

Sistemas inteligentes de micro-cogeração para redes residenciais: Uma solução sustentável para uma gestão eficiente de energia

Daniel Figueira Nunes

Tese para obtenção do Grau de Mestre em
Engenharia Eletromecânica
(2º ciclo de estudos)

Orientador: Prof. Doutor Paulo Manuel Oliveira Fael
Co-orientador: Mestre Daniel Filipe da Silva Cardoso

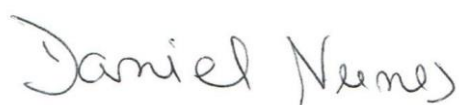
outubro de 2023

Declaração de Integridade

Eu, Daniel Figueira Nunes, que abaixo assino, estudante com o número de inscrição M12145 de/o Engenharia Eletromecânica da Faculdade de Engenharia, declaro ter desenvolvido o presente trabalho e elaborado o presente texto em total consonância com o **Código de Integridades da Universidade da Beira Interior**.

Mais concretamente afirmo não ter incorrido em qualquer das variedades de Fraude Académica, e que aqui declaro conhecer, que em particular atendi à exigida referenciação de frases, extratos, imagens e outras formas de trabalho intelectual, e assumindo assim na íntegra as responsabilidades da autoria.

Universidade da Beira Interior, Covilhã 09 /10 /2023

Handwritten signature of Daniel Nunes in black ink.

Dedicatória

A ti pai, todos os dias fazes parte de mim.

Agradecimentos

À minha mãe, por ter sido guerreira e me proporcionar todo o apoio nesta caminhada, sem ti não conseguiria.

Aos meus avós, padrinhos e tios por todo o apoio que sempre me deram.

Ao meu orientador, Professor Doutor Paulo Manuel Oliveira Fael, pela disponibilidade, ajuda e transmissão de conhecimentos.

Ao meu co-orientador Mestre Daniel Cardoso que desde o início me prestou toda a disponibilidade e ajuda para desenvolver este trabalho, transmitindo-me também conhecimentos e ferramentas ao longo do mesmo.

Às amigas que fiz nesta academia, Bruno Eusébio, Carlos Marques, Daniel Balacó, Gonçalo Almeida, Miguel Cruz, Pedro Pereira e Rodrigo Antunes. Obrigado por terem feito parte deste percurso que juntos percorremos.

À malta da Lardosa, por de forma indireta me terem ajudado por vezes a abstrair-me e ultrapassar adversidades.

Em especial a ti Mariana, por teres sido tudo, família, amiga e namorada. Contigo este percurso foi mais bonito.

Resumo

Esta dissertação apresenta uma abordagem de otimização para sistemas de micro-cogeração com motores de combustão interna integrados em redes residenciais, abordando falhas na procura de energia causadas por fontes de energia renováveis intermitentes. O método proposto utiliza técnicas de *machine learning*, estratégias de controlo e dados da rede para melhorar a flexibilidade e a eficiência do sistema na satisfação das necessidades de eletricidade e água quente sanitária. Foram analisados dados históricos da rede residencial para desenvolver um modelo de previsão da procura de eletricidade e água quente baseado em *machine learning*. O armazenamento de energia térmica foi integrado no sistema de micro-cogeração para aumentar a flexibilidade. Foi criado um modelo de otimização, considerando a eficiência, as emissões e o custo, adaptando-se às alterações da procura em tempo real. Foi concebida uma estratégia de controlo para o funcionamento flexível do sistema de micro-cogeração, tendo em conta o excesso de armazenamento de energia térmica e a atribuição de recursos. A eficácia da solução proposta foi validada através de simulações, com resultados que demonstram a capacidade do sistema de micro-cogeração para responder eficazmente a períodos de elevada procura de eletricidade e água quente, ao mesmo tempo que atenua as falhas de procura de energia proveniente de fontes de energia renováveis. A investigação apresenta uma nova abordagem com potencial para melhorar significativamente a resiliência da rede, a eficiência energética e a integração das energias renováveis nas redes residenciais, contribuindo para sistemas energéticos mais sustentáveis e fiáveis.

Palavras-chave

sistemas de micro-cogeração, motores de combustão interna, redes residenciais, *machine learning*, estratégias de controlo, gestão de energia, flexibilidade da rede, redes inteligentes, energia elétrica, energia térmica, integração de energias renováveis

Abstract

This work presents an optimization approach for micro-cogeneration systems with internal combustion engines integrated into residential grids, addressing power demand failures caused by intermittent renewable energy sources. The proposed method leverages machine learning techniques, control strategies, and grid data to improve system flexibility and efficiency in meeting electricity and domestic hot water demands. Historical residential grid data were analysed to develop a machine learning-based demand prediction model for electricity and hot water. Thermal energy storage was integrated into the micro-cogeneration system to enhance flexibility. An optimization model was created, considering efficiency, emissions, and cost while adapting to real-time demand changes. A control strategy was designed for the flexible operation of the micro-cogeneration system, addressing excess thermal energy storage and resource allocation. The proposed solution's effectiveness was validated through simulations, with results demonstrating the micro-cogeneration system's ability to efficiently address high electricity and hot water demand periods while mitigating power demand failures from renewable energy sources. The research presents a novel approach with the potential to significantly improve grid resilience, energy efficiency, and renewable energy integration in residential grids, contributing to more sustainable and reliable energy systems.

Keywords

micro-cogeneration systems, internal combustion engines, residential grids, machine learning, control strategies, energy management, grid flexibility, smart grids, electrical energy, thermal energy, renewable energy integration

Índice

Dedicatória	iv
Agradecimentos	v
Resumo	vii
Abstract	ix
Índice	xi
Lista de Figuras	xv
Lista de Tabelas	xix
Lista de Acrónimos	xxi
Lista de Símbolos	xxiii
1 Introdução	1
1.1 Enquadramento	1
1.2 Objetivos da dissertação	2
1.3 Estrutura da dissertação	4
2 Revisão Bibliográfica	5
2.1 Cogeração	5
2.1.1 Conceito da Cogeração	5
2.1.2 Evolução da Cogeração	5
2.1.3 Vantagens	7
2.2 Tecnologias de Sistemas de Cogeração	8
2.2.1 Motores de Combustão Interna	9
2.2.2 Outras Tecnologias de Cogeração	15
2.3 Sistemas de micro-cogeração baseados em motores de combustão interna	24

3	Integração de sistemas de cogeração	27
3.1	Baterias e Acumuladores Térmicos	27
3.2	Redes Inteligentes	29
4	Modelação da rede doméstica	31
4.1	Dados e análise	31
4.1.1	Fonte dos dados da rede residencial	31
4.1.2	Análise de dados e <i>machine learning</i>	31
4.2	Estratégia de controlo da rede doméstica	32
5	Modulação e Simulação	35
5.1	Modelos	35
5.1.1	Modelo Bateria	35
5.1.2	Modelo Fotovoltaico	36
5.1.3	Modelo Micro-Cogeração	37
5.1.4	Modelo de <i>machine-learning</i> para previsão de carga	38
5.2	Simulação	40
5.2.1	Cenário 1	41
5.2.2	Cenário 2	48
6	Avaliação dos resultados da solução proposta	57
7	Conclusões	59
7.1	Resumo das conclusões	59
7.2	Contribuições para a resiliência da rede, a eficiência energética e a integração das energias renováveis	60
7.3	Limitações e trabalhos futuros	61
	Referências	63
A	Anexos	69
A.1	Código Painel fotovoltaico/bateria/micro-cogeração	69
A.2	Código da rede de previsão da produção fotovoltaica	75

A.3	Código da rede de previsão da carga elétrica	78
A.4	Artigo publicado no <i>Special Issue Machine Learning and Data Based Optimization for Smart Energy Systems</i> na Revista <i>Energies</i> - MDPI 2023	81

Lista de Figuras

1.1	Vantagens do processo da cogeração.	2
2.1	Comparação das perdas elétricas entre um sistema convencional e um sistema de cogeração.	7
2.2	Sistema de cogeração segundo motor de combustão interna.	10
2.3	4 tempos do motor de ignição comandada.	11
2.4	Ciclo de <i>Otto</i> teórico com os diagramas p-V e T-S, respetivamente.	12
2.5	4 tempos do motor de ignição por compressão.	13
2.6	Ciclo de <i>Diesel</i> teórico com os diagramas p-V e T-S, respetivamente.	14
2.7	Ciclo teórico de <i>Atkinson</i> com os diagramas p-V e T-S, respetivamente.	14
2.8	Quatro etapas do funcionamento de um motor Wankel.	15
2.9	Sistema de cogeração com turbina a gás.	16
2.10	Sistema de cogeração com turbina a vapor.	18
2.11	Sistema de cogeração com motor <i>Stirling</i> utilizando biomassa.	19
2.12	Módulos termoelétricos aplicados em coletor solar de placa plana.	21
2.13	Módulos termoelétricos e lentes de <i>Fresnel</i> aplicados em coletor solar de placa plana.	21
2.14	Módulos termoelétricos aplicados em coletor de tubo a vácuo.	22
2.15	Módulos termoelétricos aplicados em coletor de foco em ponto.	22
2.16	Subsistemas principais para o funcionamento de uma pilha de combustível num sistema de cogeração.	23
3.1	Baterias disponíveis no mercado e tipo de células de iões de lítio implementadas.	28
4.1	Fluxograma da simulação da estratégia de controlo da rede doméstica.	33
5.1	Modelo da bateria <i>Kinetic (KiBam)</i>	35
5.2	Componentes principais da simulação.	40
5.3	Perfil de carga e produção fotovoltaica: a) Cenário de défice de produção fotovoltaica; b) Cenário de excesso de produção fotovoltaica.	41

5.4	Défice de produção fotovoltaica e $SOC < 0, 2$: a) procura de carga elétrica e produção fotovoltaica; b) perfil de carga elétrica; c) perfil de aquecimento de água; d) estado de carga durante as duas horas de previsão.	42
5.5	Défice de produção fotovoltaica e $SOC > 0, 2$: a) procura de carga elétrica e produção fotovoltaica; b) perfil de carga elétrica; c) perfil de aquecimento de água; d) estado de carga durante as duas horas de previsão.	43
5.6	Excesso de produção fotovoltaica e $SOC < 0, 2$: a) perfil de carga elétrica; b) perfil de aquecimento de água; c) estado de carga durante as duas horas de previsão (SOC inicial $< 0, 2$); d) estado de carga durante as duas horas de previsão (SOC inicial = 1).	44
5.7	Défice de produção fotovoltaica: a) perfil de carga elétrica; b) perfil de aquecimento de água.	46
5.8	$SOC < 0, 2$: a) perfil da carga elétrica; b) perfil do aquecimento da água; c) estado da carga durante as duas horas de previsão.	47
5.9	$SOC > 0, 2$: a) perfil da carga elétrica; b) perfil do aquecimento da água; c) estado da carga durante as duas horas de previsão.	48
5.10	Perfil de carga e produção fotovoltaica: a) Cenário de défice de produção fotovoltaica; b) Cenário de excesso de produção fotovoltaica.	49
5.11	Défice de produção fotovoltaica e $SOC < 0, 2$: a) procura de carga elétrica e produção fotovoltaica; b) perfil de carga elétrica; c) perfil de aquecimento de água; d) estado de carga durante as duas horas de previsão.	50
5.12	Défice de produção fotovoltaica e $SOC > 0, 2$: a) procura de carga elétrica e produção fotovoltaica; b) perfil de carga elétrica; c) perfil de aquecimento de água; d) estado de carga durante as duas horas de previsão.	51
5.13	Excesso de produção fotovoltaica e $SOC < 0, 2$: a) perfil de carga elétrica; b) perfil de aquecimento de água; c) estado de carga durante as duas horas de previsão (SOC inicial $< 0, 2$); d) estado de carga durante as duas horas de previsão (SOC inicial = 1).	52
5.14	Défice de produção fotovoltaica: a) perfil de carga elétrica; b) perfil de aquecimento de água.	53
5.15	$SOC < 0, 2$: a) perfil da carga elétrica; b) perfil do aquecimento da água; c) estado da carga durante as duas horas de previsão.	54
5.16	$SOC > 0, 2$: a) perfil da carga elétrica; b) perfil do aquecimento da água; c) estado da carga durante as duas horas de previsão.	56

6.1	Comparação da potência necessária para compensar 663 W de necessidades de aquecimento de água da micro-cogeração (<i>Micro-CHP</i>), de um TAE (<i>ESWH</i>) e de uma bomba de calor (<i>Heat Pump</i>).	58
-----	------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	----

Lista de Tabelas

2.1	Tecnologias de Cogeração indicadas para cada aplicação consoante o combustível.	8
2.2	Características dos motores de combustão interna em sistemas de cogeração.	10
2.3	Características da turbina a gás em sistemas de cogeração.	17
2.4	Características da turbina a vapor em sistemas de cogeração.	18
2.5	Características do motor <i>Stirling</i> em sistemas de cogeração.	20
2.6	Características principais das pilhas de combustível.	24
2.7	Especificações dos sistemas de micro-cogeração baseados em MCI.	25
4.1	Dados de radiação solar.	31
5.1	Especificações do modelo de bateria <i>Kinetic (KiBaM)</i>	36
5.2	Especificações do modelo fotovoltaico.	37

Lista de Acrónimos

MCI	Motor de Combustão Interna
EUA	Estados Unidos da América
PURPA	Lei de Política Regulatória de Serviços Públicos
UPA	Unidade Auxiliar de Potência
SULEV	Super Ultra Low Emission Vehicle
PMS	Ponto Morto Superior
PMI	Ponto Morto Inferior
AFC	Alcaline Fuel Cell
PEM	Proton Exchange Membrane
PAFC	Phosphoric Acide Fuel Cell
MCFC	Molten Carbonate Fuel Cell
SOFC	Solid Oxide Fuel Cell
NMC	Óxido Níquel-Manganês-Cobalto
LFP	Fosfato de Lítio-Ferro
AET	Acumulador de Energia Térmico
RNA	Redes Neurais Artificiais
MLP	Perceptron Multicamadas
ELM	Extreme Learning Machine
SVM	Support Vector Machine
WNN	Wavelet Neural Network
ANFIS	Adaptive Neuro-Fuzzy Inference Systems
RUSE	Root-Mean-Square Error
SOC	Estado de Carga
RNFM	Rede Neuronal Feedforward Multicamada

Lista de Símbolos

q_1	<i>Carga disponível</i>
q_2	<i>Carga vinculada</i>
c	Largura do reservatório 1
$(1 - c)$	Largura do reservatório 2
h_1	Altura manométrica do reservatório 1
h_2	Altura manométrica do reservatório 2
q'_1	<i>Available charge</i> no início de cada passo de tempo
q'_2	<i>Bound charge</i> no fim de cada passo de tempo
Δt	Duração de cada passo de tempo
P_{cd}	potência utilizada para carregar ou descarregar o sistema
q_{max}	Capacidade máxima da bateria
q_{bat}	Capacidade da bateria
P_{PV}	Potência de saída do sistema fotovoltaico
μ_{mpvt}	Eficiência na trajetória do ponto de potência máxima
P_{STC}	Potência máxima sob STC
G	Irradiância solar dada em cada passo de tempo
G_{STC}	Irradiância sob STC
α_{VOC}	Coefficiente de temperatura da tensão de circuito aberto sob STC
T_{STC}	Temperatura da célula em condições STC
N_S	Módulos ligados em série
N_p	Módulos ligados em paralelo
T_{cell}	Temperatura da célula em cada passo de tempo
T_{amb}	Temperatura ambiente
G_{NOCT}	Irradiância em condições NOCT
$NOCT$	Temperatura nominal de funcionamento da célula
T_{NOCT}	Temperatura do ar em condições NOCT
ICI_T	Potência Térmica
ICI_E	Potência Elétrica
n	Número de neurónios na camada $k - 1$
m	Número de neurónios na camada k com $n, m \in \mathbb{Z}^+$
y_j	Saída do neurónio j
x_i	Sinal de entrada para o neurónio j proveniente do neurónio i
b_j	Polarização do neurónio j
w_{ij}	Peso da ligação sináptica entre os neurónios i e j
N	Número de amostras de treino
\hat{y}_i	Saída atual da rede
y_i	Resposta de saída desejada

Capítulo 1

Introdução

Neste capítulo irá ser descrito o contexto e a importância do tema da presente dissertação, assim como os principais objetivos e a abordagem que irá ser feita ao longo do trabalho. Por fim serão indicados os conteúdos abordados em cada capítulo.

1.1 Enquadramento

Em prol da importância da produção de energia elétrica e térmica, tanto para serviços domésticos como para indústrias, desenvolveu-se um sistema, diferente do convencional, que fosse eficiente e sustentável. A sociedade cada vez mais consome energia sem olhar às consequências, tais como, as emissões de dióxido de carbono causadoras dos efeitos de estufa. A introdução da cogeração, que combina a energia elétrica e térmica num único processo, permitiu otimizar a utilização de combustível, para geração de energia útil, assim como as emissões de dióxido de carbono. Vários sistemas foram desenvolvidos, desde aqueles que produzem energia a partir da combustão de combustíveis fósseis ou de fontes renováveis.

Os sistemas de cogeração minimizam as perdas de energia comparando com a produção separada de energia elétrica e térmica. A cogeração consegue atingir eficiências entre os 80% e os 95% comparando com a eficiência da produção separada de energia elétrica e térmica de 50%, proporcionando ganhos de energia de mais de 30% e, desta forma, economiza em energias primárias em mais de 50%. Esta tecnologia mostra vantagens ecológicas e económicas bastante significativas [1]. Uma unidade industrial, normalmente, necessita de 24 unidades de energia elétrica e 34 unidades de energia térmica. Produzindo energia elétrica e térmica separada, a entrada de energia primária na fábrica, para produção de energia elétrica, será de 60 unidades (24/0,40). Se para a geração de vapor for utilizada uma caldeira, a entrada de combustível na caldeira será de 40 unidades (34/0,85). No caso de se utilizar a cogeração, a entrada de combustível na fábrica será de 68 unidades (24 + 34)/0,85 para produção de energia elétrica e térmica. Acontece assim que na produção separada, as perdas eram de 42 unidades no caso da produção separada e reduziram para 10 unidades no modo de cogeração. O processo é visível na figura 1.1 [2]. De acordo com a COGEN Europe, a cogeração fornece atualmente 11% da eletricidade e 15% do calor na Europa.

A cogeração, há muito utilizada no setor de transportes, utilizando o calor libertado pelos sistemas de propulsão para aquecimento do habitáculo, ganha agora mais importância com a necessidade de carregar as baterias nos veículos híbridos. O motor de combustão

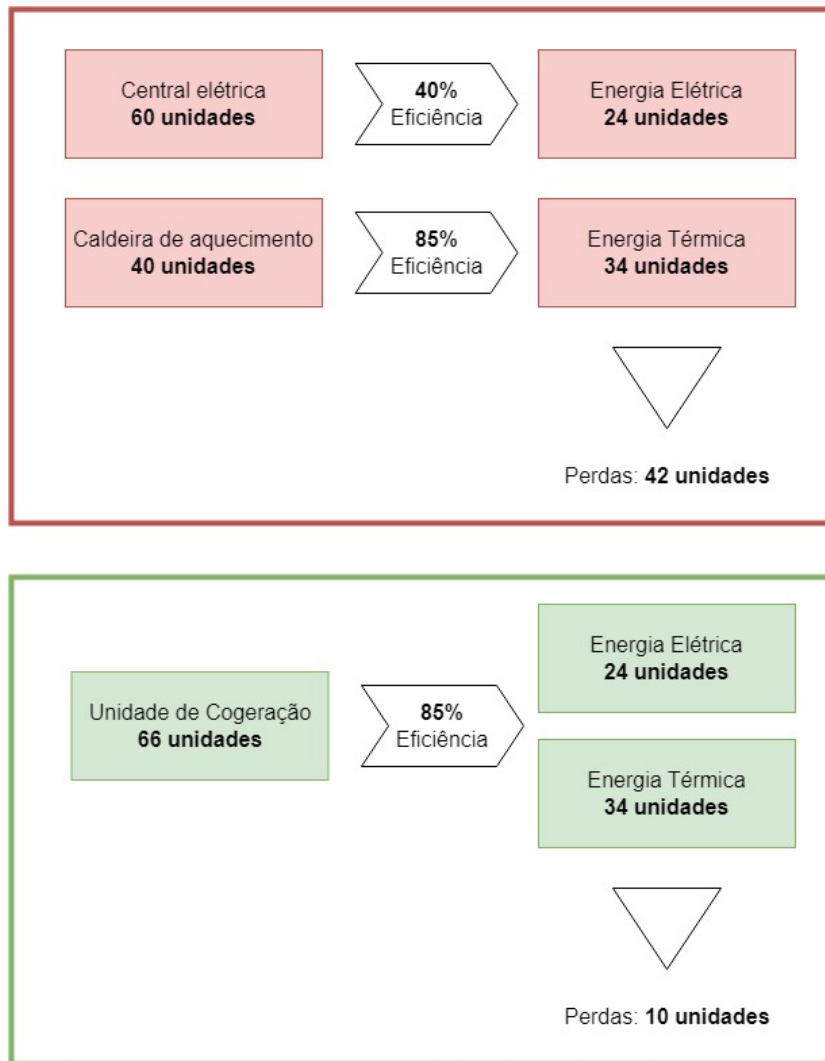


Figure 1.1: Vantagens do processo da cogeração. Adaptado de [2].

interna funciona como *range extender* permitindo aumentar a autonomia do veículo, através da conversão da energia mecânica em energia elétrica, sendo esta direcionada para a bateria. As perdas de energia térmica são aproveitadas para aquecimento ambiente do carro, em caso de necessidade. Segundo o Diagrama de *Sankey*, apenas 25% da energia do combustível é utilizada nos MCI a gasolina e a restante é rejeitada para o ambiente. Dessa energia perdida, 40% é no processo de exaustão e 30% na refrigeração [3].

1.2 Objetivos da dissertação

Com este trabalho pretende-se demonstrar a aplicação de sistemas de micro-cogeração e quantificar a energia desperdiçada, envolvendo um motor de combustão interna. Com este sistema pretende-se criar uma solução capaz de dar resposta a produção de águas quentes sanitárias, sistemas de aquecimento e produção de energia elétrica quer no setor

doméstico quer no setor dos transportes. No setor doméstico, utilizar a energia térmica para aquecimento de água e ar quente para aquecimento ambiente. No setor automóvel, permitir que o motor a gasolina carregue a bateria de um veículo elétrico de forma a aumentar a autonomia, sem a necessidade de energia adicional para além da energia do combustível. Ou seja, o motor de combustão interna irá apenas alimentar a bateria, não sendo responsável pela movimentação do veículo. A energia térmica desperdiçada é utilizada para aquecimento.

A micro-cogeração representa uma oportunidade para aumentar a estabilidade e a resiliência das redes domésticas alimentadas por fontes de energia renováveis, ultrapassando assim a barreira de implementação das energias renováveis, provocada pela produção intermitente associada a estas.

Ao integrar a micro-cogeração, as redes domésticas podem tornar-se mais eficientes e resistentes do ponto de vista energético. Os painéis fotovoltaicos e os sistemas de baterias não conseguem, por vezes, satisfazer de forma consistente as necessidades da rede doméstica, particularmente durante os períodos de baixa exposição solar. Esta dissertação propõe que o motor de combustão interna no sistema de micro-cogeração possa funcionar como uma reserva nestes casos, suportando a procura elétrica e carregando as baterias, ao mesmo tempo que fornece energia térmica para aplicações como água quente e aquecimento de espaços. Pretende-se analisar e afirmar que a micro-cogeração pode suportar ambas as necessidades em redes integradas com sistemas fotovoltaicos e de baterias, com o objetivo de as tornar independentes da rede. Os desafios associados à implementação deste sistema podem ser atribuídos a fatores como a rede de abastecimento de combustível, os custos de aquisição, os requisitos de manutenção e a adaptação às cargas impostas. A superação destes desafios é crucial para o sucesso da implementação de um sistema deste género. Este estudo pretende abordar estes desafios através da integração eficaz da produção elétrica do sistema de micro-cogeração com os requisitos de carga impostos, particularmente no contexto da energia fotovoltaica, onde a produção de energia renovável pode ser limitada.

É importante estabelecer uma estrutura que permita o cumprimento dos requisitos de carga impostos à rede, prevendo e satisfazendo eficazmente as necessidades térmicas de água quente sanitária e aquecimento residencial. Para atingir este objetivo, pretende-se utilizar máquinas adequadamente dimensionadas, associadas a redes de previsão e sistemas de armazenamento de energia. Esta abordagem integrada permite uma gestão mais precisa e eficiente do sistema, mitigando e satisfazendo as necessidades impostas. Através da utilização de tecnologias avançadas de previsão e da otimização do armazenamento de energia, as exigências impostas ao sistema podem ser eficazmente suprimidas recorrendo a sistemas de micro-cogeração, garantindo um funcionamento fiável e eficiente. Para otimizar o funcionamento do sistema proposto, são utilizadas técnicas de aprendizagem automática. Especificamente, as redes neuro artificiais (RNA) são utilizadas para prever a carga elétrica e a potência fotovoltaica com base no perfil de carga e na produção

fotovoltaica do dia anterior. Esta abordagem inovadora permite o planeamento e o controlo pro-ativos da energia elétrica e térmica, aumentando a segurança e a eficiência da rede. O principal desafio é, então, interligar e coordenar eficazmente estas diversas tecnologias dentro da rede.

O desempenho do sistema de micro-cogeração proposto, integrado com painéis fotovoltaicos e baterias, será analisado utilizando uma simulação em MATLAB[®].

1.3 Estrutura da dissertação

Este trabalho é constituído por cinco capítulos. Seguidamente é feita uma breve descrição de cada um dos capítulos.

O capítulo um refere-se à introdução que contém o enquadramento, os objetivos da dissertação assim como a presente estrutura.

No capítulo dois irá ser feita uma revisão bibliográfica de todos os fundamentos teóricos relevantes para a presente dissertação. O conceito de cogeração, a evolução e as vantagens, as tecnologias de sistemas de cogeração, como motores de combustão interna de ignição por faísca (ciclo de *Otto*), de ignição por compressão (ciclo de *Diesel*), ciclo de *Atkinson* e o motor Wankel como *range extender*. Ainda nas tecnologias de sistemas de cogeração serão referidas outras tecnologias utilizadas como turbinas, concentrador solar, pilhas de combustível, entre outros.

O capítulo três introduz a integração de sistemas de cogeração e abordará pontos como micro-cogeração, baterias e acumuladores, e redes inteligentes.

O capítulo quatro dirá respeito à modelação da rede doméstica.

O capítulo cinco refere-se à simulação e avaliação de métodos de modelação.

No capítulo seis irá ser demonstrada a avaliação dos resultados da solução proposta.

Por último, no capítulo sete, a conclusão do trabalho realizado.

Capítulo 2

Revisão Bibliográfica

2.1 Cogeração

2.1.1 Conceito da Cogeração

A cogeração é definida como a produção simultânea de duas formas diferentes de energia útil a partir de uma única fonte de energia primária. A energia útil gerada trata-se de energia mecânica e energia térmica. A energia mecânica pode ser utilizada para acionar um alternador e conseqüentemente produzir energia elétrica ou para mover equipamentos rotativos como transmissões, compressores, bombas ou ventiladores. A energia térmica pode ser usada para aplicações de processo direto ou para produção indireta de vapor, água e ar quente ou água gelada para refrigeração do processo [2].

A Cogeração pode ser aplicada para os seguintes efeitos:

- Processos de aquecimento residencial e comercial. Requerem grandes quantidades de calor (ar e água);
- Processos de aquecimento industrial. Requerem calor numa variada gama de temperaturas (secagem, aquecimento, processamento químico, fabrico, processamento de metais, mineração e agricultura);
- Processos de refrigeração residencial, comercial e institucional. O calor da cogeração pode acionar *chillers*, oferecendo, para além de serviços de aquecimento, serviços de arrefecimento [4].

O tamanho e o tipo de sistema de cogeração são definidos conforme as exigências térmicas e elétricas [4].

2.1.2 Evolução da Cogeração

A cogeração surgiu pela primeira vez na Europa no final da década de 1880 e nos Estados Unidos cerca de 20 anos depois. A maior parte das indústrias produziam eletricidade através de caldeiras a carvão e geradores de turbina a vapor. Estas aproveitavam o vapor de exaustão para processos industriais. Segundo a COGEN Europe, a cogeração produzia 58% da energia total das indústrias nos Estados Unidos, no início do século 20. Em meados dos anos 1900, devido à compra mais proveitosa da eletricidade, a maioria das indústrias

abandonou a produção de energia elétrica a partir da cogeração. Esta diminuiu significativamente para 15% e depois, em 1974, diminuiu para 4% nos EUA. A crise petrolífera, em 1973, provocou um aumento na utilização da cogeração, principalmente em grandes indústrias que exigiam elevadas quantidades de vapor. No final da década de 1970, o interesse da cogeração foi renovado em resposta à Lei de Política Regulatória de Serviços Públicos (PURPA) de 1978, que abrangia medidas para promover a cogeração como uma tecnologia eficiente. A PURPA desempenhou um papel crítico nos EUA relativamente à introdução da cogeração no mercado, referindo-se a muitos entraves que estavam presentes no início dos anos 80 [5].

Vários modelos de sistemas de cogeração têm vindo a atender a diversos propósitos como análises económicas, de desempenho e otimização [6]. Atualmente, a implementação de um sistema de cogeração depende de vários fatores, tais como: a relação entre a necessidade de calor e energia, fontes de energia e tecnologias disponíveis, a aplicação dos regulamentos existentes e da integração do processo do uso de energia da planta com as características e capacidades do sistema de cogeração [7]. A escolha do combustível está sujeita à disponibilidade do mesmo, assim como dos custos. O combustível dominante para a cogeração em grande escala ($> 50\text{MW}$) é o carvão. Para aplicações de menor escala ($< 15\text{kW}$) o gás natural e a biomassa são os mais comuns. A aplicação dos sistemas de cogeração depende da energia exigida pela planta, como referido, e por isso, é feita uma divisão em setores. No setor doméstico a energia exigida é inferior a 15 kW, no comercial varia entre os 15 kW e os 5 MW e no industrial é superior a 1 MW [1].

O estudo da cogeração tem vindo a incidir no setor dos transportes, devido à necessidade de aumentar a autonomia nos veículos elétricos e aos desafios colocados para regular a temperatura do habitáculo. Por forma a responder a estes desafios, surgiu a necessidade da implementação de *range extenders*. Existem diversos dispositivos que funcionam como *range extenders*: o motor de combustão interna, *fuel cell* e gerador linear de pistão livre. A aplicação realizada num veículo híbrido é, normalmente, a partir de um motor de ignição por faísca com a finalidade de produzir eletricidade, sendo utilizado como gerador integrado. Este apenas é utilizado para fornecer eletricidade à bateria quando a mesma se esgota, ou seja, o veículo continua totalmente elétrico em termos de propulsão. A energia térmica que provém do MCI é utilizada para aquecimento do habitáculo do veículo. A utilização de *pilhas de combustível* como *range extender* é mais frequente, em que se utiliza uma bomba de calor para extrair o calor residual das mesmas [8]. Estes têm como fatores negativos o investimento na produção de hidrogénio, pois possui um preço elevado, e o elevado consumo [9].

Segundo os Regulamentos de Veículos de Emissão Zero, o veículo elétrico de *range extender* deve cumprir os seguintes critérios: o veículo deve possuir uma autonomia totalmente elétrica de pelo menos 120km , a unidade de potência auxiliar (UPA) deve proporcionar um alcance menor ou igual ao alcance da bateria principal, não deve ser ativada até a carga da bateria principal estiver esgotada, o seu combustível deve atender às medidas de *zero*

evaporative emissions e o veículo deve cumprir os requisitos de *super ultra-low emission vehicle* (SULEV) [10].

2.1.3 Vantagens

As vantagens da utilização desta tecnologia no setor doméstico são as seguintes:

- A eficiência ultrapassa os 80%, mais de 30% caso a energia térmica e elétrica fossem produzidos separadamente;
- Verifica-se a redução da quantidade de poluentes atmosféricos emitidos, beneficiando o meio ambiente [7];
- A instalação do sistema está próxima do consumidor, desta forma, as perdas na rede elétrica são reduzidas (figura 2.1);
- Redução dos custos. Quanto maior quantidade de calor for utilizado mais atrativa, do ponto de vista financeiro, se torna a cogeração [11].

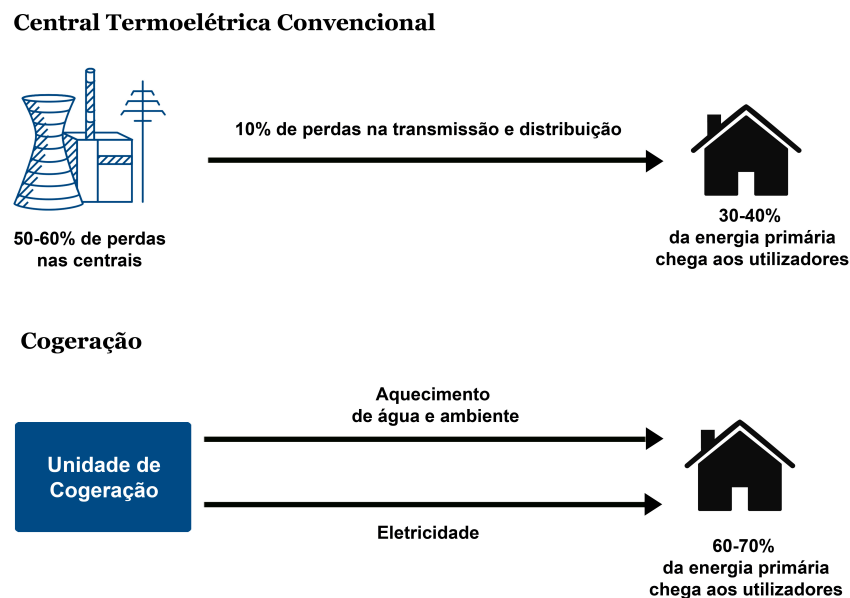


Figure 2.1: Comparação das perdas elétricas entre um sistema convencional e um sistema de cogeração. Adaptado de [12].

Para a introdução da cogeração nos veículos elétricos, com a introdução do motor de combustão interna como *range extender*, as vantagens são evidentes:

- Em condições meteorológicas de frio extremo, as baterias podem perder até 40% da energia útil, devido ao aumento da resistência interna. A utilização do motor de combustão interna aumenta a fiabilidade nestas condições;

- Aumento da autonomia do veículo [10].
- Auxiliar na transição energética no setor dos transportes.

2.2 Tecnologias de Sistemas de Cogeração

A cogeração engloba vários tipos de tecnologias. Estas tecnologias podem ser divididas em aplicações de pequena escala com a utilização de motores mais focados no fornecimento de energia térmica e aplicações de grande escala com o principal objetivo de produzir energia elétrica. Para cada aplicação são destinados diferentes tipos de tecnologias consoante a potência necessária, conforme visível na tabela 2.1.

Table 2.1: Tecnologias de Cogeração indicadas para cada aplicação consoante o combustível [1].

Setor	Potência procurada	Combustível			
		Carvão/ Carvão Biológico	Gás Natural/ Biometano	Diesel/ Biodiesel	Biomassa
Doméstico	<15 kW		MCI	MCI	
Comércio	15-100 kW		MCI	MCI	Turbina a vapor/ Ciclo Orgânico de Rankine
	0.1-1 MW		MCI	MCI	Turbina a vapor/ Ciclo Orgânico de Rankine
	1-5 MW	Turbina a vapor	Turbina a gás/MCI	Turbina a gás/MCI	Turbina a vapor/ Ciclo Orgânico de Rankine
Industrial	1-5 MW	Turbina a vapor	Turbina a gás/MCI	Turbina a gás/MCI	Turbina a vapor
	5-50 MW	Turbina a vapor	Turbina a gás/MCI	Turbina a gás/MCI	Turbina a vapor
	>50 MW	Turbina a vapor	Ciclo Combinado	Ciclo Combinado	Turbina a vapor

No setor doméstico, a tecnologia indicada é a implementação de um sistema de cogeração com um motor de combustão interna que pode ser alimentado a gás natural, biometano ou *diesel*. No setor do comércio, introduzem-se já diferentes tecnologias, unidades comerciais que exigem potências menores implementam-se motores de combustão interna e unidades que exigem potências mais elevadas implementam-se turbinas a vapor, turbinas a gás ou o ciclo de *Rankine* para utilização de biomassa. No setor industrial, utilizam-se as mesmas tecnologias implementadas no setor comercial, com destaque para a turbina a vapor e ciclo combinado para escalas com potências elevadas.

Um sistema de cogeração pode ser classificado como ciclo superior ou ciclo inferior, com base na sequência de uso da energia. No ciclo superior, o combustível fornecido é usado primeiro para produzir energia e depois gerar energia térmica, que é considerado o subproduto do ciclo. Existem quatro tipos de sistemas de cogeração de ciclo superior:

- Uma turbina a gás ou um motor a *diesel* que produz energia elétrica ou mecânica, seguida de uma caldeira de recuperação de calor para acionar uma turbina de vapor secundária;
- O sistema queima combustível para produzir vapor a pressão elevada que depois passa por uma turbina de vapor para produzir energia com a exaustão a fornecer vapor de baixa pressão proveniente do processo;
- O sistema utiliza a recuperação de calor da exaustão e do arrefecimento do motor que segue para uma caldeira de recuperação de calor, onde é convertida para originar vapor ou água quente para consumo do utilizador;
- Uma turbina a gás aciona um gerador e os gases de escape vão para uma caldeira de recuperação de calor que produz vapor ou água quente [2].

No ciclo inferior, o combustível primário produz energia térmica a elevada temperatura e o calor derivado do processo é utilizado para gerar energia, através de uma caldeira de recuperação e um gerador de turbina. O ciclo inferior é adequado para processos de fabrico que requerem calor a elevadas temperaturas. Pode ser aplicado em indústrias de cimento, aço, cerâmica e gás. Os sistemas de cogeração de ciclo inferior são menos comuns que os de ciclo superior [2].

2.2.1 Motores de Combustão Interna

A cogeração baseada em motores de combustão interna, mais aplicados em sistemas de micro-cogeração ($< 15 \text{ kW}$). Nestes são utilizados motores de ignição por faísca ou motores de ignição por compressão. A recuperação da energia térmica faz-se a partir dos gases de escape do motor ($T \approx 500^\circ \text{C}$) e dos circuitos de refrigeração de água e óleo ($T \approx 80^\circ \text{C} - 90^\circ \text{C}$) [13]. Este sistema é visível na figura 2.2.

Vantagens na utilização de motores de combustão interna:

- Rendimento elétrico elevado;
- Arranque rápido;
- Energia térmica a dois níveis de temperatura (gases de escape e arrefecimento do motor);
- Bom desempenho com carga parcial [12].

Desvantagens na utilização de motores de combustão interna:

- Custos de manutenção elevados;

- Emissões poluentes relativamente elevadas;
- Ruído produzido [12].




Figure 2.2: Sistema de cogeração segundo motor de combustão interna. Adaptado de [14].

Os dados convencionais gerados pela utilização de motores de combustão interna em sistemas de cogeração encontram-se na tabela 2.2 [12].

Table 2.2: Características dos motores de combustão interna em sistemas de cogeração [12].

Características	Motor de Ignição por Faísca	Motor de Ignição por Compressão
Ciclo Termodinâmico	Ciclo de <i>Otto</i>	Ciclo de <i>Diesel</i>
Combustíveis	Gasolina, Gás Natural, Biogás	<i>Diesel</i> , Óleo residual
Rendimento Global	70% - 92%	70% - 85%
Rendimento Elétrico	22% - 40%	25% - 40%
Rendimento Térmico	40% - 60%	40% - 60%
Potência (MW)	0,05 - 5	0,015 - 30
Arranque	10 s	10 s
Emissão de NOx (Kg/MWh)	0,5	1 - 14
Revisões (h)	24.000 - 60.000	25.000 - 30.000

2.2.1.1 Motor de Ignição Comandada - Ciclo de *Otto*

O motor de ignição comandada possui quatro tempos diferentes ao longo do seu ciclo, que estão representados na figura 2.3. O cilindro possui, pelo menos, duas válvulas na

parte superior do cilindro que são abertas e fechadas pela árvore de cames. A válvula de admissão, quando aberta, permite a entrada da pré-mistura de ar e combustível. A válvula de escape permite a saída dos gases do cilindro. Para os motores de ciclo de *Otto* de ignição comandada, o seu ciclo pode ser dividido em 4 tempos:




Figure 2.3: 4 tempos do motor de ignição comandada [15].

Na admissão, o pistão efetua um curso descendente (PMS ao PMI) estando a válvula de admissão aberta. O pistão, com o seu movimento descendente, provoca uma depressão no interior do cilindro e dá-se a entrada da mistura para o interior do mesmo [15].

Na compressão, o pistão efetua um curso ascendente (PMI ao PMS) comprimindo os gases que foram admitidos durante a admissão. A compressão vai aumentar a temperatura e a turbulência da mistura, vaporizando gasolina que esteja no estado líquido e homogeneizando a mistura. Desta forma a combustão será mais completa libertando mais calor, sendo este utilizado para aquecimento de água e aquecimento ambiente, e menores quantidades de produtos não queimados [15].

Assim que o pistão chega ao fim do curso no PMS, uma faísca elétrica é aplicada entre os eléctrodos da vela, na câmara de combustão. A mistura é queimada e a pressão da explosão é de tal forma elevada que empurra o pistão para o PMI. Este movimento do pistão é responsável por impulsionar o veio do motor permitindo que este forneça trabalho [15].

No escape, a válvula abre no PMI e os gases queimados saem por esta a elevada velocidade. O pistão, ao realizar o movimento ascendente, limpa os gases queimados do interior do cilindro e a válvula de escape fecha com a chegada do pistão ao PMS [15]. Assim que este chega ao PMS estão reunidas as condições para que o novo ciclo se inicie, regressando ao 1º tempo (admissão).

Do ponto de vista termodinâmico, o funcionamento do motor de ignição comandada é descrito pelo ciclo de Otto, tendo sido este ciclo proposto por *Nicholaus Otto*. Para este ciclo, presente na figura 2.4, ocorrem as seguintes transformações termodinâmicas:

- 1-2 Isentrópica: corresponde ao tempo de compressão. O fluido é comprimido pela

realização de trabalho W_{1-2} , definido pela área (1-2-5-6-1) do diagrama p-V;

- 2-3 Isocórica: momento em que ocorre a explosão. A quantidade de calor fornecida (área 2-3 no diagrama T-S) é definida por $Q_{2-3} = C_v(T_3 - T_2)$;
- 3-4 Isentrópica: dá-se a expansão com o pistão a ir do PMS até ao PMI. O fluido é expandido, realizando o trabalho W_{3-4} , definido pela área (4 - 3 - 5 - 6 - 4) do diagrama p-V;
- 4-1 Isocórica: perda de calor, no momento da abertura de escape, definida por $Q_{4-1} = C_v(T_3 - T_2)$ [15].




Figure 2.4: Ciclo de *Otto* teórico com os diagramas p-V e T-S, respetivamente [15].

2.2.1.2 Motor de Ignição por Compressão - Ciclo de *Diesel*

O motor de ignição por compressão foi concebido por *Rudolf Diesel* ao desenvolver um ciclo que resolvesse todos os problemas que provocavam diminuições do rendimento térmico do motor de ignição comandada. O motor de ignição por compressão utiliza os mesmos componentes que o motor de ignição comandada, mas o funcionamento é diferente. O motor, movido a *diesel*, não possui sistema de preparação da mistura no exterior nem sistema de ignição. Este admite ar puro e, devido à compressão que é sujeito, a sua pressão aumenta e conseqüentemente atinge a temperatura necessária para se dar a ignição do gasóleo, à medida que este é injetado. É indispensável a utilização de um sistema de injeção a alta pressão para que o combustível seja injetado com uma pressão superior ao ar comprimido [15]. Tal como para os motores de ciclo de *Otto* de ignição comandada, o seu ciclo pode ser dividido em 4 tempos (figura 2.5):

Na admissão, o pistão parte do PMS e desce até o PMI. A válvula de admissão encontra-se aberta durante este período, admitindo ar para dentro do cilindro. Na compressão, com ambas as válvulas fechadas, o pistão sobe até PMS, comprimindo o ar puro fechado no cilindro [15].




Figure 2.5: 4 tempos do motor de ignição por compressão [15].

Na combustão, o combustível é injetado, queimando em contacto com o ar quente. A injeção continua durante parte da descida do pistão [15].

No escape, quando o pistão chega ao PMI a válvula de escape abre-se permitindo a saída dos gases de escape, durante a subida do pistão [15].

Do ponto de vista termodinâmico, o funcionamento do motor de ignição por compressão é descrito pelo ciclo de *Diesel*. Para este ciclo, presente na figura 2.6, ocorrem as seguintes transformações termodinâmicas:

- 1-2 Isentrópica: corresponde ao tempo de compressão do ar, fornecendo o trabalho W_{1-2} , que aumenta a energia interna (área abaixo da linha 1-2 do diagrama p-V);
- 2-3 Isobárica: o combustível é injetado e queimado durante o aumento de volume, seguindo um processo de fornecimento de calor a pressão constante a pressão constante $Q_{2-3}=C_p(T_3-T_2)$;
- 3-4 Adiabática: o fluido é expandido realizando o trabalho W_{3-4} à custa da sua energia interna, definido pela área limitada pela linha 3-4 do diagrama p-V;
- 4-1 Isocórica: perda de calor ($Q_{4-1}=C_v(T_4-T_1)$) no momento da abertura de escape [15].

2.2.1.3 Ciclo de *Atkinson*

Nos ciclos de *Otto* e *Diesel* quando a válvula de escape abre, a pressão no interior do cilindro ainda é muito elevada, pelo que é desperdiçada bastante energia que podia ser aproveitada [15]. O ciclo de *Atkinson* aproveita a elevada pressão e temperatura dos gases de escape ao fazer a expansão até à pressão atmosférica [15].

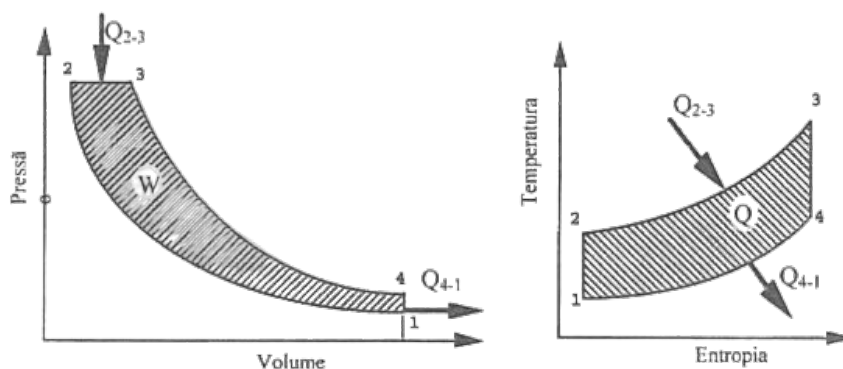


Figure 2.6: Ciclo de *Diesel* teórico com os diagramas p-V e T-S, respetivamente [15].

A representação do ciclo de *Atkinson* nos diagramas p-V e T-S pode ser visualizada na seguinte figura:




Figure 2.7: Ciclo teórico de *Atkinson* com os diagramas p-V e T-S, respetivamente [15].

2.2.1.4 *Wankel - Range Extender*

O motor *Wankel* é um motor rotativo constituído por um rotor e um estator (carcaça) em forma de “epitrocóide” [15]. Este é também denominado por motor rotativo triangular devido ao formato do seu rotor. A partir da ação da engrenagem excêntrica, o rotor faz um movimento orbital específico. O caminho do movimento da borda do rotor é delineado pela forma do corpo do “cilindro” [16]. O rotor possui 3 lóbulos, cada um com uma câmara de combustão que delimitam 3 espaços entre o rotor e o estator [15].

O funcionamento deste motor é baseado em quatro etapas: admissão, compressão, expansão e escape (figura 2.8). Na admissão, o volume entre o rotor e a carcaça aumenta, com a janela de admissão aberta. Na compressão, a admissão é fechada pelo rotor e o volume diminui até que o espaço livre seja o mínimo (PMS num motor alternativo), dando-se então a faísca das velas. Seguidamente ocorre a expansão e no final desta etapa abre-se a janela de escape, por onde saem os gases queimados durante a fase de escape, podendo ser utilizados para efeitos de cogeração [15].




Figure 2.8: Quatro etapas do funcionamento de um motor Wankel. Adaptado de [17].

Enquanto um dos lóbulos do motor faz estas 4 fases, os restantes fazem-nas também (com desfasamento), pelo que temos 3 fases motoras para cada rotação do rotor [15].

Alguns veículos elétricos possuem *range extenders* devido à sua limitação em relação à autonomia [18]. Os motores *Wankel* têm vindo a ser uma escolha mais cativante na utilização como *range extender* do que como motor de pistão alternativo. A razão da escolha deste tipo de motores passa pelas seguintes razões:

- Baixo ruído e vibração;
- Produção de binário uniforme. Na grande maioria das condições de funcionamento, o impacto das flutuações de binário no desempenho do *range extender* pode ser ignorado [16].
- Alta relação peso/potência.
- Compacto [19].

A título de exemplo a *Mazda* introduziu o *MX-30 e-Skyactiv R-EV* que conta com um motor *Wankel* acoplado a um gerador, oferece o alcance adicional pretendido. As rodas são acionadas por um motor elétrico síncrono que produz uma potência de 125 kW e um torque de 260 N.m. O *range extender* é um motor de rotor único com um volume de câmara de combustão de 0,83 L. Este produz 55 kW de potência e 116 N.m de torque. O consumo deste é de 1 L de gasolina por 100 Km [20].

2.2.2 Outras Tecnologias de Cogeração

2.2.2.1 Turbinas a Gás

Uma turbina a gás diz respeito a um tipo de motor térmico onde é produzido trabalho a partir de um fluxo contínuo de gases quentes, que têm origem da queima contínua de combustível [21]. O sistema de cogeração com a aplicação da turbina a gás (figura 2.9)

consiste geralmente num sistema de admissão de ar, câmara de combustão, sistema de exaustão, turbina de expansão e compressor conectados por um eixo. [22].

O funcionamento das turbinas, neste tipo de sistemas, inicia-se com a admissão de ar atmosférico, que é comprimido pelo compressor. O ar de elevada pressão é direcionado para a câmara de combustão onde é misturado com o respetivo combustível. Dá-se a combustão e os gases provenientes deste processo, com temperaturas entre os 50°C e os 600°C , são direcionados para a turbina, onde se expandem. A expansão permite o acionamento do compressor a ar e do dispositivo mecânico acoplado, normalmente um gerador elétrico [21]. De maneira a reaproveitar os gases de escape, é equipado um recuperador de calor obtendo maior rendimento do sistema.




Figure 2.9: Sistema de cogeração com turbina a gás. Adaptado de [23].

As vantagens da aplicação desta tecnologia são:

- O *design* compacto e flexível;
- Baixos níveis de manutenção [22].

Apresenta também as seguintes desvantagens:

- Necessidade de utilização de equipamentos anti-poeiras/sujidade e anti-corrosão;
- Inadequado para uso em aplicações frequentes de *On/Off*, devido ao tempo de arranque [21].

Esta tecnologia pode ser utilizada em sistemas com capacidades até 250 MW, pode atingir as 40000 horas de vida útil e uma temperatura de calor residual entre os 120°C e os 350°C [22]. Os restantes dados convencionais da turbina a gás encontram-se na tabela 2.3.

Table 2.3: Características da turbina a gás em sistemas de cogeração [22].

Características	Turbina a Gás
Combustíveis	Propano, Gás Natural, Bio gás, Óleo destilado
Rendimento Global	65% - 75%
Rendimento Elétrico	18% - 36%
Rendimento Térmico	40% - 60%
Potência (MW)	até 250 MW
Arranque	> 10 min
Emissão de NOx (Kg/MWh)	0,1 - 0,5
Emissão de CO ₂ (Kg/MWh)	580 - 720

2.2.2.2 Turbinas a Vapor

As turbinas a vapor requerem a implementação de caldeiras separadas de vapor a alta pressão. Dependendo do tipo de turbina a vapor, em sistemas de cogeração o vapor é extraído e utilizado diretamente [1]. Existem dois tipos de turbinas a vapor que podem ser aplicadas na cogeração:

- Turbinas de contrapressão;
- Turbinas de extração.

Nas turbinas de contrapressão, o vapor é rejeitado a pressões superiores ao vácuo do condensador. A utilização de vapor a pressões elevadas afeta o rendimento elétrico mas favorece o rendimento térmico, dadas as características do vapor mais adequadas a esta finalidade. Nas turbinas de extração, parte do vapor é enviado para o processo industrial e o restante é condensado no condensador [24].

As turbinas a vapor funcionam segundo o ciclo de *Rankine* e quando aplicados em sistemas de cogeração são constituídos, no geral, por um aquecedor, caldeira, condensador, gerador e pela própria turbina. O modo de funcionamento deste sistema inicia-se com o aquecimento da água, no aquecedor, e de seguida a água aquecida desloca-se para a caldeira. A caldeira, a partir do combustível, aquece a água até esta se transformar em vapor a alta pressão. O vapor dirige-se para a turbina fazendo com que esta rode e produza energia mecânica. O vapor, em baixa pressão, proveniente da turbina, segue para o condensador onde se transforma de novo em água, retornando à caldeira. Desta forma, não é necessário pré-aquecer a água uma vez que esta já se encontra a uma temperatura considerável. A energia mecânica gerada pela turbina permite que o gerador, acoplado a esta, produza energia elétrica. Parte do vapor que sai da turbina é reaproveitado para aquecimento do edifício onde o sistema está inserido [21]. Este sistema é visível na figura 2.10.

As vantagens da aplicação de turbinas a vapor em sistemas de cogeração são:

- Rendimento global elevado;
- Operação da caldeira com vários tipos de combustíveis;

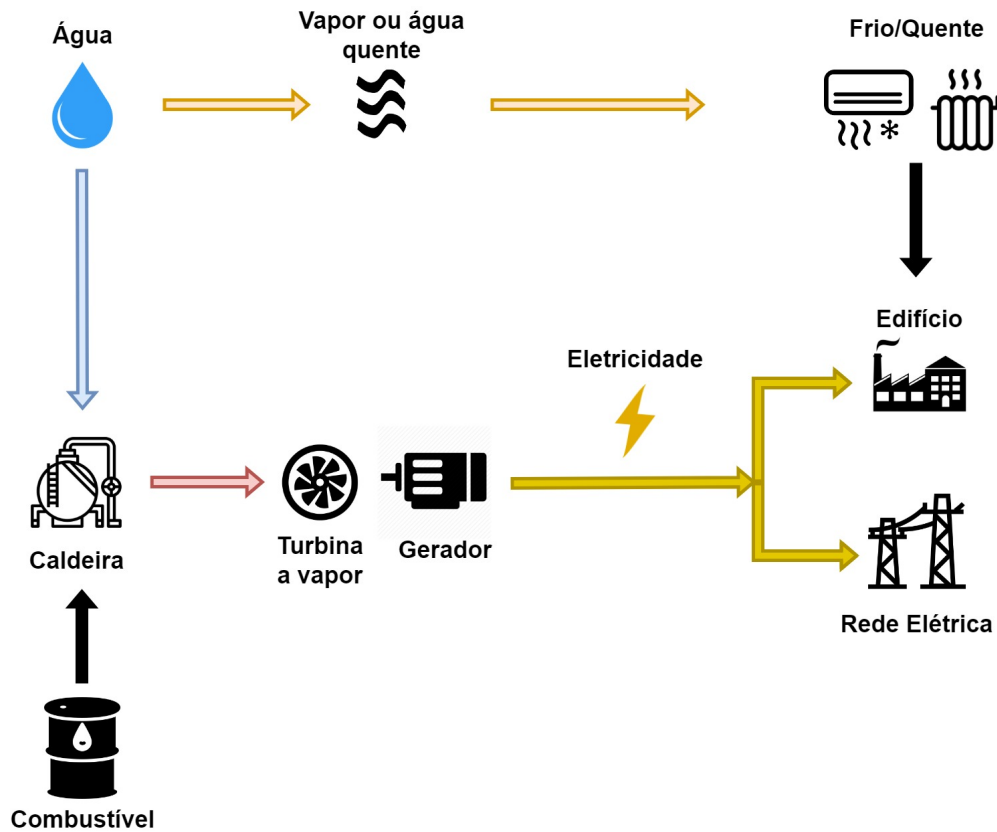


Figure 2.10: Sistema de cogeração com turbina a vapor. Adaptado de [1].

- Grandes quantidades de energia térmica disponíveis;
- Vida útil e fiabilidade elevadas [12].

Mas também apresenta desvantagens tais como:

- Arranque lento;
- Rendimento elétrico baixo [12].

Na tabela seguinte encontram-se dados convencionais da utilização deste tipo de tecnologia em sistemas de cogeração.

Table 2.4: Características da turbina a vapor em sistemas de cogeração [12].

Características	Turbina a Vapor
Combustíveis	Todos
Rendimento Global	60% - 85%
Rendimento Elétrico	10% - 40%
Rendimento Térmico	40% - 60%
Potência (MW)	0,5 - 100 MW
Arranque	1 h - 24 h

2.2.2.3 Motor Stirling

O motor *Stirling* trata-se de um motor térmico que opera por compressão e expansão cíclicas de ar ou outro gás a diferentes temperaturas, de maneira que a energia térmica transformada em energia mecânica. É um motor térmico regenerativo de ciclo fechado com um fluido de trabalho permanentemente gasoso. Ciclo fechado significa num sistema termodinâmico no qual o fluido está contido dentro do sistema, e regenerativo refere-se à utilização de um tipo específico de permutador de calor interno e acumulador térmico, denominado como regenerador. A introdução de um regenerador diferencia o motor *Stirling* de outros motores de ar quente de ciclo fechado [1]. A combustão do combustível no motor *Stirling* ocorre numa câmara de combustão separada, e por isso, é conhecido como um motor de combustão externa a pistão [22].

A figura 2.11 mostra um sistema de cogeração baseado num motor *Stirling* utilizando biomassa. De forma a alcançar elevada eficiência elétrica, a caldeira de biomassa deve operar a um nível de temperatura alto. O motor *Stirling* é projetado para elevadas temperaturas de combustão, sendo conectado diretamente ao forno. Para obter elevadas temperaturas na câmara de combustão e elevada eficiência elétrica, o ar de combustão é pré-aquecido entre 450°C e os 550°C num pré-aquecedor acoplado ao aquecedor *Stirling*. Depois o gás de combustão é arrefecido para temperaturas entre os 120°C e os 150°C [25]. Este é um exemplo de um sistema de cogeração onde o motor *Stirling* pode ser introduzido.




Figure 2.11: Sistema de cogeração com motor *Stirling* utilizando biomassa [25].

O motor referido, é conhecido pelo elevado rendimento geral em comparação com os motores de ignição por faísca e de ignição por compressão, o seu modo de operação é silencioso e tem a capacidade de utilizar qualquer fonte de calor. É compatível com fontes de energia alternativas e renováveis, podendo tornar-se cada vez mais significativo à medida que o preço dos combustíveis aumenta. Tem sido bastante utilizado como componente principal em sistemas de cogeração dado os valores de rendimento e segurança que apresenta [1].

As vantagens da utilização do motor *Stirling* são as seguintes:

- Baixos níveis de ruído e emissão;
- Ideal para aplicações residenciais;
- Possível funcionamento a partir de energias renováveis [22].

Porém apresenta desvantagens, tais como:

- Elevado tempo de arranque;
- Investimento elevado [22].

Introduzidos em sistemas até 55 KW, estes não requerem uma manutenção frequente e possuem uma eficiência mecânica reduzida comparando aos motores de combustão interna. Na tabela seguinte é possível verificar os dados convencionais que esta tecnologia descreve quando aplicada na cogeração [1].

Table 2.5: Características do motor *Stirling* em sistemas de cogeração [22].

Características	Motor <i>Stirling</i>
Combustíveis	Todos
Rendimento Global	60% - 80%
Rendimento Elétrico	15% - 35%
Potência	até 55 KW
Temperatura de calor residual ($^{\circ}C$)	até 85

2.2.2.4 Coletores Solares

A combinação de sistemas de energia solar e módulos termoeletrônicos tem sido de grande interesse na área da cogeração.

Estes dispositivos termoeletrônicos foram introduzidos pela primeira vez em coletores solares de placa plana, estes podem ser coletores de água ou de ar [26]. Os coletores de água de placa plana são a principal escolha para o aquecimento de água em residências. Os coletores de ar de placa plana são utilizados principalmente para aquecimento do meio ambiente. Costumam ser combinados com um painel fotovoltaico produzindo assim energia térmica e energia elétrica [2]. *Kraemer* aplicou nos coletores solares de placa plana estes módulos termoeletrônicos juntamente com materiais de elevada absorção. Este sistema (figura 2.12) atingiu uma eficiência elétrica de 4,6% em condições de teste padrão, superando outras investigações teóricas realizadas [26].

Ainda no ramo dos coletores de placas planas foram também estudados protótipos compostos por lentes de *Fresnel* e dispositivos termoeletrônicos (figura 2.13) para originar eletricidade e pré-aquecer a água. As lentes têm o propósito de focalizar a radiação solar no




Figure 2.12: Módulos termoelétricos aplicados em coletor solar de placa plana. Adaptado de [27].

lado quente dos termoelétricos e a água pré-aquecida flui para manter a temperatura do lado frio dos termoelétricos. O protótipo atingiu os 3,2% de eficiência elétrica e 51,33% de eficiência térmica, quando a irradiação solar é de $709,9 \text{ W/m}^2$ [26].




Figure 2.13: Módulos termoelétricos e lentes de *Fresnel* aplicados em coletor solar de placa plana. Adaptado de [26].

Os coletores de tubos a vácuo possuem no centro de cada tubo uma placa de absorção que consiste numa tira de metal. As perdas de calor por convecção são suprimidas a partir de um vácuo no tubo. Na placa de absorção existe um tubo de calor especial para transportar a energia coletada para a água [2]. Nos coletores de tubos a vácuo foram construídos sistemas constituídos por um tubo de calor, módulos termoelétricos e *water cooled envelopes* (figura 2.14). O sistema gerou eletricidade e calor ao mesmo tempo, mas a eficiência elétrica é muito baixa rondando os 0,16%. Os coletores de tubos a vácuo são úteis quando se requerem temperaturas acima dos 100°C ou a superfície disponível é limitada [26].

Nos coletores de foco em ponto (figura 2.15), que são usados para gerar vapor ou fornecer




Figure 2.14: Módulos termoeletricos aplicados em coletor de tubo a vácuo [26].

energia aos motores *Stirling*, desenvolveu-se o conceito do módulo termoeletrico incorporado no próprio coletor solar parabólico. A partir de um modelo matemático avaliou-se a geração de energia a partir de dispositivos termoeletricos. Com uma radiação solar de 1200 W/m^2 , a eficiência térmica do sistema variou entre 48 e 60%. Com a introdução de material de mudança de fase, mantendo o gradiente de temperatura entre o lado quente e frio do módulo termoeletrico, a eficiência elétrica atingiu os 2,7%, superior aos sistemas que não possuem material de mudança de fase [26].




Figure 2.15: Módulos termoeletricos aplicados em coletor de foco em ponto [26].

2.2.2.5 Pilhas de Combustível

As pilhas de combustível são dispositivos que a partir de energia química produzem energia elétrica e térmica, sem envolver ciclos de combustão [28]. O hidrogénio (combustível) e o oxigénio (comburente) são os elementos químicos utilizados para obter as duas formas de energia. Devido à disponibilidade do hidrogénio ser escassa, umas das alternativas mais eficientes de se obter hidrogénio é através do processo de Reformação. Este processo químico consiste na mistura do combustível com vapor de água ou ar que depois é aquecido a altas temperaturas. Quando misturado com vapor de água produz hidrogénio (H_2), dióxido de carbono (CO_2) e monóxido de carbono (CO), como é visível na figura 2.16 [12].

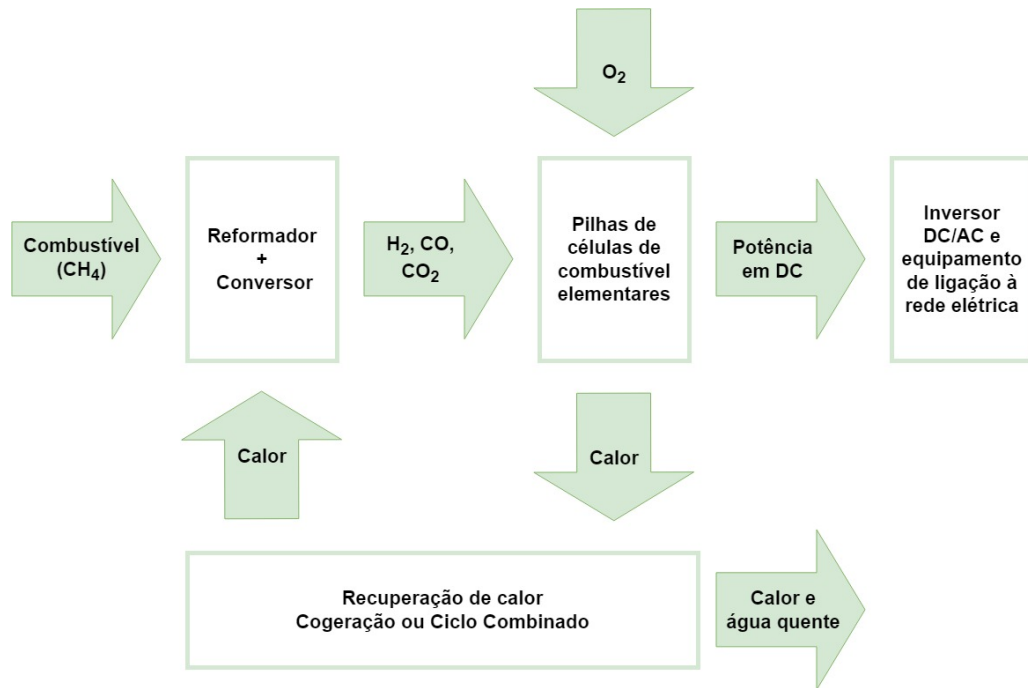


Figure 2.16: Subsistemas principais para o funcionamento de uma pilha de combustível num sistema de cogeração. Adaptado de [26].

A classificação das pilhas de combustível é realizada de acordo com a sua temperatura de trabalho ou com o tipo de eletrólito. As mais indicadas para sistemas de cogeração são:

- AFC (*Alkaline Fuel Cell*);
- PEM (*Proton Exchange Membrane*);
- PAFC (*Phosphoric Acid Fuel Cell*);
- MCFC (*Molten Carbonate Fuel Cell*);
- SOFC (*Solid Oxide Fuel Cell*) [13].

A tabela 2.6 resume as características principais das pilhas de combustível descritas acima.

No âmbito geral, as pilhas de combustível atingem rendimentos térmicos entre os 20% e os 50%, possuem um arranque demorado entre 3 horas e 2 dias e não emitem ruído [12]. As vantagens da utilização das pilhas de combustível são as seguintes:

- A cogeração via produtos químicos é eficiente;
- Baixas emissões;
- Baixo ruído;
- Maior autonomia, criando independência da rede [29].

Table 2.6: Características principais das pilhas de combustível [13].

Tipo de pilha	Eletrólito	Combustível	Oxidante	Temp. de funcionamento (°C)	Rendimento elétrico (%)	Potência Típica (kW)
AFC	Hidróxido de potássio	H ₂	Ar+H ₂ O	60-90	55-60	<7
PEM	Membrana de polímero	H ₂	Ar	70-90	35-45	5-250
PAFC	Ácido fosfórico	H ₂	Ar	200	35-45	200
MCFC	Lítio, potássio, carbonato fundido	CH ₄ , H ₂ , CO	Ar+CO ₂	600-650	45-55	2000-3000
SOFC	Óxidos de ítrio e zircônio	CH ₄ , H ₂ , CO	Ar	800-1000	45-55	Tubular: 100-5000 Planar: 50-100

O complexo processamento ou acesso ao hidrogênio, o arranque demorado e a complexidade de integração em sistemas híbridos são as principais barreiras à introdução desta tecnologia na micro-cogeração [30].

2.3 Sistemas de micro-cogeração baseados em motores de combustão interna

Várias marcas desenvolveram sistemas de micro-cogeração baseados em motores de combustão interna. A *Honda* foi pioneira no mercado em 2003 com a unidade *Ecowill Micro-CHP*, vendendo 100.000 unidades no Japão [31]. Esta unidade movida a gás natural marcou o primeiro sistema de micro-cogeração concebido com um motor de combustão interna, oferecendo 1 kW de potência elétrica e 3 kW de potência térmica com uma eficiência energética global de 85% [32]. Um modelo mais recente, lançado em 2011, apresentou uma eficiência global melhorada de 92% devido à aplicação do motor "EXlink", que apresenta um curso de expansão mais longo do que o curso de compressão graças a um mecanismo de ligação de expansão *multi-link* [33]. Outras entradas notáveis no mercado incluem o sistema de 6 kW alimentado a gás natural da *Tokyo Gas* com uma eficiência de 86% e o sistema da *Yanmar Diesel Engine Co.* que oferece uma potência de 9,8/8,2 kW, com uma eficiência de 81,55% e uma taxa de recuperação de calor até 58/56% [32, 33, 34, 35, 36].

Na Europa, a *SenerTec* domina o mercado, com mais de 20.000 unidades vendidas do seu modelo *Dachs*, que oferece 5,5 kW de potência elétrica, 10 kW de potência térmica e uma eficiência global de 90% [31, 34, 37]. Uma alternativa notável vem da *PowerPlus Technologies*, que introduziu a unidade *Ecopower Micro-CHP*, fornecendo potência elétrica

ca ajustável entre 4,7 e 1,3 kW graças ao controlo da rotação do motor e a um conversor de frequência que condiciona a saída de energia para alimentação da rede. A potência térmica da unidade varia de 4 a 12,5 kW, com uma eficiência global estimada em 89% [31].

Na tabela 2.7 estão representadas as especificações dos sistemas de micro-cogeração baseados em MCI referidos anteriormente.

Table 2.7: Especificações dos sistemas de micro-cogeração baseados em MCI [34, 31].

Modelo	<i>Honda Ecowill 2003</i>	<i>Honda Ecowill 2011</i>	<i>Tokyo Gas</i>	<i>Yanmar Diesel Engine Co.</i>	<i>SenerTec Dachs</i>	<i>PowerPlus Technologies Ecopower</i>
Output Elétrico (kW)	1	1	6	9.8/8.2	5.5	1.3-4.7
Output Térmico (kW)	3	2.5			12.5	4-12.5
Eficiência Elétrica (%)	21.3	26.3			27	24.7
Eficiência Térmica (%)	63.7	65.7			61	64.2
Eficiência Total (%)	85	92	86	81.55/80	88	88.9

Capítulo 3

Integração de sistemas de cogeração

A incorporação de um motor de combustão interna no âmbito da micro-cogeração em ambientes residenciais, com painéis fotovoltaicos e baterias existentes, implicam desafios significativos. O principal obstáculo é a interconexão eficaz de todos os sistemas de energia, com o objetivo de otimizar a rentabilidade da rede, minimizando as perdas e os custos. Consequentemente, sistemas de controlo sofisticados e automatizados são fundamentais para uma gestão eficaz da energia [38].

Darcovich et al. analisaram uma rede residencial que incluía estas tecnologias e salientaram que a utilização de painéis fotovoltaicos e baterias poderia produzir benefícios económicos, embora em menor grau após a integração de um sistema de micro-cogeração [39]. A hierarquia do consumo de energia dá geralmente prioridade à energia fotovoltaica devido ao seu carácter renovável, seguida da utilização da bateria e, finalmente, do funcionamento do motor quando a energia fotovoltaica e o nível de carga da bateria se revelarem inadequados.

Para aplicações de aquecimento de água, a energia fotovoltaica é a principal fonte de energia. No entanto, quando esta não é suficiente, a energia térmica do motor entra em ação. Em comparação com os aquecedores de água convencionais, os motores não conseguem aquecer a água tão rapidamente, o que leva à inclusão de um cilindro de água no sistema. Este componente proporciona um atraso de tempo entre o calor produzido pelo sistema de micro-cogeração e a água quente utilizada [40].

A complexidade reside em decidir para onde encaminhar a energia elétrica e em estabelecer critérios para a utilização da energia térmica do motor. Outras complicações podem advir do tempo necessário para carregar a bateria enquanto o motor suporta simultaneamente a carga elétrica da residência. Estas questões exemplificam algumas das potenciais dificuldades enfrentadas que se colocam quando se juntam estas tecnologias numa só rede [39].

3.1 Baterias e Acumuladores Térmicos

Nos dias de hoje, existem no mercado seis tipos diferentes de baterias ião-lítio cobre: Óxido de Lítio-Cobalto ($LiCoO_2$), Óxido de Lítio-Manganês ($LiMn_2O_4$), Fosfato de Lítio-Ferro ($LiFePO_4$), Óxido de Lítio-Níquel-Cobalto-Alumínio ($LiNiCoAlO_2$), Óxido de Lítio-Níquel-Manganês-Cobalto ($LiNiMn - CoO_2$) e Titanato de Lítio ($Li_4Ti_5O_{12}$). A classificação das baterias segue segundo os componentes químicos que constituem as

mesmas. As variadas famílias de íões de lítio apresentam diferentes propriedades e características em função da sua composição e estrutura interna, que implicam diferentes capacidades em termos de potência específica (W/Kg), energia específica (Wh/Kg), estabilidade térmica e desempenho. O tempo de vida útil também difere [41].

Para aplicações em setores domésticos, a introdução das baterias complementa a produção fotovoltaica permitindo que esta seja armazenada, tal como a energia elétrica que provém do sistema de micro-cogeração no caso de não ser utilizada. Para este contexto, as baterias que melhor se adaptam, segundo a literatura, são as baterias de Fosfato de Lítio-Ferro (LFP) e as baterias de Óxido de Lítio-Níquel-Manganês-Cobalto (NMC). Os modelos existentes no mercado podem ser visíveis na seguinte Figura 3.1:











Home Storage System	Li-ion Cells			
(1) LG Chem RESU	NMC			
(2) Tesla Powerwall 2	NMC	(1)	(2)	(3)
(3) Varta Pulse 6	NMC			
(4) SENEK Home Li 10	NMC	(4)	(5)	(6)
(5) Ampere Energy Square	NMC			
(6) Sonnen ECO	LFP	(7)	(8)	(9)
(7) BYD B-BOX Pro	LFP			
(8) Simpliphi PHI	LFP			(10)
(9) Pylon US 2000	LFP			
(10) Power Plus Energy L. Pr.	LFP			

Figure 3.1: Baterias disponíveis no mercado e tipo de células de íões de lítio implementadas [42].

Comparando ambas as baterias, estudos revelam que o ciclo de envelhecimento tem mais impacto nas células NMC do que nas LFP, sendo um fator que leva a que sejam as LFP as escolhidas para fazer parte das redes elétricas residenciais. Ambas apresentam um ciclo de vida útil entre os 8 e 12 anos [42].

A participação das energias renováveis nos sistemas energéticos residenciais permite a menor utilização das fontes de energia convencionais. No entanto, as energias renováveis só estão disponíveis quando o recurso está disponível, o que diminui a flexibilidade da rede elétrica. Na cogeração, a utilização da energia elétrica quando necessária, implica a produção de energia térmica. Esta pode não ser necessária no momento, daí a necessidade de atrasar a sua utilização e adotar a aplicação de sistemas de armazenamento de energia térmica (AET) [43]. As aplicações desta tecnologia incluem aquecimento ambiente, aquecimento de água quente e refrigeração [44].

Os três principais tipos de sistemas de armazenamento de energia térmica são calor sensível, calor latente e termoquímico. Todos os sistemas de armazenamento de energia tér-

mica seguem os mesmos princípios básicos. O excesso de energia é armazenado num sistema para uso posterior [45].

O armazenamento de calor sensível é o processo de armazenar energia térmica na forma de mudanças de temperatura num material. O material utilizado pode ser cerâmica, água ou óleo. O armazenamento de calor latente envolve a absorção ou libertação de calor durante uma mudança de fase, mantendo a temperatura constante. O armazenamento termoquímico envolve reações químicas reversíveis para armazenar e libertar energia térmica. Ou seja, ao invés de utilizar mudanças de fase ou variações de temperatura para armazenar energia térmica, quando uma substância química reage com outra, esta pode absorver ou libertar uma quantidade significativa de energia térmica. Estas reações são projetadas para serem reversíveis, a energia térmica pode ser armazenada durante a reação e libertada quando se inverte a reação química [46].

3.2 Redes Inteligentes

Com a elevada procura de energia elétrica a partir de meios *off-grid*, a gestão de energia numa residência é uma questão desafiante nos dias de hoje. Existem já abordagens inovadoras para a gestão dos sistemas de energia que consigam equilibrar de forma eficaz a distribuição da energia. O *machine learning* e as estratégias de controlo surgiram para promover o desenvolvimento de sistemas energéticos mais eficientes, económicos e ecológicos. Estas abordagens optimizam a utilização dos painéis fotovoltaicos, baterias e motor como micro-cogeração, reduzem o consumo de energia e melhoram o desempenho global do sistema [47].

Os modelos de *machine learning* normalmente utilizados em sistemas de energia são redes neuronais artificiais (RNA), *perceptron* multicamadas (MLP), *extreme learning machines* (ELM), *support vector machines* (SVM), *wavelet neural networks* (WNN), *adaptive neuro-fuzzy inference systems* (ANFIS), árvores de decisão, *deep machine learning*, conjuntos e modelos híbridos avançados de *machine learning*.

As redes neuronais artificiais (RNA) são estruturas para diferentes algoritmos de *machine learning* processarem entradas de dados complexos. Podem ser aplicadas em métodos de previsão, regressão e ajuste de curvas. A sua baixa complexidade face a problemas de múltiplas variáveis é uma vantagem que as caracteriza [48]. Uma versão mais desenvolvida de RNA é o modelo MLP. É denominado uma rede neuronal feed-forward e utilizado para modelagem e previsão de processos [49].

O SVM é o método de *machine learning* mais indicado para reconhecimento de padrões, classificação e análise de regressão, sendo baseado em algoritmos construídos na teoria de *statistical learning* para minimização de riscos estruturais. Devido à capacidade de realizar generalizações é bastante aplicado em previsões de carga [49].

O WNN pratica uma função utilizando uma série de dados e produzindo um valor de saída para um certo valor de entrada. Este modelo necessita de menos tempo de aprendizagem que o modelo MLP [50]. O ANFIS é um método de modelagem que integra uma rede neuronal artificial baseada no sistema de inferência *fuzzy Takagi-Sugeno*, que se aproveita dos recursos da lógica difusa e da rede neuronal. É considerado um método híbrido de *machine learning* [51]. As árvores de decisão utilizam uma estrutura em forma de árvore para decidir com base nos dados históricos de carga elétrica, cada nó da árvore representa uma característica, como a temperatura ou a hora do dia, os ramos representam as respostas para essa característica e as folhas da árvore representam as previsões para um determinado período de tempo. O *deep machine learning* utiliza redes neurais profundas para prever carga com base em dados anteriores. Estas são capazes de aprender padrões complexos e não lineares dos dados, permitindo previsões mais precisas da carga futura. Os conjuntos são uma técnica que combina vários modelos de previsão num modelo geral para melhorar a precisão da previsão. Por fim, os modelos híbridos avançados de *machine learning* combinam árvores de decisão e redes neurais profundas com a finalidade de obter mais precisão na previsão de carga. Utilizam as redes neurais profundas para extrair dados e usam estes para implementar numa árvore de decisão realizando previsões finais de carga, por exemplo [49].

Estes métodos descritos anteriormente podem ser utilizados para previsão de energia e controlo da mesma.

Capítulo 4

Modelação da rede doméstica

4.1 Dados e análise

4.1.1 Fonte dos dados da rede residencial

Os dados foram obtidos a partir da radiação solar *PVGIS-SARAH2* desenvolvido para calcular a produção de energia elétrica de um sistema fotovoltaico em função da radiação solar e de outras variáveis climáticas importantes. É baseado em dados de radiação solar global horizontal e inclinada, temperatura do ar, velocidade do vento e outros parâmetros climáticos, fornecidos por estações meteorológicas ou por modelos climáticos regionais. O modelo utiliza algoritmos de simulação e cálculo para estimar a radiação solar do sistema fotovoltaico, considerando valores como latitude, longitude, elevação, declinação, *azimuth*, potência nominal do sistema fotovoltaico e perdas do sistema. Os valores são apresentados na seguinte tabela:

Table 4.1: Dados de radiação solar.

Parâmetros	Valor
Latitude (graus)	41.157
Longitude (graus)	-8.391
Elevação (m)	166
Inclinação (graus)	37
Azimuth (graus)	10
Potência Nominal do sistema fotovoltaico (kW)	3.5
Perdas do sistema (%)	15

4.1.2 Análise de dados e *machine learning*

As redes neuronais artificiais (RNA) foram utilizadas com os dados gerados para prever os perfis diários de carga e de produção fotovoltaica. Estas previsões serviram de entrada para um controlador que determinou o funcionamento do sistema Micro-CHP e da bateria. As RNAs são vantajosas para esta aplicação porque podem aprender e fazer previsões com base em séries de dados temporais. A RNA foi treinada utilizando 80% dos dados recolhidos, sendo os restantes 20% utilizados para teste. Os valores previstos e reais foram comparados para avaliar o desempenho da RNA, sendo o root-mean-square error (RMSE) utilizado como índice de desempenho. Esta abordagem melhora o controlo otimizado do sistema, considerando os perfis de carga previstos e a produção fotovoltaica, melhorando assim o desempenho global do sistema.

4.2 Estratégia de controlo da rede doméstica

As prioridades de direccionar a energia para diferentes tipos de procura, foram definidas inicialmente de forma que a simulação realizada correspondesse às necessidades pretendidas. A prioridade primeiramente é determinar se a produção fotovoltaica, nas duas horas seguintes, é em excesso ou em défice comparativamente à carga das próximas duas horas. A eficiência energética, assim como a sustentabilidade económica e ambiental são os principais objetivos na otimização deste tipo de sistemas híbridos [52]. Estes parâmetros foram mantidos em conta para o planeamento da estratégia.

A simulação é realizada segundo iterações para cada hora das duas horas seguintes. Conforme as condições existentes, tais como o estado de carga da bateria (SOC), a *eletrical load* prevista e a produção fotovoltaica prevista, e segundo as hipóteses definidas obtém-se graficamente o perfil de *eletrical load*, o perfil do aquecimento de água, contida no cilindro elétrico, e o perfil do SOC.

O método inicial na simulação é determinar se existe défice ou excesso de produção fotovoltaica para cada hora das duas horas seguintes. Para verificar (*CheckPv*) subtraiu-se a produção fotovoltaica prevista à *eletrical load* prevista ($load_{next2hours} - P_{vproduction_{next2hours}}$). No caso de estar em défice ($CheckPv > 0$), verifica-se também que o aquecimento da água contida no cilindro não irá ser suportada pela potência fotovoltaica ($CheckWh = waterheat$), pois a prioridade é suportar a *eletrical load*. Se o SOC é suficiente para suportar a carga ($SOC > 0.2$), caso existam condições a bateria suporta a *eletrical load* na totalidade. Se a bateria não suportar a carga elétrica na totalidade e como a carga de aquecimento de água é suportada pelo motor, a energia elétrica do motor ajuda a suportar a carga elétrica restante. Caso a bateria suporte a carga na totalidade, é necessário direccionar a energia elétrica do motor para carregar a bateria. No caso de o SOC ser insuficiente ($SOC < 0.2$), o sistema de micro-cogeração auxilia no suporte da carga elétrica e, sabendo da produção de energia térmica, esta é direccionada para o aquecimento de água. A água, contida num cilindro elétrico, é aquecida pelo motor a partir de permutadores de calor que permitem conectar o motor ao cilindro. Ao mesmo tempo que o motor suporta a carga elétrica, este carrega a bateria.

No caso de haver excesso de produção solar ($CheckPv < 0$), prioriza-se a carga elétrica e depois o aquecimento de água. Se não houver energia fotovoltaica suficiente para o aquecimento de água, é necessário compensar com a energia térmica do sistema de micro-cogeração. A energia elétrica produzida é utilizada para carregar a bateria, caso exceda energia solar no aquecimento de água, aproveita-se para carregar a bateria. O fluxograma seguinte representa a estratégia descrita.

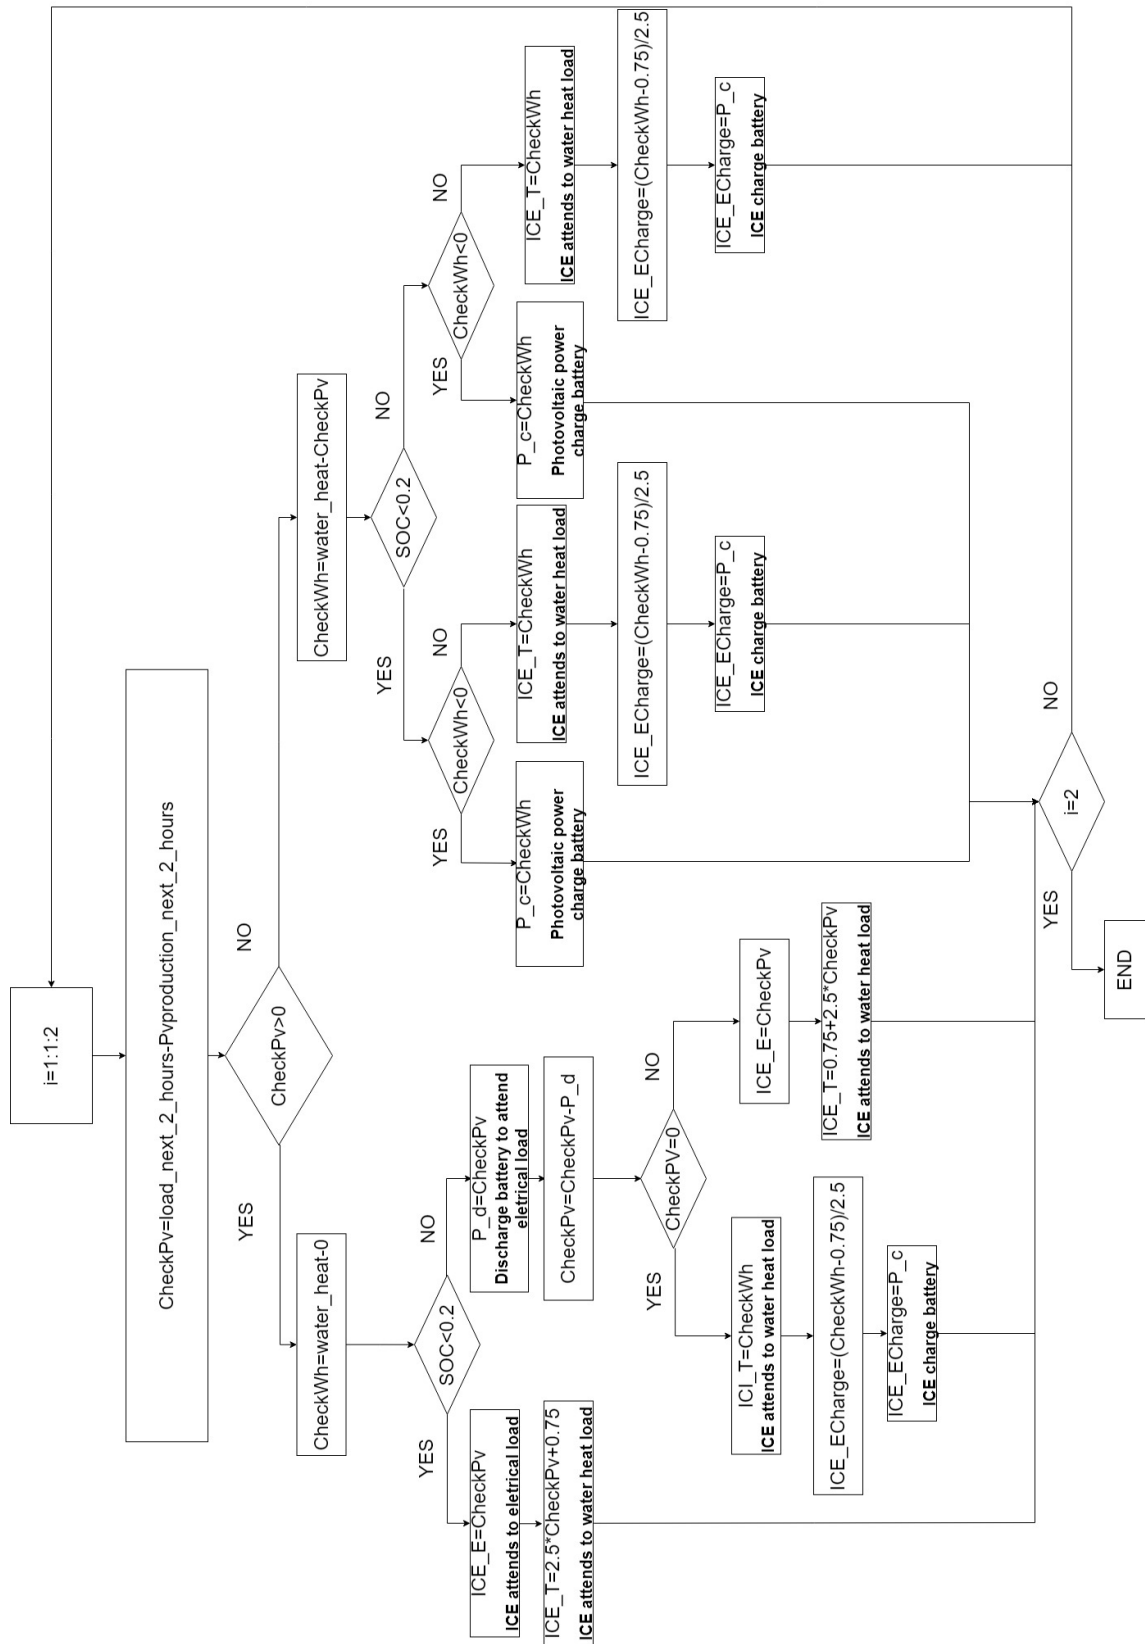


Figure 4.1: Fluxograma da simulação da estratégia de controlo da rede doméstica.

Capítulo 5

Modulação e Simulação

5.1 Modelos

5.1.1 Modelo Bateria

O modelo de bateria *Kinetic (KiBam)* (figura 2) foi proposto por *Manwell* e *McGowan* e é utilizado para capturar efeitos de capacidade não linear para rastreamento de SOC [53].

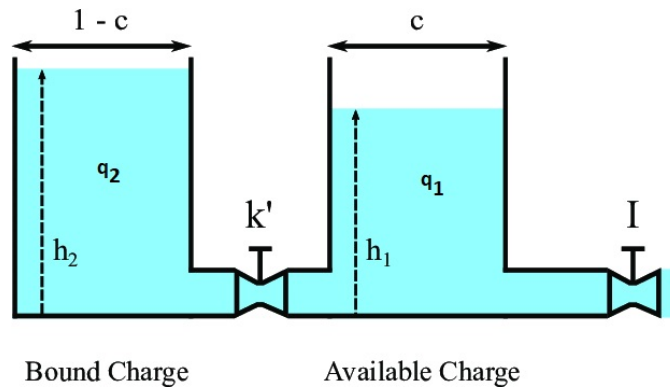


Figure 5.1: Modelo da bateria *Kinetic (KiBam)*. Adaptado de [54].

O KiBam utiliza dois reservatórios diferentes, denominados *bound charge* e *available charge*, separados por uma condutância. O reservatório *available charge* q_1 contém carga que está imediatamente disponível para ser usada pelo consumidor, o reservatório *bound charge* q_2 contém a carga que está quimicamente ligada. Cada um possui a mesma profundidade, mas diferentes larguras e consequentemente diferentes volumes. A largura do reservatório 1 (*available charge*) é c e a do reservatório 2 (*bound charge*) é $(1-c)$. A altura manométrica em cada reservatório é dada pela largura dividindo pela área.

A capacidade total da bateria é a soma de q_1 e q_2 . A variável k representa a taxa com que a carga flui de q_2 para q_1 [55].

O princípio do modelo *KiBaM* é o seguinte: quando a bateria está a descarregar, a carga de q_1 flui para fora e, simultaneamente, a carga de q_2 flui para q_1 , lentamente com k . A carga que sai de q_1 é mais rápida que a que entra, então a diferença de altura entre q_1 e q_2 irá aumentar. Caso a descarga seja interrompida a carga de q_2 flui lentamente para q_1 até que as alturas sejam iguais ($h_1 = h_2$), retratando-se no efeito de recuperação da bateria. A bateria quando está a carregar, o reservatório q_1 carrega a uma velocidade superior comparando ao reservatório q_2 [53]. A quantidade de energia contida em cada reservatório em kWh, em cada passo de tempo, é representada pelas seguintes equações:

$$q'_1 = q_1 e^{-k\Delta t} + \frac{(q_{bat}kc - P_{cd})(1 - e^{-k\Delta t})}{k} - \frac{P_{cd}c(k\Delta t - 1 + e^{-k\Delta t})}{k} \quad (5.1)$$

$$q'_2 = q_2 e^{-k\Delta t} + q_{bat}(1 - c)(1 - e^{-k\Delta t}) - \frac{P_{cd}(1 - c)(k\Delta t - 1 + e^{-k\Delta t})}{k} \quad (5.2)$$

Neste contexto, os termos q'_1 , q'_2 e q_1 , q_2 são a *available and bound charge* no início e no fim de cada passo de tempo, respetivamente. A variável Δt representa a duração de cada passo de tempo, enquanto P_{cd} refere-se à potência utilizada para carregar ou descarregar o sistema durante cada passo de tempo, medida em kW. O valor específico de P_{cd} dependerá das condições de funcionamento do sistema. As equações seguintes fornecem informações sobre a maior quantidade possível de energia que pode ser utilizada para descarregar ou carregar a bateria em cada passo de tempo, medida em kW:

$$P_d = \frac{kq_1 e^{-k\Delta t} + q_{bat}kc(1 - e^{-k\Delta t})}{1 - e^{-k\Delta t} + c(k\Delta t - 1 + e^{-k\Delta t})} \quad (5.3)$$

$$P_c = \frac{-kcq_{max} + kq_1 e^{-k\Delta t} + q_{bat}kc(1 - e^{-k\Delta t})}{1 - e^{-k\Delta t} + c(k\Delta t - 1 + e^{-k\Delta t})} \quad (5.4)$$

Onde q_{max} é a capacidade máxima da bateria [55].

Table 5.1: Especificações do modelo de bateria *Kinetic (KiBaM)*.

Parâmetros	Valores
K	0.38
c	0.271

5.1.2 Modelo Fotovoltaico

Para determinar a potência de saída dos módulos fotovoltaicos, foi utilizado um modelo em função da temperatura da célula e da irradiação solar. A potência de saída do sistema fotovoltaico (P_{PV}) é dada pela seguinte equação:

$$P_{PV} = \mu_{mppt} \left(P_{STC} \frac{G}{G_{STC}} (1 + \alpha_{VOC} (T_{cell} - T_{STC})) \right) N_s N_p \quad (5.5)$$

Em que μ_{mppt} é a eficiência na trajetória do ponto de potência máxima [%], P_{STC} é a potência máxima sob STC [W], G é a irradiância solar dada em cada passo de tempo $[\text{Wm}^{-2}]$, G_{STC} é a irradiância sob STC $[\text{Wm}^{-2}]$, α_{VOC} é o coeficiente de temperatura da tensão de circuito aberto sob STC $[\text{V}^\circ\text{C}^{-1}]$, T_{STC} é a temperatura da célula em condições STC $[\text{C}^\circ]$, N_S são os módulos ligados em série e N_p os módulos ligados em paralelo, em cada passo de tempo. T_{cell} é a temperatura da célula em cada passo de tempo $[\text{C}^\circ]$ dada pela seguinte equação:

$$T_{cell} = T_{amb} + \frac{G}{G_{NOCT}} * (NOCT - T_{NOCT}) \quad (5.6)$$

Com a temperatura em cada célula dada em função da temperatura ambiente T_{amb} em cada passo de tempo $[\text{C}^\circ]$, e G_{NOCT} é a irradiância em condições NOCT $[\text{Wm}^{-2}]$, $NOCT$ é a temperatura nominal de funcionamento da célula $[\text{C}^\circ]$, e T_{NOCT} é a temperatura do ar em condições NOCT $[\text{C}^\circ]$ [56, 57]. As especificações do modelo estão visíveis na tabela 5.2.

Table 5.2: Especificações do modelo fotovoltaico.

Parâmetros	Valores
μ_{mppt}	95%
P_{STC}	250 W
G_{STC}	1000Wm^{-2}
α_{VOC}	$-0.0044 \text{V}^\circ\text{C}^{-1}$
T_{STC}	25°C
G_{NOCT}	800Wm^{-2}
$NOCT$	47.5°C
T_{NOCT}	20°C

5.1.3 Modelo Micro-Cogeração

O sistema de micro-cogeração escolhido para este estudo foi concebido para cumprir os objetivos específicos da investigação. Foi determinado que o sistema deveria ter uma potência elétrica entre 1,3 e 4,7 kW e uma potência térmica correspondente entre 4 e 12,5 kW. Esta gama foi selecionada para assegurar uma capacidade de desempenho versátil que possa responder adequadamente às diferentes condições de procura tipicamente encontradas em ambientes residenciais.

Para estabelecer a correlação entre a potência elétrica e a potência térmica do sistema, foi formulada uma equação linear, a equação 5.7:

$$lCI_T = 2.5 \times lCI_E + 0.75 \quad (5.7)$$

Na equação 5.7, ICI_T representa a potência térmica e ICI_E refere-se à potência elétrica correspondente. Esta relação implica que, por cada unidade de aumento da potência elétrica, a potência térmica aumenta 2,5 vezes. A constante adicional de 0,75 é a potência térmica produzida quando a potência elétrica é zero. Esta fórmula foi desenvolvida para fornecer uma forma simples mas eficaz de prever o desempenho do sistema ao longo da sua gama de funcionamento.

A equação descrita é fundamental para gerir o equilíbrio entre a produção elétrica e térmica do sistema de micro-cogeração. Ao ser capaz de prever a produção térmica para uma determinada produção elétrica, o sistema pode ser operado de forma mais eficiente e eficaz, assegurando que o calor produzido não é subutilizado nem desperdiçado.

Em resumo, este modelo de micro-cogeração fornece um contexto robusto para compreender e prever o desempenho do sistema. Serve como uma ferramenta crítica para otimizar o funcionamento do sistema, alcançar a eficiência energética e facilitar a integração com outros componentes do sistema energético.

5.1.4 Modelo de *machine-learning* para previsão de carga

5.1.4.1 Seleção do Modelo e Fundamentação

A previsão de carga a partir de *machine learning* é classificada em três categorias: previsão de carga a curto prazo (uma hora a uma semana), previsão de carga a médio prazo (uma semana a um ano) e previsão de carga a longo prazo (mais de um ano). No geral, a previsão de carga de cada residência tem-se mostrado um problema mais difícil comparativamente à previsão de carga agregada. Existem duas abordagens principais para realizar a previsão de energia: previsão baseada em princípios físicos e previsão baseada em estatística e *machine learning*. As redes neuronais artificiais fazem parte da segunda abordagem [58].

As redes neuronais artificiais (RNA) imitam as funcionalidades dos neurónios do cérebro humano num computador. A computação tradicional é a ideal para guardar uma ampla quantidade de informação e reorganizá-la de acordo com instruções precisas criadas especificamente para aquela tarefa e contendo todas as possibilidades e condições da mesma. A RNA tem sido investigada desde 1990 para ser aplicada na previsão de carga [59]. São redes paralelas de elementos de processamento simples, concebidas para simular as funções e as estruturas do cérebro com o fim de resolver problemas complexos [60].

Neste estudo, as redes neuronais artificiais foram escolhidas para a previsão da carga elétrica e da produção fotovoltaica. A sua capacidade de aprender e modelar relações não lineares torna-as particularmente adequadas para lidar com as complexidades e flutuações associadas à procura de energia e à produção de energia renovável. A sua utilização neste contexto garante uma previsão mais precisa e fiável, o que é crucial para uma gestão e controlo eficientes da energia em redes residenciais.

5.1.4.2 Treino e Validação do Modelo

A rede neuronal *feedforward* multicamada (RNFM) é uma das redes neuronais mais utilizadas. Em cada camada da rede, a resposta de cada neurónio é fornecida pela função de ativação com um custo dado por uma soma ponderada, que funciona como um limiar. Para quaisquer duas camadas consecutivas (entrada-oculta, oculta-oculta ou oculta-saída), $[k - 1, k]$ pode ser expresso matematicamente pela Equação (5.8):

$$y_j = f_j\left(\sum_{t=1}^n \omega_{tj} \times x_t + b_j\right), i \in [0, n] j \in [0, m] \quad (5.8)$$

Em que n é o número de neurónios na camada $k - 1$ e m é o número de neurónios na camada k com $n, m \in \mathbb{Z}^+$; y_j é a saída do neurónio j , x_i é o sinal de entrada para o neurónio j proveniente do neurónio i ; b_j é a polarização do neurónio j ; e finalmente w_{ij} é o peso da ligação sináptica entre os neurónios i e j [60].

A aprendizagem da RNA é elaborada num processo conhecido como aprendizagem supervisionada, que consiste em atualizar o peso do vetor para minimizar o erro. Neste trabalho, a função de desempenho (erro) escolhida é o erro médio quadrático, dado pela Equação (5.9):

$$MSE = \frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5.9)$$

Em que N é o número de amostras de treino, \hat{y}_i é a saída atual da rede e y_i é a resposta de saída desejada. No entanto, ao implementar uma RNA, é necessário escolher um conjunto não trivial de aspetos sensíveis, ou seja, com impacto no desempenho do trabalho. Estes aspetos incluem a escolha das variáveis de entrada (carga, variáveis meteorológicas, etc.), o tamanho dos vetores de treino, o número de camadas ocultas, o número de neurónios em cada camada oculta, a escolha do método de treino, as funções de ativação e os critérios de paragem, e a própria topologia da rede [61].

Este artigo utilizou duas redes neuronais *feedforward* com uma arquitetura de 15 neurónios e uma única camada oculta para prever com precisão a procura fotovoltaica e o consumo de carga para as duas horas seguintes. Estas RNAs foram concebidas com cinco entradas cada, especificamente escolhidas para representar variáveis de desfaseamento do conjunto de dados de treino que apresentavam a correlação mais forte. O processo de seleção destas variáveis de desfaseamento foi realizado através de um teste de autocorrelação, garantindo a inclusão de variáveis altamente influentes para aumentar a precisão das previsões.

5.2 Simulação

A rede residencial em questão inclui uma unidade integrada de micro-cogeração com uma potência elétrica que varia entre 1,3 e 4,7 kW e uma potência térmica entre 4 e 12,5 kW. Tem uma eficiência elétrica e térmica que atinge 24,7% e 64,2%, respetivamente. O sistema está também equipado com uma bateria de 5 kW.h de capacidade e um painel fotovoltaico com uma potência de 3,5 kWpp. Considera-se que a rede está equipada com contadores inteligentes que recolhem e comunicam os dados relativos às duas horas seguintes. Os dados recolhidos por estes contadores inteligentes facilitam a gestão inteligente da unidade de micro-cogeração, da bateria e do painel fotovoltaico para responder adequadamente à procura de eletricidade da micro-rede. Adicionalmente, o sistema também gere a procura de água quente armazenada num cilindro. Esta procura térmica pode ser satisfeita quer pelo painel fotovoltaico, através da conversão do excesso de energia elétrica, quer diretamente pela energia térmica produzida pelo motor, conforme ilustrado na figura 5.2.

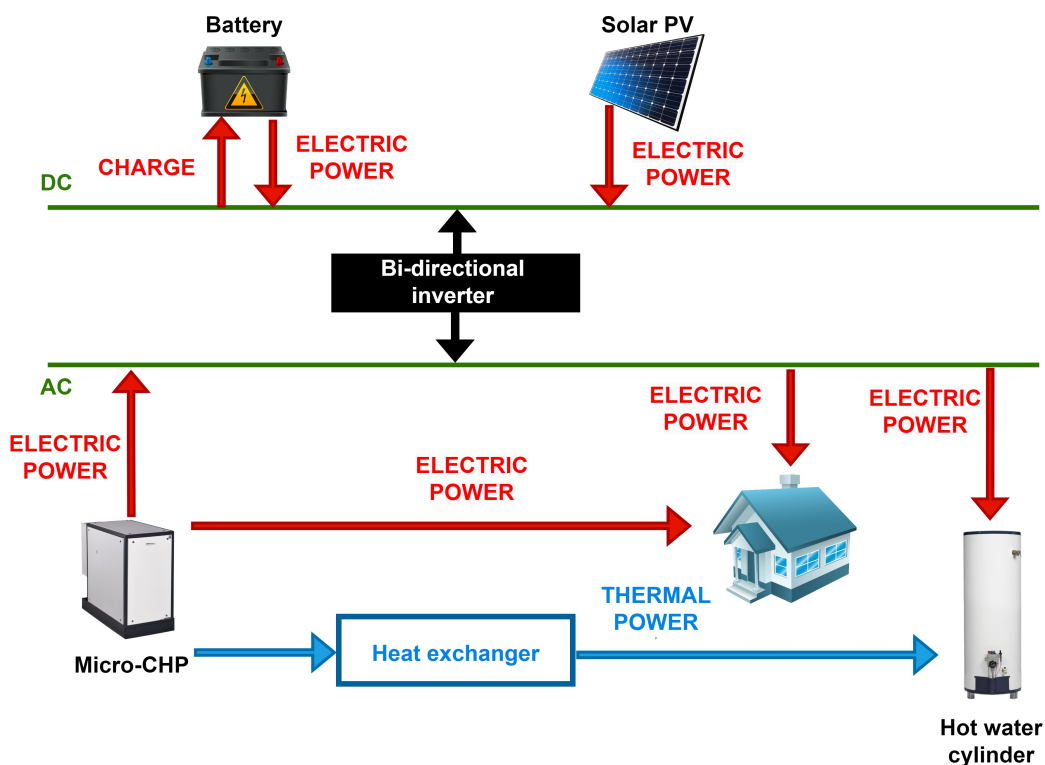


Figure 5.2: Componentes principais da simulação.

Os gráficos que se seguem, baseados na simulação efetuada em MATLAB[®], ilustram diferentes cenários em função do excesso ou do défice de produção fotovoltaica, em conjugação com o estado de carga (SOC) da bateria. Mais precisamente, os cenários de excesso ou défice fotovoltaico combinados com um SOC baixo ou alto serão exibidos em vários momentos ao longo do ano. Estes cenários serão construídos com base na previsão da carga elétrica e da produção fotovoltaica para as duas horas seguintes, utilizando modelos

de redes neuronais. Estas condições serão postas à prova para diferentes combinações de sistemas, especificamente para as configurações Painel fotovoltaico/bateria/Micro-Cogeração, Painel fotovoltaico/Micro-Cogeração e bateria/Micro-Cogeração. A integração da pilha de combustível no sistema, bem como a sua utilização para a simulação, não ocorreu devido à indisponibilidade habitual de hidrogénio canalizado dentro de uma casa, em comparação com o gás natural, que é muito mais acessível.

5.2.1 Cenário 1

5.2.1.1 Configuração e Cenários de Simulação (Painel Fotovoltaico/Bateria/Micro-Cogeração)

Num perfil de carga que compreende 8760 h, foi seleccionada uma hora para efeitos de simulação. O SOC da bateria foi definido para essa mesma hora, e as previsões da carga elétrica e da produção fotovoltaica para as duas horas seguintes foram geradas utilizando uma rede neuronal *feedforward*. De seguida, apresentam-se duas figuras que representam os dias de perfil de carga e de perfil de produção. Estas figuras fornecem uma visão abrangente de um dia de 24 horas, com previsões efetuadas em intervalos de 2 horas. A figura 5.3.a apresenta os resultados para um dia nublado, mostrando as flutuações na procura de carga e na produção de energia ao longo do dia sob condições climáticas nubladas. Por outro lado, a figura 5.3.b mostra um dia de sol, destacando o perfil de carga e a produção de energia quando a irradiação solar é abundante.

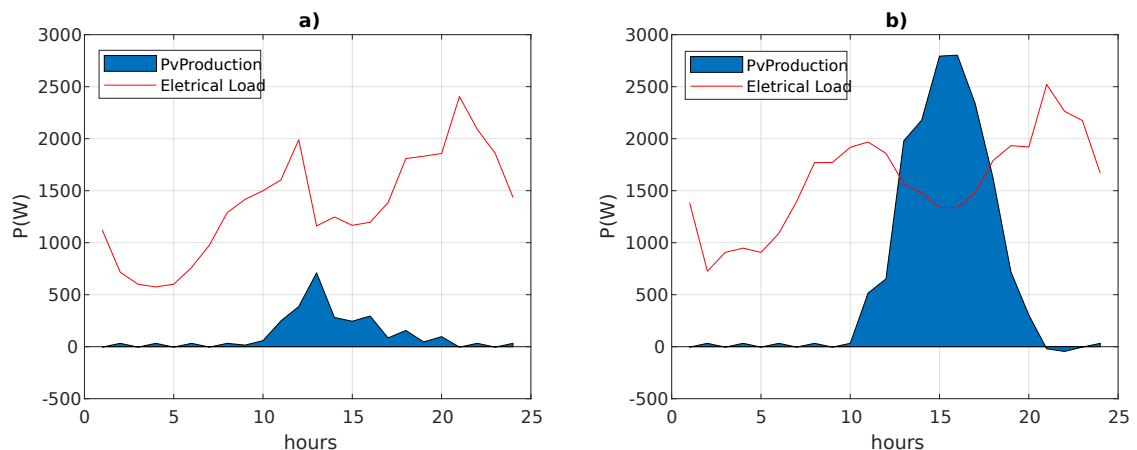


Figure 5.3: Perfil de carga e produção fotovoltaica: a) Cenário de défice de produção fotovoltaica; b) Cenário de excesso de produção fotovoltaica.

Défice de produção fotovoltaica e SOC < 0,2

Consideremos o caso do sistema equipado com painéis fotovoltaicos, bateria e micro-cogeração. A simulação foi efetuada para um período em que se verifica um défice ou um excesso de produção fotovoltaica e o SOC é inferior ou superior a 0,2. Às 11 horas de um dia nublado, para um pico de procura e uma situação em que existe um défice na

produção fotovoltaica e o SOC é inferior a 0,2, os resultados são apresentados na Figura 5.4.b.




Figure 5.4: Déficit de produção fotovoltaica e $SOC < 0,2$: a) procura de carga elétrica e produção fotovoltaica; b) perfil de carga elétrica; c) perfil de aquecimento de água; d) estado de carga durante as duas horas de previsão.

Como é ilustrado na Figura 5.4.a,b, durante a primeira hora prevista, o déficit de produção fotovoltaica (com uma procura elétrica prevista de 1989 W e uma potência fotovoltaica de 386 W) é compensado por 1603 W de energia elétrica (ICE E) da micro-cogeração. Além disso, 4009 W de energia térmica (ICE T) da micro-cogeração compensam a procura de 663 W para aquecimento de água (como mostra a Figura 5.4.c), com 3346 W de excedente térmico a serem utilizados para armazenamento num termoacumulador, do qual pode ser retirado calor para aquecimento ambiente.

Na segunda hora de previsão, 1161 W da potência elétrica do motor compensa o déficit de produção fotovoltaica, com uma procura elétrica prevista de 1871 W e uma potência fotovoltaica de 710 W. Dada a necessidade de satisfazer a procura de aquecimento de água, o sistema de micro-cogeração compensa os 565 W de procura com 2904 W de potência térmica. Aqui, 2339 W do excedente térmico é para armazenamento num acumulador

térmico. Na Figura 5.4d, o SOC é mantido constante.

Défice de produção fotovoltaica e SOC > 0,2

Na situação idêntica de um défice de produção fotovoltaica, mas em que o SOC é superior a 0,2, os resultados para o caso anterior são apresentados na Figura 5.5.

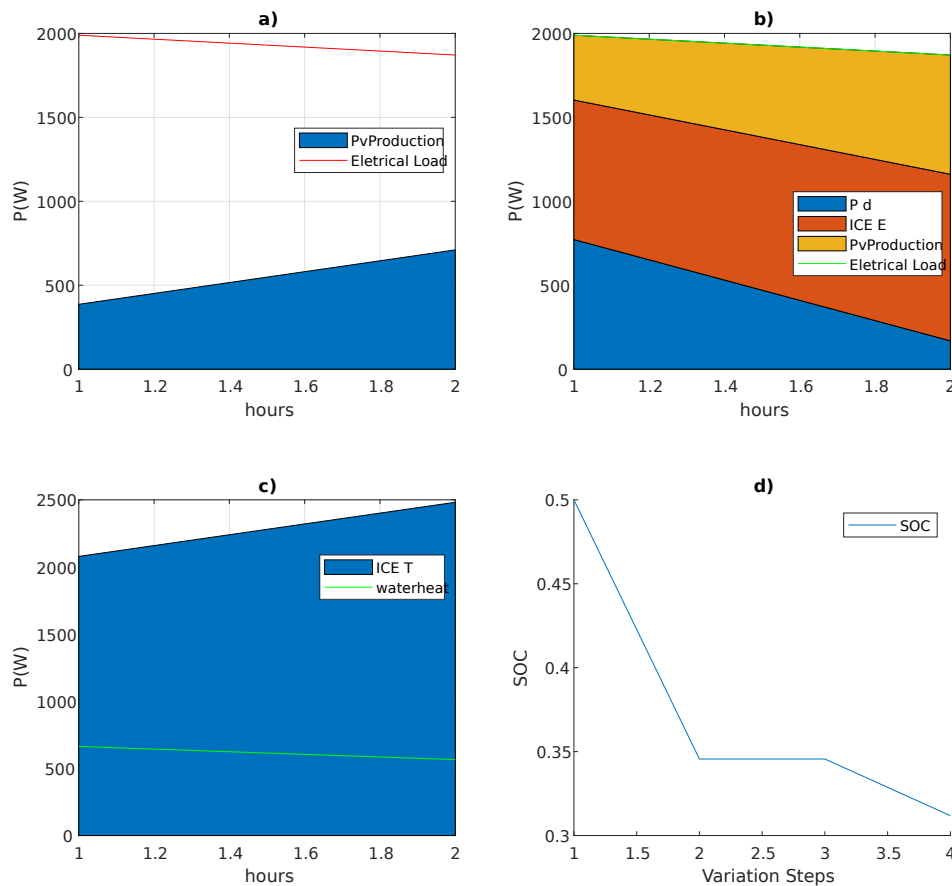


Figure 5.5: Déficit de produção fotovoltaica e SOC > 0,2: a) procura de carga elétrica e produção fotovoltaica; b) perfil de carga elétrica; c) perfil de aquecimento de água; d) estado de carga durante as duas horas de previsão.

Como se mostra na Figura 5.5.a,b, na primeira hora prevista, o défice de produção fotovoltaica (com uma procura elétrica prevista de 1989 W e uma potência fotovoltaica de 386 W) é compensado pela descarga de 772 W da bateria. Como a bateria não pode suportar totalmente a carga elétrica, 831 W de energia elétrica (ICE E) da micro-cogeração compensam o restante. Além disso, 2079 W de energia térmica (ICE T) da micro-cogeração compensa a procura de 663 W de aquecimento de água, com 1416 W de excedente térmico utilizado para armazenamento num acumulador térmico.

Durante a segunda hora prevista, 169 W da bateria e 992 W de energia elétrica (ICE E) da micro-cogeração compensam o défice de produção fotovoltaica, dada uma procura elétrica

prevista de 1871 W e uma potência fotovoltaica de 710 W. Considerando a necessidade de satisfazer a procura de aquecimento de água, o sistema de micro-cogeração compensa com 2482 W de energia térmica os 565 W de procura. Aqui, 1917 W de excedente térmico são usados para armazenamento num acumulador térmico. A Figura 5.5.d apresenta o SOC desde a hora atual ($SOC = 0,5$) até ao final da previsão de duas horas ($SOC = 0,3$). Como descrito anteriormente, na primeira hora (1 a 2) a bateria descarrega para compensar a procura elétrica e na segunda hora (3 a 4) a bateria descarrega para compensar também a procura.

Excesso de produção fotovoltaica e $SOC < 0,2$

Às 13 horas de um dia de sol, para um pico de procura e um cenário de excesso de produção fotovoltaica, em que o SOC é inferior a 0,2, os resultados são apresentados na Figura 5.6.

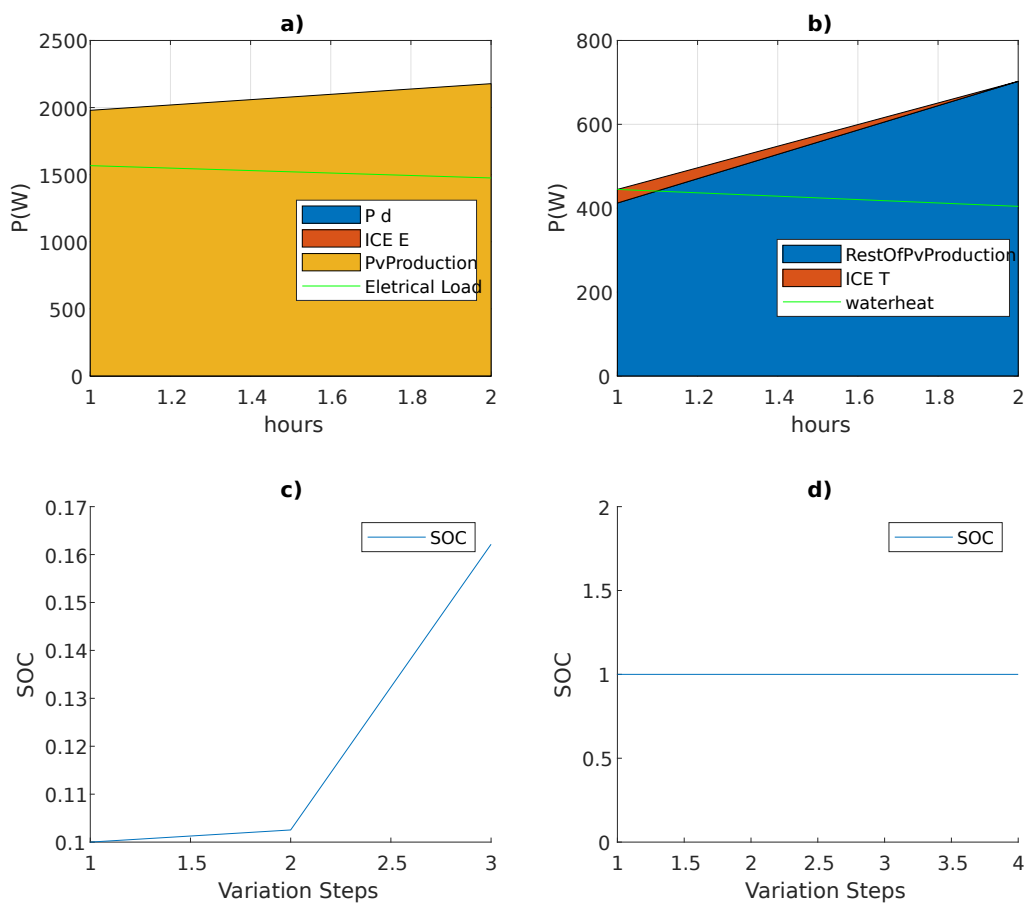


Figure 5.6: Excesso de produção fotovoltaica e $SOC < 0,2$: a) perfil de carga elétrica; b) perfil de aquecimento de água; c) estado de carga durante as duas horas de previsão (SOC inicial < 0,2); d) estado de carga durante as duas horas de previsão (SOC inicial = 1).

Como se observa na Figura 5.6.a, durante a primeira hora prevista, em que a potência fotovoltaica é de 1980 W e a procura de eletricidade é de 1567 W, a produção solar cobre

totalmente a procura de eletricidade. O excesso de produção fotovoltaica (412 W) ajuda a satisfazer a procura de aquecimento de água. No entanto, uma vez que não compensa totalmente, 32 W de energia térmica da micro-cogeração satisfazem as necessidades de aquecimento de água (mostrado na Figura 5.6.b). Adicionalmente, 13 W de energia elétrica do sistema de Micro-cogeração são utilizados para carregar a bateria (1 a 2) (Figura 5.6.c). Na segunda hora prevista, com uma potência fotovoltaica de 2178 W e uma procura elétrica de 1476W, a produção solar satisfaz completamente a procura elétrica. O excedente de produção solar (702W) satisfaz a procura de aquecimento de água de 404 W. Os restantes 298 W são utilizados para carregar a bateria (como se vê na Figura 5.6.c).

Excesso de produção fotovoltaica e SOC > 0,2

Para a situação de excesso de produção fotovoltaica e um SOC superior a 0, 2, os resultados são idênticos aos do caso anterior porque não há necessidade de suportar a procura elétrica residencial com a bateria. Consequentemente, a bateria é carregada nos mesmos ciclos (como mostrado na Figura 5.6.c). Em situações em que o SOC é igual a 1 (mostrado na Figura 5.6.d), não é viável utilizar a energia elétrica da micro-cogeração na primeira hora de previsão; 13 W são desperdiçados porque a bateria está no seu SOC máximo.

5.2.1.2 Configuração e Cenários de Simulação (Painel Fotovoltaico/Micro-Cogeração)

Esta simulação introduz numa rede residencial um sistema de micro-cogeração com potências elétrica de 1, 3 a 4, 7 kW e térmica de 4 a 12, 5 kW, complementado por um painel fotovoltaico com uma potência de 3, 5 kWp.

Défice de produção fotovoltaica

Na situação de um défice de produção fotovoltaica, idêntico ao caso analisado na Secção 5.2.1 (ver Figura 5.4.a), durante a primeira hora prevista, o défice de produção fotovoltaica de 1603 W, resultante de uma procura elétrica prevista de 1989 W contra uma potência fotovoltaica de 386 W, é coberto pela potência elétrica de 1603 W do sistema de micro-cogeração (como se mostra na Figura 5.7.a). A procura de aquecimento de água de 663 W é satisfeita pela potência térmica de 4009 W da micro-cogeração, enquanto o excedente de 3346 W de potência térmica é afetado ao armazenamento num acumulador térmico (Figura 5.7.b). Operações semelhantes são realizadas na segunda hora de previsão, sendo o défice de 1161 W satisfeito pela energia elétrica do sistema micro-cogeração (ilustrado na Figura 5.7.a). Adicionalmente, 565 W da procura de aquecimento de água é compensada pela potência térmica de 2904 W do sistema de micro-cogeração, deixando um excedente térmico de 2339 W para armazenamento num termoacumulador.

Excesso de produção fotovoltaica

Nos casos de excesso de produção fotovoltaica, seguindo o mesmo caso simulado na Secção

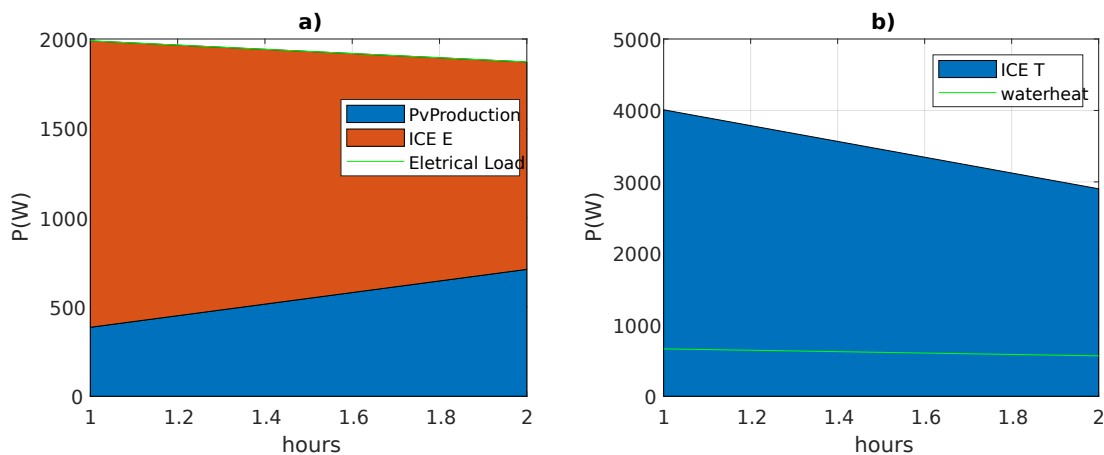


Figure 5.7: Défice de produção fotovoltaica: a) perfil de carga elétrica; b) perfil de aquecimento de água.

5.2.1 (mostrado na Figura 5.6.a,b), os resultados permanecem consistentes como previsto.

5.2.1.3 Configuração e Cenários de Simulação (Bateria/Micro-Cogeração)

O foco desta subsecção é a simulação da interação entre a micro-cogeração e uma bateria dentro de uma rede residencial, onde se pretende assegurar a energia elétrica do excedente da produção de energia térmica para água quente. O sistema incorpora uma unidade de micro-cogeração com uma potência elétrica de 1, 3 a 4, 7 kW e uma potência térmica de 4 a 12, 5 kW, junta-mente com uma bateria com uma capacidade de 5 kW.h.

SOC < 0,2

O cenário analisado é idêntico ao representado na Figura 5.4.a, com um estado de carga (SOC) da bateria inferior a 0,2. Os resultados são os seguintes: Na primeira hora de previsão, com uma procura de carga elétrica de 1989 W, a energia elétrica da micro-cogeração satisfaz totalmente essa procura (ver Figura 10a). A procura de aquecimento de água de 663 W é satisfeita por 4974 W de energia térmica da micro-cogeração. O excedente de 4311 W de energia térmica é utilizado para armazenamento num acumulador térmico (conforme ilustrado na Figura 5.8.b). Uma vez que o acumulador apenas suporta a procura de carga elétrica, a procura de aquecimento de água é consistentemente coberta pela energia térmica da micro-cogeração. A Figura 5.8.c fornece uma representação visual da capacidade de unida-de da bateria.

Na segunda hora de previsão, com uma procura de carga elétrica de 1871 W, a energia elétrica da micro-cogeração satisfaz totalmente esta procura. A necessidade de aquecimento de água de 565 W é satisfeita por 4679 W de energia térmica da micro-cogeração, sendo os restantes 4114 W de energia térmica utilizados para armazenamento num termoacumulador (ver Figura 5.8.b).

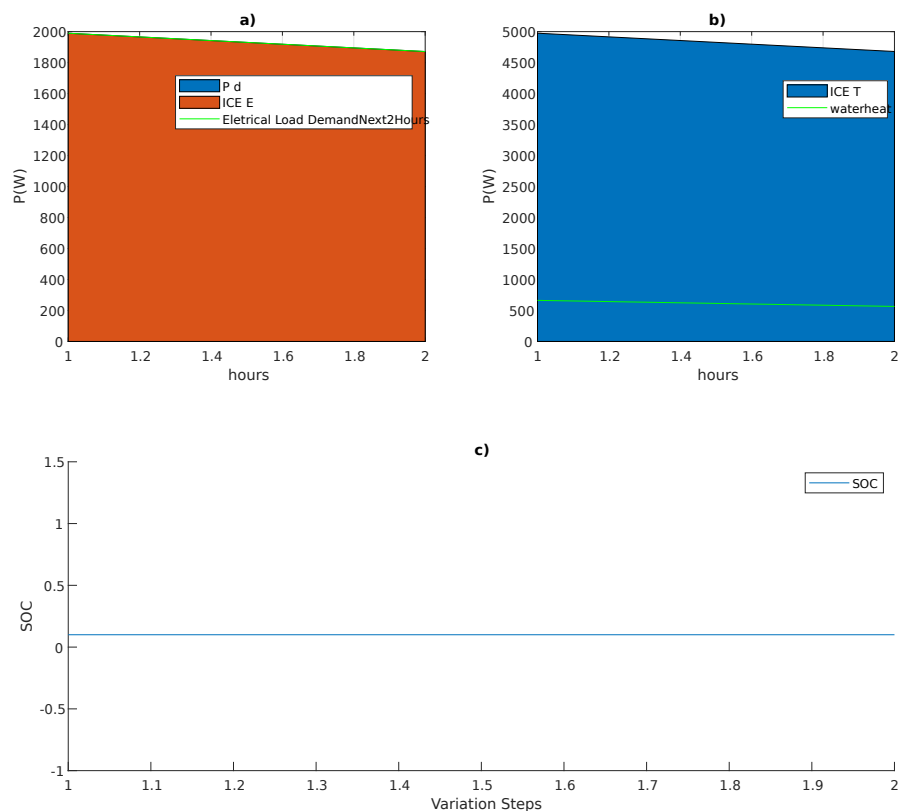


Figure 5.8: SOC < 0,2: a) perfil da carga elétrica; b) perfil do aquecimento da água; c) estado da carga durante as duas horas de previsão.

SOC > 0,2

Nos casos em que o estado de carga (SOC) é superior a 0,2, os resultados são diferentes.

Na primeira hora de previsão, com uma procura de carga elétrica prevista de 1989 W, a bateria fornece 772 W enquanto a micro-cogeração compensa a carga restante com 1217 W (ver Figura 5.9.a). A procura de aquecimento de água de 663 W é satisfeita pelos 3044 W de energia térmica da micro-cogeração. O excedente de 2381 W de energia térmica é utilizado para armazenamento num acumulador térmico (conforme ilustrado na Figura 5.9.b).

Durante a segunda hora de previsão, com uma procura de carga elétrica prevista de 1871 W, a bateria fornece 169 W e 1703 W são compensados pela energia elétrica da micro-cogeração. A procura de 565 W de aquecimento de água é satisfeita pelos 4258 W de energia térmica da micro-cogeração. O excedente de 3693 W de energia térmica é utilizado para armazenamento num acumulador térmico (como ilustrado na Figura 5.9.b).

Como se pode observar na Figura 5.9.c, a bateria descarrega-se para suportar a carga (1 a 4).

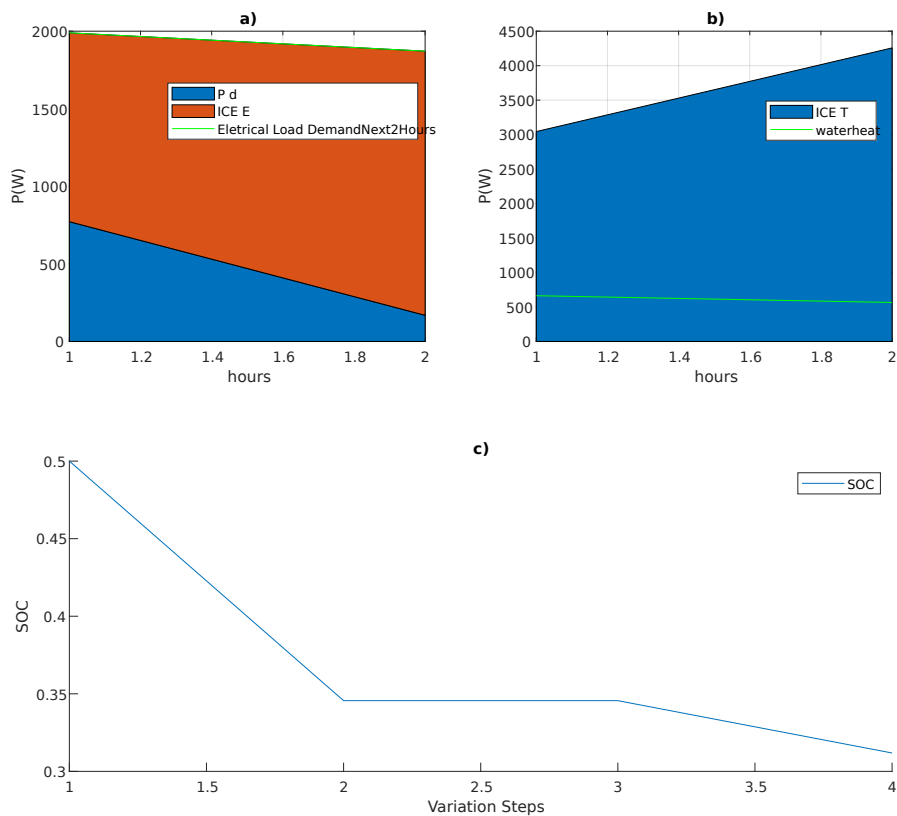


Figure 5.9: SOC > 0, 2: a) perfil da carga elétrica; b) perfil do aquecimento da água; c) estado da carga durante as duas horas de previsão.

5.2.2 Cenário 2

5.2.2.1 Configuração e Cenários de Simulação (Painel Fotovoltaico/Bateria/Micro-Cogeração)

Num perfil de carga que compreende 8760 h, foi selecionada uma hora para efeitos de simulação. O SOC da bateria foi definido para essa mesma hora, e as previsões da carga elétrica e da produção fotovoltaica para as duas horas seguintes foram geradas utilizando uma rede neuronal *feedforward*. De seguida, apresentam-se duas figuras que representam os dias de perfil de carga elevada e de perfil de produção. Estas figuras fornecem uma visão abrangente de um dia de 24 horas, com previsões efetuadas em intervalos de 2 horas. A figura 5.10.a apresenta os resultados para um dia nublado, mostrando as flutuações na procura de carga e na produção de energia ao longo do dia sob condições climáticas nubladas. Por outro lado, a figura 5.10.b mostra um dia de sol, destacando o perfil de carga e a produção de energia quando a irradiação solar é abundante.




Figure 5.10: Perfil de carga e produção fotovoltaica: a) Cenário de déficit de produção fotovoltaica; b) Cenário de excesso de produção fotovoltaica.

Défice de produção fotovoltaica e SOC < 0,2

Consideremos o caso do sistema equipado com painéis fotovoltaicos, bateria e micro-cogeração. A simulação foi efetuada para um período em que se verifica um déficit ou um excesso de produção fotovoltaica e o SOC é inferior ou superior a 0,2. Às 21 horas de noite, para um pico de procura e uma situação em que existe um déficit na produção fotovoltaica e o SOC é inferior a 0,2, os resultados são apresentados na Figura 5.11.b.

Como é evidente na Figura 5.11.a,b, durante a primeira hora prevista, o déficit de produção fotovoltaica (com uma procura elétrica prevista de 3915 W e uma potência fotovoltaica de 46 W) é compensado por 3869 W de energia elétrica (ICE E) da micro-cogeração. Além disso, 9674 W de energia térmica (ICE T) da micro-cogeração compensam a procura de 932 W para aquecimento de água (como mostra a Figura 5.11.c), com 8742 W de excedente térmico a serem utilizados para armazenamento num termoacumulador, do qual pode ser retirado calor para aquecimento ambiente.

Na segunda hora de previsão, 3760 W da potência elétrica do motor compensa o déficit de produção fotovoltaica, com uma procura elétrica prevista de 3850 W e uma potência fotovoltaica de 90 W. Dada a necessidade de satisfazer a procura de aquecimento de água, o sistema de micro-cogeração compensa os 821 W de procura com 9401 W de potência térmica. Aqui, 8580 W do excedente térmico é para armazenamento num acumulador térmico. Na Figura 5.11.d, o SOC é mantido constante.

Défice de produção fotovoltaica e SOC > 0,2

Na situação idêntica de um déficit de produção fotovoltaica, mas em que o SOC é superior a 0,2, os resultados para o caso anterior são apresentados na Figura 5.12.

Como se mostra na Figura 5.12.a,b, na primeira hora prevista, o déficit de produção fotovoltaica (com uma procura elétrica prevista de 3915 W e uma potência fotovoltaica de 46 W) é compensado pela descarga de 1235 W da bateria. Como a bateria não pode suportar

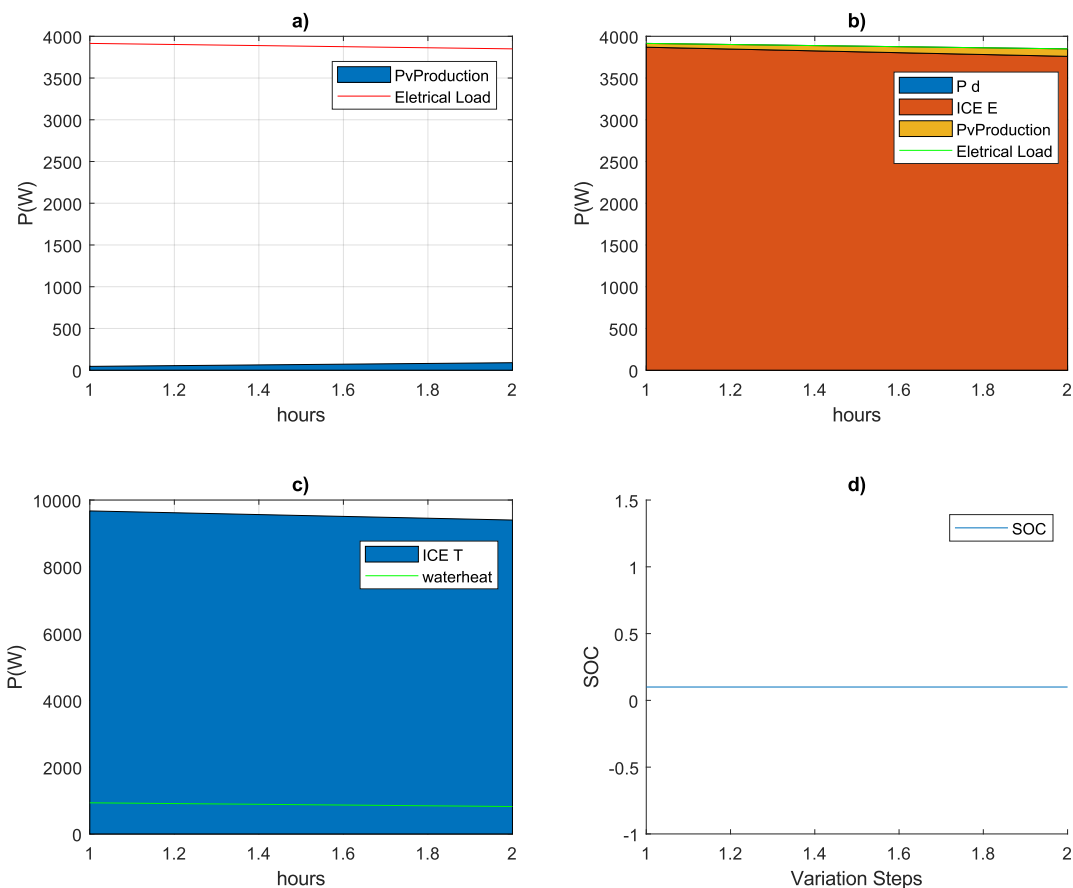


Figure 5.11: Déficit de produção fotovoltaica e $SOC < 0$, 2: a) procura de carga elétrica e produção fotovoltaica; b) perfil de carga elétrica; c) perfil de aquecimento de água; d) estado de carga durante as duas horas de previsão.

totalmente a carga elétrica, 2634 W de energia elétrica (ICE E) da micro-cogeração compensam o restante. Além disso, 6586 W de energia térmica (ICE T) da micro-cogeração compensa a procura de 932 W de aquecimento de água, com 5654 W de excedente térmico utilizado para armazenamento num acumulador térmico.

Durante a segunda hora prevista, 270 W da bateria e 3490 W de energia elétrica (ICE E) da micro-cogeração compensam o déficit de produção fotovoltaica, dada uma procura elétrica prevista de 3850 W e uma potência fotovoltaica de 90 W. Considerando a necessidade de satisfazer a procura de aquecimento de água, o sistema de micro-cogeração compensa com 8726 W de energia térmica os 821 W de procura. Aqui, 7905 W de excedente térmico são usados para armazenamento num acumulador térmico. A Figura 5.12.d apresenta o SOC desde a hora atual ($SOC = 0,8$) até ao final da previsão de duas horas ($SOC = 0,5$). Como descrito anteriormente, na primeira hora (1 a 2) a bateria descarrega para compensar a procura elétrica e na segunda hora (3 a 4) a bateria descarrega para compensar também a procura.

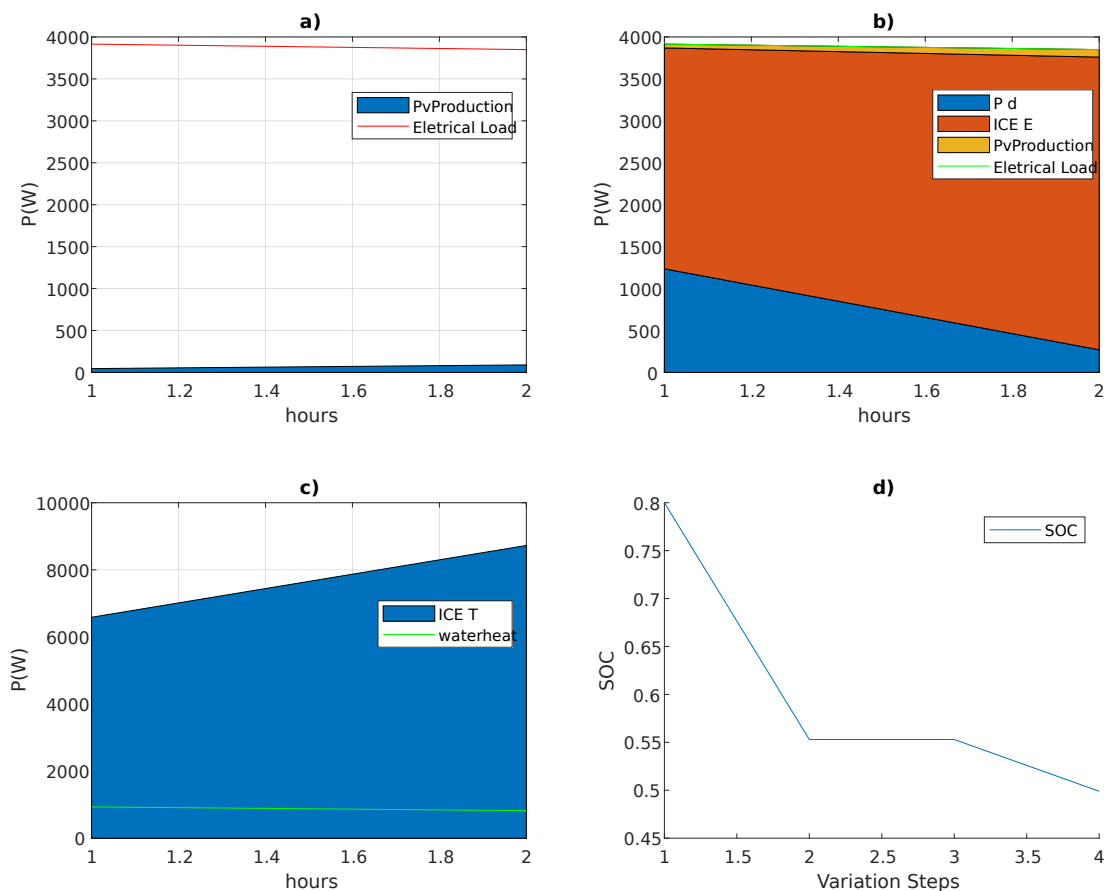


Figure 5.12: Déficit de produção fotovoltaica e $SOC > 0, 2$: a) procura de carga elétrica e produção fotovoltaica; b) perfil de carga elétrica; c) perfil de aquecimento de água; d) estado de carga durante as duas horas de previsão.

Excesso de produção fotovoltaica e $SOC < 0, 2$

Às 13 horas de um dia de sol, para um pico de procura e um cenário de excesso de produção fotovoltaica, em que o SOC é inferior a 0, 2, os resultados são apresentados na Figura 5.13.

Como se observa na Figura 5.13.a, durante a primeira hora prevista, em que a potência fotovoltaica é de 2138 W e a procura de eletricidade é de 1902 W, a produção solar cobre totalmente a procura de eletricidade. O excesso de produção fotovoltaica (236 W) ajuda a satisfazer a procura de aquecimento de água. No entanto, uma vez que não compensa totalmente, 212 W de energia térmica da micro-cogeração satisfazem as necessidades de aquecimento de água (mostrado na Figura 5.13.b). Adicionalmente, 84 W de energia elétrica do sistema de micro-cogeração são utilizados para carregar a bateria (1 a 2) (Figura 5.13.c).

Na segunda hora prevista, com uma potência fotovoltaica de 2152 W e uma procura elétrica de 1766 W, a produção solar satisfaz completamente a procura elétrica. O excedente

de produção solar (386 W) satisfaz a procura de aquecimento de água de 405 W. Os restantes 19 W são compensados pela energia térmica da micro-cogeração (Figura 5.13.c).

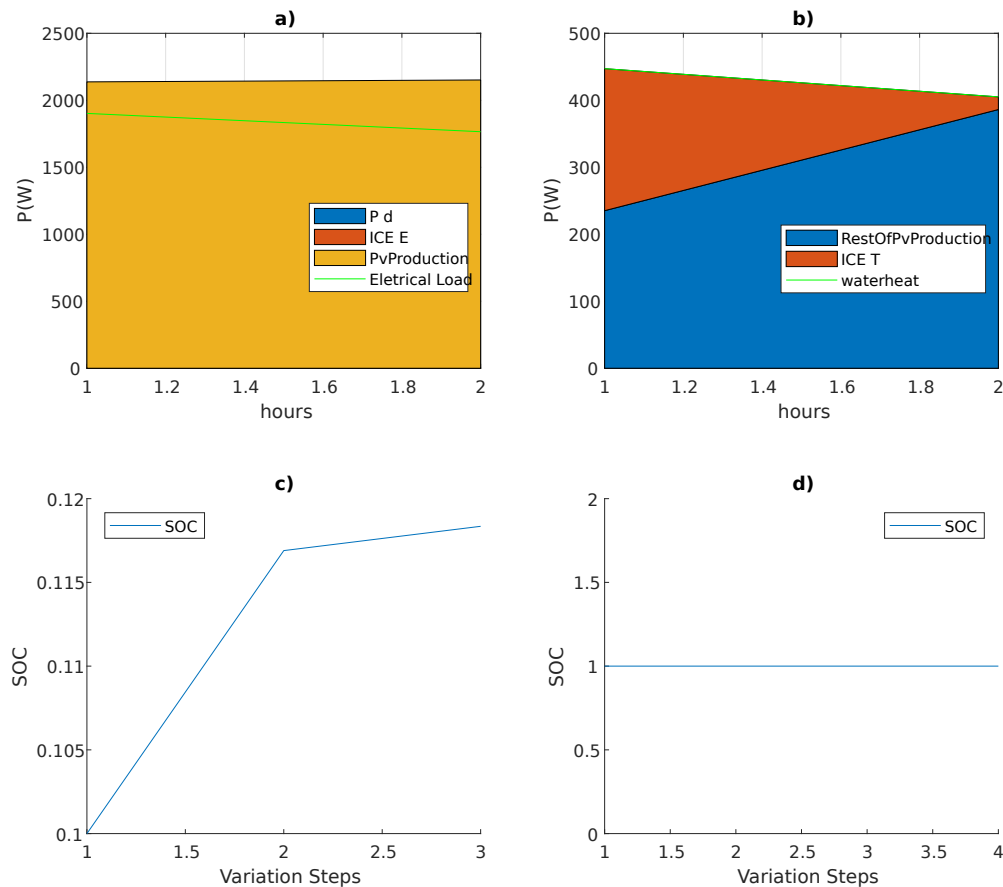


Figure 5.13: Excesso de produção fotovoltaica e $SOC < 0,2$: a) perfil de carga elétrica; b) perfil de aquecimento de água; c) estado de carga durante as duas horas de previsão (SOC inicial $< 0,2$); d) estado de carga durante as duas horas de previsão (SOC inicial = 1).

Excesso de produção fotovoltaica e $SOC > 0,2$

Para a situação de excesso de produção fotovoltaica e um SOC superior a 0,2, os resultados são idênticos aos do caso anterior porque não há necessidade de suportar a procura elétrica residencial com a bateria. Consequentemente, a bateria é carregada nos mesmos ciclos (como mostrado na Figura 5.13.c). Em situações em que o SOC é igual a 1 (mostrado na Figura 5.13.d), não é viável utilizar a energia elétrica da micro-cogeração na primeira e segunda hora de previsão, pois 84 W e 7 W são desperdiçados, respetivamente.

5.2.2.2 Configuração e Cenários de Simulação (Painel Fotovoltaico/Micro-Cogeração)

Esta simulação introduz numa rede residencial um sistema de micro-cogeração com potências elétrica de 1, 3 a 4, 7 kW e térmica de 4 a 12, 5 kW, complementado por um painel fotovoltaico (PV) com uma potência de 3, 5 kWp.

Défice de produção fotovoltaica

Na situação de um défice de produção fotovoltaica, idêntico ao caso analisado na Secção 5.2.2.1 (ver Figura 5.10.a), durante a primeira hora prevista, o défice de produção fotovoltaica de 3869 W, resultante de uma procura elétrica prevista de 3915 W contra uma potência fotovoltaica de 46 W, é coberto pela potência elétrica de 3869 W do sistema de micro-cogeração (como se mostra na Figura 5.14.a). A procura de aquecimento de água de 518 W é satisfeita pela potência térmica de 9674 W da micro-cogeração, enquanto o excedente de 9156 W de potência térmica é afetado ao armazenamento num acumulador térmico (Figura 5.14.b). Operações semelhantes são realizadas na segunda hora de previsão, sendo o défice de 3760 W satisfeito pela energia elétrica do sistema micro-cogeração (ilustrado na Figura 5.14.a). Adicional-mente, 456 W da procura de aquecimento de água é compensada pela potência térmica de 9401 W do sistema de micro-cogeração, deixando um excedente térmico de 8945 W para armazenamento num termoacumulador.




Figure 5.14: Déficit de produção fotovoltaica: a) perfil de carga elétrica; b) perfil de aquecimento de água.

Excesso de produção fotovoltaica

Nos casos de excesso de produção fotovoltaica, seguindo o mesmo caso simulado na Secção 5.2.2.2 (mostrado na Figura 5.13.a,b), os resultados permanecem consistentes como previsto.

5.2.2.3 Configuração e Cenários de Simulação (Bateria/Micro-Cogeração)

O foco desta subsecção é a simulação da interação entre a micro-cogeração e uma bateria dentro de uma rede residencial, onde se pretende assegurar a energia elétrica do excedente da produção de energia térmica para água quente. O sistema incorpora uma unidade de micro-cogeração com uma potência elétrica de 1, 3 a 4, 7 kW e uma potência térmica de 4 a 12, 5 kW, junta-mente com uma bateria com uma capacidade de 5 kW.h.

SOC < 0,2

O cenário analisado é idêntico ao representado na Figura 5.10.a, com um estado de carga (SOC) da bateria inferior a 0,2.

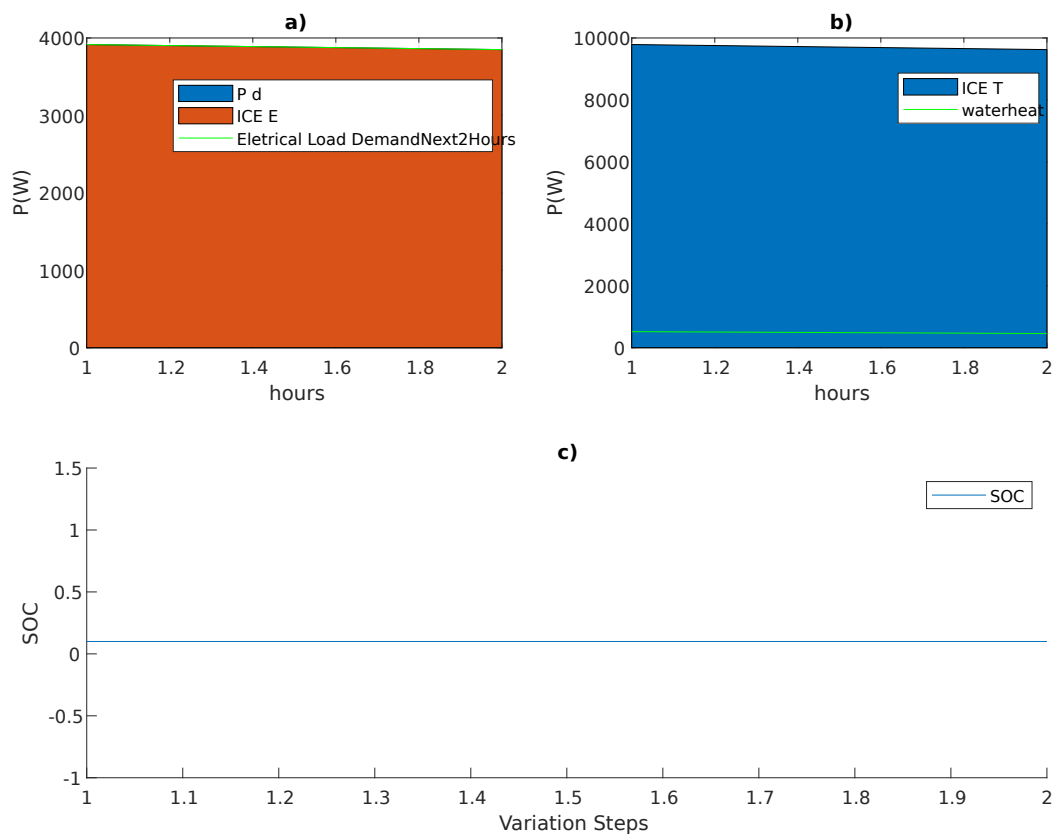


Figure 5.15: SOC < 0, 2: a) perfil da carga elétrica; b) perfil do aquecimento da água; c) estado da carga durante as duas horas de previsão.

Os resultados são os seguintes: Na primeira hora de previsão, com uma procura de carga elétrica de 3915 W, a energia elétrica da micro-cogeração satisfaz totalmente essa procura (ver Figura 10a). A procura de aquecimento de água de 518 W é satisfeita por 9788 W de energia térmica da micro-cogeração. O excedente de 9270 W de energia térmica é utilizado para armazenamento num acumulador térmico (conforme ilustrado na Figura 5.15.b). Uma vez que o acumulador apenas suporta a procura de carga elétrica, a procura de

aquecimento de água é consistentemente coberta pela energia térmica da micro-cogeração. A Figura 5.15.c fornece uma representação visual da capacidade de unidade da bateria.

Na segunda hora de previsão, com uma procura de carga elétrica de 3850 W, a energia elétrica da micro-cogeração satisfaz totalmente esta procura. A necessidade de aquecimento de água de 517 W é satisfeita por 9788 W de energia térmica da micro-cogeração, sendo os restantes 9271 W de energia térmica utilizados para armazenamento num termo-acumulador (ver Figura 5.15.b).

SOC > 0,2

Nos casos em que o estado de carga (SOC) é superior a 0,2, os resultados são diferentes. Na primeira hora de previsão, com uma procura de carga elétrica prevista de 3915 W, a bateria fornece 1235 W enquanto a micro-cogeração compensa a carga restante com 2680 W (ver Figura 5.16.a). A procura de aquecimento de água de 518 W é satisfeita pelos 6700 W de energia térmica da micro-cogeração. O excedente de 6182 W de energia térmica é utilizado para armazenamento num acumulador térmico (conforme ilustrado na Figura 5.16.b).

Durante a segunda hora de previsão, com uma procura de carga elétrica prevista de 3850 W, a bateria fornece 270 W e 3580 W são compensados pela energia elétrica da micro-cogeração. A procura de 456 W de aquecimento de água é satisfeita pelos 8950 W de energia térmica da micro-cogeração. O excedente de 8494 W de energia térmica é utilizado para armazenamento num acumulador térmico (como ilustrado na Figura 5.16.b).

Como se pode observar na Figura 5.16.c, a bateria descarrega-se para suportar a carga (1 a 4).

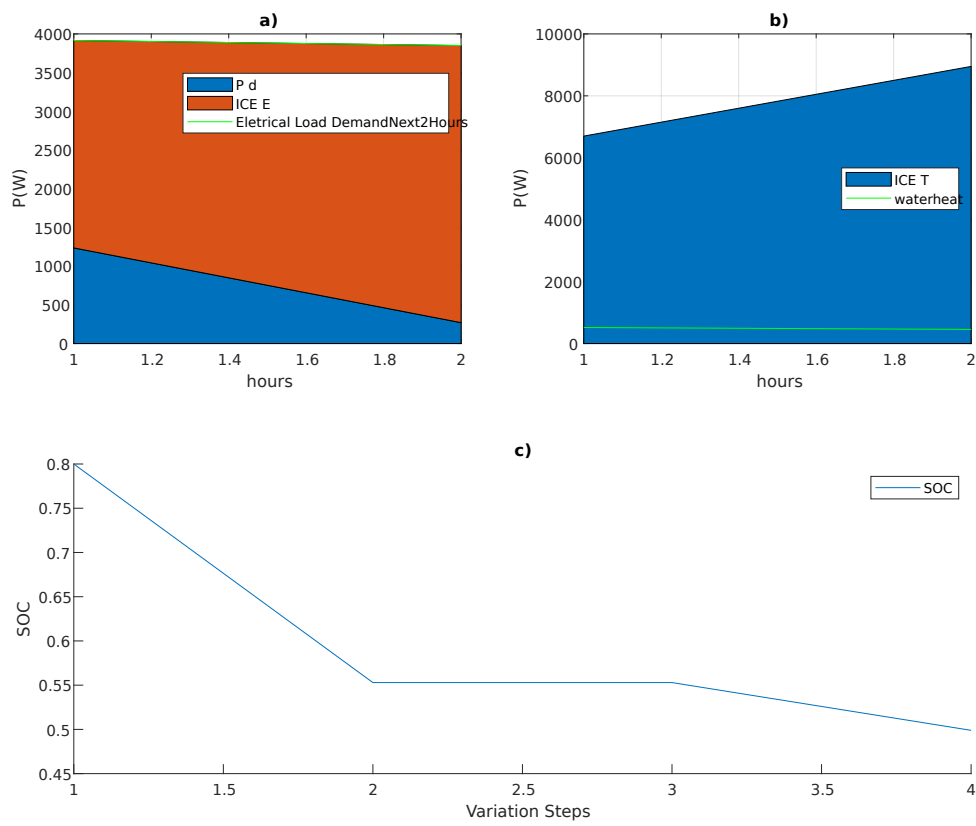


Figure 5.16: SOC > 0, 2: a) perfil da carga elétrica; b) perfil do aquecimento da água; c) estado da carga durante as duas horas de previsão.

Capítulo 6

Avaliação dos resultados da solução proposta

Entre as três simulações de sistemas efetuadas, o sistema painel fotovoltaico/bateria/micro-cogeração demonstrou a maior rentabilidade de acordo com os resultados. No sistema painel fotovoltaico/micro-cogeração, a carga pode ser totalmente suportada pela produção fotovoltaica, no entanto, fica aquém de satisfazer completamente a procura de aquecimento de água, como indicado na figura 5.6 e 5.13. Este déficit faz com que seja necessário recorrer ao sistema de micro-cogeração. Idealmente, nesta situação, a energia elétrica deveria ser direcionada para o carregamento de baterias. Mas, na ausência de um meio de armazenamento, é inevitável um desperdício de 13 W, no cenário 1, e de 84 W e 7 W no cenário 2. No entanto, este desperdício não tem um impacto significativo na rentabilidade global do sistema, uma vez que a produção fotovoltaica cobre 98 % da procura de eletricidade e das necessidades de aquecimento de água.

Em condições em que a produção fotovoltaica é deficiente, a energia gerada corresponde à produção do sistema bateria/micro-cogeração. No entanto o sistema painel fotovoltaico/bateria/micro-cogeração é mais eficiente devido à sua dependência parcial de uma fonte de energia renovável. No sistema bateria/micro-cogeração, a tecnologia primária que suporta a procura de aquecimento de água é a micro-cogeração, tornando o sistema fortemente dependente desta. A inclusão de uma bateria ajuda a minimizar a produção de energia elétrica e consequentemente térmica. As perdas de energia só ocorrem se o estado de carga (SOC) estiver na capacidade máxima, uma vez que a energia é utilizada para satisfazer a procura elétrica residencial ou para carregar a bateria.

Comparando a utilização do sistema de cogeração com o sistema convencional, a micro-cogeração é mais eficiente na procura de aquecimento de água, para além de resolver a necessidade de produção de eletricidade. Considerando a eficiência térmica mencionada acima para a micro-cogeração e a eficiência elétrica, a partir da utilização de um termoacumulador de água elétrico (TAE) de 40%, os resultados da potência necessária para satisfazer 663 W de procura de aquecimento de água são apresentados na figura 6.1. Para atingir 663 W de procura de aquecimento de água, na primeira hora do perfil da figura 5.4.c, é necessário introduzir 1657 W no caso do termoacumulador elétrico (2). Um valor um pouco mais elevado em comparação com o sistema de micro-cogeração (1) que necessita de 1033 W. Confirma-se que a utilização convencional de um termoacumulador de água elétrico é menos eficiente em comparação com a utilização do sistema de micro-cogeração.

A figura 6.1 compara o mesmo caso, mas em vez de um TAE, se a comparação for feita com uma bomba de calor (que hoje em dia pode atingir uma eficiência de 111%) para atingir 663 W de necessidade de aquecimento de água, na primeira hora do perfil de 5.4.c,

é necessário introduzir 597 W de energia elétrica no sistema com a bomba de calor (3). O valor é inferior ao do sistema com a micro-cogeração (1) que necessita de 1033 W.

Tendo em conta o caso de estudo, existe uma maior eficiência da micro-cogeração para satisfazer as necessidades de aquecimento de água. Apesar da eficiência reduzida em comparação com a bomba de calor, com a micro-cogeração, o sistema torna-se mais autónomo porque, para além da produção de energia térmica, é produzida energia elétrica no mesmo processo, permitindo uma melhor gestão do sistema, ao contrário das bombas de calor que não acrescentam nada à rede elétrica. Esta energia elétrica pode ser direcionada para a bateria no caso de a energia fotovoltaica não compensar totalmente as necessidades de aquecimento de água, como é visível nos casos das figuras 5.6.b.c e 5.13.b.c. Por outro lado, pode compensar a procura de eletricidade doméstica quando o SOC da bateria é reduzido, como é os casos das figuras 5.4.b e 5.11.b. Ao longo do estudo, foram integrados melhoramentos e ajustamentos contínuos para aumentar a eficiência global, a resiliência e a autonomia da rede. A utilização de um sistema de micro-cogeração com saída ajustável evita a necessidade de uma saída constante em diferentes perfis de carga. Esta flexibilidade evita o desperdício de energia e permite que o sistema de micro-cogeração se adapte à procura necessária. Foi dada uma ênfase significativa ao estabelecimento de pressupostos prioritários desde o início, tais como o suporte de uma carga elétrica e a subsequente satisfação da procura de aquecimento de água a partir do armazenamento de energia térmica, mais especificamente de um cilindro de água elétrico.




Figure 6.1: Comparação da potência necessária para compensar 663 W de necessidades de aquecimento de água da micro-cogeração (*Micro-CHP*), de um TAE (*ESWH*) e de uma bomba de calor (*Heat Pump*).

Capítulo 7

Conclusões

7.1 Resumo das conclusões

O desenvolvimento de uma ferramenta de previsão da carga elétrica e da produção fotovoltaica baseada numa rede neuronal *feedforward* (RNF) foi um passo significativo para melhorar a gestão da energia neste estudo. Esta ferramenta permitiu um planeamento operacional ótimo num horizonte de duas horas, assegurando que a produção do sistema de micro-cogeração fosse meticulosamente gerida para minimizar o desperdício de energia. A ferramenta de previsão revelou-se fundamental na condução preventiva do funcionamento do motor, permitindo que o sistema modulasse estrategicamente a produção elétrica ou térmica para se alinhar com as condições de procura previstas. A antecipação de alterações na carga permitiu a utilização ótima da produção do sistema de micro-cogeração, contribuindo significativamente para a melhoria da eficiência do sistema e para a redução global do desperdício de energia.

Quando a micro-cogeração foi integrada num sistema painel fotovoltaico/bateria/micro-cogeração, os ganhos foram mais substanciais. A interação entre a micro-cogeração, a bateria e a produção fotovoltaica permitiu a criação de um sistema de energia altamente eficiente e fiável, garantindo a satisfação da procura em várias condições e reduzindo a dependência da rede. Comparativamente, o sistema incorreu em perdas insignificantes em comparação com o sistema fotovoltaico/micro-cogeração autónomo, demonstrando o benefício da integração de uma bateria no sistema de energia.

Por outro lado, na configuração do sistema bateria/micro-cogeração, as despesas foram ligeiramente mais elevadas, uma vez que a micro-cogeração serviu como componente central do sistema. Era responsável por satisfazer uma parte significativa da procura e, por conseguinte, estava sujeita a uma utilização mais extensiva, o que resultou em custos operacionais mais elevados.

No entanto, o estudo revelou que a configuração ótima do sistema foi alcançada quando a micro-cogeração foi utilizada como fonte de energia de reserva. Nesta configuração, o sistema de micro-cogeração poderia entrar em ação para fornecer a carga necessária em casos de défice fotovoltaico ou quando o estado de carga (SOC) da bateria caísse abaixo de 0,2. Esta configuração assegurava que o sistema podia funcionar totalmente fora da rede durante estes períodos, contribuindo assim para melhorias significativas na eficiência do sistema, ao mesmo tempo que aumentava a independência e a resiliência da rede.

7.2 Contribuições para a resiliência da rede, a eficiência energética e a integração das energias renováveis

As conclusões e metodologias apresentadas nesta dissertação contribuem significativamente para aumentar a resiliência da rede, a eficiência energética e a incorporação de energias renováveis. A otimização dos sistemas fotovoltaicos, de baterias e de micro-cogeração numa única plataforma garante não só que o fornecimento de energia é consistente, mesmo em situações de déficit fotovoltaico, mas também que a utilização de energia é otimizada, minimizando eficazmente o desperdício.

A gestão eficaz do modelo proposto permite melhorar consideravelmente a resiliência das redes residenciais através da integração de um sistema de reserva robusto e eficiente. Este sistema de reserva, alimentado pela unidade de micro-cogeração, garante que uma fonte de energia fiável e estável está sempre disponível para satisfazer a procura, mesmo em situações em que as fontes de energia renováveis são inadequadas. Isto reforça efetivamente a capacidade da rede para resistir e adaptar-se a condições variáveis, aumentando significativamente a sua resiliência global.

Em termos de eficiência energética, o modelo desta investigação dá passos significativos em frente. O planeamento metuculoso e o controlo operacional permitidos pela ferramenta de previsão garantem que a produção do sistema micro-cogeração é utilizada de forma otimizada, minimizando o desperdício de energia e melhorando assim a eficiência energética global. Esta eficiência melhorada não só reduz os custos operacionais como também contribui para a sustentabilidade global do sistema.

Além disso, este estudo contribui de forma significativa para o impulso mais amplo no sentido da integração das energias renováveis. O modelo proposto aproveita o poder das fontes de energia renováveis, nomeadamente os painéis fotovoltaicos, para satisfazer a procura residencial de eletricidade e água quente. Ao desenvolver um sistema que pode funcionar independente da rede durante períodos de baixo estado de carga da bateria e de défices fotovoltaicos, esta investigação facilita uma maior utilização e adaptabilidade dos recursos de energia renovável. Isto não só reduz a dependência de fontes de energia convencionais e não renováveis, como também ajuda a impulsionar a mudança para um futuro mais sustentável e de energias renováveis.

Ao combinar eficientemente fontes renováveis e armazenamento com um sistema de micro-cogeração de reserva, o modelo proposto permite um fornecimento de energia mais flexível e sustentável. Marca um passo em frente na direção da criação de sistemas energéticos mais resilientes, eficientes e sustentáveis, abordando eficazmente alguns dos desafios mais prementes do nosso panorama energético atual.

7.3 Limitações e trabalhos futuros

Embora este estudo tenha produzido resultados e conhecimentos promissores, é essencial reconhecer que a literatura atual sobre a integração de uma micro-cogeração num sistema painel fotovoltaico/bateria/micro-cogeração é escassa. Existe um potencial considerável para estes sistemas integrados em vários contextos, especialmente em edifícios e complexos residenciais. O desenvolvimento e a implementação de sistemas fora da rede, como o proposto neste estudo, podem melhorar muito a interconectividade entre as necessidades residenciais e as tecnologias circundantes, oferecendo, em última análise, benefícios abrangentes em vários aspetos da utilização e gestão da energia.

No entanto, mesmo com os avanços notáveis apresentados nesta investigação, ainda existem áreas para exploração e melhoria. Uma dessas áreas é a utilização mais eficaz da energia térmica. Apesar das medidas de otimização implementadas, a energia térmica ainda constitui a parte mais desperdiçada do sistema, indicando uma oportunidade substancial para mais melhorias na eficiência do sistema.

Como via prospetiva para investigação futura, vale a pena considerar o desenvolvimento de sistemas de armazenamento de energia térmica. Tais sistemas poderiam efetivamente armazenar energia para ser utilizada em várias aplicações térmicas, fornecendo calor quando necessário. Esta abordagem não só aumentaria a utilização eficiente da energia térmica, como também conduziria a melhorias globais no desempenho do sistema. A exploração e a implementação de soluções de armazenamento de energia térmica têm um grande potencial para aumentar a eficácia e a eficiência do sistema, contribuindo assim para a melhoria do seu desempenho global.

Além disso, a investigação futura poderia aprofundar a otimização do sistema em diversas condições meteorológicas e localizações geográficas, reconhecendo a influência significativa que estes fatores têm na produção fotovoltaica e os requisitos para a gestão da temperatura residencial. Este trabalho poderia ajudar a tornar o sistema ainda mais versátil e adaptável, aumentando a sua adequação a uma gama mais alargada de aplicações.

Em conclusão, embora este estudo marque um passo significativo na otimização dos sistemas de micro-cogeração em redes residenciais, continua a haver muito potencial para mais investigação e desenvolvimento. Espera-se que a continuação do trabalho nesta área produza soluções ainda mais eficientes, flexíveis e sustentáveis para a gestão energética residencial.

Referências

- [1] D.-D. F. I. Consulting, *Cogeneration & Trigeneration How to Produce Energy Efficiently: A Practical Guide for Experts in Emerging and Developing Economies*. GIZ, 2016. 1, 6, 8, 17, 18, 19, 20
- [2] S. Bhatia, *Advanced renewable energy systems,(Part 1 and 2)*. CRC Press, 2014. 1, 2, 5, 9, 20, 21
- [3] H. S. Matharu, V. Girase, D. Pardeshi, and P. William, “Design and deployment of hybrid electric vehicle,” in *2022 International Conference on Electronics and Renewable Systems (ICEARS)*. IEEE, 2022, pp. 331–334. 2
- [4] M. A. Rosen, S. Koochi-Fayegh *et al.*, “Cogeneration and district energy systems: modelling, analysis and optimization,” IET, Tech. Rep., 2016. 5
- [5] C. Cleveland, R. Ayres, R. Costanza, J. Goldemberg, M. Ilic, E. Jochem, R. Kaufmann, A. Lovins, M. Munasinghe, R. Pachauri *et al.*, “Encyclopedia of energy. six-volume set, 1-6,” 2004. 6
- [6] J. O’Brien and P. Bansal, “Modelling of cogeneration systems. part 1: historical perspective,” *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, vol. 214, no. 2, pp. 115–124, 2000. 6
- [7] M. Coelho, F. Nash, D. Linsell, and J. Barciela, “Cogeneration—the development and implementation of a cogeneration system for a chemical plant, using a reciprocating heavy fuel oil engine with a supplementary fired boiler,” *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, vol. 217, no. 5, pp. 493–503, 2003. 6, 7
- [8] N. Zhang, Y. Lu, S. Kadam, and Z. Yu, “A fuel cell range extender integrating with heat pump for cabin heat and power generation,” *Applied Energy*, vol. 348, p. 121600, 2023. 6
- [9] M. Klell, H. Eichlseder, and A. Trattner, *Wasserstoff in der Fahrzeugtechnik*. Springer, 2018. 6
- [10] M.-K. Tran, A. Bhatti, R. Vrolyk, D. Wong, S. Panchal, M. Fowler, and R. Fraser, “A review of range extenders in battery electric vehicles: Current progress and future perspectives,” *World Electric Vehicle Journal*, vol. 12, no. 2, p. 54, 2021. 7, 8
- [11] I. Dincer and M. A. Rosen, *Exergy analysis of heating, refrigerating and air conditioning: methods and applications*. Academic Press, 2015. 7
- [12] A. F. R. de Sá. (2012) Eficiência energética e energias renováveis. [Online]. Available: <https://www.voltimum.pt/sites/www.voltimum.pt/files/>

fields/attachment_file/pt/flipbooks/others/4/20120419510201204196000.pdf 7,
9, 10, 18, 22, 23

- [13] C. Portugal. (2011) Micro cogeração. [Online]. Available: https://www.cogenportugal.com/docs/d/409/eec503_brochura_microcogeraacao__final.pdf 9, 23, 24
- [14] ——. (2009) Manual de apoio ao cogrador. [Online]. Available: http://www.marioloureiro.net/tecnica/co-trigeracao/Manual_de_Apoio_ao_Cogrador.pdf 10
- [15] J. Martins, *Motores de Combustão Interna-4ª edição Revista e Aumentada*, 2006. 11, 12, 13, 14, 15
- [16] H. Meng, C. Ji, S. Wang, and J. Yang, “A review: Centurial progress and development of wankel rotary engine,” *Fuel*, vol. 335, p. 127043, 2023. 14, 15
- [17] karthik. (2013) Mazda and the wankel engine. [Online]. Available: <https://gr8autotech.wordpress.com/2013/06/20/mazda-the-wankel-engine/> 15
- [18] E. Evelyn, A. R. A. Aziz, and P. L. Sambegoro, “A review of range extender technologies in electric vehicles,” *International Journal of Sustainable Transportation Technology*, vol. 3, no. 1, pp. 7–11, 2020. 15
- [19] S. Varnhagen, A. Same, J. Remillard, and J. W. Park, “A numerical investigation on the efficiency of range extending systems using advanced vehicle simulator,” *Journal of Power Sources*, vol. 196, no. 6, pp. 3360–3370, 2011. 15
- [20] D. Mihalascu. (2023) 2023 mazda mx-30 phev brings back rotary engine as range extender. [Online]. Available: <https://insideevs.com/news/630894/2023-mazda-mx-30-phev-brings-back-rotary-engine-as-range-extender/> 15
- [21] S. da Silva Brandão. (2004) Cogeração. [Online]. Available: <http://www.marioloureiro.net/tecnica/co-trigeracao/CogeraacaoSergioBrandao.pdf> 15, 16, 17
- [22] M. Jradi and S. Riffat, “Tri-generation systems: Energy policies, prime movers, cooling technologies, configurations and operation strategies,” *Renewable and sustainable energy reviews*, vol. 32, pp. 396–415, 2014. 16, 17, 19, 20
- [23] Y. S. Najjar, “Gas turbine cogeneration systems: a review of some novel cycles,” *Applied thermal engineering*, vol. 20, no. 2, pp. 179–197, 2000. 16
- [24] A. F. R. de Sá, *Guia de aplicações de gestão de energia e eficiência energética*, 2010. 17
- [25] G. Marinitsch, F. Biedermann, H. Carlsen, J. K. Bovin, M. Schöch, and I. Obernberger, “Development of a hot gas heat exchanger and a cleaning system for a 35kWel hermetic four cylinder Stirling engine for solid biomass fuels,” in *Proceedings of the Twelfth International Stirling Engine Conference, Durham*, 2005. 19

- [26] A. Allouhi, “Advances on solar thermal cogeneration processes based on thermoelectric devices: A review,” *Solar Energy Materials and Solar Cells*, vol. 200, p. 109954, 2019. 20, 21, 22, 23
- [27] M. Aljibory, H. Hashim, and W. Abbas, “A review of solar energy harvesting utilising a photovoltaic–thermoelectric integrated hybrid system,” in *IOP Conference Series: Materials Science and Engineering*, vol. 1067, no. 1. IOP Publishing, 2021, p. 012115. 21
- [28] F. Alcaide, P.-L. Cabot, and E. Brillas, “Fuel cells for chemicals and energy cogeneration,” *Journal of Power Sources*, vol. 153, no. 1, pp. 47–60, 2006. 22
- [29] R. J. Milcarek, J. Ahn, and J. Zhang, “Review and analysis of fuel cell-based, micro-cogeneration for residential applications: Current state and future opportunities,” *Science and Technology for the Built Environment*, vol. 23, no. 8, pp. 1224–1243, 2017. 23
- [30] A. D. Little, “Opportunities for micropower and fuel cell/gas turbine hybrid systems in industrial applications,” *Rep*, vol. 38410, 2000. 24
- [31] R. Mikalsen, “Internal combustion and reciprocating engine systems for small and micro combined heat and power (chp) applications,” *Small and micro combined heat and power (CHP) systems*, pp. 125–146, 2011. 24, 25
- [32] G. Chicco and P. Mancarella, “Assessment of the greenhouse gas emissions from cogeneration and trigeneration systems. part i: Models and indicators,” *Energy*, vol. 33, no. 3, pp. 410–417, 2008. 24
- [33] H. Tanaka, A. Suzuki, K. Yamamoto, I. Yamamoto, M. Yoshimura, and K. Togawa, “New ecowill-a new generation gas engine micro-chp,” in *International Gas Union Research Conference. Seoul.* < <http://tinyurl.com/aw7s6bl>, 2011. 24
- [34] H. Onovwiona and V. I. Ugursal, “Residential cogeneration systems: review of the current technology,” *Renewable and sustainable energy reviews*, vol. 10, no. 5, pp. 389–431, 2006. 24, 25
- [35] J. Orlando, “Cogeneration design guide. ashrae,” 1996. 24
- [36] M. A. Brown, “(discussion of national teams for caddet (center for the analysis and dissemination of demonstrated energy technologies)),” 11 1989. [Online]. Available: <https://www.osti.gov/biblio/5272034> 24
- [37] C. Frangopoulos, “Educogen, the european educational tools on cogeneration,” *European Commission. Dec*, vol. 17, 2001. 24
- [38] J. Harrison and S. Redford, “Domestic chp–what are the potential benefits?” *EA Technology Limited, Capenhurs, Chester.* <http://www.eatechnology>.

com/Embedded%20Generation/Domestic%20CHP%20report.pdf, 2001. 27

- [39] A. Hawkes and M. Leach, "Cost-effective operating strategy for residential micro-combined heat and power," *Energy*, vol. 32, no. 5, pp. 711–723, 2007. 27
- [40] E. S. Barbieri, P. R. Spina, and M. Venturini, "Analysis of innovative micro-chp systems to meet household energy demands," *Applied Energy*, vol. 97, pp. 723–733, 2012. 27
- [41] C. Zhang, Y.-L. Wei, P.-F. Cao, and M.-C. Lin, "Energy storage system: Current studies on batteries and power condition system," *Renewable and Sustainable Energy Reviews*, vol. 82, pp. 3091–3106, 2018. 28
- [42] H. Beltran, P. Ayuso, and E. Pérez, "Lifetime expectancy of li-ion batteries used for residential solar storage," *Energies*, vol. 13, no. 3, p. 568, 2020. 28
- [43] uevora. (2020) Tes thermal energy storage. [Online]. Available: <http://www.newsol.uevora.pt/technology-tes/> 28
- [44] I. Sarbu and C. Sebarchievici, *Solar heating and cooling systems: Fundamentals, experiments and applications*. Academic Press, 2016. 28
- [45] —, "A comprehensive review of thermal energy storage," *Sustainability*, vol. 10, no. 1, p. 191, 2018. 29
- [46] H. Jouhara, A. Żabnieńska-Góra, N. Khordehgah, D. Ahmad, and T. Lipinski, "Latent thermal energy storage technologies and applications: A review," *International Journal of Thermofluids*, vol. 5, p. 100039, 2020. 29
- [47] D. Cardoso, D. Nunes, J. Faria, P. Fael, and P. D. Gaspar, "Intelligent micro-cogeneration systems for residential grids: A sustainable solution for efficient energy management," *Energies*, vol. 16, no. 13, p. 5215, 2023. 29
- [48] V. Quaschnig, *Understanding renewable energy systems*. Routledge, 2014. 29
- [49] S. Faizollahzadeh Ardabili, B. Najafi, S. Shamshirband, B. Minaei Bidgoli, R. C. Deo, and K.-w. Chau, "Computational intelligence approach for modeling hydrogen production: A review," *Engineering Applications of Computational Fluid Mechanics*, vol. 12, no. 1, pp. 438–458, 2018. 29, 30
- [50] A. Mosavi, M. Salimi, S. Faizollahzadeh Ardabili, T. Rabczuk, S. Shamshirband, and A. R. Varkonyi-Koczy, "State of the art of machine learning models in energy systems, a systematic review," *Energies*, vol. 12, no. 7, p. 1301, 2019. 30
- [51] J. Zhang, G. G. Walter, Y. Miao, and W. N. W. Lee, "Wavelet neural networks for function learning," *IEEE transactions on Signal Processing*, vol. 43, no. 6, pp. 1485–1497, 1995. 30

- [52] B. U. Islam, "Comparison of conventional and modern load forecasting techniques based on artificial intelligence and expert systems," *International Journal of Computer Science Issues (IJCSI)*, vol. 8, no. 5, p. 504, 2011. 32
- [53] Q. Zhang, Y. Li, Y. Shang, B. Duan, N. Cui, and C. Zhang, "A fractional-order kinetic battery model of lithium-ion batteries considering a nonlinear capacity," *Electronics*, vol. 8, no. 4, p. 394, 2019. 35
- [54] L. M. Rodrigues, C. Montez, R. Moraes, P. Portugal, and F. Vasques, "A temperature-dependent battery model for wireless sensor networks," *Sensors*, vol. 17, no. 2, p. 422, 2017. 35
- [55] J. F. Manwell and J. G. McGowan, "Lead acid battery storage model for hybrid energy systems," *Solar energy*, vol. 50, no. 5, pp. 399–405, 1993. 35, 36
- [56] S. F. Ardabili, B. Najafi, H. Ghaebi, S. Shamshirband, and A. Mostafaeipour, "A novel enhanced exergy method in analyzing hvac system using soft computing approaches: A case study on mushroom growing hall," *Journal of Building Engineering*, vol. 13, pp. 309–318, 2017. 37
- [57] S. Mandelli, C. Brivio, E. Colombo, and M. Merlo, "A sizing methodology based on levelized cost of supplied and lost energy for off-grid rural electrification systems," *Renewable Energy*, vol. 89, pp. 475–488, 2016. 37
- [58] K. Amarasinghe, D. L. Marino, and M. Manic, "Deep neural networks for energy load forecasting," in *2017 IEEE 26th international symposium on industrial electronics (ISIE)*. IEEE, 2017, pp. 1483–1488. 38
- [59] H.-T. Zhang, F.-Y. Xu, and L. Zhou, "Artificial neural network for load forecasting in smart grid," in *2010 international conference on machine learning and cybernetics*, vol. 6. IEEE, 2010, pp. 3200–3205. 38
- [60] L. L. Lai, H. Subasinghe, N. Rajkumar, E. Vaseekar, B. J. Gwyn, and V. K. Sood, "Object-oriented genetic algorithm based artificial neural network for load forecasting," in *Simulated Evolution and Learning: Second Asia-Pacific Conference on Simulated Evolution and Learning, SEAL'98 Canberra, Australia, November 24–27, 1998 Selected Papers 2*. Springer, 1999, pp. 462–469. 38, 39
- [61] P. Bento, J. Pombo, M. Calado, and S. Mariano, "Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting," *Neurocomputing*, vol. 358, pp. 53–71, 2019. 39

Anexos A

Anexos

A.1 Código Paineis fotovoltaico/bateria/micro-cogeração

```

%% Código (Pv/battery/Micro-CHP)

clc
clear all
close all

load('data.mat');
load('nn_load.mat','net_load');
load('nn_pv.mat','net_pv');

global SOCini;
SOCini=input('Insira a capacidade da bateria que pretende simular (0-1):');
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Dados da Bateria
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

global qmax;
global k_b;
global c_b;

qmax=5; %kW.h
k_b=0.38; % condutância
c_b=0.271; % fração entre reservatórios

Q1=(c_b*qmax)*SOCini;
Q2=((1-c_b)*qmax)*SOCini;
Q=Q1+Q2;
h1=Q1/c_b;
h2=Q2/(1-c_b);

SOC=Q/qmax;

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%define hora durante o ano (Hora atual)
hora=input('Insira a hora que pretende simular (26h-8760h):');

%previsão de carga para daqui a 2 horas%
carga=carga(:,1)*1000*1.8; %kW para W
carga_horas_passadas = [carga(hora-25,1); carga(hora-24,1); carga(hora-23,1); carga(hora-2,1); carga(hora-1,1)];
carga_proximas_duas_horas = net_load(carga_horas_passadas);

%previsão de energia solar para daqui a 2 horas%
producao_horas_passadas = [p_pv(hora-25,1); p_pv(hora-24,1); p_pv(hora-23,1); p_pv(hora-2,1); p_pv(hora-1,1)];
producao_proximas_duas_horas = net_pv(producao_horas_passadas);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
verificaPv=zeros(1,2);
verificaWh=zeros(1,2);
P_compra=zeros(1,2);
P_venda=zeros(1,2);
P_c=zeros(1,2);

```

```

P_d=zeros(1,2);
MCI_E=zeros(1,2);
MCI_T=zeros(1,2);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%trocar colunas com linhas
carga_proximas_duas_horas=transpose(carga_proximas_duas_horas);
producao_proximas_duas_horas=transpose(producao_proximas_duas_horas);
water_heat=transpose(water_heat);

aux=0;

water_heat=water_heat(1,:)*1000*1.8; %converter kW em W

for i=1:1:2 %correr para as proximas 2 horas

    aux=aux+1;
    verificaPv(1,aux)=carga_proximas_duas_horas(1,aux)-producao_proximas_duas_horas(1,aux);
    %verificaWh(1,aux)=water_heat(1,hora+aux)-producao_proximas_duas_horas(1,aux); %
    water_heat_proximas_duas_horas (como prever necessidade de aquecer?)

    %Pela necessidade de suportar carga, >0 existe necessidade
    if verificaPv(1,aux)>0 %défice de energia solar para suportar consumo
        verificaWh(1,aux)=water_heat(1,hora+aux)-0;
        if SOC<0.2 %Bateria fraca->Usar Motor
            SOCverificar(1,aux)=SOC;
            MCI_E(1,aux)=verificaPv(1,aux); %Elétrica_suportaconsumo
            MCI_T(1,aux)=0.75+(2.5*verificaPv(1,aux)); %Térmica_suportawaterheat
        elseif SOC>=0.2 %Necessidade de suportar consumo com bateria e suportar carga
de água quente com motor
            if i==1
                SOCverificar(1,aux)=SOC;
            else
                SOCverificar(1,aux+1)=SOC;
            end
            bat_model(i,:)=modelo_bateria(verificaPv(1,aux)); %descarrega_bateria
            P_d(1,aux)=bat_model(i,2);
            SOC=bat_model(i,1);
            if i==1
                SOCverificar(1,aux+1)=SOC;
            else
                SOCverificar(1,aux+2)=SOC;
            end
            verificaPv(1,aux)=verificaPv(1,aux)-P_d(1,aux);
            if verificaPv(1,aux)==0 %Se a bateria suportar o déficit na totalidade,
temos de mandar a energia elétrica para a bateria
                MCI_T(1,aux)=verificaWh(1,aux);
                MCI_ECharge(1,aux)=(verificaWh(1,aux)-0.75)/2.5;
                bat_model(i,:)=modelo_bateria(-abs(MCI_ECharge(1,aux))); %
Elétrica_CarregaBateria
            P_c(1,aux)=bat_model(i,2);
            SOC=bat_model(i,1);

```

```

        if i==1
            SOCverificar(1,aux+2)=SOC;
        else
            SOCverificar(1,aux+3)=SOC;
        end
    else
        if verificaPv(1,aux)>0
            MCI_E(1,aux)=verificaPv(1,aux); %Elétrica_suportaconsumo
            MCI_T(1,aux)=0.75+2.5*verificaPv(1,aux); %Térmica_suportawaterheat
            verificaWh(1,aux)=verificaWh(1,aux)-MCI_T(1,aux);
            if verificaWh(1,aux)>0
                MCI_T(1,aux)=verificaWh(1,aux)+MCI_T(1,aux);
                MCI_ECharge(1,aux)=(MCI_T(1,aux)-0.75)/2.5;
                bat_model(i,:)=modelo_bateria(-abs(MCI_ECharge(1,aux))); %↙
            end
        end
        Elétrica_CarregaBateria
        P_c(1,aux)=bat_model(i,2);
        SOC=bat_model(i,1);
        if i==1
            SOCverificar(1,aux+2)=SOC;
        else
            SOCverificar(1,aux+3)=SOC;
        end
    end
end
end
end

if verificaPv(1,aux)<0 %excesso de produção solar
    verificaWh(1,aux)=water_heat(1,hora+aux)-abs(verificaPv(1,aux));
    if SOC<0.2 && verificaWh(1,aux)<0 %sobra energia solar
        SOCverificar(1,aux)=SOC;
        bat_model(i,:)=modelo_bateria(-abs(verificaWh(1,aux))); %Resto de energia↙
    end
    solar carrega bateria
    P_c(1,aux)=bat_model(i,2);
    SOC=bat_model(i,1);
    SOCverificar(1,aux+1)=SOC;
    %verificaWh(1,aux)=verificaWh(1,aux)-P_c(1,aux);
    %P_venda(1,aux)=verificaPv(1,aux); %Sobra?
    elseif SOC<0.2 && verificaWh(1,aux)>0 %défice de energia solar
        SOCverificar(1,aux)=SOC;
        MCI_T(1,aux)=verificaWh(1,aux);
        MCI_ECharge(1,aux)=(verificaWh(1,aux)-0.75)/2.5;
        bat_model(i,:)=modelo_bateria(-abs(MCI_ECharge(1,aux))); %↙
    end
    Elétrica_CarregaBateria
    P_c(1,aux)=bat_model(i,2);
    SOC=bat_model(i,1);
    SOCverificar(1,aux+1)=SOC;
    elseif SOC>=0.2 && verificaWh(1,aux)<0 %sobra
        if i==1
            SOCverificar(1,aux)=SOC;
        else
            SOCverificar(1,aux+1)=SOC;
        end
    end
end

```

```

        bat_model(i,:)=modelo_bateria(-abs(verificaWh(1,aux))); %Resto de energia
solar carrega bateria
    P_c(1,aux)=bat_model(i,2);
    SOC=bat_model(i,1);
    if i==1
        SOCverificar(1,aux+1)=SOC;
    else
        SOCverificar(1,aux+2)=SOC;
    end
    %verificaWh(1,aux)=verificaWh(1,aux)-P_c(1,aux); %Sobra?
    %P_venda(1,aux)=verificaWh(1,aux)
elseif SOC>=0.2 && verificaWh(1,aux)>0 %não sobra
    if i==1
        SOCverificar(1,aux)=SOC;
    else
        SOCverificar(1,aux+1)=SOC;
    end
    MCI_T(1,aux)=verificaWh(1,aux);
    MCI_ECharge(1,aux)=(verificaWh(1,aux)-0.75)/2.5;
    bat_model(i,:)=modelo_bateria(-abs(MCI_ECharge(1,aux))); %
Elétrica_CarregaBateria na mesma (fazer algo a MCI_E)
    P_c(1,aux)=bat_model(i,2);
    SOC=bat_model(i,1);
    if i==1
        SOCverificar(1,aux+1)=SOC;
    else
        SOCverificar(1,aux+2)=SOC;
    end
end
end

    %SOCverificar(1,aux)=SOC;
    waterheat(1,aux)=water_heat(1,hora+aux); %incrementar para fazer grafico com os
valores previstos de aquecimento de água

end

subplot(2,2,1)
%figure(1)
hold on
box on
grid on
title('Demand of the electrical load from the residential grid and Fotovoltaic
production');
mat=[producao_proximas_duas_horas'];
area(mat);
plot(carga_proximas_duas_horas,'r');
legend('PvProduction','Eletrical Load');
ylabel('P(W)');
xlabel('hours');

subplot(2,2,2)
%figure(2)
hold on
box on

```

```
grid on
title('a');
mat=[P_d' MCI_E' producao_proximas_duas_horas'];
area(mat)
plot(carga_proximas_duas_horas,'g')
legend('P d','ICE E','PvProduction','Eletrical Load')
ylabel('P(W)')
xlabel('hours')

subplot(2,2,3)
%figure(3)
hold on
box on
grid on
title('b');
mat=[abs(verificaPv)',MCI_T']; %abs(verificaPv)',
area(mat)
plot(waterheat,'g')
legend('RestOfPvProduction','ICE T','waterheat') %'RestOfPvProduction',
ylabel('P(W)')
xlabel('hours')

subplot(2,2,4)
%figure(4)
hold on
title('c');
plot(SOCverificar)
legend('SOC')
ylabel('SOC')
xlabel('Variation Steps')

figure(5)
hold on
box on
grid on
title('Battery Charging');
mat=[P_c'];
area(mat);
legend('P c');
ylabel('P(W)');
xlabel('hours');
```

A.2 Código da rede de previsão da produção fotovoltaica

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Este script importa um perfil de produção fotovoltaica e analisa a sua
% autocorrelação. De seguida cria e treina uma Rede neuronal com 15
% Neuronios para prever as proximas duas horas de produção.
% A Rede neuronal criada é guardada com o nome "nn_pv.mat"
% Para ser chamada e utilizada em outro script basta esse ficheiro (nn_pv.mat)
% estar no mesmo directorio que o script e chamar no seguinte formato:
% proximas_duas_horas = net();
% a variável horas passadas é um vector coluna que tem de ser construido na
% seguinte maneira:
% horas_passadas = [produção_pv_há_25_horas;produção_pv_há_24_horas;
produção_pv_há_23_horas;produção_pv_há_2_horas;produção_pv_há_1_hora]
%
% As entradas e saidas da rede são em Watts.
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
clc
clear all
close all

% Load the data
file_name = 'PV_Production_Profile';
T_selected = readtable(append(file_name, '.csv'),'Range','B2:B4380');
data(:,1) = table2array(T_selected);

autocorr(data,NumLags=30)% Analyze the Data Autocorrelation

% Prepare the data
lags = 26; % number of lags
X = zeros(size(data,1)-lags, lags); % input
Y = zeros(size(data,1)-lags, 1); % output
for i = 1:size(X,1)-1
    X(i,:) = data(i:i+lags-1, 1);
    Y(i,1) = data(i+lags, 1);
    Y(i,2) = data(i+lags+1, 1);
end
lags = 5;
aux(:,1:3) = X(:,1:3);
aux(:,4:5) = X(:,25:26); %Remove the unnecessary input lags
X = aux;

% Split the data into training and testing sets
idx = randperm(size(X,1));
X_train = X(idx(1:round(end*0.8)), :);
Y_train = Y(idx(1:round(end*0.8)), :);
X_test = X(idx(round(end*0.8)+1:end), :);
Y_test = Y(idx(round(end*0.8)+1:end), :);

% Create a neural network with one hidden layer of 10 neurons
net_pv = feedforwardnet(15);

% Train the network using the training data
net_pv = train(net_pv, X_train, Y_train);

% Test the network using the testing data
Y_pred = net_pv(X_test);

```

```
% Calculate the mean squared error  
mse = mean((Y_test - Y_pred).^2);  
  
save('nn_pv.mat', 'net_pv');
```

A.3 Código da rede de previsão da carga elétrica

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Este script importa um perfil de carga elétrica e analisa a sua
% autocorrelação. De seguida cria e treina uma Rede neuronal com 15
% Neuronios para prever as proximas duas horas de carga.
% A Rede neuronal criada é guardada com o nome "nn_load.mat"
% Para ser chamada e utilizada em outro script basta esse ficheiro (nn_load.mat)
% estar no mesmo directorio que o script e chamar no seguinte formato:
% proximas_duas_horas_carga = nnn_load();
% a variável horas passadas é um vector coluna que tem de ser construido na
% seguinte maneira:
% horas_passadas = [carga_há_25_horas;carga_há_24_horas;carga_há_23_horas;
carga_há_2_horas;carga_há_1_hora]
%
% As entradas e saídas da rede são em Watts.
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
clear all
close all

% Load the data
file_name = 'Load_profile';
T_selected = readtable(append(file_name, '.csv'), 'Range', "B2:B4380");
data(:,1) = table2array(T_selected).*1000;

autocorr(data, NumLags=30) % Analyze the Data Autocorrelation

% Prepare the data
lags = 26; % number of lags
X = zeros(size(data,1)-lags, lags); % input
Y = zeros(size(data,1)-lags, 1); % output
for i = 1:size(X,1)-1
    X(i,:) = data(i:i+lags-1, 1);
    Y(i,1) = data(i+lags, 1);
    Y(i,2) = data(i+lags+1, 1);
end
lags = 5;
aux(:,1:3) = X(:,1:3);
aux(:,4:5) = X(:,25:26); %Remove the unnecessary input lags
X = aux;

% Split the data into training and testing sets
idx = randperm(size(X,1));
X_train = X(idx(1:round(end*0.8)), :);
Y_train = Y(idx(1:round(end*0.8)), :);
X_test = X(idx(round(end*0.8)+1:end), :);
Y_test = Y(idx(round(end*0.8)+1:end), :);

% Create a neural network with one hidden layer of 10 neurons
net_load = feedforwardnet(15);

% Train the network using the training data
net_load = train(net_load, X_train, Y_train);

% Test the network using the testing data
Y_pred = net_load(X_test);



```

```
% Calculate the mean squared error  
mse = mean((Y_test - Y_pred).^2);  
  
save('nn_load.mat', 'net_load');
```

A.4 Artigo publicado no *Special Issue Machine Learning and Data Based Optimization for Smart Energy Systems* na Revista *Energies* - MDPI 2023

Article

Intelligent Micro-Cogeneration Systems for Residential Grids: A Sustainable Solution for Efficient Energy Management

Daniel Cardoso ^{1,2} , Daniel Nunes ², João Faria ^{1,3}, Paulo Fael ^{1,2} and Pedro D. Gaspar ^{1,2,*} 

¹ Department of Electromechanical Engineering, Faculty of Engineering, University of Beira Interior, Rua Marquês d'Ávila e Bolama, 6201-001 Covilhã, Portugal; silva.cardoso@ubi.pt (D.C.); joao.pedro.faria@ubi.pt (J.F.); pfael@ubi.pt (P.F.)

² C-MAST-Centre for Mechanical and Aerospace Science and Technologies, 6201-001 Covilhã, Portugal; figueira.nunes@ubi.pt

³ Instituto de Telecomunicações, Universidade da Beira Interior, 6201-001 Covilhã, Portugal

* Correspondence: dinis@ubi.pt

Abstract: This paper presents an optimization approach for Micro-cogeneration systems with internal combustion engines integrated into residential grids, addressing power demand failures caused by intermittent renewable energy sources. The proposed method leverages machine learning techniques, control strategies, and grid data to improve system flexibility and efficiency in meeting electricity and domestic hot water demands. Historical residential grid data were analysed to develop a machine learning-based demand prediction model for electricity and hot water. Thermal energy storage was integrated into the Micro-cogeneration system to enhance flexibility. An optimization model was created, considering efficiency, emissions, and cost while adapting to real-time demand changes. A control strategy was designed for the flexible operation of the Micro-cogeneration system, addressing excess thermal energy storage and resource allocation. The proposed solution's effectiveness was validated through simulations, with results demonstrating the Micro-cogeneration system's ability to efficiently address high electricity and hot water demand periods while mitigating power demand failures from renewable energy sources. The research presents a novel approach with the potential to significantly improve grid resilience, energy efficiency, and renewable energy integration in residential grids, contributing to more sustainable and reliable energy systems.

Keywords: micro-cogeneration systems; internal combustion engines; residential grids; machine learning; control strategies; energy management; grid flexibility; smart grids; electrical energy; thermal energy; renewable energy integration



Citation: Cardoso, D.; Nunes, D.; Faria, J.; Fael, P.; Gaspar, P.D. Intelligent Micro-Cogeneration Systems for Residential Grids: A Sustainable Solution for Efficient Energy Management. *Energies* **2023**, *16*, 5215. <https://doi.org/10.3390/en16135215>

Academic Editor: Holger Hesse

Received: 9 June 2023

Revised: 30 June 2023

Accepted: 4 July 2023

Published: 6 July 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Reliable energy sources are crucial for residential grids, yet renewable solutions like photovoltaic (PV) systems experience irregular power production contingent on resource availability [1]. To address this, this study proposes coupling PV with battery and Micro-cogeneration units as a holistic energy-generation solution. Notably, the incorporation of a Micro-cogeneration system, particularly a Micro combined heat and power (Micro-CHP) system powered by an internal combustion engine, presents a potential pathway towards off-grid residential energy solutions. Micro-cogeneration units are versatile systems producing both electrical and thermal energy. Despite their relatively small size (under 50 kW), they offer opportunities to reduce primary energy consumption and curb greenhouse gas emissions [2–5].

Utilizing the mechanical energy generated by the internal combustion engine converted by an alternator and the thermal energy harvested from the engine's exhaust gases and cooling circuits, these systems can contribute to overall efficiency [6]. Micro-cogeneration presents an opportunity to enhance the stability and resilience of home grids powered by renewable energy sources, thereby overcoming the implementation barrier that

arises from relying solely on renewables. By integrating Micro-cogeneration, home grids can become more energy efficient and resilient. PV panels and battery systems sometimes fall short of consistently meeting the demands of the household grid, particularly during periods of low solar exposure. This current paper proposes that the internal combustion engine in the Micro-CHP system can function as a backup in these instances, supporting electrical demand and charging the batteries while also providing thermal energy for applications such as hot water and space heating. It is intended to analyse and state that the Micro-CHP can support both demands (kW) in integrated grids with PV and battery systems, aiming to keep them off-grid. The challenges associated with implementing this system can be attributed to factors such as the fuel supply network, acquisition costs, maintenance requirements, and adaptation to imposed loads. Overcoming these challenges is crucial for the successful implementation of such a system. This study aims to address these challenges by effectively integrating the electrical production of the Microgeneration system with the imposed load requirements, particularly in the context of photovoltaic energy, where renewable energy production may be limited.

It is important to establish a framework that enables the fulfilling of load requirements imposed on the network while effectively predicting and meeting the thermal demands for domestic hot water and residential heating. To achieve this objective, it aims to employ appropriately sized machines, coupled with prediction networks and energy storage systems. This integrated approach allows for more accurate and efficient management of the system, ultimately mitigating and satisfying the imposed needs. By utilizing advanced prediction technologies and optimizing energy storage, the demands placed on the system can be effectively suppressed, ensuring a reliable and efficient operation. To optimize the operation of the proposed system, machine learning techniques are employed. Specifically, artificial neural networks (ANNs) are used to predict the electrical load and PV power based on the load profile and PV production of the previous day. This innovative approach allows for the proactive planning and control of electrical and thermal energy, enhancing network safety and efficiency. The main challenge, then, is to efficiently interconnect and coordinate these diverse technologies within the network.

The proposed Micro-cogeneration system's performance, integrated with PV panels and batteries, will be analysed using MATLAB simulation.

2. Literature Review

2.1. Micro-Cogeneration Systems with Internal Combustion Engines

Micro-CHP systems featuring internal combustion engines (ICEs) have emerged as the preferred choice for small-scale applications, owing to their robustness and time-tested technology [7]. Nevertheless, regular maintenance is crucial for maintaining their operational viability [8]. These systems demonstrate versatility in terms of fuel use and can be adapted to fulfil the electricity and heat requirements of the infrastructure where they are deployed [9].

The energy yielded from the fuel is apportioned into three parts: approximately one-third is converted into mechanical work, another third dissipates as heat in the exhaust gases, and the remaining third is manifested as internal engine heat losses. Some of these heat losses occur due to various heat transfer mechanisms within the engine's cooling circuit [6].

When implemented into Micro-cogeneration, internal combustion engines generally adopt a standard configuration as depicted in Figure 1. The system's constituent elements comprise an engine, a generator, a heat recovery system—including a water jacket and exhaust gas heat exchangers—and an acoustic isolator. The engine propels the generator through its mechanical energy, while the heat exchangers recover thermal energy from the engine's exhaust system and cooling circuits. A pump typically drives the heat recovery system, prompting the coolant to circulate through the engine and into the heat exchangers, consequently producing hot water [8].




Figure 1. Standard configuration of a Micro-CHP system based on ICE.

Several brands have developed Micro-CHP systems based on internal combustion engines. Honda pioneered the market in 2003 with the Ecovill Micro-CHP unit, selling 100,000 units in Japan [6]. This natural gas-powered unit marked the first Micro-cogeneration system designed with an internal combustion engine, offering 1 kW of electrical power and 3 kW of thermal power with an overall energy efficiency of 85% [10]. An upgraded model launched in 2011 boasted an enhanced overall efficiency of 92% due to the application of the “EXlink” engine, which features an expansion stroke longer than the compression stroke thanks to a multi-link expansion linkage mechanism [11]. Other notable entries into the market include Tokyo Gas’s natural gas-powered 6 kW system with an efficiency of 86% and Yanmar Diesel Engine Co.’s system offering an output of 9.8/8.2 kW, with an efficiency of 81.55% and a heat recovery rate of up to 58/56% [8,12].

In Europe, SenerTec dominates the market, with over 20,000 units sold of their Dachs model, which offers 5.5 kW of electrical power, 10 kW of thermal power, and an overall efficiency of 90% [6,8]. A notable alternative comes from PowerPlus Technologies, which has introduced the Ecopower Micro-CHP unit, providing adjustable electrical power ranging from 4.7 to 1.3 kW thanks to engine rotation control and a frequency converter that conditions the energy output for grid feeding. The unit’s thermal power ranges from 4 to 12.5 kW, with overall efficiency estimated at 89% [6].

2.2. Micro-Cogeneration Systems with Fuel Cells

Fuel cells are devices that produce electrical and thermal energy from chemical energy, without involving combustion cycles. Hydrogen (fuel) and oxygen (oxidant) are the chemical elements used to obtain the two forms of energy. Fuel cells are classified according

to their working temperature or the type of electrolyte. The most suitable for cogeneration systems are alkaline fuel cells (AFCs), proton exchange membranes (PEMs), phosphoric acid fuel cells (PAFCs), molten carbonate fuel cells (MCFCs), and solid oxide fuel cells (SOFCs) [13]. Their use in Micro-cogeneration has advantages such as low emissions, high efficiency, low noise, and greater autonomy, creating independence from the grid [14]. The complex processing or access to hydrogen, the time-consuming start-up, and the complexity of integration in hybrid systems are the main barriers to the introduction of this technology in Micro-cogeneration [15].

2.3. Challenges in Integrating Micro-Cogeneration into Residential Grids

Incorporating an internal combustion engine within the framework of Micro-cogeneration into residential settings with existing photovoltaic panels and batteries poses significant challenges. The primary hurdle is the effective interconnection of all energy systems, aiming to optimize grid profitability while minimizing losses and costs. Consequently, sophisticated and automated control systems are paramount for effective energy management [16].

Darcovich et al. scrutinized a residential grid comprising these technologies and emphasized that utilizing photovoltaic panels and batteries could yield economic benefits, albeit to a lesser extent upon the integration of a Micro-CHP system [17]. The energy consumption hierarchy generally prioritizes photovoltaic power due to its renewable nature, followed by battery usage, and finally, engine operation when the photovoltaic power and battery charge level prove inadequate.

For water heating applications, photovoltaic power is the primary energy source. However, when it falls short, the engine's thermal energy steps in. Compared to conventional water heaters, engines cannot heat water as rapidly, leading to the inclusion of a water cylinder in the system. This component provides a time buffer between the heat produced by the Micro-CHP and the hot water utilized [18].

The complexity arises in deciding where to direct the electrical energy and establishing criteria for using the engine's thermal energy. Further complications could stem from the time taken to charge the battery while the engine simultaneously supports the residence's electrical load. These issues exemplify some of the potential difficulties faced when amalgamating these technologies within a unified grid [17].

2.4. Machine Learning and Control Strategies for Energy Management

Addressing the significant electricity demand from off-grid sources has made energy management a pressing issue in residential settings. Several innovative approaches have emerged, using machine learning and control strategies to manage energy systems effectively, balancing energy distribution, and optimizing the use of photovoltaic panels, batteries, and internal combustion engines in Micro-cogeneration. These strategies strive to decrease energy consumption and enhance overall system performance.

Machine learning models extensively utilized in energy systems include artificial neural networks (ANNs), multilayer perceptron (MLP), extreme learning machine (ELM), support vector machines (SVMs), wavelet neural networks (WNNs), adaptive neuro-fuzzy inference systems (ANFISs), decision trees, deep machine learning, ensemble models, and hybrid advanced machine learning models.

ANNs serve as a framework for various machine learning algorithms designed to process complex data inputs and can be applied to prediction, regression, and curve-fitting methodologies. Their simplicity when faced with multi-variable problems makes them stand out [19]. MLPs are a more sophisticated variant of ANNs, often referred to as feedforward neural networks, widely used in process modelling and prediction [19–21].

An SVM, on the other hand, is particularly suitable for pattern recognition, classification, and regression analysis due to its ability to execute generalizations. Its algorithms, based on statistical learning theory for structural risk minimization, find wide applicability in load forecasting [22].

A WNN leverages a function to process a data series and yield an output value for a specific input value. This model requires less learning time compared to the MLP model [23]. The ANFIS methodology is a fusion of fuzzy logic and neural network features, integrating an ANN based on the Takagi–Sugeno fuzzy inference system, marking it as a hybrid machine learning method [24]. Decision trees utilize a tree-like model to make decisions based on historical electric load data. Deep machine learning employs deep neural networks to predict load based on past data, allowing for more precise future load predictions due to its ability to learn complex, non-linear patterns. Ensemble techniques amalgamate multiple prediction models into an overarching model to enhance prediction accuracy. Finally, hybrid advanced machine learning models combine decision trees and deep neural networks to accomplish highly accurate load forecasting [22].

All the methodologies can be deployed for energy forecasting and control.

3. Data Collection and Analysis

3.1. Residential Grid Data Sources

Load profiles were obtained from the Building America Housing Simulation B10 Benchmark. The base load profile represents the electrical demand (kW) and was estimated by scaling the base load profile from other houses. A random deviation of $\pm 20\%$ was included in the home's load profile to consider variability.

A PV generation profile was collected from the solar radiation database PVGIS-SARAH2, developed to calculate the electricity production of a photovoltaic system as a function of solar radiation and other important climate variables. It is based on data of global horizontal and inclined solar radiation, air temperature, wind speed, and other climatic parameters, provided by meteorological stations or by regional climate models. The model uses simulation and calculation algorithms to estimate the solar radiation of the photovoltaic system, considering values such as latitude, longitude, elevation, declination, azimuth, the nominal power of the PV system, and system losses. The latitude and longitude refer to the location where the data were collected. The parameters and corresponding values used to generate the hourly data in one year are presented in the following table (Table 1).

Table 1. Solar radiation data.

Parameter	Value
Latitude (deg.)	41.157
Longitude (deg.)	−8.391
Elevation (m)	166
Slope (deg.)	37
Azimuth (deg.)	10
Nominal power PV system (kW)	3.5
System losses (%)	15

3.2. Data Analysis and Machine Learning

Artificial neural networks (ANNs) were employed with the generated data to predict the daily load and PV production profiles. These forecasts served as inputs for a controller that determined the operation of the Micro-CHP system and battery. ANNs are advantageous for this application because they can learn from and make predictions based on time-series data. The ANN was trained using 80% of the collected data, with the remaining 20% used for testing. The predicted and actual values were then compared to gauge the performance of the ANN, with the root-mean-square error (RMSE) being used as the performance index. This approach improves the optimized control of the system considering the anticipated load profiles and PV production and thereby enhancing the overall system performance.

4. Mathematical Model

4.1. PV Model

To determine the power output of the photovoltaic modules, a model was used as a function of cell temperature and solar irradiation. The power output of the photovoltaic system (P_{PV}) is given by Equation (1):

$$P_{PV} = \mu_{mppt} \left(P_{STC} \frac{G}{G_{STC}} (1 + \alpha_{VOC} (T_{cell} - T_{STC})) \right) N_s N_p \tag{1}$$

where μ_{mppt} is the efficiency at the maximum power point track (%), P_{STC} is the maximum power under STC (W), G is the given solar irradiance in each time step (Wm^{-2}), G_{STC} is the irradiance under STC (Wm^{-2}), α_{VOC} is the temperature coefficient of the open-circuit voltage under STC ($V\ ^\circ C^{-1}$), T_{STC} is cell temperature under STC conditions ($^\circ C$), and N_s are the modules connected in series and N_p the modules connected in parallel, in each time step. T_{cell} is the cell temperature in each time step ($^\circ C$) given by Equation (2):

$$T_{cell} = T_{amb} + \frac{G}{G_{NOCT}} * (NOCT - T_{NOCT}) \tag{2}$$

With the temperature in each cell given as a function of the ambient temperature T_{amb} in each time step ($^\circ C$), and G_{NOCT} is the irradiance under NOCT conditions (Wm^{-2}), NOCT is the nominal operating cell temperature ($^\circ C$), and T_{NOCT} is the air temperature under NOCT conditions ($^\circ C$) [25,26]. The model specifications are listed in Table 2.

Table 2. PV model specifications.

Parameter	Value
μ_{mppt}	95%
P_{STC}	250 W
G_{STC}	1000 Wm^{-2}
α_{VOC}	-0.0044 $V\ ^\circ C^{-1}$
T_{STC}	25 $^\circ C$
G_{NOCT}	800 Wm^{-2}
NOCT	47.5 $^\circ C$
T_{NOCT}	20 $^\circ C$

4.2. Battery Model

The kinetic battery model (KiBaM), shown in Figure 2, was proposed by Manwell and McGowan and is used to capture non-linear capacity effects for state-of-charge (SOC) tracking [27].




Figure 2. Kinetic battery model (KiBaM) [28].

The KiBaM uses two different reservoirs, called bound charge and available charge, separated by conductance. The available charge reservoir q_1 contains a charge that is immediately available for use by the consumer, and the bound charge reservoir q_2 contains a charge that is chemically bound. Each has the same depth, but different widths and hence different volumes. The width of reservoir 1 (available charge) is c and that of reservoir 2 (bound charge) is $(1 - c)$. The head in each reservoir is given by the width divided by the area.

The battery's total capacity is the sum of q_1 and q_2 . The variable k represents the rate at which charge flows from q_2 to q_1 [29].

The principle of the KiBaM model is as follows. When the battery is discharging, the charge from q_1 flows out and simultaneously the charge from q_2 flows into q_1 , slowly with k . The charge leaving q_1 is faster than the charge entering, so the height difference between q_1 and q_2 will increase. If the discharge is stopped, the charge from q_2 flows slowly to q_1 until the heights are equal ($h_1 = h_2$), depicted in the battery recovery effect. When the battery is charging, reservoir q_1 charges at a higher rate compared to reservoir q_2 [27]. The amount of energy contained in each reservoir in kWh at each time step is represented by Equations (3) and (4). The kinetic battery model (KiBaM) specifications are listed in Table 3.

$$q'_1 = q_1 e^{-k\Delta t} + \frac{(q_{bat}kc - P_{cd})(1 - e^{-k\Delta t})}{k} - \frac{P_{cd}c(k\Delta t - 1 + e^{-k\Delta t})}{k} \quad (3)$$

$$q'_2 = q_2 e^{-k\Delta t} + q_{bat}(1 - c)(1 - e^{-k\Delta t}) - \frac{P_{cd}(1 - c)(k\Delta t - 1 + e^{-k\Delta t})}{k} \quad (4)$$

Table 3. Kinetic battery model (KiBaM) specifications.

Parameter	Value
k	0.38
c	0.271

In this context, the terms q'_1 , q'_2 and q_1 , q_2 are the available and bound charge at the beginning and end of each time step, respectively. The variable Δt represents the duration of each time step, while P_{cd} refers to the power used to charge or discharge the system during each time step, measured in kW, given by Equations (5) and (6):

$$P_d = \frac{kq_1 e^{-k\Delta t} + q_{bat}kc(1 - e^{-k\Delta t})}{1 - e^{-k\Delta t} + c(k\Delta t - 1 + e^{-k\Delta t})} \quad (5)$$

$$P_c = \frac{-kcq_{max} + kq_1 e^{-k\Delta t} + q_{bat}kc(1 - e^{-k\Delta t})}{1 - e^{-k\Delta t} + c(k\Delta t - 1 + e^{-k\Delta t})} \quad (6)$$

where q_{max} is the maximum capacity of the battery [29].

4.3. Micro-CHP Model

The Micro-cogeneration system that was chosen for this study was designed to fulfil the specific objectives of the research. It was determined that the system should have an electrical output range between 1.3 and 4.7 kW and a corresponding thermal output ranging from 4 to 12.5 kW. This range was selected to ensure a versatile performance capacity that can adequately respond to the varying demand conditions typically found in residential settings.

To establish the correlation between the electrical and thermal output of the system, a linear equation, Equation (7), was formulated:

$$ICI_T = 2.5 \times ICI_E + 0.75 \quad (7)$$

In Equation (7), ICI_T denotes the thermal power and ICI_E refers to the corresponding electrical power. This relationship implies that for each unit increase in electrical output, the thermal output increases by 2.5 times. The additional constant of 0.75 is the thermal power produced when the electrical output is zero. This formula was developed to provide a simple yet effective way to predict the system's performance across its operating range.

Equation (7) is critical in managing the balance between the electrical and thermal production of the Micro-CHP system. By being able to predict the thermal output for a given electrical output, the system can be operated more efficiently and effectively, ensuring that the heat produced is neither underutilized nor wasted.

In summary, this Micro-CHP model provides a robust framework for understanding and predicting the performance of the system. It serves as a critical tool for optimizing system operation, achieving energy efficiency, and facilitating effective integration with other components of the energy system.

5. Machine Learning-Based Demand Prediction Model

5.1. Model Selection and Rationale

Load forecasting, enabled by machine learning, falls into three primary categories: short-term load forecasting (ranging from one hour to one week), medium-term load forecasting (spanning one week to one year), and long-term load forecasting (extending over a year). Despite the established efficiency of these methods, individual household load forecasting has shown to be more challenging compared to aggregate load forecasting. Two prevalent approaches inform energy forecasting: one based on physical principles and another rooted in statistical methods and machine learning [30].

Artificial neural networks (ANNs), part of the statistical and machine learning approach, simulate the functionality of human brain neurons within a computing framework. In contrast to traditional computing, which excels in storing vast amounts of information and reorganizing it according to specific instructions tailored for that task, ANNs present a novel solution. The potential of ANNs for load prediction has been explored since 1990 [31]. These are parallel networks of simple processing units, designed to emulate the functionalities and structures of the human brain to tackle complex problems [32].

In this study, artificial neural networks have been chosen for the prediction of electrical load and photovoltaic production. Their ability to learn and model non-linear relationships makes them particularly suitable for handling the complexities and fluctuations associated with energy demand and renewable energy production. Their use in this context ensures a more accurate and reliable forecast, which is crucial for efficient energy management and control in residential grids.

5.2. Model Training and Validation

The multi-layer feedforward neural network (FFNN) is one of the most widely used neural networks. In each network layer, each neuron response is provided by the activation function with a cost given by a weighted sum, which acts as a threshold. For any two consecutive layers (input-hidden, hidden-hidden, or hidden-output), $[k - 1, k]$ can be expressed mathematically by Equation (8):

$$y_j = f_j\left(\sum_{i=1}^n \omega_{ij} \times x_i + b_j\right), \quad i \in [0, n] \quad j \in [0, m] \quad (8)$$

where n is the number of neurons in layer $k - 1$ and m is the number of neurons in layer k with $n, m \in \mathbb{Z}^+$; y_j is the output of neuron j , x_i is the input signal to neuron j coming from neuron i ; b_j is the bias of neuron j ; and finally w_{ij} is the synaptic connection weight between neurons i and j [33].

ANN learning is elaborated in a process known as supervised learning, which consists of updating the weight of the vector to minimize the error. In this work, the performance (error) function chosen is the mean squared error, given by Equation (9):

$$MSE = \frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

where N is the number of training samples, \hat{y}_i is the current network output, and y_i is the desired output response [34]. However, when implementing an ANN, a non-trivial set of sensitive aspects, i.e., with an impact on work performance, must be chosen. These aspects include the choice of input variables (load, weather variables, etc.), the size of the training vectors, the number of hidden layers, the number of neurons in each hidden layer, the choice of the training method, the activation functions and the stopping criteria, and a network topology itself [34].

This article employed two feedforward neural networks with a 15-neuron architecture and a single hidden layer to accurately forecast both PV demand and load consumption for the next two hours. These ANNs were designed with five inputs each, specifically chosen to represent lag variables from the training dataset that displayed the strongest correlation. The selection process for these lag variables was conducted through an autocorrelation test, guaranteeing the inclusion of highly influential predictors to enhance the accuracy of the forecasts.

6. Control Strategy for Flexible Operation

Designing the Control Strategy

In the development of the control strategy, energy direction priorities toward different demand types were initially defined. This was necessary to ensure that the resulting simulation would align with the intended requirements. The priority was to ascertain if the photovoltaic production in the upcoming two hours would present a surplus or a deficit when compared to the load forecast for the same duration. The underlying objectives of energy efficiency and economic and environmental sustainability were crucial in the process of optimizing these types of hybrid systems [35]. These considerations were consistently central throughout the development of the strategy.

The simulation operated iteratively for each hour within the following two hours. This resulted in graphical representations of the electric load profile, the water heating profile contained in the electric cylinder, and the state-of-charge (SOC) profile. Current conditions such as SOC, predicted electric load, and forecasted photovoltaic production inform these iterations and align with defined hypotheses.

The selection of a two-hour horizon in the simulation considers several factors to ensure optimal performance of the Micro-cogeneration system. One of the primary considerations is the need to minimize prediction errors in forecasting photovoltaic production and load demand. By limiting the time horizon to two hours, the accuracy of the predictions can be significantly improved, as shorter time intervals generally yield more reliable results. Additionally, the two-hour horizon allows sufficient time for the Micro-cogeneration system to ramp up its energy production to meet the anticipated demand. This is particularly crucial in situations where the system needs to generate thermal energy, as it requires time for the engine to reach optimal operating conditions and produce the desired output. By starting the production of thermal energy within a two-hour timeframe, the Micro-cogeneration system can efficiently answer to the expected demand without compromising its performance. It is important to consider that increasing the time before initiating the production of thermal energy could lead to greater energy losses. This is because the system would need to operate for a longer duration without fulfilling the demand, resulting in wasted energy and reduced overall efficiency. By confining the simulation to a two-hour horizon, the Micro-cogeneration system can align its energy production more closely with the forecasted requirements, minimizing unnecessary energy losses and maximizing energy utilization. In summary, the choice of a two-hour horizon strikes a balance

7. Simulation and Validation

7.1. Simulation Setup and Scenarios (PV/Battery/Micro-CHP)

The residential grid in focus includes an integrated Micro-CHP unit with electrical power ranging from 1.3 to 4.7 kW and thermal power from 4 to 12.5 kW. It has an electrical and thermal efficiency that reaches 24.7% and 64.2%, respectively. The system is also equipped with a battery of 5 kWh capacity and a photovoltaic (PV) panel with a power capacity of 3.5 kWp. It is postulated that the grid is furnished with smart meters that collect and report data for the forthcoming two hours. The data gathered by these smart meters facilitate the intelligent management of the Micro-CHP unit, battery, and PV panel to adequately respond to the electrical demand of the Microgrid. Additionally, the system also manages the demand for hot water stored in a cylinder. This thermal demand can be addressed either by the PV panel, via conversion of excess electrical energy, or directly by the thermal energy produced by the Micro-CHP engine, as depicted in Figure 4.




Figure 4. Main components of the simulation.

The forthcoming graphics, based on the simulation run in MATLAB, illustrate different scenarios depending on whether there is an excess or deficit of photovoltaic production, in conjunction with the state of charge (SOC) of the battery. More precisely, scenarios of photovoltaic excess or deficit combined with a low or high SOC will be exhibited at various times throughout the year. These scenarios will be constructed on the prediction of the electric load and photovoltaic production for the forthcoming two hours, utilizing neural network models. These conditions will be put to the test for different combinations of systems, specifically the PV/battery/Micro-CHP, PV/Micro-CHP, and battery/Micro-CHP configurations. The integration of the fuel cell in the system as well as its use for the simulation did not occur due to the usual unavailability of piped hydrogen within a household, compared to natural gas which is much more accessible.

In a load profile comprising 8760 h, an hour was selected for simulation purposes. The SOC of the battery was set for this same hour, and the predictions for the electric load and photovoltaic production for the next two hours were generated using a feedforward neural network. Below are two figures representing the load profile and production profile days. These figures provide a comprehensive view of a 24 h day, with predictions made at 2 h intervals. Figure 5a shows the results for a cloudy day, showcasing the fluctuations in load demand and energy production throughout the day under overcast weather conditions. Conversely, Figure 5b depicts a sunny day, highlighting the load profile and energy production when solar irradiation is abundant.

Consider the case of the system equipped with PV panels, battery, and Micro-CHP. The simulation was conducted for a period where either a deficit or an excess of PV production arises, and the SOC was either lower or higher than 0.2. At 11 am on a cloudy day, for peak demand and a situation where there is a deficit in photovoltaic production and the SOC is less than 0.2, the results are shown in Figure 6.

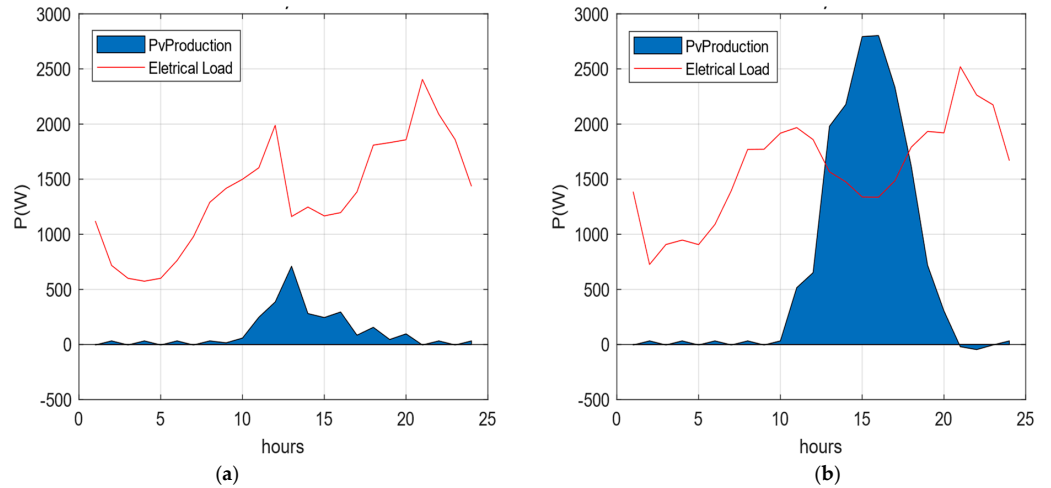


Figure 5. Load profile and production profile days: (a) the scenario of deficit PV production; (b) scenario of excess PV production.

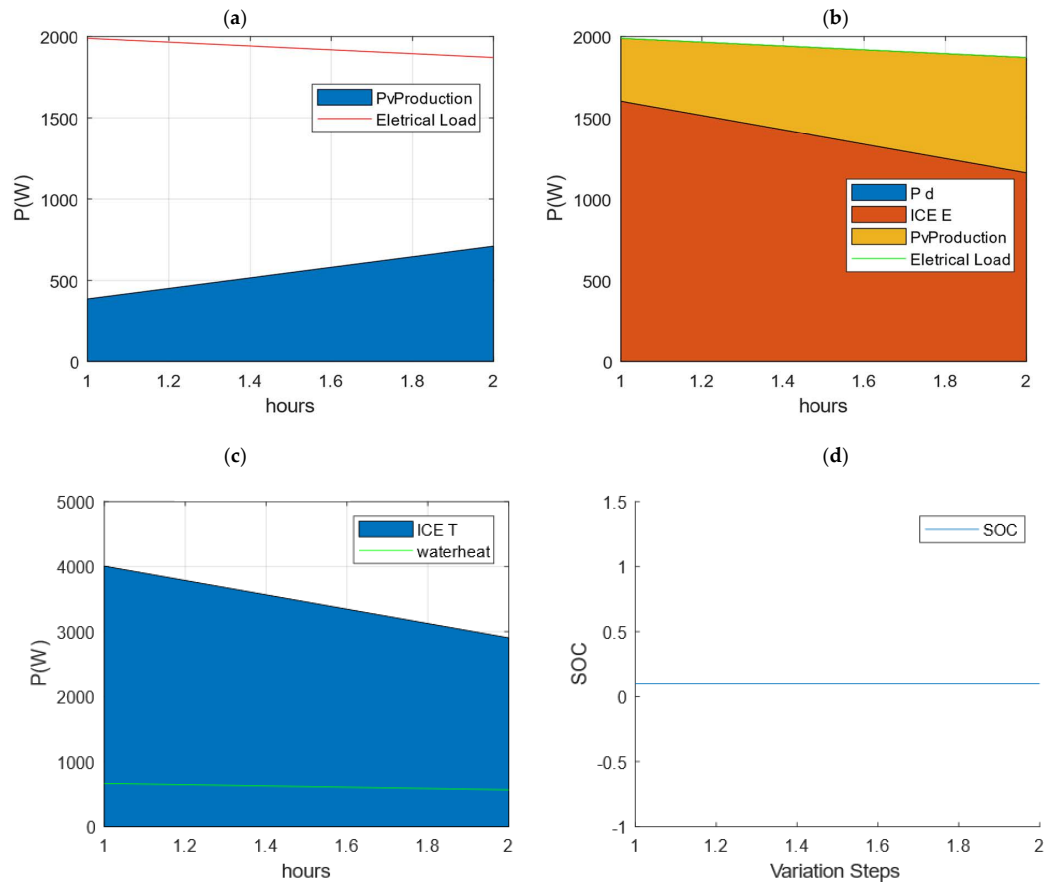


Figure 6. PV production deficit and SOC < 0.2: (a) demand of the electrical load and photovoltaic production; (b) electrical load profile; (c) water heating profile; (d) state of charge during the two prediction hours.

As evident in Figure 6a,b, during the first forecasted hour, the photovoltaic generation deficit (with a projected electrical demand of 1989 W and a photovoltaic power of 386 W) is compensated by 1603 W of electrical energy (ICE E) from the Micro-CHP. Furthermore, 4009 W of thermal energy (ICE T) from the Micro-CHP offsets the demand of 663 W for water heating (as shown in Figure 5c), with 3346 W of thermal surplus being used for storage in a thermal accumulator, from which can be drawn heat for space heating. In the second forecast hour, 1161 W of the electrical power of the engine compensates for the PV production deficit, with a forecasted electric demand of 1871 W and a PV power of 710 W. Given the need to meet the water heating demand, the Micro-cogeneration system compensates the 565 W of demand with 2904 W of thermal power. Here, 2339 W of the thermal surplus is for storage in a thermal accumulator. In Figure 6d, the SOC is kept constant.

In the identical situation of a PV generation deficit, but where the SOC is greater than 0.2, the results for the previous case are shown in Figure 7.

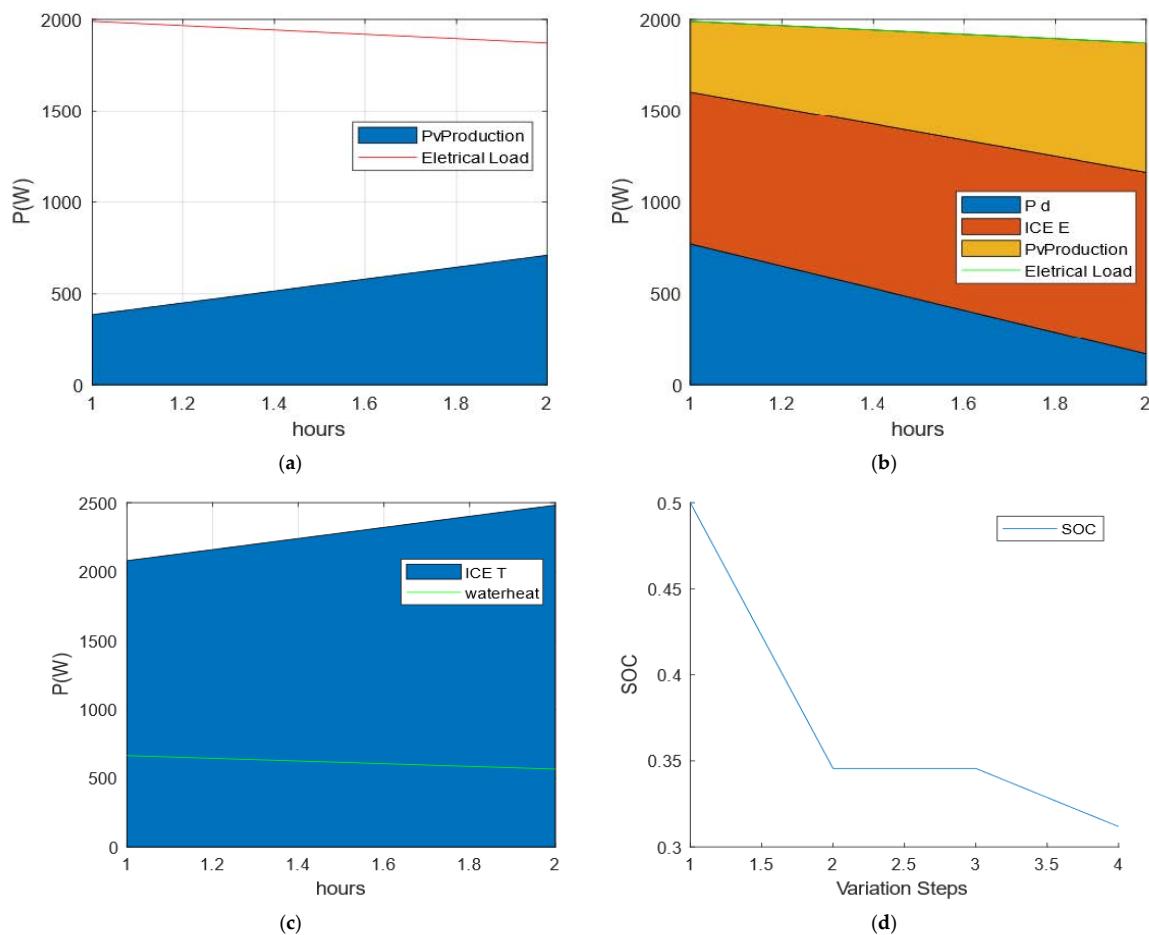


Figure 7. PV production deficit and SOC > 0.2: (a) demand of the electrical load and photovoltaic production; (b) electrical load profile; (c) water heating profile; (d) state of charge during the two prediction hours.

As depicted in Figure 7a,b, in the first forecasted hour, the PV generation deficit (with a forecasted electric demand of 1989 W and a PV power of 386 W) is offset by discharging 772 W from the battery. Because the battery cannot fully support the electrical load, 831 W of electrical power (ICE E) from the Micro-CHP compensates for the remainder. Moreover, 2079 W of thermal power (ICE T) from the Micro-CHP compensates for the 663 W water heating demand, with 1416 W of thermal surplus deployed for storage in a thermal accumulator.

During the second forecasted hour, 169 W from the battery and 992 W of electrical power (ICE E) from the Micro-CHP offsets the PV production deficit, given a forecasted electric demand of 1871 W and a PV power of 710 W. Considering the requirement to satisfy the water heating demand, the Micro-CHP system compensates with 2482 W of thermal power for the 565 W of demand. Here, 1917 W of thermal surplus is used for storage in a thermal accumulator. Figure 7d presents the SOC from the current time (SOC = 0.5) to the end of the two-hour forecast (SOC = 0.3). As described previously, in the first hour (1 to 2) the battery discharges to compensate for electrical demand, and in the second hour (3 to 4) the battery discharges to also compensate for demand.

At 1 pm on a sunny day, for peak demand and a scenario of excess PV production, where the SOC is less than 0.2, the results are shown in Figure 8.

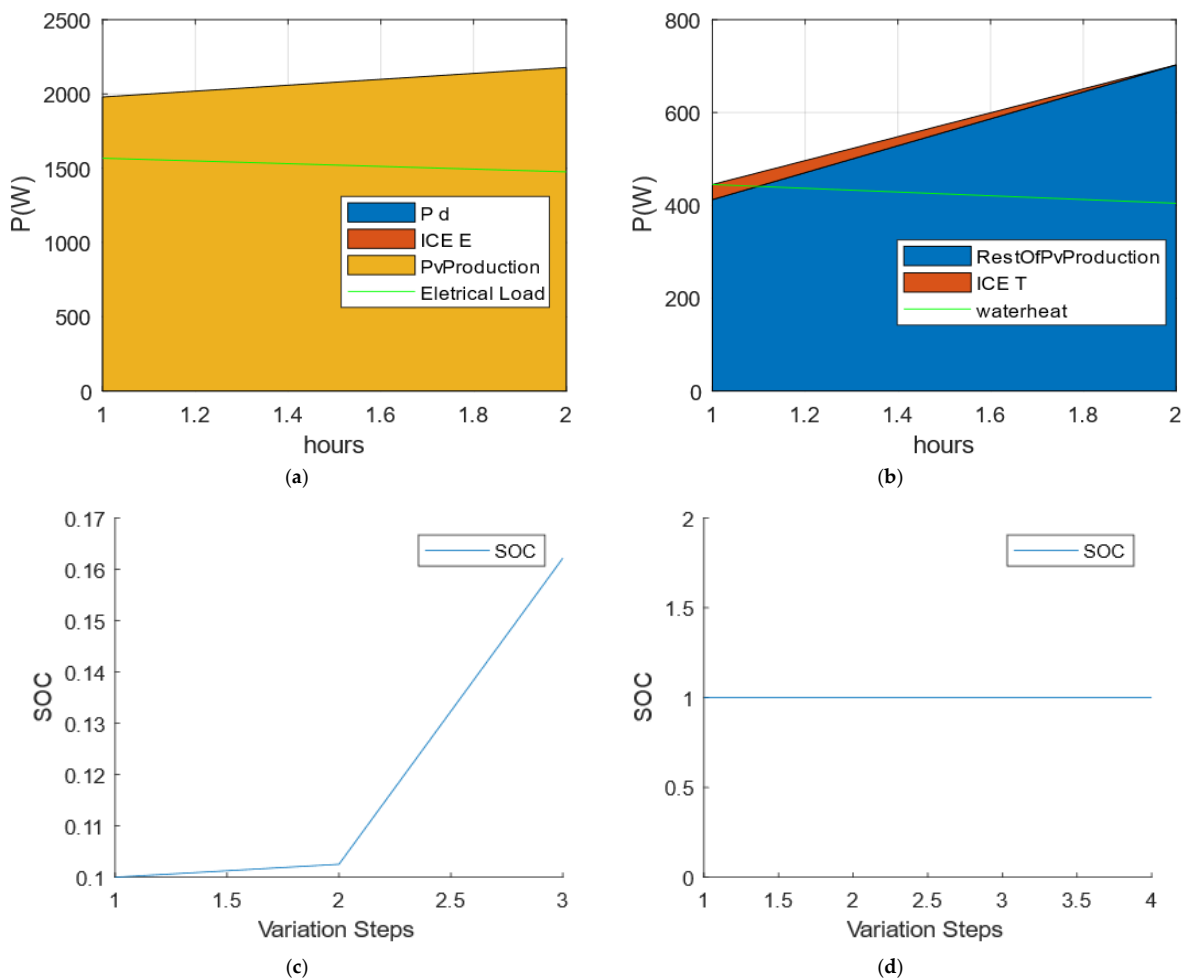


Figure 8. Excess PV production and SOC < 0.2: (a) electrical load profile; (b) water heating profile; (c) state of charge during the two prediction hours (initial SOC < 0.2); (d) state of charge during the two prediction hours (initial SOC = 1).

As observed in Figure 8a, during the first forecasted hour, where the photovoltaic power is 1980 W and the electrical demand is 1567 W, solar production fully covers the electrical demand. The excess PV production (412 W) assists in fulfilling the demand for water heating. However, since it does not entirely compensate, 32 W of thermal power from the Micro-CHP makes up the water heating demand (shown in Figure 8b). Additionally, 13 W of electrical power from the Micro-cogeneration system is used to charge the battery (1 to 2) (Figure 8c). In the second forecasted hour, with a photovoltaic power of 2178 W and an electrical demand of 1476 W, solar production completely satisfies the electrical demand.

The surplus solar production (702 W) caters to the water heating demand of 404 W. The remaining 298 W is used to charge the battery (as seen in Figure 8c).

For the situation of excess PV production and a SOC greater than 0.2, the results are identical to the previous case because there is no requirement to support the residential electrical demand with the battery. Consequently, the battery is charged in the same cycles (as shown in Figure 8c). In situations where the SOC equals 1 (shown in Figure 8d), it is not feasible to utilize the electrical energy from the Micro-CHP in the first prediction hour; 13 W is wasted because the battery is at its maximum SOC.

7.2. Simulation Setup and Scenarios (PV/Micro-CHP)

This simulation introduces a Micro-cogeneration system with electrical power ranging from 1.3 to 4.7 kW and thermal power from 4 to 12.5 kW into a residential grid, complemented by a photovoltaic (PV) panel with a power capacity of 3.5 kWp. In the situation of a PV production deficit, identical to the case examined in Section 7.1 (see Figure 6a), during the first forecasted hour, the PV generation deficit of 1603 W, arising from an expected electrical demand of 1989 W against a PV power of 386 W, is covered by the 1603 W electric power of the Micro-CHP system (as depicted in Figure 9a). The 663 W water heating demand is fulfilled by the 4009 W thermal power of the Micro-CHP, while the surplus of 3346 W of thermal power is allocated to storage in a thermal accumulator (Figure 9b). Similar operations are performed in the second forecast hour, with the 1161 W deficit being met by the Micro-CHP system's electrical power (illustrated in Figure 9a). Additionally, 565 W of the water heating demand is compensated by the Micro-cogeneration system's 2904 W thermal power, leaving a thermal surplus of 2339 W for storage in a thermal accumulator. In instances of excess PV production, following the same case simulated in Section 7.1 (shown in Figure 8a,b), the results remain consistent as anticipated.




Figure 9. Deficit PV production: (a) electrical load profile; (b) water heating profile.

7.3. Simulation Setup and Scenarios (Battery/Micro-CHP)

The focus of this sub-section is the simulation of the interaction between the Micro-CHP and a battery within a residential network. The system incorporates a Micro-CHP unit with electrical power ranging from 1.3 to 4.7 kW and thermal power from 4 to 12.5 kW, alongside a battery with a capacity of 5 kWh. The scenario examined here is identical to the one represented in Figure 6a, with a battery state of charge (SOC) less than 0.2. The results are as follows: In the first hour of prediction, with an electrical load demand of 1989 W, the electric power of the Micro-CHP fully satisfies this demand (refer to Figure 10a). The 663 W water heating demand is met by 4974 W of thermal power of the Micro-CHP. The surplus 4311 W of thermal power is used for storage in a thermal accumulator (as

depicted in Figure 10b). Since the battery only supports the electrical load demand, the water heating demand is consistently covered by the thermal power of the Micro-CHP. Figure 10c provides a visual representation of the battery’s unitability.




Figure 10. SOC < 0.2: (a) electrical load profile; (b) water heating profile; (c) state of charge during the two prediction hours.

In the second forecast hour, featuring an electrical load demand of 1871 W, the electric power of the Micro-CHP fully satisfies this demand. The water heating demand of 565 W is met by 4679 W of thermal power of the Micro-CHP, with the remaining 4114 W of thermal power utilized for storage in a thermal accumulator (refer to Figure 10b).

In cases where the state of charge (SOC) is greater than 0.2, the results unfold differently. In the first forecast hour, with a predicted electrical load demand of 1989 W, the battery supplies 772 W while the Micro-CHP compensates for the remaining load with 1217 W (refer to Figure 11a). The 663 W water heating demand is met by the 3044 W of thermal power of the Micro-CHP. The surplus of 2381 W of thermal power is used for storage in a thermal accumulator (as depicted in Figure 11b).

During the second forecasting hour, with an anticipated electrical load demand of 1871 W, the battery provides 169 W, and 1703 W is compensated by the electrical power from the Micro-CHP. The 565 W water heating demand is met by the 4258 W of thermal power of the Micro-CHP. The surplus 3693 W of thermal power is used for storage in a thermal accumulator (as depicted in Figure 11b).

As can be observed in Figure 11c, the battery discharges to support the load (1 to 4).




Figure 11. SOC > 0.2: (a) electrical load profile; (b) water heating profile; (c) state of charge during the two prediction hours.

8. Performance Evaluation of the Proposed Solution

Among the three system simulations performed, the PV/battery/Micro-CHP system demonstrated the highest profitability according to the findings. In the PV/Micro-CHP system, the load can be totally supported by the PV production; however, it falls short of completely satisfying the water heating demand, as indicated in Figure 8. This deficit makes it necessary to resort to the Micro-CHP system. Ideally, in this scenario, the electrical energy should be directed to battery charging. But in the absence of a means of storage, a waste of 13 W is inevitable. However, this waste does not have a significant impact on the overall profitability of the system since photovoltaic production covers 98% of electricity demand and water heating needs.

In conditions where photovoltaic production is deficient, the energy generated by the engine matches the output of the battery/Micro-CHP system. However, the former is more efficient due to its partial reliance on renewable energy sources. In the battery/Micro-CHP system, the primary technology supporting the water heating demand is the Micro-CHP, making the system heavily dependent on it. The inclusion of a battery helps to minimize the electric and thermal power production when the Micro-CHP and the battery jointly support the electricity demand, thanks to the ability of the system to vary the electric and thermal production. Power losses only occur if the state of charge (SOC) is at maximum capacity, as energy is then diverted to meet residential electrical demand or charged to the battery.

Comparing the use of the cogeneration system with the conventional system, the Micro-CHP is more efficient in water heat demand in addition to solving the need for electricity production. Considering the thermal efficiency mentioned above for the Micro-CHP and electrical efficiency, from the conventional use of an electric storage water heater (ESWH) of 40%, the results of the power required to satisfy 663 W of water heat demand are as shown in Figure 12.

To reach 663 W of water heating demand, in the first hour of the profile of Figure 5c, it is necessary to introduce 1657 W of electric power in the system without the Micro-CHP (2); a little bit higher in value compared to the system with the Micro-CHP (1) that needs 1033 W. It is confirmed that the conventional use of an ESWH is less efficient compared to the use of a system with the Micro-CHP.

Figure 12 compares the same case, but instead of an ESWH, if the comparison is made with a heat pump (that nowadays can reach 111% efficiency) to reach 663 W of water heating demand, in the first hour of the profile of Figure 5c, it is necessary to introduce 597 W of electrical power in the system with the heat pump (2). The value is lower, compared to the system with the Micro-CHP (1), which needs 1033 W. Considering the case study, there is a higher efficiency for the Micro-CHP to satisfy the water heating demand. Despite the reduced efficiency compared to the heat pump, with the Micro-CHP, the system becomes more autonomous because, besides the thermal energy production, electric energy is produced in the same process allowing better management of the system, unlike heat pumps which do not add anything to the electricity grid. This electrical energy can be directed to the battery in case the PV power does not fully compensate for the water heating demand, as is visible in the case of Figure 8b,c. On the other hand, it can compensate for the household electric demand when the battery SOC is reduced, as is the case in Figure 6b.

Continuous enhancements and adjustments were integrated throughout the study to enhance the overall efficiency, resilience, and autonomy of the grid. The use of a Micro-CHP system with adjustable output avoids the need for a constant output at different load profiles. This flexibility avoids wasted energy and allows the Micro-CHP system to adapt to the required demand. Significant emphasis was placed on establishing priority assumptions from the outset, such as supporting an electric load and subsequently meeting the demand for water heating from thermal energy storage; more specifically, an electric water cylinder.




Figure 12. Comparing the power required to compensate 663 W of water heating demand of the Micro-CHP, an ESWH, and a heat pump.

9. Conclusions

9.1. Summary of Findings

The development of an electrical load and photovoltaic (PV) production forecasting tool based on a feedforward neural network (FFNN) was a significant step toward enhancing energy management in this study. This tool allowed for optimal operational planning over a two-hour horizon, ensuring that the output of the Micro-combined heat and power (Micro-CHP) system was meticulously managed to minimize energy wastage.

The forecasting tool proved instrumental in pre-emptively driving the engine operation, enabling the system to strategically modulate the electrical or thermal output to align with the anticipated demand conditions. The anticipation of changes in load allowed for the optimal use of the Micro-CHP system's output, contributing significantly to the improvement of the system's efficiency and the overall reduction in energy wastage.

When the Micro-CHP was integrated into a PV/battery/Micro-CHP system, the gains were most substantial. The interplay between the Micro-CHP, battery, and PV production allowed for a highly efficient and reliable energy system, ensuring that demand could be met under various conditions while reducing dependency on the grid. Comparatively, the system incurred negligible losses in comparison to the standalone PV/Micro-CHP system, demonstrating the benefit of integrating a battery into the energy system.

On the other hand, in the battery/Micro-CHP system configuration, expenses were slightly higher, as the Micro-CHP served as the core component of the system. It was responsible for catering to a significant proportion of the demand and was, therefore, subject to more extensive use, which resulted in higher operational costs.

However, the study revealed that the optimal system configuration was achieved when the Micro-CHP was utilized as a backup energy source. In this configuration, the Micro-CHP system could step in to supply the required load in instances of a photovoltaic deficit or when the state of charge (SOC) of the battery fell below 0.2. This setup ensured that the system could function entirely off-grid during these periods, thereby contributing to significant improvements in system efficiency while enhancing grid independence and resilience.

9.2. Contributions to Grid Resilience, Energy Efficiency, and Renewable Energy Integration

The findings and methodologies presented in this research make a significant contribution to enhancing grid resilience, energy efficiency, and the incorporation of renewable energy. The optimization of the PV, battery, and Micro-CHP systems in a single platform ensures that not only is the supply of energy consistent, even during instances of photovoltaic deficits, but also that energy usage is optimized, effectively minimizing wastage.

The effective management of the proposed model serves to greatly improve the resilience of residential grids by integrating a robust and efficient backup system. This

backup system, powered by the Micro-CHP unit, ensures that a reliable and steady source of power is always available to meet demand, even in situations where renewable energy sources are inadequate. This effectively strengthens the ability of the grid to withstand and adapt to changing conditions, significantly enhancing its overall resilience.

In terms of energy efficiency, this research's model takes significant strides forward. The meticulous planning and operational control allowed by the forecasting tool ensure that the Micro-CHP system's output is optimally used, minimizing energy wastage and thereby improving overall energy efficiency. This improved efficiency not only reduces operational costs but also contributes to the overall sustainability of the system.

Furthermore, this study contributes meaningfully to the broader push toward renewable energy integration. The proposed model harnesses the power of renewable energy sources, namely photovoltaic panels, to meet residential demand for electricity and hot water. By developing a system that can operate independently of the grid during periods of low battery state of charge and photovoltaic deficits, this research facilitates increased utilization and adaptability of renewable energy resources. This not only reduces dependency on conventional, non-renewable energy sources but also helps propel the move towards a more sustainable, renewable energy future.

By efficiently combining renewable sources and storage with a backup Micro-CHP system, the proposed model allows for a more flexible and sustainable energy supply. It marks a step forward in the direction of creating more resilient, efficient, and sustainable energy systems, effectively addressing some of the most pressing challenges of our current energy landscape.

9.3. Limitations and Future Work

While this study has yielded promising results and insights, it is essential to acknowledge that the current literature on the integration of a Micro-CHP into a PV/battery/Micro-CHP system is sparse. There is considerable potential for such integrated systems in various settings, especially in buildings and residential complexes. The development and implementation of off-grid systems like the one proposed in this study can greatly enhance the interconnectivity between residential demands and surrounding technologies, ultimately offering comprehensive benefits across multiple aspects of energy use and management.

However, even with the notable advances presented in this research, there remain areas for further exploration and improvement. One such area is the more effective utilization of thermal power. Despite the optimization measures put in place, thermal power still constitutes the most wasted part of the system, indicating a substantial opportunity for further enhancements in system efficiency.

As a prospective avenue for future research, it is worth considering the development of thermal energy storage systems. Such systems could effectively store energy to be utilized for various thermal applications, providing heat when needed. This approach would not only enhance the efficient utilization of thermal power but also lead to overall improvements in system performance. Exploring and implementing thermal energy storage solutions holds great potential for advancing the effectiveness and efficiency of the system, thereby contributing to its overall performance enhancements.

Additionally, future research could delve into optimizing the system across diverse weather conditions and geographical locations, recognizing the significant influence these factors have on PV production and the requirements for residential temperature management. Such work could help to make the system even more versatile and adaptable, enhancing its suitability for a broader range of applications.

In conclusion, while this study marks a significant step forward in the optimization of Micro-cogeneration systems within residential grids, there remains much potential for further research and development. It is anticipated that the continuation of work in this area will yield even more efficient, flexible, and sustainable solutions for residential energy management.

Author Contributions: Conceptualization, D.C. and D.N.; methodology, D.C. and D.N.; software, D.N. and D.C.; validation, P.F. and P.D.G.; formal analysis, P.F. and P.D.G.; investigation, D.C., D.N. and P.F.; data curation, J.F.; writing—original draft preparation, D.C. and D.N.; writing—review and editing, D.C., D.N., P.F. and P.D.G.; supervision, P.F. and P.D.G. All authors have read and agreed to the published version of the manuscript.

Funding: The authors would like to express their gratitude to Fundação para a Ciência e Tecnologia (FCT) and C-MAST (Centre for Mechanical and Aerospace Science and Technologies) for their support in the form of funding under the project UIDB/00151/2020.

Conflicts of Interest: The authors declare no conflict of interest.

References

- Faria, J.; Pombo, J.; Mariano, S.; Rosario Calado, M.D. Power Management Strategy for Standalone PV Applications with Hybrid Energy Storage System. In Proceedings of the 2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe), Palermo, Italy, 12–15 June 2018; Volume 1–6, p. 101109.
- Entchev, E.; Yang, L.; Ghorab, M.; Rosato, A.; Sibilio, S. Energy, economic and environmental performance simulation of a hybrid renewable Microgeneration system with neural network predictive control. *Alex. Eng. J.* **2018**, *57*, 455–473. [[CrossRef](#)]
- Ribberink, H.; Entchev, E. Exploring the potential synergy between Micro-cogeneration and electric vehicle charging. *Appl. Therm. Eng.* **2014**, *71*, 677–685. [[CrossRef](#)]
- Koohi-Fayegh, S.; Rosen, M.A. A review of energy storage types, applications, and recent developments. *J. Energy Storage* **2020**, *27*, 101047. [[CrossRef](#)]
- Kang, E.-C.; Lee, E.-J.; Ghorab, M.; Yang, L.; Entchev, E.; Lee, K.-S.; Lyu, N.-J. Investigation of energy and environmental potentials of a renewable trigeneration system in a residential application. *Energies* **2016**, *9*, 760. [[CrossRef](#)]
- Mikalsen, R. Internal combustion and reciprocating engine systems for small and Micro combined heat and power (CHP) applications. In *Small and Micro Combined Heat and Power (CHP) Systems*; Elsevier: Amsterdam, The Netherlands, 2011; Volume 125–146, p. 101533.
- Frangopoulos, C.A. *EDUCOGEN, The European Educational Tools on Cogeneration*; European Commission: Brussels, Belgium, 2001.
- Onovwiona, H.I.; Ugursal, V.I. Residential cogeneration systems: Review of the current technology. *Renew. Sustain. Energy Rev.* **2006**, *105*, 389–431. [[CrossRef](#)]
- Orlando, J.A. *Cogeneration Design Guide*; ASHRAE: Atlanta, GA, USA, 1996.
- Chicco, G.; Mancarella, P. Assessment of the greenhouse gas emissions from cogeneration and trigeneration systems. Part I: Models and indicators. *Energy* **2008**, *33*, 410–417. [[CrossRef](#)]
- Tanaka, H.; Suzuki, A.; Yamamoto, K.; Yamamoto, I.; Yoshimura, M.; Togawa, K. New Ecowill—A new generation gas engine Micro-CHP. In Proceedings of the International Gas Union Research Conference 2011, Seoul, Republic of Korea, 19–21 October 2011.
- Japan’s Smallest Gas Engine Cogeneration System. The Netherlands: Centre for the Analysis and Dissemination of Demonstrated Energy Technologies. In *CADDET Energy Efficiency*; IEA/OECD: Paris, France, 2001.
- Alcaide, F.; Cabot, P.-L.; Brillas, E. Fuel cells for chemicals and energy cogeneration. *J. Power Sources* **2006**, *153*, 47–60. [[CrossRef](#)]
- Milcarek, R.J.; Ahn, J.; Zhang, J. Review and analysis of fuel cell-based, Micro-cogeneration for residential applications: Current state and future opportunities. *Sci. Technol. Built Environ.* **2018**, *23*, 1224–1243. [[CrossRef](#)]
- Little, A.D. Volume I: Main Text. In *Opportunities for Micropower and Fuel Cell/Gas Turbine Hybrid Systems in Industrial Applications*; Arthur D. Little, Inc.: Cambridge, MA, USA, 2000; Volume 1, p. 173.
- Isa, N.M.; Tan, C.W.; Yatim, A.H.M. A comprehensive review of cogeneration system in a Microgrid: A perspective from architecture and operating system. *Renew. Sustain. Energy Rev.* **2018**, *81*, 2236–2263. [[CrossRef](#)]
- Darcovich, K.; Henquin, E.R.; Kenney, B.; Davidson, I.J.; Saldanha, N.; Beausoleil-Morrison, I. Higher-capacity lithium ion battery chemistries for improved residential energy storage with Micro-cogeneration. *Appl. Energy* **2013**, *111*, 853–861. [[CrossRef](#)]
- Desideri, U.; Cinti, G.; Discepoli, G.; Sisani, E.; Penchini, D. SOFC Micro-CHP integration in residential buildings. In *Proceedings of the 25th International Conference on Efficiency, Cost, Optimization and Simulation of Energy Conversion Systems and Processes, ECOS 2012*; Firenze University Press: Firenze, Italy, 2012; pp. 26–29.
- Quaschnig, V. *Understanding Renewable Energy Systems*; Routledge: Abingdon, UK, 2016.
- Faizollahzadeh Ardabili, S.; Mahmoudi, A.; Mesri Gundoshmian, T. Modeling and simulation controlling system of HVAC using fuzzy and predictive (radial basis function, RBF) controllers. *J. Build. Eng.* **2016**, *6*, 301–308. [[CrossRef](#)]
- Karballaezadeh, N.; Mohammadzadeh, S.D.; Shamshirband, S.; Hajikhodaverdikhan, P.; Mosavi, A.; Chau, K.W. Prediction of remaining service life of pavement using an optimized support vector machine. *Eng. Appl. Comput. Fluid Mech.* **2019**, *13*, 188–198.
- Faizollahzadeh Ardabili, S.; Najafi, B.; Shamshirband, S.; Minaei Bidgoli, B.; Deo, R.C.; Chau, K.-W. Computational intelligence approach for modeling hydrogen production: A review. *Eng. Appl. Comput. Fluid Mech.* **2018**, *12*, 438–458. [[CrossRef](#)]
- Mosavi, A.; Salimi, M.; Faizollahzadeh Ardabili, S.; Rabczuk, T.; Shamshirband, S.; Varkonyi-Koczy, A. State of the Art of Machine Learning Models in Energy Systems, a Systematic Review. *Energies* **2019**, *12*, 1301. [[CrossRef](#)]

24. Zhang, J.; Walter, G.G.; Miao, Y.; Lee, W.N.W. Wavelet neural networks for function learning. *IEEE Trans. Signal Process.* **1995**, *43*, 1485–1497. [[CrossRef](#)]
25. Faizollahzadeh Ardabili, S.; Najafi, B.; Ghaebi, H.; Shamsirband, S.; Mostafaeipour, A. A novel enhanced exergy method in analyzing HVAC system using soft computing approaches: A case study on mushroom growing hall. *J. Build. Eng.* **2017**, *13*, 309–318. [[CrossRef](#)]
26. Mandelli, S.; Brivio, C.; Colombo, E.; Merlo, M. A sizing methodology based on Levelized Cost of Supplied and Lost Energy for off-grid rural electrification systems. *Renew. Energy* **2016**, *89*, 475–488. [[CrossRef](#)]
27. Okoye, C.O.; Solyali, O. Optimal sizing of stand-alone photovoltaic systems in residential buildings. *Energy* **2017**, *126*, 573–584. [[CrossRef](#)]
28. Zhang, Q.; Li, Y.; Shang, Y.; Duan, B.; Cui, N.; Zhang, C. A Fractional-Order Kinetic Battery Model of Lithium-Ion Batteries Considering a Nonlinear Capacity. *Electronics* **2019**, *8*, 394. [[CrossRef](#)]
29. Rodrigues, L.; Montez, C.; Moraes, R.; Portugal, P.; Vasques, F. A Temperature-Dependent Battery Model for Wireless Sensor Networks. *Sensors* **2017**, *17*, 422. [[CrossRef](#)] [[PubMed](#)]
30. Manwell, J.F.; McGowan, J.G. Lead acid battery storage model for hybrid energy systems. *Solar Energy* **1993**, *50*, 399–405. [[CrossRef](#)]
31. Amarasinghe, K.; Marino, D.L.; Manic, M. Deep neural networks for energy load forecasting. In Proceedings of the 2017 IEEE 26th International Symposium on Industrial Electronics (ISIE), Edinburgh, UK, 19–21 June 2017; pp. 1483–1488.
32. Zhang, H.-T.; Xu, F.-Y.; Zhou, L. Artificial neural network for load forecasting in smart grid. In Proceedings of the 2010 International Conference on Machine Learning and Cybernetics, Qingdao, China, 11–14 July 2010; pp. 3200–3205.
33. Lai, L.L.; Subasinghe, H.; Rajkumar, N.; Vaseekar, E.; Gwyn, B.J.; Sood, V.K. Object-oriented genetic algorithm based artificial neural network for load forecasting. In Proceedings of the Simulated Evolution and Learning: Second Asia-Pacific Conference on Simulated Evolution and Learning, SEAL'98, Canberra, Australia, 24–27 November 1999; pp. 462–469.
34. Bento, P.M.R.; Pombo, J.A.N.; Calado, M.R.A.; Mariano, S.J.P.S. Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting. *Neurocomputing* **2019**, *358*, 53–71. [[CrossRef](#)]
35. Islam, B.U. Comparison of conventional and modern load forecasting techniques based on artificial intelligence and expert systems. *Int. J. Comput. Sci. Issues* **2011**, *8*, 504–513.

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.