar is Exponential Better”, Las Vegas Convention Center, October 20-23 2014.
- [10] Renewable Energy Focus, “Case Study in CSP plant Performance”, March/April 2015.
- [11] IRENA, “Renewable Energy Technologies: Cost Analysis Series, Volume 1: Power Sector Issue 2/5”, June 2012.
- [12] Report of the Conference of the Parties on its fifteenth session, held in Copenhagen, 2009. Disponível em: <http://unfccc.int>.

- [13] Hugo Alexandre Fernandes dos Santos e Silva, “Planeamento de Curto Prazo de Sistemas de Energia Solar Usando Técnicas de Otimização Robusta”, Dissertação para obtenção do Grau de Mestre, ISEL, Dezembro de 2014.
- [14] J. A. Taylor, D. S. Callaway, K. Poolla, “Competitive energy storage in the presence of renewables”, *IEEE Transactions on Power System*, vol. 28, no. 2, pp. 985–996, May 2013.
- [15] S. H. Madaeni, R. Sioshansi, P. Denholm, “How Thermal Energy Storage Enhances the Economic Viability of Concentrating Solar Power, Proc. IEEE, Vol. 100, No. 2, pp. 335-347, February 2012.
- [16] H. M. I. Pousinho, V. M. F. Mendes, M. Collares-Pereira, C. Pereira Cabrita, “Análise do Sistema Eletroprodutor Ibérico e a Integração de Centrais de Concentração Solar”, *Ingenium*, pp. 78-83, Janeiro/Fevereiro 2015.
- [17] Massachusetts Institute of Technology, “The Future of Solar Energy: An Interdisciplinary MIT Study”, 2015.
- [18] IEA, “Technology Roadmap: Solar Thermal Electricity”, 2014.
- [19] H. L. Zhang, J. Baeyens, J. Degreè, G. Cacères, “Concentrated solar power plants: Review and design methodology”, *Renewable and Sustainable Energy Reviews*, vol. 22, pp. 466-481, Jun.
- [20] E. H. M. van Voorthuysen, “The promising prespective of Concentrating Solar Power (CSP)”, Nov. 2005.
- [21] K. Williges, J. Lillestam, A. Patt, “Making concentrated solar power competitive with coal: The costs of a European feed-in tariff”, *Energy Policy*, vol.38, no.6, pp. 3089-3097, Jun. 2010.

- [22] B. Tamimi, C. Cañizares, K. Bhattacharya, “System Stability Impact of Large-Scale and Distributed Solar Photovoltaic Generation: The Case of Ontario, Canada” ,IEEE Transactions on Sustainable Energy, vol. 4, no. 3, pp. 680-688, Jul. 2013.
- [23] KIC InnoEnergy, “Future renewable energy costs: solar-thermal electricity”, 2015.
- [24] ETSAP, IRENA, “Concentrating Solar Power Technology Brief”, Jan. 2013.
- [25] Renewable Energy Focus, “CSP: Developments in heat transfer and storage materials”, September/October 2010.
- [26] Society of Tribology & Lubrication Engineers, “Heat Transfer Fluids: Selection, maintenance & new applications”, May 2009.
- [27] S. Y. Wang, J. L. Yu, “Optimal sizing of the CAES system in a power system with high wind power penetration”, International Journal Electrical Power and Energy Systems, vol. 37, pp. 117-125, May 2012.
- [28] R. Shah, N. Mithulananthan, R. C. Bansal, “Damping performance analysis of battery energy storage system, ultracapacitor and shunt capacitor with large-scale photovoltaic plants”, Applied Energy, vol.96, pp.235-244, Ago. 2012.
- [29] H. Daneshi, H. Daneshi, N.M. Tabari, A. N. Jahromi, “Security-constrained unit commitment with wind generation and compressed air energy storage” IET Gener. Transm. Distrib. 6, pp. 167–175, 2012.
- [30] J. R. Birge, F. Louveaux, “Introduction to stochastic programming”, Springer Verlag, New York, 1997.
- [31] A. J. Conejo, M. Carrión, J. M. Morales, “Decision Making Under Uncertainty in Electricity Markets”, Springer, 2010.

- [32] R. Sioshansi, P. Denholm, “The Value of Concentrating Solar Power and Thermal Energy Storage”, *IEEE Transactions on Sustainable Energy*, vol. 1, no. 3, pp. 173-183, Oct. 2010.
- [33] J. Usaola, “Operation of concentrating solar power plants with storage in spot electricity markets”, *Renewable Power Generation*, vol. 6, no. 1, pp. 59-66, Jan. 2012.
- [34] S. H. Madaeni, E. Sioshansi, P. Denholm, “Estimating the capacity value of concentrating solar power plants with thermal energy storage: A case study of the Southwestern United States”, *IEEE Transactions on Power System*, vol. 28, no. 2, pp. 1205-1215, May 2013.
- [35] H. M. I. Pousinho, P. Freire, J. Esteves, V. M. F. Mendes, C. P. Cabrita, M. C. C. Pereira, “Optimal Generation Scheduling of Wind-CSP Systems in Day-Ahead Electricity Markets”, *Technological Innovation for Cloud-Based Engineering Systems, DoCEIS 2015*, pp. 285-295, Springer.
- [36] H. M. I. Pousinho, V. M. F. Mendes, J. P. S. Catalão, “A stochastic programming approach for the development of offering strategies for wind power producer”, *Electric Power Systems Research*, vol. 89, pp. 45-53, Aug. 2012.
- [37] J. L. Higle, “Stochastic programming: Optimization when uncertainty matters”, *Tutorials in Operations Research, INFORMS 2005*.
- [38] S. Sen, J. L. Higle, “An introductory tutorial on stochastic linear programming models”, *Institute for Operations Research and the Management Sciences*, vol. 29, pp. 33-61, March-April 1999.
- [39] J. L. Higle, S. Sen, “Stochastic decomposition: An algorithm for two-stage linear programs with recourse”, *Mathematics of Operations Research*, vol. 16, no. 3, pp. 650-669, August 1991.

- [40] J. Poland, K. S. Stadler, “Stochastic Optimal Planning of Solar Thermal Power”, IEEE Conference on Control Applications, October 2014.
- [41] R. H. Know, D. Frances, “Optimization-Based Bidding in Day-Ahead Electricity Auction Markets: A Review of Models for Power Producers”, Handbook of Networks in Power Systems I, Energy Systems, Springer, 2012.
- [42] H. M. I. Pousinho, H. Silva, V.M.F. Mendes, M. C. Pereira, C. Pereira Cabrita, “Self-scheduling for energy and spinning reserve of wind/CSP plants by a MILP approach”, ELSEVIER Energy, 2014.
- [43] J. Dupačová, N. G. Kuska, and W. Römisch, “Scenario reduction in stochastic programming: An approach using probability metrics”, Mathematical Programming Series A, vol. 95, pp.493–511, Mar. 2003.
- [44] H. Heitsch, W. Römisch, “Scenario reduction algorithms in stochastic programming. Computational Optimization and Applications”, vol. 24, no. 2-3, pp. 187–206, Feb.-Mar. 2003.
- [45] J. M. Morales, S. Pineda, A. J. Conejo, and M. Carrión, “Scenario reduction for futures market trading in electricity markets”, IEEE Transactions on Power Systems, vol. 24, no. 2, pp.878–888, May 2009.
- [46] P. Artzner, F. Delbaen, J. M. Eber, D. Heath, “Coherent measures of risk”, Mathematical Finance, vol. 9, no. 3, pp. 203–228, Jul. 1999.
- [47] H. M. Markowitz, “Portfolio Selection: Efficient Diversification of Investments”, Wiley, New York, 1959.
- [48] W. Ogryczak, A. Ruszczyński, “From stochastic dominance to mean-risk models: Semideviations as risk measures”, European Journal of Operational Research, vol. 116, no. 1, pp. 33–50, 1999.

- [49] R. T. Rockafellar, S. Uryasev, “Optimization of conditional value-at-risk”, *Journal of Risk*, vol. 2, no. 3, pp. 21–41, 2000.
- [50] R. T. Rockafellar, S. Uryasev, “Conditional value-at-risk for general loss distributions” *Journal of Banking & Finance*, vol. 26, no. 7, pp. 1443–1471, Jul. 2002.
- [51] D. Dentcheva, A. Ruszczyński, “Portfolio optimization with stochastic dominance constraints”, *Journal of Banking & Finance*, vol. 30, no.2, pp. 433–451, 2006.
- [52] D. Dentcheva, A. Ruszczyński, “Optimization with stochastic dominance constraints”, *SIAM Journal on Optimization*, vol. 14, no. 2, pp. 548–566, Feb. 2003.
- [53] R. Gollmer, U. Gotzes, R. Schultz, “Second-order stochastic dominance constraints induced by mixed-integer linear recourse”, Preprint 644-2007, Department of Mathematics, University of Duisburg-Essen, 2007.
- [54] R. Gollmer, F. Neise, R. Schultz “Stochastic programs with first-order dominance constraints induced by mixed-integer linear recourse”, Preprint 641-2006, Department of Mathematics, University of Duisburg-Essen, 2006.
- [55] R. Schultz, S. Tiedemann, “Risk aversion via excess probabilities in stochastic programs with mixed-integer recourse”, *Mathematical Finance*, vol. 14, no. 1, pp.115–138, 2003.
- [56] H. M. I. Pousinho, “Optimização da Exploração de Curto Prazo e das Ofertas em Mercado para um Sistema Electroprodutor Considerando Incerteza e Risco”, Tese para obtenção do Grau de Doutor, Universidade da Beira Interior, Maio de 2012.
- [57] P. Bacher, H. Madsen, H. A. Nielson, “Online short-term solar power forecasting”, *Solar Energy*, vol. 83, pp. 1772-1783, Out. 2009.

- [58] Robert Foster, Majid Ghassemi, Alma Cota, “Solar Energy Renewable Energy and the Environment”, CRC Press Taylor & Francis Group, 2011.
- [59] L. Martín, L. F. Zarzalejo, J. Polo, A. Navarro, R. Marchante, M. Cony, “Prediction of global solar irradiance based on time series analysis: Application to solar thermal power plants energy production planning”, *Solar Energy*, vol. 84, pp. 1772-1781, Jul. 2010.
- [60] NOVATEC SOLAR. Disponível em: <http://novatecsolar.com>.
- [61] ARIAE, “Las centrales termosolares: Situación y perspectivas en Iberoamérica”, Madrid, Marzo-2015.
- [62] U. S. Department of Energy. Disponível em: <http://energy.gov>.
- [63] K. Larsen, “The power of the concentrated sun”, *Renewable Energy Focus*, pp. 54-57, May/June 2010.
- [64] N. Zendejdel, A. Karimpour, M. Oloomi, “Optimal Unit Commitment Using Equivalent Linear Minimum Up and Down Time Constraints”, 2nd IEEE International Conference on Power and Energy (PECon 08), 2008.
- [65] L. Baringo, A. J. Conejo, “Offering Strategy Via Robust Optimization”, *IEEE Transactions on Power Systems*, vol. 26, no. 3, August 2011.
- [66] H.M.I. Pousinho, V.M.F. Mendes, M.C.Pereira, C.P.Cabrita, “Integração de energia solar térmica na rede elétrica”, *Mundo Académico*, pp. 40-46.
- [67] C. Voyant, M. Muselli, C. Paoli, M. Nivet, “Hybrid methodology for hourly global radiation forecasting in Mediterranean area”, *Renewable Energy*, vol. 53, pp. 1-11, May 2013.
- [68] T. H. M. El-Fouly, E. F. El-Saadany, M. M. A. Salama, “One day ahead prediction of wind speed using annual trends”, *Power Engineering Society General Meeting 2006*.

- [69] S. N. Kaplanis, “New methodologies to estimate the hourly global solar radiation; Comparisons with existing models”, *Renewable Energy*, vol. 31, pp. 781-790, May 2006.
- [70] J. Soares, A. P. Oliveira, M. Z. Božnar, P. Mlakar, J. F. Escobedo, A. J. Machado, “Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique”, *Applied Energy*, vol. 79, pp. 201-214, Abr. 2004.
- [71] A. S. S. Dorvlo, J. A. Jervase, A. Al-Lawati, “Solar radiation estimation using artificial neural networks”, *Applied Energy*, vol. 71, pp. 307-319, Abr. 2002.
- [72] S. Rehaman, M. Mohandes, “Artificial neural networks estimation of global solar radiation using air temperature and relative humidity”, *Energy Policy*, vol. 36, pp. 571-576, Fev. 2008.
- [73] V. Gómez, A. Casanovas, “Fuzzy modeling of solar irradiance on inclined surfaces”, *Solar energy*, vol. 75, pp. 307-315, Out. 2003.
- [74] A. Will, J. Bustos, M. Bocco, J. Gotay, C. Lamelas, “On the use of niching genetic algorithms for variable selection in solar radiation estimation”, *Renewable Energy*, vol. 50, pp. 168-176, Fev. 2013.
- [75] J. Wu, C. K. Chan, “Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNN”, *Solar Energy*, vol. 85, pp. 808-817, May 2011.
- [76] J. F. Mendes, A. Joyce, M. Giestas, P. Horta, M. J. Brites, “Armazenamento de energia solar térmica”, *Laboratório Nacional de Energia e Geologia*, 2010.

- [77] R. Laia, H. M. I. Pousinho, R. Melício, V. M. F. Mendes, “Self-scheduling and bidding strategies of thermal units with stochastic emissions constraints”, Elsevier, Energy conversion and management, vol. 89, pp. 975-984, 2015.
- [78] H. M. I. Pousinho, “Nova metodologia de otimização da exploração de recursos hídricos: programação linear inteira mista”, Dissertação para obtenção do Grau de Mestre, Junho 2009.
- [79] The IBM CPLEX. Disponível em: <http://www-01.ibm.com/software/commerce/optimization/cplex-optimizer/>.
- [80] R. E. Rosenthal, “GAMS, A user’s guide”, GAMS development corporation, Washington, DC, USA, 2010.
- [81] Red Eléctrica de España. Disponível em: <http://www.esios.ree.es/web-publica/>.
- [82] M. C. Ferris, “MATLAB and GAMS: Interfacing optimization and visualization software”, May 2005.
- [83] GAMS development corporation, “GAMS GDX facilities and tools”, 2013.

Anexos

6th Doctoral Conference on Computing, Electrical and Industrial Systems –
DoCEIS 2015

**Optimal Generation Scheduling of Wind-CSP Systems in
Day-Ahead Electricity Markets**

Optimal Generation Scheduling of Wind-CSP Systems in Day-Ahead Electricity Markets

H.M.I. Pousinho^{1,2}, P. Freire³, J. Esteves³, V.M.F. Mendes^{1,3}, C. Pereira Cabrita⁴,
M. Collares-Pereira¹

¹ University of Évora, Évora, Portugal, hpousinho@gmail.com, collarespereira@uevora.pt

² IDMEC/LAETA, Instituto Superior Técnico, Universidade de Lisboa, Lisbon, Portugal

³ Instituto Superior de Engenharia de Lisboa, Lisbon, Portugal, vfmendes@deea.isel.pt

⁴ CISE, University of Beira Interior, R. Fonte do Lameiro, 6201-001 Covilhã, Portugal, cabrita@ubi.pt

Abstract. This paper presents a coordination approach to maximize the total profit of wind power systems coordinated with concentrated solar power systems, having molten-salt thermal energy storage. Both systems are effectively handled by mixed-integer linear programming in the approach, allowing enhancement on the operational during non-insolation periods. Transmission grid constraints and technical operating constraints on both systems are modeled to enable a true management support for the integration of renewable energy sources in day-ahead electricity markets. A representative case study based on real systems is considered to demonstrate the effectiveness of the proposed approach.

Keywords: Concentrated solar power; wind power; mixed-integer linear programming; transmission constraints.

1 Introduction

Renewable energy grid integration increased in the E.U. to fulfill the Energy – 2020 initiative. Energy efficiency improvement, renewable technologies and lower emissions are priorities to ensure environmental sustainability [1]. Wind power systems and concentrated solar power (CSP) systems are engaged in the meeting of demand increase in the Southern Mediterranean, profiting from favorable renewable energy sources. But, the non-controllable variability and limited predictability of the energy source of these systems [2] conveys real-time uncertainty posing capacity planning challenges related to the tuning of ancillary services needed to ensure system stability and reliability [3]. Also, real-time uncertainty on renewable energy availability can increase costs if an unfitting prediction occurs. Hence, a coordination approach seems to be an adequate required option in order to reduce the uncertainty in power output. The wind-CSP systems coordination is a reliable option, enabling to accommodate energy integration into the power grid and day-ahead electricity markets [4], as well as to increment the dispatchability attribute on the accommodation. The non-dispatchable characteristic of CSP systems is lessened with thermal energy storage (TES) systems, enabling plant base load support. TES not only allows offsetting generation deficit during non-insolation periods, reducing real-time net generation variability, but also allows shifting of generation towards appropriate periods [5]. TES has proved to be a reliable option [6], allowing control on the energy, improving the capacity value and profits. Moreover, TES further increments the dispatchability and can reduce the running of conventional thermal power plants in short-term ancillary services [7], reducing the need for spinning, implying a noted reduction in reserve costs. Also, TES allows reducing high marginal cost units when an unpredicted drop in renewable energy input occurs. Therefore, the line of research of coordination approach for wind-CSP having TES systems is regarded as an important promising one offering new technical challenges to the researchers and this paper presents a contribution on this regard.

The paper presents a mixed-integer linear programming (MILP) model for solving the generation scheduling problem of wind-CSP having TES systems. The aim is to achieve the optimal generation schedule that maximizes the profit of a power producer taking part in a day-ahead electricity market. The optimization approach considers not only transmission line constraints, but also technical operating constraints on wind power systems and on CSP systems to enable a true management support for the integration of renewable energy sources in day-ahead electricity markets.

2 Relationship to cloud-based solutions

Cloud-based solutions can help the processing of approaches for helping trading in a day-ahead electricity market in order to take greater advantages of bids, requiring methodological approaches demanding computational effort not currently available to all power producers. Among these approaches the ones for the solution of the problems concerned with scheduling: energy management, unit commitment and energy offers are particular vital for upholding power producers. The approaches to solve these problems have been limited by the available computational resources, i.e., details concerning some reality are disregarded in view of the excessive use of processing requirements. These limitations are evident for large systems and lead to solutions not addressed in convenient agreement with the reality, because the computational resources do not allow the usage of data or modeling for delivering more real adequate solutions.

Cloud-based solutions are able to contribute for upholding a power producer exploiting wind-CSP systems by setting out an adequate availability of computational resources needed to address scheduling problems in due time. Although of the uncertainty on the wind and solar power, i.e., intermittency and variability, cloud-based engineering systems will deal with problems having a better approach to the full reality in due time with gains in terms of profit. Cloud-based solutions will help on the smoothing of the electricity price due to the fact of having bids of wind power with higher level of energy and with more certainty in what regards the satisfaction on delivering the electric energy accepted at the closing of the market. Also, environmental benefit is expected with mitigation of the deviation from the assumed compromises by a better finding of offers able of fulfillment, less spinning reserve is needed, less thermal units are needed and less fossil fuel is used. Eventually, cloud-based solutions will allow approaches in order that when a power producer exploiting a wind-CSP systems at site has renewable energy available is all captured to be converted into electric energy injected without concerns on dynamic stability into the power grid in due time.

3 State of the Art

The literature on optimal scheduling is still rapidly growing. Coordination strategies and optimization approaches for short-term scheduling have been in research, for instances: a envisaged wind-thermal coordination via simulated annealing unveiled an improvement of smoothing the active power fluctuations [8], and one via MILP unveiled a reduction of the uncertainty in wind power output [9]; a envisaged coordination of wind power with compressed air energy storage unveiled an improvement due to the synergies between wind power and compressed air energy storage [10]; a envisaged wind and hydro power coordination, specially pumped-storage hydro power systems [11,12], unveiled an improvement on minimization of curtailment, energy imbalance and dispatchability. Furthermore, electrical vehicles connection to the power grid are expected to be used as controllable loads and a convenient operation with suitable market design may help in the accommodation more wind power [13].

Coordination strategies have unveiled progress in reducing of the uncertainty of wind power output by the use of different dispatchable resources or loads, even though resources may not be installed in the same region of wind power systems deployment. But, when the surrounding of the load centres has attractive conditions of wind speed and solar irradiation, wind-CSP is an option design to be considered. This option enables a better accommodation of energy integration into the power grid and day-head electricity markets [14], as well as to increase the dispatchability attribute on the accommodation. The scheduling proposed in this paper is based on a MILP approach, which has been a successful approach for solving scheduling problems in general. So, also is expected to be one to help support decisions in a day-head electricity market.

4 Problem Formulation

The scheduling is computed by the maximization of the objective function given by the profit subject to transmission and systems constraints.

4.1 Objective function

The profit is equal to the revenues from day-ahead electricity market sales and wind production incentive rate minus the CSP variable costs during the time horizon of the schedule. The objective function to be maximized is given as follows:

$$F = \sum_{k \in K} \left[\pi_k^{da} (p_k^s - p_k^b) + \sum_{i \in I} \xi p_{i,k}^{Wind} - \sum_{c \in C} \beta_c p_{c,k}^{CSP} \right] \quad (1)$$

In (1), K is the set of hours in the time horizon, π_k^{da} is the forecasted day-ahead market price in hour k , p_k^s is the power sold to day-ahead electricity market in hour k , p_k^b is the power purchased from day-ahead electricity market in hour k , I is the set of wind turbines, ξ is the wind production incentive rate, $p_{i,k}^{Wind}$ is the power output of the wind turbine i , C is the set of CSP systems, β_c is the variable cost of the CSP system c and $p_{c,k}^{CSP}$ is the power output of the CSP system c in hour k .

4.2 Constraints

The constraints for the scheduling are due to the transmission grid, operation of wind systems, operation or minimum up/down time of CSP systems.

4.2.1 Transmission grid

The transmission grid constraints are given as follows:

$$(1-\psi)^{-1} p_k^s - (1-\psi) p_k^b = \sum_{i \in I} p_{i,k}^{Wind} + \sum_{c \in C} p_{c,k}^{CSP} \quad \forall k \quad (2)$$

$$-\chi \leq (1-\psi)^{-1} p_k^s - (1-\psi) p_k^b \leq \chi \quad \forall k \quad (3)$$

$$0 \leq \sum_{i \in I} p_{i,k}^{Wind} + \sum_{c \in C} p_{c,k}^{CSP} \leq \chi \quad \forall k \quad (4)$$

$$0 \leq p_k^s \leq \chi y_k \quad \forall k \quad (5)$$

$$0 \leq p_k^b \leq \chi(1-y_k) \quad \forall k \quad (6)$$

In (2) to (6), ψ is the transmission loss, χ is the transmission capacity, and y_k is a 0/1 variable. In (2), the electric power balance is enforced between the day-ahead electricity market trading with wind power systems and CSP systems. In (3) and (4), the electric

power bounds are set for the transmission line. In (5) and (6), the energy flow in the line is set infeasible for simultaneously trading by selling and purchasing.

4.2.2 Operation of wind systems

The operational constraints of wind power system are given as follows:

$$0 \leq p_{i,k}^{Wind} \leq W_{i,k} \quad \forall i, k \quad (7)$$

$$0 \leq p_{i,k}^{Wind} \leq \overline{P}_i^{Wind} \quad \forall i, k \quad (8)$$

where $W_{i,k}$ is the scheduled of wind turbine i in hour k , and \overline{P}_i^{Wind} is the wind turbine i power bound. In (7), the operating limits for the scheduled wind power of each wind turbine i are set. In (8), the maximum power capacity of each wind turbine i is set.

4.2.3 Operation of CSP systems

The operational constraints of CSP systems are given as follows:

$$p_{c,k}^{CSP} = p_{c,k}^{FE} + p_{c,k}^{SE} - X_c \quad \forall c, k \quad (9)$$

$$p_{c,k}^{FE} = \eta_1 q_{c,k}^{FE} \quad \forall c, k \quad (10)$$

$$p_{c,k}^{SE} = \eta_3 q_{c,k}^{SE} \quad \forall c, k \quad (11)$$

$$\underline{Q}_c^{PB} u_{c,k} \leq q_{c,k}^{FE} + q_{c,k}^{SE} \leq \overline{Q}_c^{PB} u_{c,k} \quad \forall c, k \quad (12)$$

$$q_{c,k}^{FE} + q_{c,k}^{FS} \leq S_{c,k} \quad \forall c, k \quad (13)$$

$$q_{c,k}^S = q_{c,k-1}^S + \eta_2 q_{c,k}^{FS} - q_{c,k}^{SE} \quad \forall c, k \quad (14)$$

$$\underline{Q}_c^S \leq q_{c,k}^S \leq \overline{Q}_c^S \quad \forall c, k \quad (15)$$

$$\underline{Q}_c^{FE} \leq q_{c,k}^{FE} \leq \overline{Q}_c^{FE} \quad \forall c, k \quad (16)$$

$$0 \leq p_{c,k}^{CSP} \leq \overline{P}_c^{CSP} \quad \forall c, k \quad (17)$$

$$p_{c,k}^{SE} - p_{c,k+1}^{SE} \leq RD_c^T \quad \forall c, k = 0, \dots, K-1 \quad (18)$$

$$\eta_2 (q_{c,k+1}^{FS} - q_{c,k}^{FS}) \leq RU_c^T \quad \forall c, k = 0, \dots, K-1 \quad (19)$$

$$0 \leq p_{c,k}^{SE} \leq M z_{c,k} \quad \forall c, k \quad (20)$$

$$0 \leq p_{c,k}^{FS} \leq M (1 - z_{c,k}) \quad \forall c, k \quad (21)$$

$$p_{c,k}^{FE}, p_{c,k}^{SE}, q_{c,k}^{FE}, q_{c,k}^{SE} \geq 0 \quad \forall c, k \quad (22)$$

In (9) to (21), $p_{c,k}^{FE}$ and $p_{c,k}^{SE}$ are the power produced by the solar field (SF) c and the TES c in hour k , X_c is the parasitic power of the CSP plant c , η_1 is the SF efficiency, $q_{c,k}^{FE}$ is the thermal power from the SF c in hour k , η_3 is the molten-salt tanks efficiency, $q_{c,k}^{SE}$ is the storage power in TES c to produce electricity in hour k , \underline{Q}_c^{PB} and \overline{Q}_c^{PB} are the thermal power bounds of the power block of CSP plant c , $u_{c,k}$ is the CSP plant c commitment in hour k , $q_{c,k}^{FS}$ is the thermal power from the SF c stored in hour k , $S_{c,k}$ is the thermal power produced by the SF c in hour k , $q_{c,k}^S$ is the thermal energy stored in TES c at the end of hour k , η_2 is the TES efficiency, \underline{Q}_c^S and \overline{Q}_c^S are the TES c thermal energy bounds, \underline{Q}_c^{FE} and \overline{Q}_c^{FE} are the thermal power bounds from the SF c ,

\bar{P}_c^{CSP} is the CSP plant c power bound, RD_c^T and RU_c^T are the ramp-up and ramp-down limits for charging and discharging the stored energy of TES c , M is a sufficiently large constant $M \geq \bar{P}_c^{CSP}$, and $z_{c,k}$ is the 0/1 variable equal to 1 if TES c discharges power in hour k . In (9), the electric power balance is enforced between the power output of CSP system with the electric power produced from the SF, the storage and the parasitic power needed for maintaining the molten-salt fluid in operation conditions. This parasitic power occurs even if a CSP system is not operating, eventually implying that if the producer has not enough energy available, a small quantity of energy is soaked up from the grid, incurring on an associated cost. The parasitic power is assumed constant. In (10) and (11), the electric power from the SF and TES is considered dependent on the efficiencies associated with the thermal power of the SF and the storage power, respectively. In (12), the bounds for the sum of the power from the SF and TES are set. In (13) and (14), the balance of the thermal power in the SF and the energy stored in the TES is set, respectively. In (15), the bounds for the thermal power storage in the TES are set in order to avoid the solidification of salts and the maximum storage capacity to be exceeded. In (16), the bounds for the thermal power from the SF are set. In (17), the bounds for the power output of the CSP systems are set. In (18) and (19), the charge and the discharge ramp rates of the TES are set, respectively. In (20) and (21), power restrictions are set to prevent simultaneous discharging and charging of the TES in the same hour, imposed by the 0/1 variable, z_k .

4.2.4 Minimum up/down time of CSP systems

The minimum up/down time constraints of CSP systems are given as follows:

$$\sum_{r=k-UT_c^{SF+T}+1, r \geq 1 \in k} (u_{c,r} - u_{c,r-1}) \leq u_{c,k} \quad \forall c, k = L^{SF+T} + 1, \dots, K \quad (23)$$

$$\sum_{r=k-DT_c^{SF+T}+1, r \geq 1 \in k} (u_{c,r-1} - u_{c,r}) \leq 1 - u_{c,k} \quad \forall c, k = F^{SF+T} + 1, \dots, K \quad (24)$$

In (23) and (24), the minimum up/down times for the CSP system c are set based on [18], where $L_c^{SF+T} = \min[K, UT_c^{SF+T}]$ and $F_c^{SF+T} = \min[K, DT_c^{SF+T}]$.

5 Case Study

The case study is intended to show the advantages of the coordination between wind power systems and CSP systems having TES. These advantages are coming from the synergies between both systems and the adequate optimal mix of synergies is in favor of the proposed approach. The MILP for the approach has been solved using CPLEX 12.1 solver under GAMS environment [15]. A computer with 8 GB RAM with 2.30 GHz of CPU is used for the simulations of realistic case studies based on a Iberian wind-CSP system with 40 wind turbines, $i = 1, \dots, 40$, and 2 CSP plants, $c = 1, 2$ and carried out with technical data shown in Table 1.

$\underline{P}_i^{Wind} / \bar{P}_i^{Wind}$ (MW)	$\underline{P}_c^{CSP} / \bar{P}_c^{CSP}$ (MWe)	$\underline{Q}_c^S / \bar{Q}_c^S$ (MWh)	$\underline{Q}_c^{FE} / \bar{Q}_c^{FE}$ (MWh)
0 / 2	0 / 50	45 / 700	0 / 150
$\underline{Q}_c^{PB} / \bar{Q}_c^{PB}$ (MWh)	$q_{c,0}^S$ (MWh)	RU_c^T / RD_c^T (MWe/h)	$UT_c^{SF+T} / DT_c^{SF+T}$ (h)
50 / 125	120	35 / 80	2 / 2

Table 1. Wind-CSP system data.

All wind power systems have the same data as well as CSP systems, respectively. The installed wind power capacity is 80 MW and for CSP is 100 MW_e. The systems share a transmission line connecting to the power grid. This line has 3 % of losses and exported power is assumed to be between 50 MW and 130 MW. The module efficiencies for the CSP systems are respectively: 1) $\eta_1 = 0.40$; 2) $\eta_2 = 0.35$; 3) $\eta_3 = 0.80$. The parasitic power is 3.5 MW_e and the wind production incentive rate is assumed to be of 35 €/MWh.

The time horizon in the simulations is a day on an hourly basis, corresponding to a participation in a day-ahead electricity market. Within the time horizon are considered as input data not only the solar and the wind power profiles, but also the day-ahead market prices profile. The solar irradiation profile derived from the System Advisor Model [16] was converted into available thermal power. The wind power profile is derived from the ANN forecaster designed in [17]. The wind power and thermal power output profiles respectively are assumed to be the same for each wind turbine and CSP systems as is shown in Fig. 1.




Fig 1. SF thermal and wind power profiles.

The scheduling problem for the wind-CSP coordination has a day-ahead time horizon, due to this short horizon, the energy market prices can be assumed as deterministic input data given by forecast average prices. The prices of the Iberian electricity market given in [18] are used in the case study and shown in Fig. 2.




Fig 2. Day-ahead energy market prices.

A summary of the optimizing characteristics for processing the problem presented in the case study in what regards the number of constraints, continuous variables, binary variables and computation times is shown in Table 1.

#	Constraints	Continuous variables	Binary variables	CPU time (s)
Case study	1,436	864	120	8

Table 1. Optimizing characteristics of the case study.

The number of installed wind turbines and CSP systems having TES are 20 and 2, respectively. The total installed capacities of wind power systems and CSP systems having TES are 80 MW and 100 MW_e, respectively. The energy and profit for the

transmission line capacity of $\chi = 60$ MW and $\chi = 130$ MW associated with the enforced system are shown in Table 2.

#	Transmission capacity (MW)	Energy stored (MWh)	Energy sold (MWh)	Profit (€)
Case study	60	6,405	1,259	83,527
	130	6,269	1,544	95,673

Table 2. Energy and profit in function of transmission capacity.

Table 2 allows a comparison between the profits, revealing a reduction of about 15% for $\chi = 60$ MW. Table 2 shows that an increase in the transmission line capacity of the line allows to make a better use of the energy stored, allowing an augmented profit.

The optimal schedule for the wind-CSP coordination in what regards the assessing of the impact of transmission line constraints with $\chi = 60$ MW and with $\chi = 130$ MW are respectively shown in Fig. 3 (a) and (b).




Fig 3. Coordination for transmission capacities: (a) $\chi = 60$ MW; (b) $\chi = 130$ MW.

Fig. 3 (a) shows for the high price hours a significant CSP production in comparison with low price hours. The benefit of TES shifting the production is revealed and the excess energy eventually overloading transmission from hours 8, 10 to 12 and 16 is able to be stored for a convenient discharge at hours 11 to 13, 17, 18 and 24. Additionally, the synergies between wind energy and solar energy allows for the possibility of enhancing the scheduling due to the negative correlation. Thus, an efficient energy schedule is obtained, illustrating the proficiency of the optimization approach for accommodating this deployment with different changing patterns of renewable energy in a power grid. The thermal energy storage shows the significance of the line capacity regarding the storage in the TES. For instance, the increase in the line capacity raises the level of the storage in the low prices hours with solar thermal power in order to be conveniently used during the other hours. If the capacity factor is incremented by downsizing the transmission capacity, then curtailment is to be expected and consequent decrease of the energy produced. The thermal energy storages in function of the transmission capacity and of the time are shown in Fig. 4.




Fig 4. Thermal energy storages in function of transmission capacity and over the time horizon.

6 Conclusions

An approach based on MILP is proposed for the coordination problem of wind-CSP having TES systems and for supporting decisions of participating in day-ahead markets, taking into account transmission line constraints and prevailing technical operating ones for the wind power, CSP and TES. The approach reduces uncertainty and improves the integration of more energy into a grid due to the convenient optimal mix of synergies. The TES is effectively handled to improve the operational productivity. The case studies are in favour of the approach to support decisions in day-ahead markets.

Acknowledgements


This work was supported by Fundação para a Ciência e a Tecnologia (FCT), through IDMEC under LAETA, Instituto Superior Técnico, Universidade de Lisboa, Portugal.

References

1. Energy 2020 – A strategy for competitive, sustainable and secure energy, 2011. Available: <http://europa.eu>
2. Taylor, J.A., Callaway, D.S., Poolla, K.: Competitive energy storage in the presence of renewables. *IEEE Trans. Power Syst.* 28, 985–996 (2013)
3. Lannoye, E., Flynn, D., O'Malley, M.: Evaluation of power system flexibility. *IEEE Trans. Power Syst.* 27, 922–931 (2012)
4. Sioshansi, R., Denholm, P.: The value of concentrating solar power and thermal energy storage. *IEEE Trans. Sust. Energy* 1, 173–183 (2010)
5. Dominguez, R., Baringo, L., Conejo, A.J.: Optimal offering strategy for a concentrating solar power plant. *Applied Energy* 98, 316–325 (2012)
6. Madaeni, S.H., Sioshansi, R., Denholm, P.: How thermal energy storage enhances the economic viability of concentrating solar power. *Proc. IEEE* 100, 335–347 (2012)
7. García-González, J., de la Muela, R.M.R., Santos, L.M., González, A.M.: Stochastic joint optimization of wind generation and pumped-storage units in an electricity market. *IEEE Trans. Power Syst.* 23, 460–468 (2008)
8. Chen, C.-L.: Simulated annealing-based optimal wind-thermal coordination scheduling. *IET Gener. Transm. Distrib.* 1, 447–455 (2007)
9. Kamalinia, S., Shahidehpour M.: Generation expansion planning in wind-thermal power systems. *IET Gener. Transm. Distrib.* 4, 940–951 (2010)
10. Daneshi, H., Srivastava, A.K.: Security-constrained unit commitment with wind generation and compressed air energy storage. *IET Gener. Transm. Distrib.* 6, 167–175 (2012)
11. Sanchez de la Nieta, A.A., Contreras, J., Munoz, J.I.: Optimal coordinated wind-hydro bidding strategies in day-ahead markets. *IEEE Trans. Power Syst.* 28, 798–809 (2013)
12. Khodayar, M.E., Shahidehpour, M., Wu, L.: Enhancing the dispatchability of variable wind generation by coordination with pumped-storage hydro units in stochastic power systems. *IEEE Trans. Power Syst.* 28, 2808–2818 (2013)
13. Li, Z., Guo, Q., Sun, H., Wang, Y., Xin, S.: Emission-concerned wind-EV coordination on the transmission grid side with network constraints: Concept and case study. *IEEE Trans. Smart Grid* 4, 1692–1704 (2013)
14. Usaola, J.: Operation of concentrating solar power plants with storage in spot electricity markets. *IET Renew. Power Gener.* 6, 59–66 (2012)
15. Cplex, Gams, Solver manuals. Gams/Cplex, 2014. Available: <http://www.gams.com>
16. Catalão, J.P.S., Pousinho, H.M.I., Mendes, V.M.F.: An artificial neural network approach for short-term wind power forecasting in Portugal. *Eng. Intell. Syst. Electr. Eng. Commun.* 17, 5–11 (2009)
17. National Renewable Energy Laboratory, USA, Solar Advisor Model User Guide for Version 2.0, 2008. Available: <http://www.nrel.gov/docs>
18. Market operator of the electricity market of the Iberian Peninsula, OMEL, 2014. Available: <http://www.omel.es>

Renewable Energy – Elsevier

**Bilevel Approach to Wind-CSP Day-ahead Scheduling with Spinning
Reserve under Controllable Degree of Trust**



Bilevel approach to wind-CSP day-ahead scheduling with spinning reserve under controllable degree of trust



H.M.I. Pousinho ^{a,b,*}, J. Esteves ^c, V.M.F. Mendes ^{a,c}, M. Collares-Pereira ^a,
C. Pereira Cabrita ^d

^a Department of Physics, University of Évora, R. Romão Ramalho, Évora 7002-554, Portugal

^b IDMEC/LAETA, Instituto Superior Técnico, Av. Rovisco Pais, Lisbon 1049-001, Portugal

^c Department of Electrical Engineering and Automation, Institute Superior of Engineering of Lisbon, R. Conselheiro Emídio Navarro, Lisbon 1950-062, Portugal

^d CISE, University of Beira Interior, Convento de Santo António, Covilhã 6200-001, Portugal

ARTICLE INFO

Article history:

Received 26 January 2015

Received in revised form

14 May 2015

Accepted 7 July 2015

Available online xxx

Keywords:

Bilevel programming

$n - K$ security criterion

Spinning reserve

Transmission constraints

Wind-CSP day-ahead schedule

ABSTRACT

This paper proposes a day-ahead schedule harmonization between wind power plants and concentrating solar thermal power plants having thermal energy storage. The negative correlation between wind power and solar power is computed and an artificial neural network method estimates the power. The schedule is carried out by a bilevel mathematical programming approach. The upper-level determines energy and spinning reserve schedule by the maximization of profit subject to all lower-level problems. Lower-level problems minimize the post-contingency power output. A controllable degree of trust on the schedule is introduced based on $n - K$ security criterion for worst-case contingency. The approach uses duality theory and problem approximations for a conversion into an equivalent mixed-integer linear programming problem. A case study is presented to illustrate the effectiveness of the approach for power producers not only with transmission constraints, but also valuing safekeeping on the day-ahead schedule to ensure a degree trust on the satisfaction of compromises within electricity markets.

© 2015 Elsevier Ltd. All rights reserved.

1. Introduction

Market-based power systems and large-scale integration of renewable energy sources (RES) are causes of concern for decision-makers, regarding the need to guarantee the reliability and security performance of the power grid [1]. A course of action for fading this concern is to accommodate the changing patterns of different intermittent and variable RES into a harmonization scheme.

E.U. has a significant share of installed wind power capacity, contributing to meet low-carbon emission targets [2] and to reduce expenditure on fossil fuels. However, wind power integration due to the limited predictability may have potential adverse impact on the power grid operation. Thus, stand-alone wind power plants are unavoidable fated to be curtailed [3]. One reason for curtailment due to congestion situations is the recurrent stressing of transmission lines [4–6]. In addition, wind power integration tends to

increase provision and calls to reserve power [7].

Wind energy capturing is often installed in remote regions of the load centres, because those regions have not only more favourable wind speeds, but also sites for wind power plants are straightforwardly available. Hence, to bring the wind energy to load centres new transmission lines are expected to be required in order to circumvent congestion situations [8]. These lines are not only costly, but also due to the land-use and topography limitations often tend to be hard to erect [9]. Additionally, if the lines are only scaled for wind power plants, then the maximum transmission capacity will rarely be achieved due to the low capacity factor of wind power plants [3], e.g., in the Iberian Peninsula usually less than 30% [10]. A more efficient scaling of the lines is possible by a proper exploitation of wind energy with other energy sources in a harmonization scheme. This harmonization scheme should be cared for not only at the level of generation expansion planning, but also at the level of day-ahead scheduling. Surveys about harmonization schemes have unveiled enhancements on power system operation planning [11]. For instance, in Ref. [12], a wind-thermal scheduling solved by a simulated annealing-based approach shows an enhanced

* Corresponding author. Department of Physics, University of Évora, R. Romão Ramalho, Évora, 7002-554, Portugal.

E-mail address: hpousinho@gmail.com (H.M.I. Pousinho).

Nomenclature	
<i>Indexes, constants and parameters</i>	
c, C	CSP plant, SF or TES index and set
i, I	wind turbine index and set
k, K	period index and set
β_c	variable cost of the CSP plant c
χ	transmission capacity
π_k^{da}	day-ahead market price in period k
π_k^{sr}	SR market price in period k
σ	maximum SR capacity
ξ	wind generation incentive rate
ψ	transmission loss
$S_{c,k}$	thermal power produced by the solar field (SF) c in period k
$W_{i,k}$	scheduled of wind turbine i in period k
X_c	parasitic power of the CSP plant c
$\bar{P}_c^{CSP}, \underline{P}_c^{CSP}$	CSP plant c power bounds
\bar{P}_i^{Wind}	wind turbine i power bound
$\bar{Q}_c^S, \underline{Q}_c^S$	TES c thermal energy bounds
$\bar{Q}_c^{FE}, \underline{Q}_c^{FE}$	thermal power bounds from the SF c
$\bar{Q}_c^{PB}, \underline{Q}_c^{PB}$	thermal power bounds of the power block of CSP plant c
RU_c^T, RD_c^T	ramp-up/down limit for charging/discharging the stored energy of TES c
UT_c^{SF+T}, DT_c^{SF+T}	minimum up/down time of CSP plant c
<i>Continuous variables</i>	
p_k^b	power purchased from day-ahead market in period k
p_k^s	power sold to day-ahead market in period k
p_k^{Wind}	power output of wind power plant in period k
$p_{i,k}^{Wind}$	power generated by the wind turbine i in period k
$P_{c,k}^{CSP}$	power output of CSP plant c in period k
$p_{c,k}^{FE}$	power generated by the SF c in period k
$P_{c,k}^{SE}$	power generated from the energy stored in TES c in period k
$P_{c,k}^{SE,SR}$	SR generated from the energy stored in TES c in period k
$P_{c,k}^{SR}$	power generated of CSP plant c , if SR is called in period k
$q_{c,k}^{FE}$	thermal power from the SF c in period k
$q_{c,k}^{FS}$	thermal power from the SF c stored in period k
$q_{c,k}^{SE}$	storage power in TES c to produce electricity in period k
$q_{c,k}^{SE,SR}$	storage power in TES c to produce SR in period k
$q_{c,k}^S$	thermal energy stored in TES c at the end of period k
$q_{c,k}^{S,SR}$	thermal energy stored in TES c , used for SR, at the end of period k
$r_{c,k}$	SR sold by CSP plant c to SR market in period k
$v_{c,k}, v_{i,k}$	dual variables of the upper bound for plant c/i availability in period k
w_k	dual variable of $n - K$ security constraint in period k
<i>Binary variables</i>	
$a_{c,k}, a_{i,k}$	equal to 1 if plant c/i is available in the worst-contingency state of period k
$u_{c,k}$	CSP plant c commitment in period k
y_k	equal to 1 if energy is sold in period k
$z_{c,k}$	equal to 1 if TES c discharges power in period k

performance in what regards the smoothing of the active power fluctuations. Also, in Ref. [13], a generation expansion planning of wind-thermal power plants solved by a mixed-integer linear programming (MILP)-based approach shows an enhancement of profit, but with the need to strengthen ramping capabilities for thermal units. In Ref. [7], a unit commitment with wind generation and compressed air energy storage is addressed, showing an improvement due to worthy synergies between wind energy and the compressed air energy storage. In Refs. [14,15], a modelling for wind power and pumped-storage hydro power plants shows advantages of not only minimizing curtailments and energy imbalances, but also an enhancement on the dispatchability relatively to the stand-alone wind power plants. Harmonization schemes between wind power and concentrating solar power (CSP) plants are important for the Southern Iberian Peninsula [16], due to favourable wind resources and solar irradiation levels near load centres.

CSP plants benefit from the possibility of adding low cost thermal energy storage (TES) systems [17,18], enhancing dispatchability and ability to be in the spinning reserve (SR) market. The provision of SR from the CSP plants may be called up on when the power system is stressed [16]. Also, TES allows for: offsetting generation deficit during times of insufficient solar irradiation, reducing real-time net power variability and peak shaving; shifting of generation towards suitable periods [19], increasing the economic revenue. TES has proved to be a reliable option for CSP plants [20], reducing high marginal cost units when an unpredicted drop in renewable power occurs.

Although investment analysis on new CSP plants can lead to a questionable economical installation of new transmission lines, an association with wind power plants under a harmonization scheme is capable of economically corroborate the installation of these lines. Sharing transmission line costs between those power plants generates mutual benefits, e.g., the dispatchability of CSP having TES could raise the profit by going into production at the period of low wind power, avowing a low capacity factor of a wind power plant standing alone [21]. But for best economic exploitation, a minimum transmission capacity factor of a line is usually required, entailing that the transmission capacity has to be smaller than the maximum capacity of the CSP and of the wind power plants standing alone. Hence, although a CSP plant having TES should ideally go into production at maximum output power during high price periods [22], the power plant may be required to operate in less profitable ones due to transmission constraints. Also, there can be periods of high wind and solar irradiation, implying the need for curtailment.

This paper proposes a harmonization scheme between wind power and CSP having TES plants and taking into account transmission concerns, in order to achieve better profit in day-ahead and SR energy markets. The formulation for this scheme uses a bilevel mathematical programming approach to determine simultaneously energy and SR schedule. Also, the model is integrated with an $n - K$ security criterion for worst-case contingency state on the plants, allowing for a controllable degree of safekeeping on the schedule for energy and SR, to guarantee under contingency state of a loss up to K over the n plants the satisfaction of the compromises

with the electricity market [23]. The model is capable of unveiling the synergy concerning the association of those plants, assuming a negative correlation between the real-time availability of plants and having an added flexibility provided by TES. The contributions of this paper are as follows: 1) The optimal scheduling of wind power with CSP having TES plants; 2) The impact assessment of transmission constraints; 3) The economic impact of $n - K$ security criterion.

The remainder of this paper is organized as follows. Section 2 describes the features of the problem. Section 3 provides the formulation, consisting in a bilevel mathematical approach which is recasted as a MILP problem. Section 4 presents the results of applying the proposed approach to a case study. Section 5 concludes the paper providing relevant remarks.

2. Problem description

2.1. Decision framework

The modelling framework under study is motivated by the Iberian electricity market, as in Ref. [24], which includes the day-ahead and SR markets [25]. The goal is to maximize the profit of wind power and CSP having TES plants in these markets. The maximization delivers the schedule for energy and SR under a controllable degree of trust on the schedule based on $n - K$ security criterion for worst-case contingency.

The framework considered is the day-ahead schedule of wind power and CSP having TES plants for a power producer taking part in a pool-based electricity market that comprises two independent short-term trading floors: the day-ahead and SR markets. The power producer is considered to have a marginal effect on electricity prices in either of the aforementioned markets, and so, is assumed to have the behaviour of a price-taker. This implies that electricity prices are assumed as given input data, impacting not only the behaviour of the loads, but also the generation. The decision for trades involves electric power scheduled on an hourly basis with one day in advance as depicted in Fig. 1.

SR is a commodity traded in the market to counteract unpredictable power changes [26]. The provision for SR, if possible and conveniently scheduled an accepted in the SR market, allows an enhancement on profitability for the power producer.

The scheduling mathematical formulation proposed in this paper aims to explore synergies between wind power and CSP plants, assuming that the plants are spread over geographical areas close to each other and consequently making possible to inject the energy into the same substation, which is connected through a single transmission line to the remainder of the power grid as depicted in Fig. 2.




Fig. 1. Temporal schedule in an electricity market.

The wind-CSP day-ahead schedule allows for the sharing of the transmission line with the purpose of mitigating wind curtailment, transmission congestion and increasing the utilization factor of the line. This wind-CSP day-ahead schedule is accomplished considering not only constrained transmission, but also the flexibility given by the CSP with TES, allowing partial dispatch, i.e., enabling solar thermal power to be shifted and to fill-in excess transmission capacity during lower-resource periods of wind power. The model prioritizes the wind power, because CSP plants having TES allows for flexibility. Also, this is due to wind generation being more valuable than CSP, given the variable cost of CSP and losses of energy on the conversion procedure. The SR scheduled is only assumed for the CSP plants and, additionally, the eventuality of simultaneous contingencies is assumed during the schedule horizon. The simultaneous contingencies are modelled by an $n - K$ security criterion for worst-case contingency state on the plants. The $n - K$ security criterion allows power producer to have a controllable degree of trust on the schedule for energy and SR, giving a safekeeping satisfaction on the compromises assumed within the electricity markets under a contingency state of a loss up to K over the n plants.

2.2. Solar irradiation/wind power modelling

Solar irradiation and wind power modelling have to be assessed in terms of assisting the correct expansion planning, identifying the convenient location for the deployments of power plants. Once the power plants have been deployed have to be assessed in terms of operation planning in order to identify the convenient day-ahead schedule. The operation planning mitigation of power fluctuations is strongly dependent on the correlation between solar irradiation and wind power, i.e., on the locations of the wind-CSP plants. In Ref. [27], a method for assisting expansion planning of wind-CSP plants is developed for assessment location across a region, aiming at mitigating the power production fluctuation. This method uses canonical correlation analysis for analysing spatio-temporal balancing between solar irradiation and wind power. An application of the method in southern half of the Iberian Peninsula shows valuable balancing patterns, but with a marked seasonality in strength, sign, and spatial coverage. In Ref. [28], a method for assisting expansion planning uses principal component analysis in two steps to allow assessment of wind power plant locations. An application of the method in the southern Iberian Peninsula, including offshore areas, shows not only a valuable spatial balancing pattern, but also shows that the convenient interconnection of wind power plants across the region substantially reduces power production fluctuation. Hence, the expansion planning assessment for the deployments of power plants is a relevant step, i.e., the choice of the power plants for wind-CSP plants schedule has to be conveniently regarded in order to achieve excellence on the schedule for the wind-CSP plants. In Ref. [29], a method for assisting expansion planning based on an annealing algorithm shows the strong potential on the Iberian Peninsula at least at the monthly time-scale for operation with mitigation of fluctuation of power produced by wind-CSP plants.

The wind-CSP day-ahead schedule has the advantage of having a forecasting short-term horizon implying that the short-term scheduling is less affected by the uncertainty on the forecast. Hence, the prospect for scheduling solar thermal and wind power contributing for the conversion during periods of low solar output can have more acceptance, avowing additional generation capacity commitment. This paper assumes key focus on the mixed-integer modelling of the wind-CSP day-ahead schedule problem, using wind and solar short-term forecast as acceptable data information for the purpose of the schedule. This schedule for solar irradiation

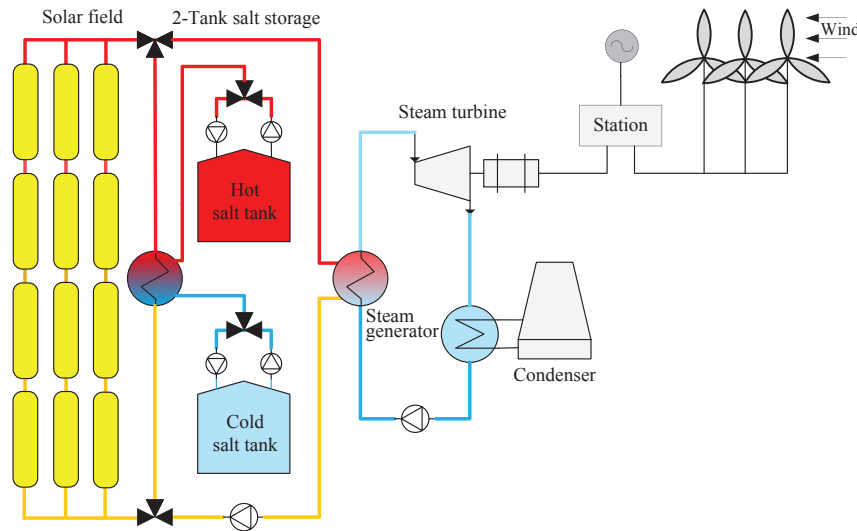


Fig. 2. Structure of the wind-CSP coordination.

and wind power with a negative correlation is a promising one in order to reduce the wind-CSP power fluctuation [30] and increment the line capacity factor.

An artificial neural network (ANN) method is used in this paper for forecasting in terms of operation planning solar irradiation and wind power up to one day-ahead. A feed-forward ANN is intended to be used on large data sets for mapping the dynamic behaviour of the input data. The architecture used is as in Ref. [31] a three-layered feed forward ANN model.

The three-layered feed-forward network has one input layer having four units, one hidden layer having nine units with a hyperbolic tangent sigmoid transfer function, and one output layer having one unit with pure linear transfer function. This architecture has been proven to be a universal mapper, provided that the hidden layer has enough units [32]. On one hand, if there are too few units, the network will not be flexible enough to conveniently model the data and, on the other hand, if there are too many units, the network may over-fit the data. The number of units in the hidden layer, n_{hidden} , is chosen by an empirical method giving $n_{hidden} = 2 n_{input} + 1$, where n_{input} is the number of input variables. Hence, there are $2 \times 4 + 1 = 9$ units in the hidden layer. The flowchart of the algorithm for implementing the ANN method is depicted in Fig. 3.

The steps for the algorithm are as follow:

First step: Create the matrices with daily profiles by column respectively for the historical data set on solar irradiation and on wind power;

Second step: Select by correlation criterion a number of columns on the matrices so that the set of selected columns conveniently emulate the dynamic of the input data;

Third step: Normalize the selected data from the data real range $[\min_A, \max_A]$ into the range $[-1, 1]$, using the Min-Max method;

Fourth step: Fed the normalized data and train the ANN for forecasting solar irradiation and wind power series, using the Levenberg–Marquardt (LM) algorithm as in Ref. [31];

Fifth step: Recover the data from the range $[-1, 1]$ into the range $[\min_A, \max_A]$ to assess the forecast for the solar irradiation and wind power output series.

The matrices in the first step have been chosen with 30 columns, corresponding to the 30 previous days to the day whose solar irradiation and wind power are to be forecasted. In the

second step, correlation is imposed on the selection of solar irradiation and wind power in order to conveniently emulate the dynamic of the input data. The correlation coefficient, $\rho_{S,P}$ between the data series of the solar irradiation, S_k , and wind power, P_k , is stated as:

$$\rho_{S,P} = \frac{\sum_k (S_k - \bar{S})(P_k - \bar{P})}{\sqrt{\sum_k (S_k - \bar{S})^2} \sqrt{\sum_k (P_k - \bar{P})^2}} \quad (1)$$

The daily average correlation (1) assessed in terms of operation planning in the case study, Section 4, used for the wind-CSP plants locations in the Iberia Peninsula, computed for 30 days on an hourly basis is -0.31 . This value is used for preserving representativeness of the negative correlation for the entire historical data set. Hence, the criterion is to select inputs with correlation coefficient smaller than -0.31 and 7 of the 30 days are selected. In the third step, the used normalization is the transformation stated as:

$$x'_k = \frac{x_k - \min_a}{\max_a - \min_a} (\max_A - \min_A) + \min_A \quad (2)$$

where \min_a and \max_a are the lower and upper values of the input data x_k , respectively. While in the fifth step data is recovered using the transformation stated as:

$$x_k = \frac{x'_k - \min_A}{\max_A - \min_A} (\max_a - \min_a) + \min_a \quad (3)$$

The training epoch is set to 100 in the fourth step. The LM algorithm is used due to its advantage of having a small computation time for a large ANN size comparatively to the usual back-propagation algorithm. The LM algorithm is a variation of Newton's method [31], mixing updating concepts of Newton with Gauss-Newton methods. The Newton update for minimizing a convex function $V(\mathbf{x})$ with respect to the vector \mathbf{x} is stated as:

$$\Delta(\mathbf{x}) = -[\nabla^2 V(\mathbf{x})]^{-1} \nabla V(\mathbf{x}) \quad (4)$$

where $\nabla^2 V(\mathbf{x})$ is the Hessian matrix and $\nabla V(\mathbf{x})$ is the gradient vector. Neglecting the second-order derivatives of the error vector, the Hessian matrix is stated as:

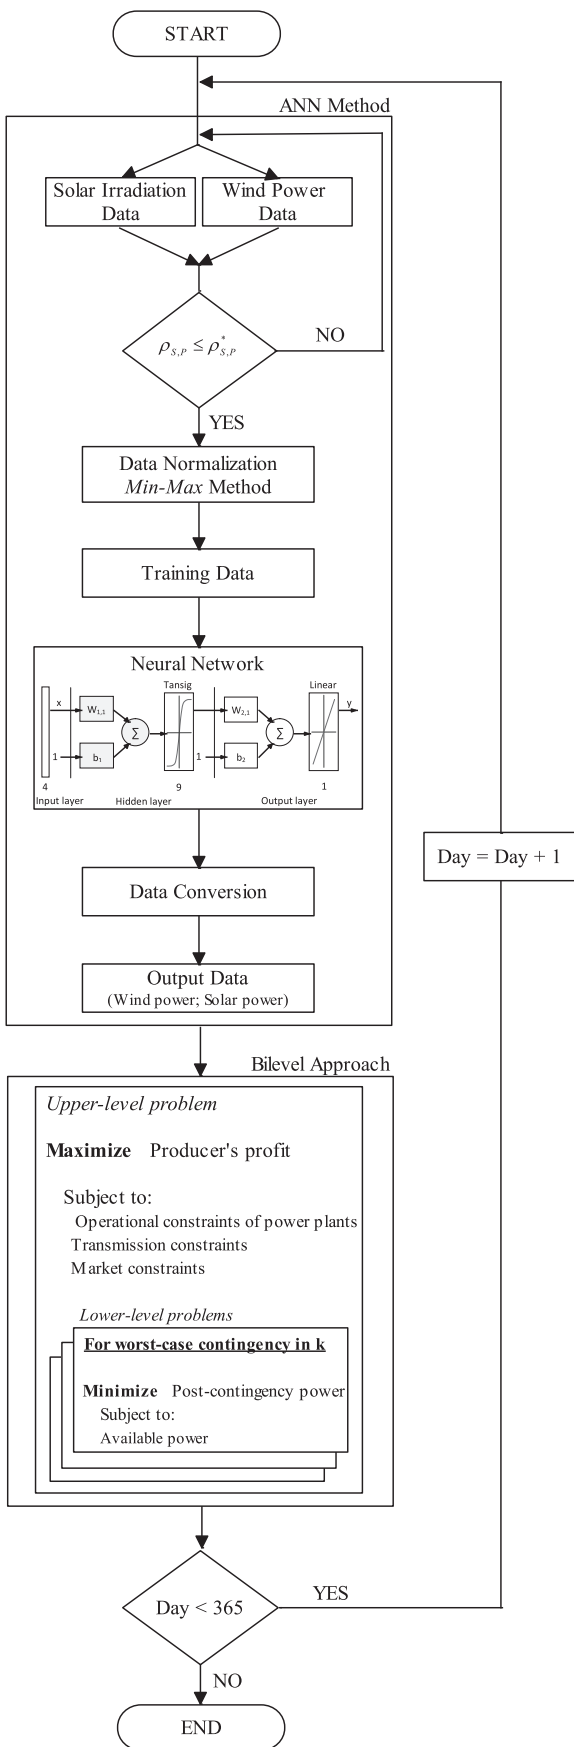


Fig. 3. Flowchart of ANN method and bilevel approach.

$$\nabla^2 V(\mathbf{x}) = 2\mathbf{J}^T(\mathbf{x})\mathbf{J}(\mathbf{x}) \quad (5)$$

where $\mathbf{J}(\mathbf{x})$ is the Jacobian matrix. The Gauss-Newton update is stated as:

$$\Delta(\mathbf{x}) = -[\mathbf{J}^T(\mathbf{x})\mathbf{J}(\mathbf{x})]^{-1}\mathbf{J}^T(\mathbf{x})\mathbf{e}(\mathbf{x}) \quad (6)$$

where $\mathbf{e}(\mathbf{x})$ is the error vector. The advantage of Gauss-Newton over the standard Newton's method is that it does not need computation of second-order derivatives. While the LM consists in the update stated as:

$$\Delta(\mathbf{x}) = -[\mathbf{J}^T(\mathbf{x})\mathbf{J}(\mathbf{x}) + \mu\mathbf{I}]^{-1}\mathbf{J}^T(\mathbf{x})\mathbf{e}(\mathbf{x}) \quad (7)$$

where μ is suitably modified during the algorithm iterations. Even so, the matrix $\mathbf{J}^T(\mathbf{x})\mathbf{J}(\mathbf{x})$ may not be invertible, this method can overcome the drawback of the Gauss-Newton one [33].

2.3. $n - K$ security criterion

A security criterion ensures a power producer degree of immunity to adverse situations capped by the criterion. Security in the proposed wind-CSP day-ahead schedule is crucial to safeguard the energy and SR scheduling in occurrence of adversities on CSP plants or on wind power plants. Methods of security have been proposed [34–37], ranging from the $n - 1$ and $n - 2$ security, usual implemented in practice [34] and [35], to generalization to multiple contingency cases known by $n - K$ security criterion [36,37], ensuring that a power producer with n plants has a degree of immunity to K or fewer plants contingencies. A difficulty with $n - K$ security is linked with the high number of contingency combinations, i.e., the total number of possible sets of contingencies is the sum with i ranging from 1 to K of the combination given by $n!/[(n - i)!]$. Although not all of the contingencies have a significant value for the probability of occurrence, $n - K$ contingencies can occur and if so, then significant profit losses are deemed to occur. Hence, precautions for avowing multiple contingency are crucial. Robust optimization is used in Ref. [36] to address the issue of the K critical components that will spawn the worst-case, instead of brute force per enumeration or of a plausible list of contingencies. The approach proposed for the wind-CSP day-ahead schedule addresses this issue by robust optimization using a bilevel approach, circumventing the setbacks with solution of the larger problem by solving a set easier smaller sub-problems. Furthermore, the bilevel approach is converted into an approximate MILP approach in order to achieve computational tractability.

3. Mathematical formulation

The mathematical optimization problem for the wind-CSP day-ahead schedule is stated as to find out the optimal schedule, which maximizes the profit of a price-taker producer in a day-ahead market. The optimal schedule for the exploitation of the wind-CSP plants considers a connection to the grid with one single transmission line having congestion problems.

3.1. General MILP approach

The wind-CSP day-ahead schedule is generally formulated as a MILP approach. The objective function to be maximized is stated as follows:

$$\sum_{k \in K} [\pi_k^{da}(p_k^s - p_k^b) + \xi p_k^{Wind} - \sum_{c \in C} \beta_c p_{c,k}^{CSP}] \quad (8)$$

The objective function to be maximized (8) provides the profit from the coordinated generation of wind turbines with CSP plants. The first term in (8) represents the revenue from the day-ahead market sales, where π_k^{da} is the day-ahead market price in period k , p_k^s is the power sold to day-ahead market in period k and p_k^b is the power purchased from day-ahead market in period k . The second term in (8) represents the revenue from the wind generation incentive rate, where ξ is the wind generation incentive rate and p_k^{Wind} is the power output of wind power plant in period k . The third term in (8) represents the incurred variable costs by the CSP plants, where β_c is the variable cost of the CSP plant c and $p_{c,k}^{CSP}$ is the power output of CSP plant c in period k . Note that, the generation cost for the wind turbines is assumed to be null. The optimal value of the objective function is determined subject to constraints: equality constraints and inequality constraints or simple bounds on the variables. The constraints are as follow:

- Transmission constraints

$$(1 - \psi)^{-1} p_k^s - (1 - \psi) p_k^b = p_k^{Wind} + \sum_{c \in C} p_{c,k}^{CSP} \quad \forall k \quad (9)$$

$$-\chi \leq (1 - \psi)^{-1} p_k^s - (1 - \psi) p_k^b \leq \chi \quad \forall k \quad (10)$$

$$0 \leq p_k^s \leq \chi y_k \quad \forall k \quad (11)$$

$$0 \leq p_k^b \leq \chi(1 - y_k) \quad \forall k \quad (12)$$

Constraints (9) enforce the balance of electric power between the day-ahead market trading with wind and CSP power, where ψ is the transmission loss. Constraints (10) set the electric power bounds for the single transmission line, where χ is the transmission capacity. Constraints (11) and (12) set that the energy flow in the line cannot be for sale and purchase simultaneously, because the 0/1 variable, y_k , that is equal to 1 if energy is sold in period k imposes no simultaneity.

- Operational constraints of CSP plants

$$p_{c,k}^{CSP} = p_{c,k}^{FE} + p_{c,k}^{SE} - X_c \quad \forall c, k \quad (13)$$

$$p_{c,k}^{FE} = \eta_1 q_{c,k}^{FE} \quad \forall c, k \quad (14)$$

$$p_{c,k}^{SE} = \eta_3 q_{c,k}^{SE} \quad \forall c, k \quad (15)$$

$$\underline{Q}_c^{PB} u_{c,k} \leq q_{c,k}^{FE} + q_{c,k}^{SE} \leq \overline{Q}_c^{PB} u_{c,k} \quad \forall c, k \quad (16)$$

$$q_{c,k}^{FE} + q_{c,k}^{FS} \leq S_{c,k} \quad \forall c, k \quad (17)$$

$$q_{c,k}^S = q_{c,k-1}^S + \eta_2 q_{c,k}^{FS} - q_{c,k}^{SE} \quad \forall c, k \quad (18)$$

$$\underline{Q}_c^S \leq q_{c,k}^S \leq \overline{Q}_c^S \quad \forall c, k \quad (19)$$

$$\underline{Q}_c^{FE} \leq q_{c,k}^{FE} \leq \overline{Q}_c^{FE} \quad \forall c, k \quad (20)$$

$$\underline{p}_c^{CSP} \leq p_{c,k}^{CSP} \leq \overline{p}_c^{CSP} \quad \forall c, k \quad (21)$$

$$p_{c,k}^{SE} - p_{c,k+1}^{SE} \leq RD_c^T \quad \forall c, k = 0, \dots, K-1 \quad (22)$$

$$\eta_2 (q_{c,k+1}^{FS} - q_{c,k}^{FS}) \leq RU_c^T \quad \forall c, k = 0, \dots, K-1 \quad (23)$$

$$0 \leq p_{c,k}^{SE} \leq M z_{c,k} \quad \forall c, k \quad (24)$$

$$0 \leq p_{c,k}^{FS} \leq M(1 - z_{c,k}) \quad \forall c, k \quad (25)$$

$$p_{c,k}^{FE}, p_{c,k}^{SE}, q_{c,k}^{FE}, q_{c,k}^{SE} \geq 0 \quad \forall c, k \quad (26)$$

Constraints (13) enforce the balance of the electric power between the power output of CSP plant, $p_{c,k}^{CSP}$, with the electric power generated from the SF, $p_{c,k}^{FE}$, the storage power, $p_{c,k}^{SE}$, and the parasitic power, X_c , needed for maintaining the molten-salt fluid in operational conditions. The parasitic power associated with fluid pumping occurs even when a CSP plant is not operating. This implies that the CSP plant will absorb a small quantity of energy from the grid and that has an associated cost [22]. In this paper, the parasitic power is assumed constant. Constraints (14) and (15) impose that the electric power from the SF and TES depends on the efficiencies η_1 and η_3 associated with the thermal power of the SF, $q_{c,k}^{FE}$, and the storage power, $q_{c,k}^{SE}$, respectively. Constraints (16) set the bounds \underline{Q}_c^{PB} and \overline{Q}_c^{PB} for the sum of the power from the SF and TES. The commitment decision of each CSP plant is considered. Hence, the binary variable, $u_{c,k}$, is equal to 1 if the CSP plant c is online in period k , otherwise is equal to 0. Constraints (17) and (18) set the balance of the thermal power in the SF, $q_{c,k}^{FS}$, and the energy stored in the TES, $q_{c,k}^S$, respectively. Constraints (19) set the bounds \underline{Q}_c^S and \overline{Q}_c^S for the thermal power storage in the TES, avoiding the solidification of salts and the maximum storage capacity to be exceeded. Constraints (20) set the bounds \underline{Q}_c^{FE} and \overline{Q}_c^{FE} for the thermal power from the SF. Constraints (21) set the bounds \underline{p}_c^{CSP} and \overline{p}_c^{CSP} for the power output of the CSP plants. Constraints (22) and (23) set the charge and discharge ramp rates of the TES, respectively. Constraints (24) and (25) set the power restrictions to prevent simultaneous discharging and charging of the TES at the same period, imposed by the 0/1 variable, z_k , where M is a large power quantity. Constraints (26) set the non-negativeness of power flows.

- Minimum up/down time constraints of SF + TES

$$\sum_{r=k-UT_c^{SF+T}+1, r \geq 1 \in k} (u_{c,r} - u_{c,r-1}) \leq u_{c,k} \quad \forall c, k = L^{SF+T} + 1, \dots, K \quad (27)$$

$$\sum_{r=k-DT_c^{SF+T}+1, r \geq 1 \in k} (u_{c,r-1} - u_{c,r}) \leq 1 - u_{c,k} \quad \forall c, k = F^{SF+T} + 1, \dots, K \quad (28)$$

Constraints (27) and (28) set the minimum up/down times for the SF and TES, where $L_c^{SF+T} = \min[K, UT_c^{SF+T}]$ and $F_c^{SF+T} = \min[K, DT_c^{SF+T}]$. These constraints, based on [38], can have a favourable impact on the computation time.

- Operational constraints of wind power plants

$$p_k^{Wind} = \sum_{i \in I} p_{i,k}^{Wind} \quad \forall k \quad (29)$$

$$0 \leq p_{i,k}^{Wind} \leq W_{i,k} \quad \forall i, k \quad (30)$$

$$0 \leq p_{i,k}^{Wind} \leq \bar{P}_i^{Wind} \quad \forall i, k \quad (31)$$

Constraints (29) enforce the total wind power generated, p_k^{Wind} , as the sum of the power generated for each wind turbine i , $p_{i,k}^{Wind}$. Constraints (30) set the operating limits for the scheduled wind power of each wind turbine i , $W_{i,k}$. Constraints (31) set the maximum power capacity of each wind turbine i , \bar{P}_i^{Wind} .

The CSP plants are considered in this paper to have ability of providing SR. Thus, a joint energy and SR scheduling approach is designed, based on the approach given by (8)–(31). Additionally, the occurrence of contingencies is considered for a set of CSP plants or wind turbines under a security criterion in a single-bus model, as stated in the following subsection.

3.2. Bilevel approach with SR and $n - K$ security criterion

The wind-CSP day-ahead schedule problem to simultaneously schedule energy and SR under the $n - K$ security criterion can be formulated using a bilevel approach [39]. The bilevel approach of the problem is depicted in Fig. 3. The upper-level problem finds the schedule of energy and SR so as to maximize the profit. The profit maximization is subject to the worst-case contingency modelled by the lower-level optimization problems. The lower-level problem finds the combination of outage plants so as to minimize the post-contingency power output.

The wind-CSP day-ahead schedule problem as a bilevel approach is stated as follows:

$$\text{Maximize} \quad \sum_{k \in K} [\pi_k^{da} (p_k^s - p_k^b)] + \xi p_k^{Wind} + \sum_{c \in C} \sum_{c \in C} (\pi_k^{sr} r_{c,k} - \beta_c p_{c,k}^{CSP}) \quad (32)$$

Subject to:

$$\text{Constraints (9) – (31)} \quad (33)$$

$$0 \leq p_k^{Wind} + \sum_{c \in C} (p_{c,k}^{CSP} + r_{c,k}^{sr}) \leq \chi \quad \forall k \quad (34)$$

$$0 \leq r_{c,k} \leq \sigma \bar{P}_c^{CSP} \quad \forall c, k \quad (35)$$

$$p_{c,k}^{sr} = p_{c,k}^{CSP} + r_{c,k} \quad \forall c, k \quad (36)$$

$$p_{c,k}^{sr} = p_{c,k}^{FE} + p_{c,k}^{SE, sr} \quad \forall c, k \quad (37)$$

$$p_{c,k}^{SE, sr} = \eta_3 q_{c,k}^{SE, sr} \quad \forall c, k \quad (38)$$

$$\underline{Q}_c^{PB} u_{c,k} \leq q_{c,k}^{FE} + q_{c,k}^{SE, sr} \leq \bar{Q}_c^{PB} u_{c,k} \quad \forall c, k \quad (39)$$

$$q_{c,k}^{S, sr} = q_{c,k-1}^S + \eta_2 q_{c,k}^{FS} - q_{c,k}^{SE, sr} \quad \forall c, k \quad (40)$$

$$\underline{Q}_c^S \leq q_{c,k}^{S, sr} \leq \bar{Q}_c^S \quad \forall c, k \quad (41)$$

$$p_{c,k}^{SE, sr} - p_{c,k+1}^{SE, sr} \leq RD_c^T \quad \forall c, k = 0, \dots, K - 1 \quad (42)$$

$$0 \leq p_{c,k}^{SE, sr} \leq M z_{c,k} \quad \forall c, k \quad (43)$$

$$p_k^{wc*} \geq \sum_{i \in I} p_{i,k}^{Wind} + \sum_{c \in C} p_{c,k}^{CSP} \quad \forall c, k \quad (44)$$

$$p_k^{wc*} = \text{Minimize} \quad \sum_{i \in I} a_{i,k} p_{i,k}^{Wind} + \sum_{c \in C} a_{c,k} (p_{c,k}^{CSP} + r_{c,k}) \quad (45)$$

Subject to:

$$\sum_{i \in I} a_{i,k} + \sum_{c \in C} a_{c,k} \geq n - K \quad : \quad w_k \quad \forall k \quad (46)$$

$$0 \leq a_{i,k} \leq 1 \quad : \quad v_{i,k} \quad \forall i, k \quad (47)$$

$$0 \leq a_{c,k} \leq 1 \quad : \quad v_{c,k} \quad \forall c, k \quad (48)$$

Problem (32)–(48) is composed of an upper-level problem (32)–(44) and of lower-level problems (45)–(48). The corresponding dual variable of each constraint of the lower-level problems is indicated following a colon.

The upper-level objective function to be maximized (32) provides the revenues from day-ahead, SR markets sales and wind generation incentive rate minus the CSP variable costs.

The constraints to (9)–(31) are introduced as upper-level constraints in (33). Constraints (34) are similar to (10). Constraints (35) limit SR sales based on the ramping capability of the power block. Constraints (36)–(39) compel the operation of CSP plants to satisfy the SR. Constraints (36) enforce that the CSP generation is virtual balanced by the energy and SR sales, in case of SR calling this is the real net generation. Constraints (37) enforce the balance of SR sold. Constraints (38)–(43) model requirements described for the problem (8)–(31). Constraints (44) set that the generation capability under the worst-case contingency is greater than or equal to the power contribution of the wind power plants and CSP plants. The upper-level problem (32)–(44) is constrained by a collection of lower-level problems (45)–(48). The dual variables associated with (46), (47) and (48) are w_k , $v_{i,k}$ and $v_{c,k}$, respectively.

The lower-level objective function to be minimized supplies at the optimum of the problem (45)–(48) the post-contingency power output available to be delivered by the plants. This availability depends on the lower-level decision variables $a_{i,k}$ and $a_{c,k}$. Hence, the solution of the lower-level problem assesses the worst-case contingency. Constraints (46) set the $n - K$ security criterion. Finally, constraints (47) and (48) set the bounds for variables $a_{i,k}$ and $a_{c,k}$.

The involvedness of the mixed-integer problem (32)–(48) is due not only to the continuous and binary variables, but also to the nonlinear products $a_{i,k} p_{i,k}^{Wind}$, $a_{c,k} p_{c,k}^{CSP}$, and $a_{c,k} r_{c,k}$ in (45). The mixed-integer problem (32)–(48) is reformulated as a single-level MILP problem solved using standard software, as stated in the following subsection.

3.3. Approximated MILP approach

The mixed-integer problem (32)–(48) is a bilevel one to be

Table 1
Wind-CSP plants data.

$\frac{Q_c^{PB}}{Q_c^{PB}} (MW_t)$	$\frac{p_c^{CSP}}{p_c^{CSP}} (MW_e)$	$q_{c,0}^s (MWh_t)$	$RD_c^T (MW_e/h)$	$RU_c^T (MW_e/h)$
24/93	0/30	95	15	20
$\frac{Q_c^{FE}}{Q_c^{FE}} (MW_t)$	$\frac{Q_c^s}{Q_c^s} (MWh_t)$	$DT_c^{SF+T} (h)$	$UT_c^{SF+T} (h)$	$\frac{P_i^{Wind}}{P_i^{Wind}} (MW)$
0/93	45/529	2	2	0/3

turned into a MILP one by replacing each of the lower-level problems (45)–(48). The transformation due to the lower-level problems (45)–(48) provide for $a_{i,k}$ and $a_{c,k}$ integer optimal solutions. Hence, the equivalent single-level MILP for the bilevel problem (32)–(48) is stated as follows:

$$\text{Maximize } \sum_{k \in K} [\pi_k^{da} (p_k^s - p_k^b)] + \xi p_k^{Wind} + \sum_{c \in C} \sum_{k \in K} (\pi_k^{sr} r_{c,k} - \beta_c p_{c,k}^{CSP}) \quad (49)$$

Subject to:

$$\text{Constraints (33) – (43)} \quad (50)$$

$$(n - K)w_k - \sum_{i \in I} v_{i,k} - \sum_{c \in C} v_{c,k} \geq \sum_{i \in I} p_{i,k}^{Wind} + \sum_{c \in C} p_{c,k}^{CSP} \quad \forall k \quad (51)$$

$$w_k - v_{i,k} \leq p_{i,k}^{Wind} \quad \forall i, k \quad (52)$$

$$w_k - v_{c,k} \leq p_{c,k}^{CSP} + r_{c,k} \quad \forall c, k \quad (53)$$

$$w_k, v_{i,k}, v_{c,k} \geq 0 \quad (54)$$

Constraints (51) correspond to (44). Finally, constraints (52)–(54) are the dual feasibility constraints of the lower-level problems (46)–(48).

For the sake of simplicity, some features of real-world markets are not included in the proposed approach, such as forward contracting. However, note that forward contracting for a known schedule horizon can be regarded as a constant term that increases the revenue of the power producer, which can be easily integrated into the proposed model.

4. Case study

The proposed approach is applied to a case study based on a system with 87 power plants, $n = 87$, 80 wind turbines, $i = 1, \dots, 80$, and 7 CSP plants, $c = 1, \dots, 7$. A 24-h time period, $k = 1, \dots, 24$, is considered and the data used are depicted in Table 1.

CSP plants as well as wind turbines have respectively the same characteristics. Installed capacity for CSP is 210 MW_e and for wind power is 240 MW. The plants share one line to connect to power grid, having 3.5% of transmission losses and line power has to be between 190 MW and 450 MW. The CSP plant module efficiencies is: i) $\eta_1 = 0.40$, for the SF installed parabolic trough collectors; ii) $\eta_2 = 0.35$, for the TES, using two molten-salt tanks with an efficiency $\eta_3 = 0.80$. Parasitic power loss due to the fluid pumping occurs even if the CSP plant is not operated. The parasitic power is 3.5 MW_e and only CSP plants provide SR up to 66% of the maximum capacity. The wind generation incentive rate is 10 €/MWh.

Solar irradiation and wind power forecasts through ANNs uses data from the [40] concerning one month (30 days) of year 2009. For the proposed forecasting model, 24-h ahead predictions are computed, taking into account the hourly historical data of the 7 days (or 168 h) previous to the day whose solar irradiation/wind power is to be forecasted. Thus, the forecaster output directly




Fig. 4. SF thermal and wind power forecasts.

provides a vector of dimension equal to the length of the forecasting horizon (24-h ahead).

Solar irradiation and wind power output series are assumed to be the same, respectively, for each CSP plant and wind turbine. The solar irradiation and wind power output series have a power correlation as depicted in Fig. 4.

A comparison between the proposed ANN method and two other methods (persistence and ARIMA), with respect to the mean absolute percentage error (MAPE) criterion is depicted in Table 2.

The persistence method states that the solar irradiation and wind power forecast is the same as the last measured value [41]. The ARIMA method is developed using SPSS software. Parameter estimation is performed with the aid of this software. The configuration considered corresponds to an ARIMA (1,2,1). Table 2 shows a good accuracy of the proposed ANN method was ascertained. The MAPE has a value of 7.14% and 9.78% for solar irradiation and wind power forecasting, respectively.

The low forecasting error in the wind-CSP day-ahead schedule provides advantage knowledge for bidding in day-ahead energy market, to improve power plants operations and a better usage of

Table 2
Comparative MAPE results.

	Solar irradiation	Wind power
Persistence	19.05	24.96
ARIMA	14.52	16.37
ANN	7.14	9.78




Fig. 5. Hourly market prices.




Fig. 6. Wind-CSP day-ahead schedule for $\chi = 255$ MW: (a) CSP without TES; (b) CSP with TES.

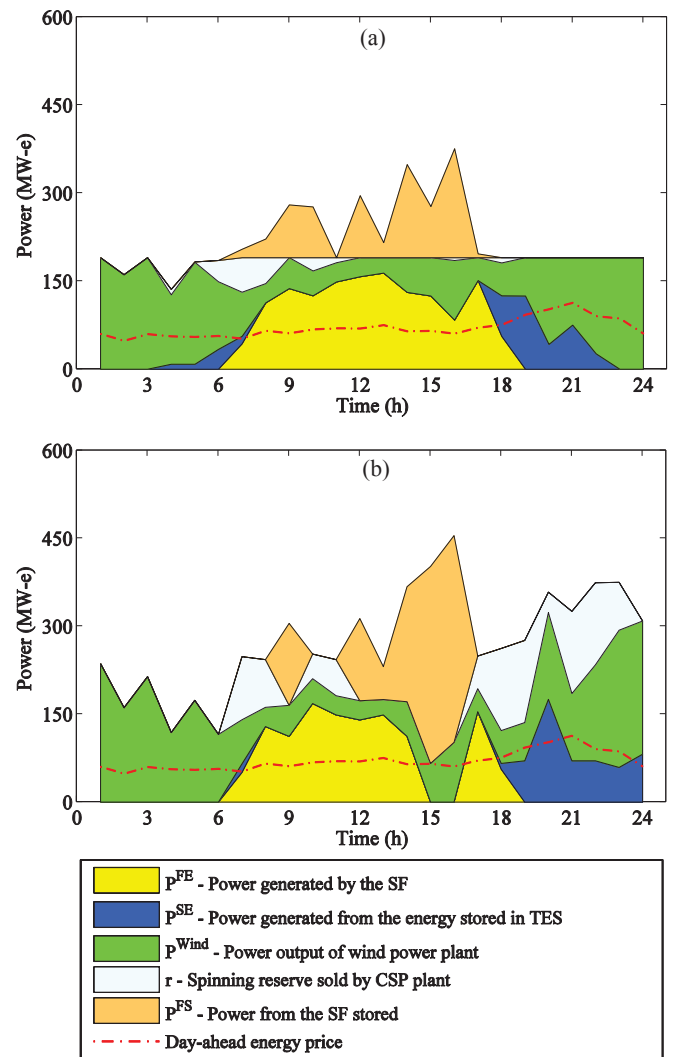


Fig. 7. Wind-CSP harmonization scheduling for different transmission-constrained cases: (a) $\chi = 190$ MW; (b) $\chi = 450$ MW.

the transmission lines. In addition, accurate forecasts are also important in reducing the occurrence of curtailments.

The performance of the ANN method is better than the performance of persistence and ARIMA methods. Moreover, the average computation time required by the proposed ANN method is less than 6 s using MATLAB. Instead, the ARIMA method requires about 1 min of computation time. Hence, the proposed ANN method provides a powerful tool of easy implementation for short-term solar irradiation and wind power forecasting.

Iberian electricity market day-ahead energy and SR prices for an arbitrary day from the year 2009 of the [25] are used and depicted in Fig. 5.

The size of proposed MILP approach (49)–(54) is characterized by $\{K(7 + 3I + 26C) - 4C\} \Leftrightarrow \{10,268\}$ constraints and $\{K(5 + 2I + 15C)\} \Leftrightarrow \{6,480\}$ variables, $\{K(4 + 2I + 13C)\} \Leftrightarrow \{6,120\}$ being continuous and $\{K(1 + 2C)\} \Leftrightarrow \{360\}$ binary variables. The proposed MILP approach is implemented on an Intel Core i7-3600 2.30 GHz processor of 8 GB RAM using CPLEX 12.1 under GAMS [42]. The interior point method for linear programming, with a branch-and-cut optimizer for integer programming is used for solving this scheduling problem. Results from the proposed approach are presented in the following subsections.




Fig. 8. Thermal energy storage for different transmission capacities over 24-h time period.

Table 3
Transmission capacity, energy and profit.

Transmission capacity (MW)	Average energy stored (MWh)	Energy sold (MWh)	SR sold (MWh)	Profit (€)
190	729.96	4120.41	194.52	281,293
450	976.14	4204.10	1025.08	316,589

Table 4
Economic impact of $n - K$ security criterion on profit.

# plants	Profit without security (€)	Relative decreasing on profit (%)			
	$K = 0$	$K = 1$	$K = 2$	$K = 3$	$K = 4$
17	141,772	7.81	13.13	16.72	21.36
37	190,841	9.56	17.23	21.65	25.21
57	240,789	13.20	24.60	27.39	29.24
87	316,589	16.13	26.70	30.63	33.45

4.1. Optimal scheduling of CSP plants with wind power integration

The wind-CSP day-ahead schedule without and with TES for $\chi = 255$ MW is depicted in Fig. 6 (a) and (b), respectively.

Fig. 6 (a) shows the existence of the negative correlation between wind and solar thermal power since wind power is reasonably high during the night when there is no solar thermal power. So, adding CSP allows a better transmission capacity factor usage. For CSP without TES, the power producer can only operate both plants considering the availability of both energy sources. Fig. 6 (b) shows that CSP with TES introduces dispatchability, allowing solar to be shifted and to fill-in the transmission line in order to increment the capacity factor during lower-source hours. Roughly 20% of the solar energy captured by the SF is stored on hour 9 and from hour 12 to 16 to be in production between hours 18 to 24. Also, introduced dispatchability allows for SR, which corresponds to an added improvement on the profit. The comparison of Fig. 6 (a) with Fig. 6 (b) reveals loss of conversion relatively to the CSP having TES, due to the solar energy available from hour 6 to 7 and from hour 18 to 19 is not enough to operate the power block. Also, wind power is prioritized over CSP due to the wind generation incentive rate, which makes wind generation more profitable, mitigating the variable cost of CSP. The benefit of TES is revealed with the profit increase from 273,093 € to 309,025 €.




Fig. 9. Profit for different sized plants under $n - K$ security.

4.2. Impact assessment of transmission constraints

The impact of transmission constraints is assessed for $\chi = 190$ MW and $\chi = 450$ MW depicted in Fig. 7 (a) and (b), respectively.

Fig. 7 (a) and (b) show for the high price hours a significant CSP production in comparison with low price hours. The benefit of TES shifting the production is revealed, e.g. in Fig. 7 (b) where the excess energy eventually overloading transmission from hours 12 to 16 is able to be stored for a convenient discharge from hours 18 to 24. The thermal energy storage for different transmission capacities is depicted in Fig. 8.

Fig. 8 shows the importance of line transmission capacity concerning TES over the day, e.g., the level of the storage is raised with increase in line transmission in the low prices hours with solar thermal power in order to be conveniently used during the other hours. The power output not only follows market prices, increasing power in hours of high prices and storing the energy coming from the SF during hours of low prices, but also takes into consideration the transmission capacity. The capacity factor is incremented by downsizing the transmission, causing curtailment and consequent decrease of the energy produced.

The energy and profit for the transmission capacity of $\chi = 190$ MW and $\chi = 450$ MW are depicted in Table 3.

Table 3 allows a comparison between the profits, revealing a reduction of about 11%.

4.3. Economic impact of $n - K$ security criterion

Three additional case studies are considered to assess the economic impact of $n - K$ security criterion. This assessment is carried out on hourly basis over a scheduling time horizon of 24 h, taking into account the data shown in the beginning of the case study. The goal is to assess the optimal value of the objective function for the wind-CSP day-ahead schedule problem with different values of K , i.e., a comparison of results is performed with different $n - K$ rules, e.g., $K = 0, 1, 2, 3$ and 4, being the $n - 0$ rule the condition without security. The additional case studies allow a comparison benchmark to display the compromise between an eventual profit loss and accounting for avoiding that loss.

The profit for different K values ranging between 0 and 4 is depicted in Table 4.

Table 4 shows the profit without security and the relative profit decrease due to different security levels. The profit obtained from the proposed approach decreases as the value of K increases, i.e., when security is accounted for. Furthermore, note that for each K , profit undergoes an increase as the system size grows as depicted in

Table 5
CPU time for different K contingencies.

# plants	CPU time (s)				
	$K = 0$	$K = 1$	$K = 2$	$K = 3$	$K = 4$
17	8	185	361	385	453
37	17	267	482	861	1285
57	20	283	573	1023	1459
87	25	302	747	1357	1942

Fig. 9. For instance, for $K = 3$, profit increases from 118,074 € to 219,629 €, due to downsizing on security. These results show that tighter security levels than usually used $n - 1$ and $n - 2$ criteria might be attractive to be implemented, because the relative profit decrease is less as K increases.

The CPU time for different K values ranging between 0 and 4 is depicted in Table 5.

Table 5 shows that the CPU time, for solving the proposed approach (49)–(54), tends to increase as the K value and the system size increase. However, CPU times are clearly acceptable, taking into account the tractability of problems and the memory available.

5. Conclusions

A bilevel programming approach is proposed to schedule energy and SR for the wind-CSP day-ahead schedule, having TES and has a novelty a controllable safekeeping of compromises assumed within the electricity markets. This approach is turned into a MILP problem computed by a CPLEX solver in GAMS. The approach considers constraints due to the transmission line link with the power grid in order to allow a better capacity factor usage. Moreover, curtailing is mitigated by the proposed approach and the power producer is able to have an enhancement on the profit. A major contribution of the paper is to unveil the synergy obtained by the approach. The synergy allows for dispatchability achieved with the introduction of TES, allowing the solar thermal power to be shifted and to fill-in the transmission line during low wind power periods, which constitutes an advantage concerning the capacity factor. Also, the excess energy eventually overloading the transmission is stored in the TES and adequately discharged so as to increase the profit. The economic impact of the safekeeping, i.e., of having $n - K$ security criterion is assessed in terms of profit giving the decision-making an economic indicator about a compromise between security and profit.

Acknowledgements

This work was partially supported by Fundação para a Ciência e a Tecnologia (FCT), through IDMEC under LAETA Pest-OE/EME/LA0022/2014, Instituto Superior Técnico, Universidade de Lisboa, Portugal.

References

- [1] I.A. Grant Wilson, P.G. McGregor, D.G. Infield, P.J. Hall, Grid-connected renewables, storage and the UK electricity market, *Renew. Energy* 36 (8) (2011) 2166–2170.
- [2] Report: Europe Renewable Energy Policy Handbook 2013, 2013, pp. 1–319.
- [3] E.V. Mc Garrigle, J.P. Deane, P.G. Leahy, How much wind energy will be curtailed on the 2020 Irish power system? *Renew. Energy* 55 (2013) 544–553.
- [4] J.S. González, M.B. Payán, J.R. Santos, Optimum design of transmissions systems for offshore wind farms including decision making under risk, *Renew. Energy* 59 (2013) 115–127.
- [5] C. Muñoz, E. Sauma, J. Contreras, J. Aguado, S. de La Torre, Impact of high wind power penetration on transmission network expansion planning, *IET Gener. Transm. Distrib.* 6 (12) (2012) 1281–1291.
- [6] D. Nock, V. Krishnan, J.D. McCalley, Dispatching intermittent wind resources for ancillary services via wind control and its impact on power system economics, *Renew. Energy* 71 (2014) 396–400.
- [7] H. Daneshi, A.K. Srivastava, Security-constrained unit commitment with wind generation and compressed air energy storage, *IET Gener. Transm. Distrib.* 6 (2) (2012) 167–175.
- [8] P. Heejung, R. Baldick, Y. Gu, L. Xie, Transmission planning under uncertainties of wind and load: sequential approximation approach, *IEEE Trans. Power Syst.* 28 (3) (2013) 2395–2402.
- [9] J. Matevosyan, M. Olsson, L. Söder, Hydropower planning coordinated with wind power in areas with congestion problems for trading on the spot and the regulating, *Electr. Power Syst. Res.* 79 (1) (2009) 39–48.
- [10] Report: IEA Wind 2012 Annual Report, 2013, pp. 1–172.
- [11] F. Bouffard, F.D. Galiana, Stochastic security for operations planning with significant wind power generation, *IEEE Trans. Power Syst.* 23 (2) (2008) 306–316.
- [12] C.-L. Chen, Simulated annealing-based optimal wind-thermal coordination scheduling, *IET Gener. Transm. Distrib.* 1 (3) (2007) 447–455.
- [13] S. Kamalinia, M. Shahidehpour, Generation expansion planning in wind-thermal power systems, *IET Gener. Transm. Distrib.* 4 (8) (2010) 940–951.
- [14] M.E. Khodayar, L. Abreu, M. Shahidehpour, Transmission-constrained intra-hour coordination of wind and pumped-storage hydro units, *IET Gener. Transm. Distrib.* 7 (7) (2013) 755–765.
- [15] A.A. Sanchez de la Nieta, J. Contreras, J.I. Muñoz, Optimal coordinated wind-hydro bidding strategies in day-ahead markets, *IEEE Trans. Power Syst.* 28 (2) (2013) 798–809.
- [16] J. Usaola, Participation of CSP plants in the reserve markets: A new challenge for regulators, *Energy Pol.* 49 (2012) 562–571.
- [17] J. Usaola, Operation of concentrating solar power plants with storage in spot electricity markets, *IET Renew. Power Gener.* 6 (1) (2012) 59–66.
- [18] J.H. Peterseim, S. White, A. Tadros, U. Hellwig, Concentrating solar power hybrid plants – enabling cost effective synergies, *Renew. Energy* 67 (2014) 178–185.
- [19] R. Dominguez, L. Baringo, A.J. Conejo, Optimal offering strategy for a concentrating solar power plant, *Appl. Energy* 98 (2012) 316–325.
- [20] S.H. Madaeni, R. Sioshansi, P. Denholm, How thermal energy storage enhances the economic viability of concentrating solar power, *Proc. IEEE* 100 (2) (2012) 335–347.
- [21] L. Hirth, F. Ueckerdt, O. Edenhofer, Integration costs revisited – an economic framework for wind and solar variability, *Renew. Energy* 74 (2015) 925–939.
- [22] R. Sioshansi, P. Denholm, The value of concentrating solar power and thermal energy storage, *IEEE Trans. Sust. Energy* 1 (3) (2010) 173–183.
- [23] Q. Wang, J.-P. Watson, Y. Guan, Two-stage robust optimization for contingency-constrained unit commitment, *IEEE Trans. Power Syst.* 28 (3) (2013) 2366–2375.
- [24] H.M.I. Pousinho, J. Contreras, J.P.S. Catalão, Short-term optimal scheduling of a price-maker hydro producer in a pool-based day-ahead market, *IET Gener. Transm. Distrib.* 6 (12) (2012) 1243–1251.
- [25] Market Operator of the Electricity Market of the Iberian Peninsula, OMEL, 2014. Available at: <http://www.ome.es>.
- [26] A. Ahmadi-Khatir, A.J. Conejo, R. Cherkaoui, Multi-area energy and reserve dispatch under wind uncertainty and equipment failures, *IEEE Trans. Power Syst.* 28 (4) (2013) 4373–4383.
- [27] F. Santos-Alamillos, D. Pozo-Vázquez, J.A. Ruiz-Arias, V. Lara-Fanego, Analysis of spatiotemporal balancing between wind and solar energy resources in the southern Iberian Peninsula, *J. Appl. Meteorol. Climatol.* 51 (11) (2012) 2005–2024.
- [28] F. Santos-Alamillos, D. Pozo-Vázquez, J.A. Ruiz-Arias, V. Lara-Fanego, A methodology for evaluating the spatial variability of wind energy resources: application to assess the potential contribution of wind energy to base load power, *Renew. Energy* 69 (2014) 147–156.
- [29] S. Jerez, R.M. Trigo, A. Sarsa, R. Lorente-Plazas, D. Pozo-Vázquez, Spatio-temporal complementarity between solar and wind power in the Iberian Peninsula, *Energy Procedia* 40 (2014) 48–57.
- [30] F. Santos-Alamillos, D. Pozo-Vázquez, J.A. Ruiz-Arias, L. Von Bremen, Combining wind farms with concentrating solar plants to provide stable renewable power, *Renew. Energy* 76 (2015) 539–550.
- [31] J.P.S. Catalão, H.M.I. Pousinho, V.M.F. Mendes, An artificial neural network approach for short-term wind power forecasting in Portugal, *Eng. Intell. Syst. Electr. Eng. Commun.* 17 (1) (2009) 5–11.
- [32] J.C. Principe, N.R. Euliano, W.C. Lefebvre, *Neural and Adaptive Systems: Fundamentals through Simulations*, Wiley, New York, 2000.
- [33] M.T. Hagan, M.B. Menhaj, Training feedforward networks with the Marquardt algorithm, *IEEE Trans. Neural Netw.* 5 (6) (1994) 989–993.
- [34] A.J. Wood, B.F. Wollenberg, *Power Generation, Operation, and Control*, Wiley, New York, USA, 1996.
- [35] F. Bouffard, F. Galiana, An electricity market with a probabilistic spinning reserve criterion, *IEEE Trans. Power Syst.* 19 (1) (2004) 300–307.
- [36] A. Street, F. Oliveira, J.M. Arroyo, Contingency-constrained unit commitment with $n - K$ security criterion: a robust optimization approach, *IEEE Trans. Power Syst.* 26 (3) (2011) 1581–1590.
- [37] D. Pozo, J. Contreras, A chance-constrained unit commitment with an $n - K$ security criterion and significant wind generation, *IEEE Trans. Power Syst.* 28 (3) (2013) 2842–2851.
- [38] J. Ostrowski, M.F. Anjos, A. Vannelli, Tight mixed integer linear programming formulations for the unit commitment problem, *IEEE Trans. Power Syst.* 27 (1) (2012) 39–46.
- [39] B. Colson, P. Marcotte, G. Savard, An overview of bilevel optimization, *Ann. Oper. Res.* 153 (1) (2007) 235–256.
- [40] Centro de informacao, 2014. Available at: <http://www.centrodeinformacao.ren.pt>.
- [41] J. Kennedy, B. Fox, D.J. Morrow, Distributed generation as a balancing resource for wind generation, *IET Renew. Power Gener.* 1 (3) (2007) 167–174.
- [42] Gams Cplex, The Solver Manuals, Gams/Cplex, 2014. Available at: <http://www.gams.com>.