

Aplicação de algoritmos da inteligência artificial à otimização de painéis fotovoltaicos usando MPPT

JOÃO PEDRO TEIXEIRA DE SOUSA
julho de 2025

POLITÉCNICO DO PORTO
INSTITUTO SUPERIOR DE ENGENHARIA DO PORTO

Aplicação de algoritmos da inteligência artificial à otimização de painéis fotovoltaicos usando MPPT

João Pedro Teixeira de Sousa

Mestrado em Engenharia Electrotécnica e de Computadores
Área de Especialização em Automação e Sistemas

ISEP INSTITUTO SUPERIOR
DE ENGENHARIA DO PORTO

DEPARTAMENTO DE ENGENHARIA ELETROTÉCNICA
Instituto Superior de Engenharia do Porto

Julho, 2025

*Esta dissertação satisfaz, parcialmente, os requisitos que constam da Ficha de
Unidade Curricular de Tese/Dissertação, do 2º ano, do Mestrado em
Engenharia Electrotécnica e de Computadores, Área de Especialização em
Automação e Sistemas.*

Candidato: João Pedro Teixeira de Sousa, N.º 1201034, 1201034@isep.ipp.pt

Orientação Científica: Ramiro Barbosa, rsb@isep.ipp.pt

ISEP INSTITUTO SUPERIOR
DE ENGENHARIA DO PORTO

DEPARTAMENTO DE ENGENHARIA ELETROTÉCNICA
Instituto Superior de Engenharia do Porto
Rua Dr. António Bernardino de Almeida, 431, 4200-072 Porto

Julho, 2025

Agradecimentos

Agradeço ao Eng. Ramiro Barbosa pelo apoio que me deu na realização deste projeto, não só pelo conhecimento que me transmitiu como também pela disponibilidade manifestada, dedicação, paciência e supervisão durante toda a realização deste trabalho. Agradeço a todas as pessoas que conheci durante o meu percurso académico.

Por fim, agradeço aos meus pais, Luís Sousa e Cristiana Teixeira, por me disponibilizarem as condições para a minha formação académica.

Resumo

Esta dissertação aborda a aplicação de algoritmos de inteligência artificial na otimização de painéis fotovoltaicos através de algoritmos MPPT. Desenvolveram-se modelos de simulação no MATLAB/Simulink para sistemas fotovoltaicos, integrando várias abordagens de monitorização do ponto de máxima potência, com foco principal nas redes neurais e *Deep Reinforcement Learning*, com o objetivo de maximizar a eficiência energética em diferentes condições de irradiância e temperatura.

O sistema proposto incluiu o dimensionamento de um conversor DC/DC *buck* e a validação em diferentes cenários meteorológicos, com análises quantitativas baseadas em métricas de avaliação.

Foram implementados e comparados diferentes algoritmos MPPT, incluindo métodos convencionais (*Perturb and Observe*, *Incremental Conductance*), lógica difusa (FLC), algoritmos genéticos (GA) e técnicas baseadas em inteligência artificial.

Os resultados obtidos demonstraram que os métodos baseados em inteligência artificial, em particular as redes neurais e o agente *Deep Q-Network*, apresentaram melhor desempenho em termos de eficiência média e tempo de convergência, especialmente em cenários com condições de sombra parcial (*Partial Shading Conditions* (PSC)). As conclusões reforçam a viabilidade da aplicação destas abordagens em sistemas fotovoltaicos, contribuindo para uma produção energética mais eficiente perante condições não uniformes.

Palavras-Chave: Sistema Fotovoltaico, *Maximum Power Point* (MPP), *Maximum Power Point Tracking* (MPPT), Conversor *Buck*, Eficiência Energética, Inteligência Artificial, Redes Neurais, *Deep Reinforcement Learning*.

Abstract

This dissertation explores the application of artificial intelligence algorithms to the optimization of photovoltaic panels through MPPT algorithms. Simulation models were developed in MATLAB/Simulink for photovoltaic systems, integrating various approaches to maximum power point tracking, with a primary focus on neural networks and Deep Reinforcement Learning, aiming to maximize energy efficiency under different irradiance and temperature conditions.

The proposed system included the design of a DC/DC buck converter and validation under different weather scenarios, with quantitative analyses based on evaluation metrics.

Different MPPT algorithms were implemented and compared, including conventional methods (Perturb and Observe, Incremental Conductance), fuzzy logic control (FLC), genetic algorithms (GA), and techniques based on artificial intelligence.

The results demonstrated that artificial intelligence-based methods, particularly neural networks and the Deep Q-Network agent, achieved superior performance in terms of average efficiency and convergence time, especially in scenarios with partial shading conditions (PSC). The conclusions support the feasibility of applying these approaches to photovoltaic systems, contributing to more efficient energy production under non-uniform conditions.

Keywords: Photovoltaic System, Maximum Power Point (MPP), Maximum Power Point Tracking (MPPT), Buck Converter, Energy Efficiency, Artificial Intelligence, Neural Networks, Deep Reinforcement Learning.

Índice

Lista de Figuras	ix
Lista de Tabelas	xiii
Listagens	xv
Lista de Acrónimos	xvii
1 Introdução	1
1.1 Contextualização	1
1.2 Objetivos	2
1.3 Organização da Dissertação	2
1.4 Calendarização	3
2 Estado da Arte	5
2.1 Sistema Fotovoltaico	5
2.1.1 Sistema <i>Off-Grid</i>	6
2.1.2 Sistema <i>On-Grid</i>	7
2.2 Painel Fotovoltaico	8
2.3 Efeito Fotovoltaico	9
2.3.1 Junção P-N e Funcionamento da Célula Fotovoltaica	9
2.4 Tipo de células fotovoltaicas	10
2.4.1 Silício Monocristalino (mono-Si)	11
2.4.2 Silício Policristalino (multi-Si)	11
2.4.3 Silício Amorfo (a-Si)	13
2.5 Modelo da Célula Fotovoltaica	14
2.6 Princípio de Funcionamento Díodos <i>Bypass</i> (BP)	16
2.7 Características da Curva I-V de Painéis Fotovoltaicos	17
2.8 Impacto da Temperatura e Irradiância na Curva I-V	18
2.8.1 Efeito da Temperatura	19
2.8.2 Efeito da Irradiância	20
2.8.3 Fator de Forma (<i>Fill Factor</i> (FF))	20
2.8.4 Impacto do Efeito de Sombra Parcial (PSC) nas Características Fotovoltaicas	21

2.8.5	Condições Padrão de Teste (<i>Standard Test Conditions</i> (STC))	23
2.9	Conversores DC/DC	23
2.9.1	Conversor DC/DC <i>Buck</i>	24
2.10	Tipos de Baterias em Sistemas Fotovoltaicos	29
2.10.1	Baterias de Chumbo-Ácido	29
2.10.2	Fases de carregamento	29
2.11	Revisão de Literatura	30
3	Algoritmos MPPT	33
3.1	Classificação de Algoritmos MPPT	33
3.2	Algoritmos Convencionais	34
3.2.1	Perturbação e Observação (<i>Perturb and Observe</i> (P&O))	34
3.2.2	Condutância Incremental (<i>Incremental Conductance</i> (InC))	35
3.3	Algoritmo Baseado em Lógica de Controlo	37
3.3.1	Lógica Difusa (<i>Fuzzy Logic Control</i> (FLC))	37
3.4	Algoritmos de Otimização	40
3.4.1	Otimização com Algoritmo Genético (<i>Genetic Algorithm</i> (GA))	41
3.5	Algoritmos Baseados em Inteligência Artificial	42
3.5.1	<i>Artificial Neural Networks</i> (<i>Artificial Neural Networks</i> (ANN))	42
3.5.2	<i>Deep Reinforcement Learning</i> (DRL) para Sistemas Fotovoltaicos	45
3.6	Comparação de Algoritmos <i>Maximum Power Point Tracking</i> (MPPT)	49
3.6.1	CrITÉRIOS de Comparação	49
3.6.2	Métricas de avaliação	51
4	Arquitetura do Sistema	55
4.1	Arquitetura Geral do Sistema	55
4.2	Características do Painel Fotovoltaico	56
4.3	Cálculos Iniciais do Painel Fotovoltaico	57
4.4	Dimensionamento dos Componentes do Conversor DC/DC <i>Buck</i> para Simulação	59
4.4.1	Razão Cíclica (<i>Duty Cycle</i>)	60
4.4.2	Cálculo do Indutor	60
4.4.3	Cálculo Condensador de Saída	60
5	Implementação	61
5.1	Controlo do Sistema MPPT com um Painel Fotovoltaico	61
5.2	Controlo do Sistema MPPT com Três Grupos de Células Fotovoltaicas Conectadas em Série	62
5.3	Parâmetros de Simulação Simulink	63
5.4	Algoritmos Convencionais	63
5.5	Lógica Difusa (FLC)	65

5.5.1	Fuzzificação	65
5.5.2	Inferência <i>Fuzzy</i>	66
5.5.3	Defuzzificação	67
5.6	Algoritmos Híbridos	68
5.6.1	Perturbação Observação (P&O) com Algoritmo Genético (GA)	68
5.6.2	Condutância Incremental (InC) com Algoritmo Genético (GA)	70
5.6.3	Condutância Incremental (InC) com Perturbação Observação (P&O)	70
5.7	Algoritmo ANN	71
5.7.1	<i>Dataset</i>	71
5.7.2	Treino da Rede Neuronal	74
5.8	Algoritmo ANN em PSC	79
5.8.1	Adaptação do <i>Dataset</i> para PSC	79
5.8.2	Treino da Rede Neuronal para PSC	80
5.9	Algoritmo <i>Deep Q-Network</i> (DQN)	82
5.9.1	Arquitetura do Agente DQN	82
5.9.2	Estrutura da <i>Critic Network</i>	86
5.9.3	Parâmetros de simulação DQN	88
5.9.4	Processo de Treino com o Método DQN	90
5.10	Cenários Simulados em Diferentes Condições Meteorológicas	91
5.10.1	Análise das Curvas I-V e P-V em Condições PSC	93
6	Testes e Análise de Resultados	95
6.1	<i>Setup</i> do <i>Hardware</i>	95
6.2	Testes e Análise de Resultados - Cenários com Apenas um Díodo <i>Bypass</i>	95
6.2.1	Cenário 1	96
6.2.2	Cenário 2	98
6.2.3	Cenário 3	100
6.2.4	Cenário 4	101
6.3	Testes e Análise de Resultados - Cenários PSC	102
6.3.1	Cenário PSC 1	103
6.3.2	Cenário PSC 2	105
6.3.3	Cenário PSC 3	106
6.3.4	Cenário PSC 4	107
6.4	Análise Comparativa dos Algoritmos	110
6.4.1	Análise dos Tempos de Simulação	111
7	Conclusões	113
7.1	Trabalho Futuro	113
	Referências	115

Lista de Figuras

2.1	Sistema <i>Off-grid</i>	6
2.2	Sistema <i>On-grid</i>	7
2.3	Estrutura de um módulo painel fotovoltaico	9
2.4	Célula fotovoltaica cristalina em três dimensões	10
2.5	Disposição dos átomos de silício numa célula	10
2.6	Comparação entre painel e célula de silício monocristalino	11
2.7	Comparação entre painel e célula de silício policristalino	12
2.8	Comparação entre painel e célula de silício amorfo	13
2.9	Circuito elétrico equivalente célula painel fotovoltaico.	14
2.10	Painel Fotovoltaico com Sombra Parcial em apenas uma célula.	17
2.11	Estados de operação das células com <i>Bypass</i> (BP).	17
2.12	Curva de características I-V célula fotovoltaica	18
2.13	Efeito da irradiância e temperatura no comportamento da curva I-V	19
2.14	<i>Fill Factor</i>	21
2.15	Efeito de sombra parcial nas curvas características	22
2.16	Esquema elétrico do conversor DC/DC <i>buck</i>	24
2.17	Formas de onda conversor <i>buck</i>	26
2.18	Primeira etapa de operação do conversor DC/DC <i>buck</i> em modo <i>Continuous Conduction Mode</i> (CCM).	26
2.19	Segunda etapa de operação do conversor DC/DC <i>buck</i> em modo CCM.	27
2.20	Ciclo de carregamento de uma bateria chumbo-ácido.	30
3.1	Fluxograma do algoritmo P&O MPPT	35
3.2	Curva P-V: Relação entre o declive e a posição do <i>Maximum Power Point</i> (MPP).	36
3.3	Fluxograma do algoritmo InC MPPT.	37
3.4	Diagrama da lógica difusa.	38
3.5	Função de pertinência triangular e trapezoidal.	40
3.6	Funcionamento do algoritmo genético.	42
3.7	Modelo de neurónio <i>Artificial Neural Networks</i> (ANN).	43
3.8	Arquitetura de rede neuronal.	43
3.9	Fluxograma do processo de treino	45
3.10	Diagrama da interação agente-ambiente.	46

3.11	Taxonomia dos algoritmos em <i>Reinforcement Learning</i> (RL).	46
3.12	Diagrama do agente <i>Deep Q-Network</i> (DQN).	49
4.1	Diagrama de blocos do sistema MPPT.	56
4.2	SOLARPOWER XUNZEL 30W 24V	57
4.3	Curvas I-V e P-V do SOLARPOWER 30W 24V.	57
4.4	Diagrama conversor DC/DC <i>buck</i> .	59
5.1	Modelo Simulink com painel fotovoltaico e conversor DC/DC.	62
5.2	Parâmetros do painel fotovoltaico definidos no Simulink.	63
5.3	Modelo Simulink com três grupos de células fotovoltaicas conectadas em série.	64
5.4	Parâmetros em cada grupo de células fotovoltaicas definidos no Simulink.	65
5.5	Funções de pertinência triangulares para as variáveis de entrada: erro (E) e derivada do erro (dE)	66
5.6	(a) Função de pertinência de saída para a variação do <i>duty cycle</i> (ΔD) e (b) Superfície de controlo <i>fuzzy</i>	67
5.7	Algoritmo <i>Genetic Algorithm</i> (GA)+ <i>Perturb and Observe</i> (P&O).	69
5.8	Diagrama de blocos do sistema de controlo baseado na rede neuronal e controlador PI.	71
5.9	Gráficos da variação ao longo do tempo do perfil de temperatura e irradiância.	72
5.10	Modelo Simulink para recolha dos dados de treino.	72
5.11	Arquitetura da rede neuronal MATLAB.	75
5.12	Resultados do treino da rede neuronal.	77
5.13	Modelo Simulink com rede neuronal.	78
5.14	Distribuição de irradiância nos três grupos de células	80
5.15	Modelo Simulink para recolha dos dados de treino em PSC.	81
5.16	Resultados do treino da rede neuronal	82
5.17	Bloco <i>Function Fitting Neural Network</i> aplicado no modelo.	82
5.18	Controlo <i>Maximum Power Point Tracking</i> (MPPT) baseado em RL.	83
5.19	Estrutura <i>Critic Network</i> .	86
5.20	Processo de treino pelo método DQN.	90
5.21	Perfis de irradiância e temperatura nos cenários.	92
5.22	Perfis de irradiância em cenários de PSC com $T = 25\text{ }^{\circ}\text{C}$.	93
5.23	Curvas características I-V e P-V dos quatro cenários PSC com $T = 25\text{ }^{\circ}\text{C}$.	94
6.1	Tempos de convergência dos algoritmos ANN e DQN.	96
6.2	Comparação tempos de convergência dos restantes algoritmos.	97

6.4	Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 1: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.	97
6.3	Resultados do Cenário 1 para os restantes algoritmos: (a) Saída de potência (P_o); (b) <i>Duty Cycle</i>	98
6.5	Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 2: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.	99
6.6	Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 3: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.	101
6.7	Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 4: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.	102
6.8	Potência de saída dos algoritmos.	102
6.9	(a) Dados de P_o e (b) Dados da potência de entrada P_{pv} separados no Cenário 4.	104
6.10	Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 1 PSC: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.	105
6.11	Comparação dos erros: (a) ANN e (b) DQN no intervalo de 0,5 segundos.	105
6.12	Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 2 PSC: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.	106
6.13	Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 3 PSC: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.	107
6.14	Dados de P_o separados no Cenário 3.	108
6.15	(a) Dados de P_o e (b) Dados da potência de entrada P_{pv} separados no Cenário 4.	109
6.16	Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 4 PSC: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.	110
7.1	Diagrama de blocos do sistema MPPT.	114

Lista de Tabelas

1.1	Calendarização por semanas.	3
2.1	Comparação direta entre sistemas fotovoltaicos.	7
2.2	Comparação entre tipos de células fotovoltaicas.	14
3.1	Classificação dos Algoritmos MPPT.	34
3.2	Resposta do sistema de controlo para cada caso do algoritmo P&O. . .	35
3.3	Tabela de regras FLC.	39
3.4	Etapas de um algoritmo genético.	41
3.5	Critérios de comparação de algoritmos MPPT.	50
4.1	Especificações Pannel Fotovoltaico.	58
4.2	Resultados dos cálculos do conversor.	59
5.1	Parâmetros dos algoritmos P&O e InC.	65
5.2	Base de regras <i>fuzzy</i> para ΔD (variação do <i>duty cycle</i>) com variáveis linguísticas	67
5.3	Parâmetros do Algoritmo Genético.	70
5.4	Estatísticas das variáveis em cada um dos gráficos.	73
5.5	Parâmetros da rede neuronal.	75
5.6	Comparação de configurações de neurónios nas camadas ocultas. . .	76
5.7	Resultados para Tensão (V_{mp})	78
5.8	Resultados para Potência (P_{mp})	79
5.9	Estatísticas das variáveis em cada um dos gráficos.	79
5.10	Resultados das previsões de V_{mp} e P_{mp} para diferentes cenários. . . .	83
5.11	Camadas da rede do crítico.	87
5.12	Parâmetros do agente DQN.	88
5.13	Parâmetros de treino do agente DQN.	89
5.14	Resumo do treino com o agente <i>rlDQNAgent</i>	91
5.15	Cenários do painel fotovoltaico com apenas um diódo <i>bypass</i>	91
5.16	Cenários PSC do painel fotovoltaico com três díodos <i>bypass</i>	93
6.1	Especificações do <i>hardware</i> utilizado.	96
6.2	Métricas de avaliação para o Cenário 1.	98
6.3	Métricas de avaliação para o Cenário 2.	99

6.4	Métricas de avaliação para o Cenário 3.	100
6.5	Métricas de avaliação para o Cenário 4.	101
6.6	Métricas de avaliação para o Cenário PSC 1.	103
6.7	Métricas de avaliação para o Cenário PSC 2.	106
6.8	Métricas de avaliação para o Cenário PSC 3.	107
6.9	Métricas de avaliação para o Cenário PSC 4.	108
6.10	Comparação dos Algoritmos MPPT.	111
6.11	Tempos de execução dos algoritmos MPPT ordenados (valores em minutos)	111

Listagens

5.1	Operador de implicação Mamdani no código	66
-----	--	----

Lista de Acrónimos

AF	<i>Activation Function</i>
AM	<i>Air Mass</i>
ANN	<i>Artificial Neural Networks</i>
BP	<i>Bypass</i>
CA	Corrente Alternada
CC	Corrente Contínua
CCM	<i>Continuous Conduction Mode</i>
COA	<i>Center of Area</i>
COG	<i>Center of Gravity</i>
DDPG	<i>Deep Deterministic Policy Gradient</i>
DL	<i>Deep Learning</i>
DQN	<i>Deep Q-Network</i>
DRL	<i>Deep Reinforcement Learning</i>
EVA	<i>Ethyl Vinyl Acetate</i>
FF	<i>Fill Factor</i>
FLC	<i>Fuzzy Logic Control</i>
GA	<i>Genetic Algorithm</i>
GMPP	<i>Global Maximum Power Point</i>
IAE	<i>Integral Absolute Error</i>
InC	<i>Incremental Conductance</i>
ISE	<i>Integral Squared Error</i>
LMPP	<i>Local Maximum Power Point</i>

MAE	<i>Mean Absolute Error</i>
MCM	<i>Max Criterion Method</i>
MDP	<i>Markov Decision Process</i>
MPP	<i>Maximum Power Point</i>
MPPT	<i>Maximum Power Point Tracking</i>
MSE	<i>Mean Squared Error</i>
NOCT	<i>Nominal Operating Cell Temperature</i>
P&O	<i>Perturb and Observe</i>
PSC	<i>Partial Shading Conditions</i>
PWM	<i>Pulse Width Modulation</i>
RL	<i>Reinforcement Learning</i>
SDM	<i>Single Diode Model</i>
STC	<i>Standard Test Conditions</i>

Capítulo 1

Introdução

Atualmente, num mundo cada vez mais consciente dos desafios energéticos e ambientais, a energia solar fotovoltaica assume um papel fundamental na transição para um paradigma energético sustentável. A crise climática global, aliada à crescente escassez de recursos fósseis, tem impulsionado a adoção de soluções renováveis, posicionando a tecnologia fotovoltaica como principal elemento nas estratégias de descarbonização a nível mundial. Neste contexto, os sistemas fotovoltaicos emergem como uma alternativa viável, não apenas pela sua capacidade de gerar energia limpa, mas também pela versatilidade de aplicação, desde pequenas instalações residenciais até grandes centrais de produção.

1.1 Contextualização

A eficiência dos sistemas fotovoltaicos está diretamente associada à capacidade de extrair a potência máxima disponível dos painéis fotovoltaicos, um desafio que se torna complexo devido à variação das condições ambientais, tais como a irradiância, temperatura e efeito de sombra parcial. Deste modo, para superar estas limitações, algoritmos MPPT têm sido amplamente estudados e implementados, com o objetivo de otimizar o desempenho dos painéis através do ajuste dinâmico do ponto de operação.

A integração de algoritmos de inteligência artificial na otimização de sistemas fotovoltaicos representa um avanço significativo, permitindo não só uma resposta mais rápida e precisa às variações ambientais, mas também a adaptação a cenários

complexos, como por exemplo, em sombras parciais ou degradação dos painéis fotovoltaicos. Esta dissertação explora a aplicação destes algoritmos referidos, combinando modelos de simulação em MATLAB/Simulink com técnicas avançadas de controlo, e uma análise comparativa entre as técnicas propostas.

1.2 Objetivos

O principal objetivo desta dissertação consiste em desenvolver modelos de simulação para painéis fotovoltaicos e implementar algoritmos de inteligência artificial para otimização do desempenho através de técnicas MPPT. Desta forma, o foco será na criação de modelos Simulink no *software* MATLAB que permitam simular e controlar o comportamento de sistemas fotovoltaicos, integrando diversas abordagens de monitorização do ponto máximo de potência (MPPT). Será realizada uma análise comparativa entre algoritmos MPPT convencionais e métodos baseados em inteligência artificial, bem como o estudo de um conversor DC/DC *buck*. As simulações irão abranger diversas condições ambientais, incluindo variações de irradiância, temperatura e sombras parciais, com o objetivo de avaliar o comportamento do sistema em diferentes situações.

1.3 Organização da Dissertação

Esta dissertação está estruturada em sete capítulos, que refletem a progressão do trabalho desenvolvido. No primeiro capítulo, é apresentada a introdução ao tema, incluindo a contextualização, os objetivos principais e a calendarização do projeto.

O segundo capítulo corresponde ao estado da arte, onde é explorada a fundamentação teórica dos sistemas fotovoltaicos, os diversos tipos de painéis solares, o efeito fotovoltaico, os modelos matemáticos das células, bem como as principais topologias de conversores DC/DC e a sua relação com os algoritmos MPPT.

No terceiro capítulo, são abordadas as técnicas de monitorização do ponto de máxima potência, classificando os algoritmos MPPT em várias categorias, com especial destaque para aqueles baseados em inteligência artificial.

O quarto capítulo descreve a arquitetura do sistema proposto, incluindo o dimensionamento dos componentes, a implementação dos algoritmos no *software* MATLAB/Simulink e os detalhes do modelo baseado em inteligência artificial.

O quinto capítulo apresenta a implementação dos algoritmos MPPT, enquanto no sexto capítulo é realizada a análise dos resultados obtidos, avaliando o desempenho do sistema sob diferentes cenários.

Por fim, o sétimo e último capítulo sintetiza as conclusões do que foi desenvolvido nesta dissertação e trabalhos futuros propostos.

Capítulo 2

Estado da Arte

Este capítulo tem como objetivo apresentar os conceitos básicos, tecnologias e componentes fundamentais dos sistemas fotovoltaicos. Inicialmente, são abordados os sistemas fotovoltaicos, a constituição dos painéis fotovoltaicos, efeito fotovoltaico, e o funcionamento em detalhe das células fotovoltaicas, incluindo os diferentes tipos de células e os respetivos modelos matemáticos que descrevem o comportamento elétrico. Posteriormente, são descritas as características da curva I-V dos painéis fotovoltaicos e os impactos da temperatura e irradiância. Por último, é realizada uma análise das topologias de conversores DC/DC utilizados nestes sistemas fotovoltaicos, realçando características e aplicações.

2.1 Sistema Fotovoltaico

Atualmente, existem diferentes tipos de sistemas fotovoltaicos que oferecem soluções energéticas adaptadas a uma variedade de necessidades e condições. Desta forma, é possível selecionar a configuração mais adequada consoante a localização, requisitos energéticos e viabilidade económica.

Os sistemas fotovoltaicos dividem-se fundamentalmente em duas categorias distintas:

- Sistemas isolados - **Sistemas *Off-Grid***;
- Sistemas conectados à rede - **Sistemas *On-Grid***.

2.1.1 Sistema *Off-Grid*

Os sistemas *Off-Grid*, operam de forma independente, não estando conectados à rede principal, sendo ideais para locais remotos ou onde a conexão à rede é inviável. Além de proporcionar autossuficiência energética e redução das contas de eletricidade, a energia solar *off-grid* também tem um impacto positivo no meio ambiente, uma vez que é uma fonte de energia limpa e renovável. No entanto, a instalação deste tipo de sistema envolve custos iniciais, que devem ser ponderados em relação aos benefícios a longo prazo trazidos pelo sistema *off-grid* [1].

Um dos aspetos mais relevantes dos sistemas solares autónomos é a possibilidade de armazenar a energia gerada em baterias, para posterior uso em horários de baixa ou nenhuma incidência solar. Isto garante que o sistema possa fornecer energia mesmo em períodos de pouca luz.

Um sistema *Off-Grid* é composto por alguns componentes, tais como [1]:

- **Módulos fotovoltaicos:** São responsáveis pela conversão da radiação solar em energia elétrica (Corrente Contínua (CC)).
- **Controlador de carga MPPT:** É um dispositivo que regula o fluxo de energia entre os painéis solares e as baterias, protegendo-as de sobrecargas e descargas excessivas.
- **Baterias:** Armazenam a energia gerada pelos painéis solares para uso posterior, garantindo autonomia do sistema mesmo em períodos de baixa irradiação solar.
- **Inversor:** Converte a corrente contínua (CC) produzida pelo sistema em Corrente Alternada (CA) para alimentar equipamentos de CA.

Na Figura 2.1 está representado um diagrama com uma configuração básica com baterias 12 V em série, controlador de carga MPPT com saída para cargas DC, e inversor para fornecer energia a equipamentos AC, como por exemplo um computador.




Figura 2.1: Sistema *Off-grid* [2].

2.1.2 Sistema *On-Grid*

Um sistema fotovoltaico *On-Grid*, está conectado à rede elétrica pública, permitindo a troca de energia entre a instalação fotovoltaica e a rede. Quando os painéis produzem mais energia do que a necessária para o consumo local, o excedente é injetado na rede, podendo ser compensado através de mecanismos como o regime de autoconsumo ou a venda de energia. Em contrapartida, quando a produção é insuficiente, a energia é obtida da rede convencional. Assim sendo, este tipo de sistema não requer o uso de baterias, podendo reduzir os custos de instalação e manutenção. Na Figura 2.2 está ilustrado os componentes essenciais neste sistema, que incluem os painéis fotovoltaicos, um inversor *on-grid* (que sincroniza a energia produzida com a rede) e um contador bidirecional. Contudo, este é um sistema ideal para zonas urbanas ou locais com acesso estável à rede, contribuindo para a redução da fatura energética e para a sustentabilidade ambiental [1].




Figura 2.2: Sistema *On-grid* [3].

Na Tabela 2.1 está apresentada uma comparação entre os dois tipos de sistemas referidos.

Tabela 2.1: Comparação direta entre sistemas fotovoltaicos.

Característica	<i>Off-Grid</i>	<i>On-Grid</i>
Conexão à rede	Não	Sim
Armazenamento	Baterias	Não necessário
Custo inicial	Alto	Médio
Manutenção	Complexa	Simples
Aplicação típica	Zonas remotas	Zonas urbanas

2.2 Painele Fotovoltaico

Um painele fotovoltaico é a associação de células fotovoltaicas em série e/ou em paralelo, que têm como material base o silício.

A composição e a estrutura dos módulos fotovoltaicos de silício cristalino é fundamental, uma vez que apresentam um formato multicamada, onde cada camada desempenha funções específicas para proteção e outras funcionalidades. Esta secção explora a composição dos painéis solares de silício cristalino, analisando a função e a importância de cada componente.

De maneira a manter a eficiência dos módulos fotovoltaicos, preservar a sua estrutura e proteger os seus componentes em condições meteorológicas exteriores, tais como a precipitação, poeiras e o desgaste causado pela exposição, é necessário incluir alguns materiais na sua composição.

Desta forma, no esquema da Figura 2.3 estão representados os componentes incluídos na estrutura de um módulo fotovoltaico, nomeadamente [4]:

- **Moldura (*Frame*):** Feita principalmente de alumínio, oferece um suporte estrutural, permitindo que o painele resista a pressões ambientais, como por exemplo, vento e neve. Ainda assim, contribui significativamente para o peso total do painele;
- **Vidro Frontal (*Front Glass*):** É composto por vidro temperado que funciona como uma camada de proteção, tendo o objetivo de proteger as células de fatores ambientais, permitindo a penetração ideal da luz solar. É essencial para manter a funcionalidade das células e prevenir perdas de eficiência devido a danos externos;
- **Encapsulantes (*Encapsulants*):** São compostos principalmente por acetato de etileno vinilo (*Ethyl Vinyl Acetate* (EVA)), protegem as células, fornecem isolamento elétrico e funcionam como barreira contra humidade. Estes compostos são aplicados como camadas finas e polimerizados a 150 °C para solidificar a estrutura do módulo;
- **Células de Silício (*Solar Cells*):** As células de silício, monocristalinas ou policristalinas, convertem a luz solar em eletricidade, e são aplicadas camadas como a junção n-p e um revestimento antirrefletor para otimizar o desempenho;
- **Filme Traseiro (*Backing film*):** Estão posicionadas atrás das células de silício, e fornecem isolamento e proteção externa, podendo existir diferentes tipos, como por exemplo, duplo fluoropolímero e não fluoropolímero, que afetam o custo e o desempenho do painele;
- **Caixa de Junção (*Junction Box*):** Localizada na parte traseira, nesta caixa de junção estão presentes os componentes elétricos essenciais para a recolha e

transferência de eletricidade. Inclui díodos de *bypass* para prevenir perdas de energia e a danificação das células fotovoltaicas devido a sombras parciais;

- Revestimento Anti-Refletor (*Anti-Reflective Coating*): Este revestimento aumenta a absorção da luz solar, minimizando a perda por reflexão, garantindo que a quantidade máxima de luz atinja as células, para melhorar a eficiência do painel.




Figura 2.3: Estrutura de um módulo painel fotovoltaico [4].

2.3 Efeito Fotovoltaico

O efeito fotovoltaico ocorre em materiais semicondutores, que se caracterizam pela presença de bandas de energia, designadas por banda de valência e banda de condução. Na banda de valência, encontram-se os elétrons associados aos átomos, enquanto a banda de condução é descrito pela região para onde os elétrons de valência se deslocam quando são libertados da banda de valência. Esta transição de elétrons da banda de valência para a banda de condução é denominada por condução elétrica.

2.3.1 Junção P-N e Funcionamento da Célula Fotovoltaica

As células típicas de silício mono ou policristalino são formadas por uma junção semicondutores P-N, onde a região p é uma região dopada com impurezas aceitadoras e a região n é a região dopada com impurezas dadoras [5]. Desta forma, célula fotovoltaica converte radiação proveniente da incidência de luz solar em energia elétrica, sendo este um processo que pode ser explicado através do princípio de funcionamento da junção P-N ilustrado na Figura 2.4.

Na Figura 2.5 está representada a disposição dos átomos de silício numa célula fotovoltaica, onde a camada descrita com a letra P é tratada com fósforo (P), ficando com elétrons extra, representados simbolicamente pelas bolas azuis. Por outro lado, a camada representada com a letra B é tratada com boro (B), o que resulta numa




Figura 2.4: Célula solar cristalina em três dimensões [6].

carência de elétrons, originando lacunas, representadas por bolas pretas. Assim, estas duas camadas combinadas, formam a junção P-N [7].




Figura 2.5: Disposição dos átomos de silício numa célula [7].

Quando este sistema é exposto à radiação solar, a energia dos fótons é suficiente para excitar os elétrons, fazendo com que estes abandonem o seu lugar na banda de valência e se movam livremente pelo sistema, deixando lacunas na banda de valência. Devido ao campo elétrico existente na região de depleção (com sentido de n para p), onde os elétrons se deslocam apenas em direção ao lado negativo (n), enquanto as lacunas permanecem no lado positivo (p) [7].

Os elétrons livres seguem o caminho através de um circuito externo, retornando ao silício do tipo p, onde preenchem as lacunas existentes. Este movimento fecha o ciclo de circulação de cargas, gerando uma corrente elétrica.

2.4 Tipo de células fotovoltaicas

Nesta secção, serão abordados os três principais tipos de células fotovoltaicas, nomeadamente, silício monocristalino (mono-Si), silício policristalino ou multicristalino (multi-Si) e silício amorfo (a-Si). Cada uma destas tecnologias apresenta vantagens e

desvantagens, que serão descritas ao longo desta secção, permitindo uma compreensão clara das suas diferenças.

2.4.1 Silício Monocristalino (mono-Si)

Os módulos de silício monocristalino são fabricados a partir de um único cristal de silício, o que lhes confere uma estrutura uniforme e um efeito fotovoltaico próximo do ideal. Desta forma, esta característica resulta numa eficiência que ronda os 15%, apresentando uma forma quadrada com cantos arredondados tal como está ilustrado na Figura 2.6a [7].

A estrutura monocristalina caracterizada pela presença de um único tipo de cristal, é obtida através do processo *Czochralski* (Químico Polaco que inventou este processo). Neste método, o silício é fundido em conjunto com uma pequena quantidade de dopante, geralmente boro (tipo P). Posteriormente, utilizando um fragmento de cristal, vai sendo extraído do material fundido um grande cilindro de silício monocristalino levemente dopado. Por último, este cilindro é cortado em fatias finas, com espessuras de aproximadamente $300\ \mu m$, utilizadas na produção de células fotovoltaicas [5].




Figura 2.6: Comparação entre painel e célula de silício monocristalino: (a) Painel fotovoltaico monocristalino [8], (b) Detalhe da célula individual [9].

2.4.2 Silício Policristalino (multi-Si)

Os módulos de silício policristalino multicristalino, são constituídos por diversos cristais de silício tal como está apresentado na Figura 2.7a, onde no seu fabrico, vários


fragmentos de cristais de silício são derretidos e solidificados juntos até formarem um bloco [7].

A produção das células de silício policristalino é menos dispendiosa em comparação com as células de silício monocristalino, uma vez que exige um processo de preparação menos rigoroso, conseguindo obter uma eficiência que ronda os 12% [5].

O processo de fabrico das células de silício policristalino ilustrado na Figura 2.7b envolve o controlo rigoroso do aquecimento e arrefecimento do bloco de silício. Durante a solidificação unidirecional, o bloco arrefece de forma uniforme numa direção específica, com o objetivo de formar o máximo de cristais de silício homogêneos. Estes cristais apresentam dimensões de grão que variam desde alguns milímetros até vários centímetros [5].

A região fronteira entre os grãos constitui um defeito no cristal, favorecendo o fenómeno da recombinação que aumenta a resistividade do material, influenciando na eficiência das células de silício policristalinas negativamente, quando comparadas com as células monocristalinas.

Após a solidificação, são obtidos grandes blocos de silício, sendo posteriormente cortados em fatias com aproximadamente 0,3 mm de espessura. Estas fatias são submetidas a um processo de limpeza química e dopadas com fósforo. Por último, é aplicado um revestimento anti-refletor, são impressos os contactos elétricos e removidas as fronteiras, num processo semelhante ao utilizado nas células monocristalinas [5].



(a)



(b)

Figura 2.7: Comparação entre painel e célula de silício policristalino: (a) Painel fotovoltaico policristalino [8], (b) Detalhe da célula individual [10].

2.4.3 Silício Amorfo (a-Si)

Os módulos de silício amorfo ilustrados na Figura 2.8a surgiu como uma tecnologia alternativa no mercado de energia fotovoltaica com o principal propósito de competir comercialmente com as restantes tecnologias, uma vez que a sua constituição não exige uma produção tão elaborada como as opções mencionadas anteriormente. Este tipo de células representadas na Figura 2.8b possui uma eficiência na ordem dos 6% e distinguem-se das estruturas cristalinas por apresentarem um elevado grau de desordem na disposição dos átomos. A utilização de silício amorfo em painéis fotovoltaicos tem demonstrado vantagens significativas, tanto ao nível das propriedades elétricas como no processo de produção. Contudo, devido à sua elevada absorção da radiação solar na faixa do visível e à possibilidade de ser fabricado através da deposição em diversos tipos de substratos, o silício amorfo surge como uma solução de baixo custo para aplicação em sistemas solares fotovoltaicos [5].



Figura 2.8: Comparação entre painel e célula de silício amorfo: (a) Painel fotovoltaico de silício amorfo [8], (b) Detalhe da célula individual [10].

Na Tabela 2.2 está representada a comparação entre os diferentes tipos de células fotovoltaicas.

Tabela 2.2: Comparação entre tipos de células fotovoltaicas.

Característica	mono-Si	mc-Si	a-Si
Estrutura	Único cristal	Múltiplos cristais	Amorfo
Eficiência	15%	12%	6%
Custo	Elevado	Moderado	Baixo
Processo	Czochralski	Solidificação	Deposição
Vantagens	Alta eficiência	Custo moderado	Flexibilidade
Desvantagens	Custo elevado	Eficiência média	Eficiência baixa

2.5 Modelo da Célula Fotovoltaica

As células fotovoltaicas são habitualmente representadas através de um circuito elétrico equivalente, denominado por modelo de díodo único (*Single Diode Model* (SDM)), que integra apenas um díodo no circuito elétrico, sendo amplamente utilizado devido à sua simplicidade e ao bom nível de precisão que oferece. No entanto, também existem outros tipos de circuitos equivalentes propostos com dois, três ou, de forma mais genérica, "n" díodos, com o objetivo de alcançar uma maior precisão. Contudo, estes modelos apresentam uma maior complexidade de implementação e gestão, exigindo um número superior de parâmetros em comparação com o SDM [11].

A célula de um painel fotovoltaico apresenta um comportamento não linear de corrente e de potência de saída relativamente à variação da tensão de saída, dependendo da mudança de condições meteorológicas instantâneas. A potência de saída é positivamente influenciada pelo nível de irradiância ou intensidade luminosa, porém é negativamente afetada pela temperatura ambiente [12]. Na Figura 2.9 é ilustrado o circuito elétrico equivalente que representa a célula fotovoltaica. É de notar que o díodo representa a junção P-N, a resistência série (R_s) resulta da própria resistência do material semicondutor, dos contactos metálicos e da junção metal-semicondutor. Já a resistência *shunt* (R_{sh}) corresponde às impurezas e defeitos na estrutura.




Figura 2.9: Circuito elétrico equivalente célula painel fotovoltaico.

A corrente I que passa através da resistência série pode ser determinada subtraindo a corrente gerada pela luz I_L pela corrente do díodo I_D e corrente na resistência *shunt* I_{sh} , tal como está representado na Equação (2.1).

A equação principal que descreve este circuito equivalente é formulada com base na lei das correntes de *Kirchhoff* [13][14]:

$$I = I_L - I_D - I_{sh} \quad (2.1)$$

Onde:

- I_L : Corrente gerada pela luz na célula;
- I_D : Corrente no díodo;
- I_{sh} : Corrente na resistência *shunt*.

O modelo SDM descreve a corrente I_D com a equação de *Shockley* (2.2) para um díodo ideal [13][14]:

$$I_D = I_0 \left[\exp \left(\frac{V + IR_s}{nV_T} \right) - 1 \right] \quad (2.2)$$

Onde:

- I_0 : Corrente de saturação do díodo;
- n : Fator ideal do díodo;
- V_T : Tensão térmica.

V_T descrito na equação (2.3), representa o efeito da temperatura no comportamento elétrico do díodo.

$$V_T = \frac{kT}{q} \quad (2.3)$$

Onde:

- k : Constante de Boltzmann ($1,381 \times 10^{-23}$ J/K);
- q : Carga elementar ($1,602 \times 10^{-19}$ C).

A corrente na resistência *shunt* I_{sh} é retratada pela equação (2.4) [13].

$$I_{sh} = \frac{V + IR_s}{R_{sh}} \quad (2.4)$$

Combinando estas equações, a expressão completa que representa o modelo de díodo simples é descrita pela equação (2.5) [13][14]:

$$I = I_L - I_0 \left[\exp \left(\frac{V + IR_s}{nV_T} \right) - 1 \right] - \frac{V + IR_s}{R_{sh}} \quad (2.5)$$

Onde os cinco parâmetros fundamentais deste modelo são:

- I_L : Corrente gerada pela luz (A);
- I_0 : Corrente de saturação do díodo (A);
- R_s : Resistência série (Ω);
- R_{sh} : Resistência *shunt* (Ω);
- n : Fator ideal do díodo.

Para um módulo ou conjunto de células fotovoltaicas em série, assumindo que todas as células são idênticas e operam sob condições uniformes de irradiação e temperatura, a tensão total de saída do módulo fotovoltaico V_{module} pode ser representada pelo produto da tensão de saída de uma célula fotovoltaica V_{PV} pelo número de células fotovoltaicas conectadas em série N_s [13][14]:

$$V_{module} = N_s \times V_{cell} \quad (2.6)$$

$$I_{module} = I_{cell} \quad (2.7)$$

A equação para o módulo ou conjunto de módulos torna-se [13][14]:

$$I_M = I_L - I_0 \left[\exp \left(\frac{V_M + I_M R_s}{n N_s V_T} \right) - 1 \right] - \frac{V_M + I_M R_s}{R_{sh}} \quad (2.8)$$

Onde I_M e V_M são, respetivamente, a corrente e a tensão do módulo.

2.6 Princípio de Funcionamento Díodos BP

Para minimizar as perdas por efeito de sombra parcial, os módulos fotovoltaicos incorporam díodos BP conectados em paralelo mas com polaridade invertida a grupos de células em série. Estes componentes ficam localizados na caixa de junção (*junction box*), na traseira do módulo, atuando como caminho alternativo para a corrente quando uma ou mais células ficam inversamente polarizadas devido ao efeito de sombra (Figura 2.10).

Desta forma, quando uma célula é sombreada, fica no estado de polarização inversa (*reversed bias*) e faz com que o díodo correspondente entre em condução (*forward biased*), permitindo que a corrente circule através do díodo, tal como está representado na Figura 2.11. Quando a sombra é removida, a célula volta ao estado de polarização direta (*forward bias*), e o díodo retorna ao estado de polarização inversa [16][17].




Figura 2.10: Pannel Fotovoltaico com Sombra Parcial em apenas uma célula [15].




Figura 2.11: Estados de operação das células com BP [17].

Ainda assim, com ativação dos díodos BP, são criados múltiplos máximos locais na curva P-V do módulo, dificultando a identificação do ponto *Global Maximum Power Point* (GMPP).

2.7 Características da Curva I-V de Painéis Fotovoltaicos

A Figura 2.12 ilustra a variação da curva I-V, onde é possível identificar três pontos de operação fundamentais que caracterizam o desempenho de um painel fotovoltaico, nomeadamente:

- **Ponto I_{sc} :** Caracterizado pela corrente de curto-circuito, que representa a corrente máxima que o painel consegue gerar quando a tensão nos terminais é nula. Este é um valor que depende do nível de radiação solar incidente.

- **Ponto V_{oc} :** Caracterizado pela tensão em circuito aberto, corresponde ao valor de tensão obtido nos terminais do painel fotovoltaico quando a corrente nos terminais é nula.
- **Ponto MPP:** Denominado Ponto de Máxima Potência (MPP), onde o painel opera com a máxima eficiência, fornecendo a máxima potência possível ($P_{max} = V_{mp} \times I_{mp}$).




Figura 2.12: Curva de características I-V célula fotovoltaica [18].

O conceito de MPPT refere-se à técnica utilizada para garantir que o painel fotovoltaico opere sempre no ponto de máxima potência (MPP), independentemente das variações nas condições de irradiância e temperatura. A Figura 2.12 ilustra a localização do MPP na curva I-V.

2.8 Impacto da Temperatura e Irradiância na Curva I-V

Em condições reais, os valores dos parâmetros medidos são influenciados por variações de temperatura e irradiância, onde cada conjunto de medições distintas resulta numa curva característica corrente-tensão (I-V) única.

A consequência mais notória das variações na irradiância, tal como ilustrado na Figura 2.13a, é o aumento linear da corrente de curto-circuito (I_{SC}) à medida que a irradiância aumenta, sendo visível de igual forma um ligeiro aumento da tensão de circuito aberto. Por outro lado, o principal efeito do aumento da temperatura na célula fotovoltaica é a redução linear da tensão de circuito aberto, tal como está demonstrado na Figura 2.13b. Além disso, este é um comportamento que resulta numa diminuição da eficiência da célula, uma vez que a tensão decresce com o aumento da temperatura [19].




Figura 2.13: Efeito da irradiância e temperatura no comportamento da curva I-V: (a) Efeito da Irradiância, (b) Efeito da Temperatura.

2.8.1 Efeito da Temperatura

A tensão no ponto de máxima potência (V_{mp}) e a potência máxima (P_{mp}) de um painel solar são significativamente influenciados pela temperatura. Com o aumento da temperatura, a tensão no ponto máximo de potência diminui, afetando diretamente a potência máxima do painel, tal como representado anteriormente na Figura 2.13b [19].

O cálculo da tensão no ponto de máxima potência ($V_{mp,T}$) é descrito pela equação (2.9) [20]:

$$V_{mp,T} = V_{mp,ref} + \beta_{V_{oc}} \times (T - T_{ref}) \quad (2.9)$$

Onde:

- $V_{mp,T}$: Tensão no ponto de máxima potência à temperatura T (V);
- $V_{mp,ref}$: Tensão no ponto de máxima potência em condições de referência (V);
- $\beta_{V_{oc}}$: Coeficiente de temperatura da tensão de circuito aberto definido nas características de cada painel fotovoltaico (V/°C);
- T : Temperatura atual do painel (°C);
- T_{ref} : Temperatura de referência (25°C).

É de notar, que durante o processo de conversão da energia solar em energia elétrica, verifica-se um aumento da temperatura na superfície da célula fotovoltaica, que é dissipada sob a forma de calor. Desta forma, a temperatura da célula fotovoltaica pode ser estimada utilizando a seguinte equação [21]:

$$T_c = T_a + \frac{NOCT - 20}{800} \cdot G_c \quad (2.10)$$

Onde:

- T_c - Temperatura da célula fotovoltaica [$^{\circ}\text{C}$];
- T_a - Temperatura ambiente [$^{\circ}\text{C}$];
- G_c - Intensidade da radiação solar na célula [W/m^2];
- *Nominal Operating Cell Temperature* (NOCT) – Temperatura nominal de operação da célula (normalmente dado pelo fabricante).

2.8.2 Efeito da Irradiância

A corrente gerada por um painel solar (I_L) depende principalmente da irradiância (G), a quantidade de luz que incide sobre o painel fotovoltaico. Quanto maior for a irradiância, maior será a corrente gerada, porém, a corrente também é ligeiramente influenciada pela temperatura tal como está demonstrado na Figura 2.13b.

A relação entre a corrente, a irradiância e a temperatura é dada pela equação (2.11) [20]:

$$I_L = \frac{G}{G_{ref}} (I_{L,ref} + \alpha_{ISC}(T - T_{ref})) \quad (2.11)$$

Onde:

- I_L : Corrente gerada pela luz incidente no painel fotovoltaico;
- G : Irradiância atual (W/m^2);
- G_{ref} : Irradiância de referência ($1000 \text{ W}/\text{m}^2$);
- $I_{L,ref}$: Corrente em condições de referência (irradiância G_{ref} e temperatura T_{ref});
- α_{ISC} : Coeficiente de temperatura da corrente de curto-circuito;
- T : Temperatura atual do painel ($^{\circ}\text{C}$);
- T_{ref} : Temperatura de referência (25°C).

A equação (2.11) mostra que a corrente é diretamente proporcional à irradiância, mas também é ligeiramente influenciada pela temperatura.

2.8.3 Fator de Forma (*Fill Factor* (FF))

O Fator de forma caracteriza o desempenho da célula fotovoltaica, sendo definido pelo quociente entre a potência máxima (P_{MAX}) que a célula pode fornecer à carga e a potência no ponto (I_{sc} , V_{oc}), definido pela seguinte equação [21]:

$$FF = \frac{V_{mp} \cdot I_{MP}}{V_{oc} \cdot I_{sc}} \quad (2.12)$$

A qualidade de uma célula fotovoltaica reflete-se diretamente no valor da relação entre potências, cujo resultado tende para a unidade. O fator de forma (FF) representado no gráfico da Figura 2.14, apresenta uma pequena variação entre diferentes células fotovoltaicas, com valores compreendidos entre 0,7 e 0,8 para a grande maioria das células de semicondutores cristalinos [21].




Figura 2.14: *Fill Factor*.

A eficiência do sistema fotovoltaico pode ser calculada com base na potência máxima (P_{MAX}), parâmetro que traduz a razão entre a energia elétrica produzida pela célula e a radiação solar incidente na mesma. Deste modo, a eficiência de um módulo ou célula fotovoltaica é expressa pela seguinte equação [21]:

$$\eta(\%) = 100 \cdot \frac{P_{MAX}}{A \cdot G_C} \quad (2.13)$$

Onde:

- P_{MAX} : é a potência máxima capaz de ser gerada pelo módulo (W);
- A : é a área útil do módulo (m^2);
- G_C : é a irradiância no módulo (W/m^2).

2.8.4 Impacto do Efeito de Sombra Parcial (*Partial Shading Conditions* (PSC)) nas Características Fotovoltaicas

Os painéis fotovoltaicos apresentam um comportamento não linear e o seu desempenho depende dos algoritmos MPPT utilizados. No entanto, diversos fatores externos podem comprometer o desempenho do painel, tais como:

- Perturbações atmosféricas (nuvens, nevoeiro);
- Obstáculos físicos (vegetação, estruturas arquitetónicas);
- Deposição de materiais (neve, poeiras, folhas);
- Degradação ou sujidade dos módulos.

Estes fenómenos resultam numa distribuição não uniforme da radiação solar sobre a superfície dos painéis, criando o fenómeno conhecido por PSC.

As curvas tensão-corrente (V-I) e potência-corrente (P-I) de um sistema fotovoltaico em condições de irradiação homogénea e sombra parcial estão apresentadas na Figura 2.15.




Figura 2.15: Efeito de sombra parcial nas características elétricas de painéis fotovoltaicos: (a) Curva V-I [22], (b) Curva P-I [22].

A curva V-I ilustrada na Figura 2.15a apresenta uma variação suave e a curva P-I mostra apenas um único máximo no caso de irradiação uniforme. Em condições de sombra parcial, a curva V-I apresenta um comportamento em degraus e diferentes pontos de potência máxima surgem na curva P-I apresentada na Figura 2.15b, resultando em características fotovoltaicas mais complexas [22].

Se o controlador MPPT detetar automaticamente máximos locais durante o efeito de sombra parcial, a eficiência do painel fotovoltaico diminui significativamente, uma vez que a potência nos máximos locais é inferior à do máximo global. Na Figura 2.15 estão representados dois máximos locais para a radiação solar não uniforme, e um ponto que corresponde ao máximo global denominado por GMPP [22].

2.8.5 Condições Padrão de Teste (*Standard Test Conditions* (STC))

Para possibilitar a comparação entre diferentes células ou módulos fotovoltaicos, são especificadas condições uniformes para a leitura de parâmetros elétricos, a partir dos quais é calculada a curva característica V-I da célula. Estas condições, conhecidas como condições de teste padrão (STC) onde a potência da célula é máxima, estão relacionadas com as normas IEC 60904/DIN EN 60904, em que [23]:

- Irradiância vertical E de 1000 W/m^2 ;
- Temperatura da célula T de 25°C , com uma tolerância de $\pm 2^\circ\text{C}$;
- Espectro de luz definido (distribuição espectral da irradiância solar de referência, conforme a norma IEC 60904-3) com uma massa de ar $AM = 1,5$. É de referir que o valor de massa de ar refere-se à intensidade e distribuição espectral resultante da distância percorrida pela luz solar através da atmosfera. O valor de 1 *Air Mass* (AM) indica que o sol se encontra perpendicular a superfície terrestre. Porém, o valor de 1,5 AM indica que a posição do sol está de tal forma que a distância percorrida pela luz solar é 1,5 vezes maior [21].

2.9 Conversores DC/DC

Estes conversores são amplamente utilizados em aplicações como sistemas fotovoltaicos, carregamento de baterias e alimentação de dispositivos eletrônicos. Abaixo, estão descritos dois principais de conversores DC/DC utilizados:

- **Conversores DC/DC *Buck*:** É um conversor abaixador de tensão, que gera à saída um sinal de tensão DC de igual valor ou inferior ao da entrada. Em sistemas fotovoltaicos, estes conversores são frequentemente integrados com algoritmos MPPT para ajustar a tensão do painel solar no ponto (MPP). Esta integração permite maximizar a eficiência do sistema, garantindo que o painel realize a operação sempre no ponto ótimo, independentemente das variações de irradiação e temperatura [24].
- **Conversores DC/DC Bidirecionais *Buck-Boost*:** Estes conversores são capazes de aumentar (*boost*) ou reduzir (*buck*) a tensão de entrada, conforme necessário. Deste modo, esta capacidade bidirecional permite o fluxo de energia em ambos os sentidos, sendo particularmente útil em aplicações tais como o armazenamento de energia em baterias, onde esta pode ser carregada ou descarregada conforme a necessidade.

2.9.1 Conversor DC/DC *Buck*

O princípio de funcionamento do conversor *buck* ilustrado na Figura 2.16 envolve a transferência controlada de energia da entrada para a saída através de interruptores (*switch*), um indutor e um condensador. Um *high-side switch* (MOSFET) e um *low-side switch* (diodo) são utilizados no conversor para controlar o fluxo de corrente através do indutor. Desta forma, ao ajustar a razão cíclica do *high-side switch*, a tensão de saída média pode ser regulada proporcionalmente à tensão de entrada [13][25].




Figura 2.16: Esquema elétrico do conversor DC/DC *buck*.

Para o conversor o modo selecionado foi o *Continuous Conduction Mode* (CCM), neste caso a corrente que flui através do indutor nunca cai a zero durante todo o ciclo de comutação, resultando numa ondulação de tensão de saída inferior e numa operação mais estável. Desta forma, garante que o indutor armazene e liberte energia de forma contínua ao longo do ciclo, enquanto a tensão de saída é determinada principalmente pela razão cíclica do *high-side switch* e pela tensão de entrada [13][25].

O funcionamento do conversor *buck* pode ser dividido em duas etapas principais, alternam continuamente para regular a tensão de saída. Estas etapas são controladas pelo estado do interruptor principal (MOSFET) e do diodo.

Funcionamento Contínuo e Controlo com *Pulse Width Modulation* (PWM)

O controlo do conversor baseia-se na repetição cíclica de duas etapas principais, operando a uma frequência de comutação elevada, tipicamente na ordem dos *kHz*. Este processo é detalhado da seguinte forma:

- **Primeira etapa:** O interruptor principal permanece ligado durante um intervalo de tempo t_{on} , sendo calculado com base no período de comutação T_s e na razão cíclica D [26]:

$$t_{on} = D \cdot T_s \quad (2.14)$$

Onde D representa a razão cíclica.

- **Segunda etapa:** O interruptor principal encontra-se desligado durante o intervalo t_{off} , que corresponde ao restante período de comutação designado por T_s . Este intervalo é determinado por [26]:

$$t_{off} = (1 - D) \cdot T_s \quad (2.15)$$

- **Regulação da tensão de saída:** A tensão de saída V_{out} é regulada pela relação entre a razão cíclica D e a tensão de entrada V_{in} [26]. Desta forma, para determinar a razão cíclica, pelo princípio da conservação de energia, é possível assumir que a tensão média sobre o indutor em regime permanente é nula, logo:

$$\frac{1}{T_s} \int_0^{T_s} v_L dt = (V_{in} - V_o) \cdot D - V_o \cdot (1 - D) \quad (2.16)$$

Assim,

$$(V_{in} - V_o) \cdot D = V_o \cdot (1 - D) \quad (2.17)$$

$$D = \frac{V_o}{V_{in}} \quad (2.18)$$

- **Controlo por PWM:** Para garantir uma regulação precisa da tensão de saída, é necessário o controlo por PWM, sendo possível ajustar a razão cíclica D variando a largura do pulso t_{on} em relação ao período total T_s .

A Figura 2.17 ilustra os modos de funcionamento do conversor *buck*, nomeadamente as formas de onda da corrente no indutor (i_L) e da tensão no condensador (V_C) durante os intervalos t_{on} e t_{off} .

Primeira Etapa

Durante a etapa de condução apresentada na Figura 2.18, o interruptor principal denominado por S está ligado (ON), enquanto o diodo D encontra-se desligado (OFF), uma vez que está polarizado inversamente. Nesta fase, a corrente flui da fonte de entrada (tensão de entrada, V_{in}) através do interruptor principal e do indutor L . O indutor armazena energia no campo magnético à medida que a corrente aumenta, ou seja, o indutor está magnetizado. Desta forma, parte dessa corrente é fornecida à carga, carregando simultaneamente o condensador de saída C para manter a tensão de saída estável [13][25][28].




Figura 2.17: Formas de onda conversor *buck* [27].

A tensão no indutor é positiva ($V_{in} - V_{out}$), o que faz com que a corrente no indutor aumente linearmente, resultando na energia transferida da fonte de entrada para a carga e para o condensador de saída, de forma a assegurar o fornecimento de energia durante esta etapa [25].




Figura 2.18: Primeira etapa de operação do conversor DC/DC *buck* em modo CCM.

Ainda assim, a corrente no condensador é dada por:

$$i_C = i_L - I_o = i_L - \frac{V_o}{R_o} \quad (2.19)$$

Segunda Etapa

Nesta etapa representada no circuito da Figura 2.19, o interruptor principal S é desligado (OFF), o díodo D entra em condução (ON), uma vez que está em diretamente polarizado. Como a corrente no indutor L não pode mudar instantaneamente, o campo magnético do indutor colapsa, a bobina é desmagnetizada, resultando na libertação da energia armazenada. A corrente flui agora através do díodo, mantendo o circuito fechado, transferindo a energia armazenada no indutor para a carga e para o condensador de saída C [13][25][28].

A tensão no indutor é negativa ($-V_o$), o que faz com que a corrente no indutor diminua linearmente. Desta forma, a carga continua a ser alimentada pela energia armazenada no indutor e no condensador de saída, garantindo a continuidade do fornecimento de energia [25].




Figura 2.19: Segunda etapa de operação do conversor DC/DC *buck* em modo CCM.

A corrente no condensador é dada por:

$$i_c = i_L - \frac{V_o}{R_o} \quad (2.20)$$

Dimensionamento do Indutor

Durante a primeira etapa de operação, sabe-se que a tensão no indutor é descrita pela seguinte equação [29]:

$$v_L = L \cdot \frac{di_L}{dt} = V_{in} - V_o \quad (2.21)$$

Assim, a expressão no tempo que descreve a corrente é dada pela equação (2.22), onde I_{min} representa a corrente mínima [29]:

$$i_L = \frac{V_{in} - V_o}{L} \cdot t + I_{min} \quad (2.22)$$

Como a corrente máxima (I_{max}) ocorre em $t = D \cdot T_s$, então a equação é dada por [29]:

$$I_{max} = \frac{V_{in} - V_o}{L} \cdot D \cdot T_s + I_{min} \quad (2.23)$$

Seja a ondulação de corrente (*ripple*) (ΔI_L) dada pela diferença entre a corrente máxima e a corrente mínima, esta relação pode ser descrita da seguinte forma [29]:

$$\Delta I_L = I_{max} - I_{min} = \frac{V_{in} - V_o}{L} \cdot D \cdot T_s \quad (2.24)$$

No entanto, caso o valor do indutor não seja conhecido, a ondulação de corrente (ΔI_L) deve situar-se entre 20% a 40% de I_o [29]. Esta relação pode ser expressa por:

$$\Delta I_L = (0,20 \text{ a } 0,40) \cdot I_o \quad (2.25)$$

Onde:

- ΔI_L representa a ondulação de corrente no indutor;
- I_o é a corrente máxima de saída.

Por último, ao isolar L na equação (2.24), obtém-se a equação (2.26) que permite determinar o valor do indutor para uma dada ondulação de corrente [29]:

$$L \geq \frac{(V_{in} - V_o) \cdot D}{f_s \cdot \Delta I_L} \quad (2.26)$$

Onde:

- L : Indutor;
- V_{in} : Tensão de entrada;
- V_o : Tensão de saída;
- D : Razão cíclica;
- f_s : Frequência de comutação;
- ΔI_L : Ondulação de corrente.

A corrente máxima do indutor é dada por:

$$I_{Lmax} = I_o + \frac{\Delta I_L}{2} \quad (2.27)$$

Dimensionamento Condensador de saída

Quando a corrente no condensador é positiva, este é carregado e a tensão aumenta gradualmente desde o valor mínimo até ao valor máximo. A relação entre a variação da carga (ΔQ) e a variação da tensão (ΔV_C) no condensador é dada pela capacitância (C), conforme na equação descrita [25]:

$$\Delta V_C = \frac{\Delta Q}{C} \quad (2.28)$$

Desta forma, esta equação indica que para um dado valor de capacitância (C), quanto maior for a variação da carga (ΔQ), maior será a variação da tensão (ΔV_C).

Ainda assim, é de notar que a variação da carga no condensador, (ΔQ), corresponde à área destacada pela cor verde na Figura 2.17, que representa a variação da corrente no indutor (ΔI_L) durante o período de comutação (T_s). A área do triângulo é dada pela seguinte equação [25]:

$$\Delta Q = \frac{1}{2} \cdot \frac{\Delta I_L}{2} \cdot \frac{T_s}{2} = \frac{\Delta I_L \cdot T_s}{8} \quad (2.29)$$

Substituindo a equação (2.28) na equação (2.29), obtém-se:

$$C = \frac{\Delta I_L}{8 \cdot f_s \cdot \Delta V_C} \quad (2.30)$$

2.10 Tipos de Baterias em Sistemas Fotovoltaicos

Nos sistemas fotovoltaicos, particularmente em configurações *off-grid*, as baterias desempenham um papel crucial no armazenamento energético, permitindo o fornecimento contínuo de energia durante períodos sem irradiação solar. Entre as diversas tecnologias existentes, as baterias de chumbo-ácido (*Lead-Acid*) e ião-lítio (*Li-ion*) emergem como as soluções mais relevantes, embora com aplicações distintas.

2.10.1 Baterias de Chumbo-Ácido

As baterias de chumbo-ácido são adequadas para ciclos de carga e descarga frequentes, sendo bastante utilizadas para instalações fotovoltaicas estacionárias. A utilização destas baterias deve-se não só à sua elevada fiabilidade, taxa de reciclagem (superior a 95%) e custo significativamente inferior comparativamente às baterias de lítio, mas também à sua facilidade de integração em sistemas.

Para garantir o carregamento adequado de uma bateria de chumbo-ácido, o processo ocorre em três fases, tal como é ilustrado na Figura 2.20.

2.10.2 Fases de carregamento

Existem três fases para caracterizar o carregamento das baterias de chumbo-ácido, nomeadamente, a fase de *bulk*, a fase de absorção e a fase de armazenamento (*float*), tal como é demonstrado na Figura 2.20. Estas etapas estão descritas nos tópicos seguintes [30]:

- **Etapa 1: Fase de *bulk* (T0-T1)**

O carregamento *bulk* é a primeira fase, em que as baterias se encontram com




Figura 2.20: Ciclo de carregamento de uma bateria chumbo-ácido (Adaptado de [30]).

um estado de carga baixo, normalmente inferior a 80%. Nesta etapa, o painel solar fornece a corrente máxima possível às baterias, tratando-se de uma fase de carregamento rápido.

- **Etapa 2: Fase de absorção (T1-T2)**

A fase de absorção (cerca de 20% da capacidade) é responsável por manter a tensão no valor de absorção (normalmente cerca de 14,5 V para baterias de chumbo-ácido), diminuindo gradualmente a corrente até a bateria estar totalmente carregada.

- **Etapa 3: Fase de armazenamento (T2-T3)**

A bateria muda para a fase de armazenamento (*float*) quando está totalmente carregada ($\approx 13,6$ V), permitindo reduzir a evolução de gases e a perda de água, evitando a polarização da bateria e o sobrecarregamento, prolongando assim a sua vida útil.

2.11 Revisão de Literatura

O artigo "Modeling of a Photovoltaic Array in MATLAB Simulink and Maximum Power Point Tracking Using Neural Network" [31], propõe uma abordagem para

a monitorização do ponto de potência máxima (MPPT) em sistemas fotovoltaicos utilizando as redes neurais (ANN). Os autores começam por testar um algoritmo MPPT convencional, o algoritmo Perturbação e Observação (P&O), que embora seja amplamente utilizado, apresenta limitações e dificuldades em condições de irradiância variável. Os resultados finais demonstraram que a ANN supera o método P&O em precisão e menor tempo de resposta. O artigo reforça assim o potencial uso das ANN para melhorar a eficiência de sistemas fotovoltaicos, destacando a melhor estabilidade e precisão em comparação com métodos tradicionais.

No artigo "Deep reinforcement learning using deep-Q-network for Global Maximum Power Point tracking: Design and experiments in real photovoltaic systems" [32] é utilizado *Deep Reinforcement Learning* (DRL), especificamente através de uma *Deep Q-Network* (DQN), destacando-se pela validação experimental em tempo real, comparando o desempenho do agente DQN com o algoritmo convencional Perturbação e Observação (P&O) em condições PSC e uniforme. De acordo com o estudo, o agente superou o algoritmo P&O nas simulações, porém em cenários de teste real, o DQN nem sempre apresentou um desempenho superior ao P&O. É de referir que o P&O ficou "preso" num *Local Maximum Power Point* (LMPP) durante cenários PSC, e o algoritmo DQN conseguiu produzir até 63,5% mais energia relativamente ao P&O.

No estudo realizado por *Phan et al. (2020)* no artigo "A Deep Reinforcement Learning-Based MPPT Control for PV Systems under Partial Shading Condition" [33], os autores propõem uma abordagem para o controlo MPPT em sistemas fotovoltaicos com simulações no MATLAB/Simulink, utilizando métodos baseados em inteligência artificial, mais especificamente *Deep Reinforcement Learning* (DRL), tais como o DQN e *Deep Deterministic Policy Gradient* (DDPG). O estudo foca-se particularmente no desafio das condições PSC, onde os métodos tradicionais como P&O têm dificuldade em identificar o ponto máximo global de potência. Os resultados das simulações revelaram que o método DQN obteve melhorias notáveis na eficiência de monitorização do MPP comparativamente ao P&O em diferentes condições ambientais. Em condições uniformes de irradiância (1000 W/m^2), o DQN aumentou a eficiência em 5,83% enquanto o DDPG registou uma melhoria de 3,21% em relação ao P&O.

No artigo "Analysis of a Traditional and a Fuzzy Logic Enhanced Perturb and Observe Algorithm for the MPPT of a Photovoltaic System" de Diogo Remoaldo e Isabel Jesus (2021) [34], os autores comparam o desempenho do algoritmo tradicional P&O com uma versão melhorada por lógica *fuzzy* (FLP&O) para a monitorização do ponto MPP em sistemas fotovoltaicos. Este estudo foca-se na resposta a variações de irradiância e temperatura ambiente, utilizando um sistema com cinco painéis em série e um conversor *boost*. As simulações em MATLAB/Simulink demonstraram que o FLP&O tem um tempo de resposta mais rápido, atingindo o valor correto de

MPP com maior rapidez que o P&O em condições onde existem grandes variações de irradiância.

Adicionalmente, o artigo "A Comprehensive Review of Maximum Power Point Tracking (MPPT) Techniques Used in Solar PV Systems" [35] destaca que os métodos convencionais, como o P&O, são pouco eficientes em condições PSC, uma vez que têm dificuldade em localizar o ponto de máxima potência global (GMPP). Nestes casos, os métodos inteligentes, híbridos e de otimização demonstram melhor desempenho, porém com uma maior complexidade e custo. Assim, embora os métodos convencionais sejam mais simples, são menos adequados para condições ambientais variáveis.

Outro artigo relevante é apresentado por Sharma et al. [36], que comparam técnicas convencionais e metaheurísticas aplicadas ao MPPT. Este estudo destaca que métodos tradicionais, como o P&O, são limitados em condições PSC, enquanto abordagens baseadas em inteligência artificial e otimização, como ANN e GA, respetivamente, apresentam melhor desempenho, embora com maior complexidade.

Capítulo 3

Algoritmos MPPT

Este capítulo aborda os algoritmos MPPT essenciais para maximizar a eficiência de sistemas fotovoltaicos. Estes algoritmos tem como função monitorizar continuamente o ponto MPP, adaptando-se às variações de irradiância, temperatura e de sombra parcial. Ainda assim, também serão apresentadas as principais técnicas, desde métodos convencionais até abordagens baseadas em inteligência artificial e algoritmos híbridos, analisando as suas vantagens e limitações em diferentes cenários.

3.1 Classificação de Algoritmos MPPT

Os algoritmos utilizados para a monitorização do ponto MPP podem ser classificados em diferentes categorias, tais como:

- **Algoritmos Convencionais;**
- **Algoritmos Baseados em Lógica de Controlo;**
- **Algoritmos de Otimização;**
- **Algoritmos Baseados em Inteligência Artificial;**
- **Algoritmos Híbridos.**

A Tabela 3.1 apresenta a classificação dos algoritmos MPPT, divididos em cinco classes principais, com as respetivas subclasses e acrónimos.

Tabela 3.1: Classificação dos Algoritmos MPPT.

Classe	Subclasse	Acrônimo
Algoritmos Convencionais	Perturbação e Observação	P&O
	Condutância Incremental	InC
Algoritmo Baseado em Lógica de Controlo	Lógica Difusa (<i>Fuzzy</i>)	FLC
Algoritmos Baseados em Inteligência Artificial	Redes Neurais	ANN
	<i>Reinforcement Learning</i>	RL
Algoritmos de Otimização	Algoritmos Genéticos	GA
Algoritmos Híbridos	InC com P&O	InC-P&O
	GA com InC	GA-InC
	GA com P&O	GA-P&O

3.2 Algoritmos Convencionais

Os algoritmos convencionais de MPPT constituem métodos clássicos, amplamente utilizados devido à sua simplicidade de implementação e baixo custo computacional. Estas técnicas, tais como o Perturbação e Observação (P&O) e a Condutância Incremental (*Incremental Conductance* (InC)), baseiam-se na análise direta das variações de tensão e corrente do painel fotovoltaico, ajustando o ponto de operação em função da resposta obtida. Deste modo, apesar da eficácia sob condições ambientais estáveis, podem revelar limitações em cenários onde existe uma rápida variação de irradiância, temperatura ou de sombra parcial.

3.2.1 Perturbação e Observação (P&O)

O método P&O consiste em introduzir uma pequena perturbação na variável de referência (tensão ou corrente) e, analisar o impacto dessa perturbação na potência gerada pelo sistema fotovoltaico. É de notar que a análise é realizada com base nas medições obtidas pelos sensores de tensão e corrente instalados na saída do sistema.

O princípio fundamental do algoritmo é comparar os valores de potência em duas iterações consecutivas. Se a potência do painel fotovoltaico aumentar após a perturbação, significa que a alteração foi benéfica, e a próxima perturbação deverá ser aplicada no mesmo sentido. Por outro lado, se a potência diminuir, a perturbação teve um efeito negativo, e a próxima alteração deverá ocorrer no sentido oposto. Este processo, ilustrado através do fluxograma na Figura 3.1, repete-se iterativamente até que o sistema atinja o ponto MPP, onde a potência gerada é máxima [30].

A Tabela 3.2 resume as quatro possíveis respostas do sistema de controlo perante uma perturbação, com base no sinal de ΔV (variação de tensão), ΔP (variação de




Figura 3.1: Fluxograma do algoritmo P&O MPPT (Adaptado de [30]).

potência) e do gradiente $\frac{\Delta P}{\Delta V}$. A direção de monitorização é ajustada conforme a lógica descrita, garantindo a convergência para o MPP.

Tabela 3.2: Resposta do sistema de controlo para cada caso do algoritmo P&O.

Caso nº	ΔV	ΔP	$\frac{\Delta P}{\Delta V}$	Direção de Monitorização	Resposta de Controlo
1	+	+	+	Boa	Incrementar <i>Duty</i>
2	-	-	+	Má	Incrementar <i>Duty</i>
3	+	-	-	Má	Decrementar <i>Duty</i>
4	-	+	-	Boa	Decrementar <i>Duty</i>

3.2.2 Condutância Incremental (InC)

O método de Condutância Incremental (InC) necessita de sensores de tensão e corrente, tal como o método P&O. Este método InC analisa o sinal da derivada da potência em relação à tensão do sistema e procura o ponto onde o valor desta derivada se anula, o que corresponde ao ponto de máxima potência.

Conforme ilustrado na Figura 3.2, onde mostra a curva P-V e os respetivos declives, a posição do ponto de máxima potência é determinada pela magnitude do declive [30]:

- O ponto B, com declive $\frac{dP_{pv}}{dV_{pv}} = 0$, corresponde ao MPP;
- O ponto A, com declive $\frac{dP_{pv}}{dV_{pv}} < 0$, situa-se à direita do MPP;
- O ponto C, com declive $\frac{dP_{pv}}{dV_{pv}} > 0$, situa-se à esquerda do MPP.




Figura 3.2: Curva P-V: Relação entre o declive e a posição do MPP (Adaptado de [37]).

A derivada da potência pode ser descrita pela seguinte forma:

$$\frac{dP}{dV} = \frac{d(VI)}{dV} = I \frac{dV}{dV} + V \frac{dI}{dV} = I + V \frac{dI}{dV} \approx V \frac{\Delta I}{\Delta V} + I \quad (3.1)$$

Onde,

$$\begin{cases} \frac{\Delta I}{\Delta V} = -\frac{I}{V} & , \text{ está no MPP} \\ \frac{\Delta I}{\Delta V} < -\frac{I}{V} & , \text{ está à direita do MPP} \\ \frac{\Delta I}{\Delta V} > -\frac{I}{V} & , \text{ está à esquerda do MPP} \end{cases}$$

Ainda assim, uma vez atingido o ponto MPP, o algoritmo interrompe a variação do duty cycle, contribuindo para a eliminação de oscilações em regime permanente. Desta forma, o cálculo de ΔI continua a ser realizado, e quando se verifica uma variação significativa de corrente definida pela condição $\Delta I \neq 0$, o algoritmo de monitorização volta a atuar novamente. Na Figura 3.3 está ilustrado o fluxograma do algoritmo.

As principais vantagens deste método incluem uma maior precisão em condições de irradiação variável e menor oscilação em regime permanente. No entanto, a implementação pode ser mais complexa devido à necessidade de medições precisas de corrente e tensão, bem como ao cálculo de derivadas.




Figura 3.3: Fluxograma do algoritmo InC MPPT (Adaptado de [30]).

3.3 Algoritmo Baseado em Lógica de Controle

Os algoritmos baseados em lógica de controle recorrem a estratégias avançadas, como a lógica difusa (*Fuzzy Logic Control* (FLC)), para realizar a monitorização do ponto MPP. Estas abordagens permitem lidar com as não-linearidades de um sistema fotovoltaico, proporcionando uma boa resposta às variações de irradiância e temperatura.

3.3.1 Lógica Difusa (FLC)

Esta técnica baseada no controle de lógica difusa (FLC), também designado por *Fuzzy*, consegue monitorizar o ponto MPP mesmo com entradas imprecisas, como é o caso de um controlador MPPT, onde a tensão e a corrente têm muitas oscilações com a variação da temperatura e irradiância. O controle difuso não requer um modelo matemático preciso e apresenta a vantagem de lidar com sistemas não lineares, sendo composto pelas seguintes etapas:

- **Fuzzificação (*Fuzzification*)**: Conversão de entradas numéricas em variáveis linguísticas, utilizando funções de pertinência.

- **Sistema de Inferência (*Inference System*)**: Aplicação de regras linguísticas (base de regras) para mapear as entradas difusas em saídas difusas.
- **Defuzzificação (*Defuzzification*)**: Conversão da saída difusa em valores numéricos utilizáveis pelo sistema de controlo.

Na Figura 3.4 está representado um diagrama com todas as etapas descritas.




Figura 3.4: Diagrama da lógica difusa.

As equações (3.2) e (3.3) mostram o erro e a variação do erro, onde estas são as entradas mais frequentemente utilizadas no controlo *fuzzy*. A equação (3.2) representa o declive da curva P-V, cujo valor diminui à medida que se aproxima do ponto de máxima potência. Desta forma, quando este valor se torna zero, é atingido o ponto de máxima potência, sendo este valor utilizado como entrada para o controlo *fuzzy* [37].

$$E(k) = \frac{\Delta P_{pv}}{\Delta V_{pv}} = \frac{P_{pv}(k) - P_{pv}(k-1)}{V_{pv}(k) - V_{pv}(k-1)} \quad \text{ou} \quad E(k) = \frac{I_{pv}}{V_{pv}} + \frac{\Delta I_{pv}}{\Delta V_{pv}} \quad (3.2)$$

$$\Delta E(k) = E(k) - E(k-1) \quad (3.3)$$

O método de *Mamdani*, que implementa uma regra sobre a entrada difusa para definir a saída difusa, é utilizado para determinar o sistema de interferência difuso.

Desta forma, para obter um valor linguístico aceitável, o valor real de entrada deve ser fuzzificado antes que a regra possa ser avaliada [38].

A Tabela 3.3 apresenta a tabela de regras do controlador difuso (FLC), onde as entradas são os conjuntos difusos das variáveis $E(k)$ (erro) e $\Delta E(k)$ (variação do erro), e a saída é a razão cíclica D . Cada célula da tabela representa a regra de inferência correspondente à combinação das variáveis de entrada. É de notar que esta tabela contém 25 regras difusas, formando uma tabela 5×5 , onde as regras de controlo são avaliadas segundo a seguinte estrutura:

SE $E(k)$ é ... **e** $\Delta E(k)$ é ... **ENTÃO** D é ...

Por exemplo:

- Regra 1: **SE** $E(k)$ é NB **e** $\Delta E(k)$ é NB, **ENTÃO** D é NB.
- Regra 2: **SE** $E(k)$ é ZE **e** $\Delta E(k)$ é PS, **ENTÃO** D é PS.
- Regra 3: **SE** $E(k)$ é PB **e** $\Delta E(k)$ é NS, **ENTÃO** D é PS.

O objetivo principal das regras é aproximar o ponto de operação do módulo fotovoltaico ao ponto de máxima potência (MPP), através do ajuste da razão cíclica do conversor DC-DC, com base na posição do ponto de operação em relação ao MPP [38]. Para isso, a inferência tem como função chegar a uma decisão lógica com base no conjunto de regras fuzzy, transformando a base de regras num output linguístico fuzzy.

Tabela 3.3: Tabela de regras FLC.

$E \backslash \Delta E$	NB	NS	ZE	PS	PB
NB	NB	NB	NB	NS	ZE
NS	NB	NS	NS	ZE	PS
ZE	NB	NS	ZE	PS	PB
PS	NB	ZE	PS	PB	PB
PB	ZE	PS	PB	PB	PB

No estado de defuzzificação, a saída do FLC é convertida de uma variável linguística para uma variável numérica recorrendo ao uso de uma função de pertinência ilustrada na Figura 3.5. Desta forma, a razão cíclica pode ser determinada utilizando métodos distintos, tais como:

- Centro de Gravidade (*Center of Gravity* (COG));
- Centro da Área (*Center of Area* (COA));
- Método do Critério Máximo (*Max Criterion Method* (MCM)).

No entanto, a forma mais comum de defuzzificação é o cálculo do centro de gravidade (COG) do conjunto combinado final, dado por [38]:

$$D = \frac{\sum_{j=1}^n \mu(\Delta D_j) \cdot \Delta D_j}{\sum_{j=1}^n \mu(\Delta D_j)} \quad (3.4)$$

Onde:

- D – Valor final do *duty cycle* obtido após a defuzzificação;
- ΔD_j – Valor discreto de *duty cycle* considerado na saída *fuzzy* (ponto de amostragem j);
- $\mu(\Delta D_j)$ – Grau de pertinência associado ao valor ΔD_j , definido pela função de pertinência da saída difusa;
- n – Número total de pontos ΔD_j utilizados no processo de defuzzificação.

Na função de pertinência ilustrada na Figura 3.5, são utilizadas cinco variáveis linguísticas (NB: *Negative Big*, NS: *Negative Small*, ZE: *Zero*, PS: *Positive Small*, PB: *Positive Big*). À medida que o número de variáveis linguísticas aumenta, a precisão melhora, porém o tempo de processamento do algoritmo aumenta [37].




Figura 3.5: Função de pertinência triangular e trapezoidal.

3.4 Algoritmos de Otimização

Os algoritmos de otimização aplicam técnicas inspiradas em processos evolutivos para encontrar o ponto MPP, mostrando uma boa eficácia em cenários complexos como condições de sombra parcial onde existem múltiplos máximos locais. Entre eles, destaca-se o Algoritmo Genético (GA), que simula mecanismos de seleção natural e evolução para otimizar o sistema.

3.4.1 Otimização com Algoritmo Genético (GA)

O Algoritmo Genético (GA) é uma técnica metaheurística de otimização inspirada nos princípios da evolução natural e da genética. Desenvolvido por John Holland na década de 1960, o GA tem como objetivo principal transformar uma população inicial de soluções candidatas, representadas como cadeias de bits (1's e 0's), em soluções mais adaptadas ao problema em questão. Este processo é realizado através de operadores inspirados na seleção natural, tais como o cruzamento (*crossover*), a mutação (*mutation*) e a seleção, que simulam a variação genética observada na natureza [39].

Na Figura 3.6 está ilustrado o fluxograma do funcionamento do algoritmo genético. Ainda assim, na Tabela 3.4 estão representadas as seguintes etapas fundamentais do algoritmo genético.

Tabela 3.4: Etapas de um algoritmo genético.

Etapa	Descrição
1. Inicialização	Gerar aleatoriamente uma população inicial de soluções candidatas.
2. Avaliação	Cálculo da aptidão (<i>fitness</i>) de cada indivíduo através de uma função objetivo.
3. Seleção	Escolha dos indivíduos mais aptos para reprodução, usando métodos como seleção por roleta ou torneio.
4. Cruzamento	Recombinação dos indivíduos selecionados para produzir descendentes.
5. Mutação	Aplicação de pequenas alterações aleatórias para manter diversidade genética.
6. Substituição	Formação de uma nova geração a partir dos descendentes e melhores indivíduos.
7. Critério de paragem	Verificação das condições de finalização (número máximo de gerações, convergência, entre outras).

Devido às vantagens em lidar com formulações de múltiplos objetivos e múltiplas soluções, os algoritmos genéticos são amplamente utilizados para resolver uma variedade crescente de problemas complexos do mundo real, onde métodos convencionais podem falhar [39].

Desta forma, para a aplicação da técnica de monitorização do ponto de máxima potência (MPP) baseado no algoritmo genético, é utilizada uma abordagem sistemática que relaciona diretamente as grandezas elétricas do painel fotovoltaico, nomeadamente, valores de tensão (V), corrente (I) e potência (P) do painel. No contexto do algoritmo genético, cada solução possível é codificada como um cromossoma, onde os valores de tensão representam os genes que compõem esses cromossomas, e a potência, calculada como produto da tensão pela corrente ($P = V.I$), assume o




Figura 3.6: Funcionamento do algoritmo genético.

papel de função de aptidão (*fitness*), servindo como critério objetivo para avaliar a qualidade de cada solução candidata.

3.5 Algoritmos Baseados em Inteligência Artificial

Os algoritmos baseados em inteligência artificial, tais como as ANN, introduzem a capacidade de aprendizagem e generalização na otimização de sistemas fotovoltaicos. Através do treino com dados adquiridos como por exemplo a irradiância e a temperatura ao longo do tempo, é possível prever o comportamento do sistema perante diferentes condições, permitindo uma monitorização rápida e precisa do ponto MPP.

3.5.1 *Artificial Neural Networks* (ANN)

As redes neuronais são capazes de classificar e reconhecer padrões de forma análoga ao cérebro biológico, sendo consideradas uma técnica de monitorização inteligente, devido ao processo de aprendizagem e à natureza biológica dos neurónios. Desta forma, uma ANN pode ser representada por um diagrama onde os nós e as extremidades correspondem aos neurónios e às sinapses (conexões).

Na Figura 3.7 está representado um modelo de um neurónio, com uma função de ativação (*Activation Function* (AF)), onde Z é o argumento da AF, dado pela expressão:

$$Z = \sum_{m=1}^M X_m W_m + \alpha \quad (3.5)$$

Onde:

- X_m são os M sinais de entrada;
- W_m são os pesos sinápticos;
- α é o termo de polarização (*bias*).




Figura 3.7: Modelo de neurônio ANN.

A saída é obtida através de uma função de ativação não-linear (AF) designado por $f(Z)$, como por exemplo a *sigmoide* ou tangente hiperbólica.

A Figura 3.8 ilustra a arquitetura de uma rede neuronal aplicada ao MPPT, composta por uma camada de entrada, uma camada oculta e uma camada de saída. As variáveis de entrada nesta rede são a irradiância (G) e a temperatura ambiente (T), enquanto as saídas da rede correspondem à tensão (V_{pv}) e à potência (P_{pv}) do painel previstas, sendo utilizadas para determinar o ponto MPP.




Figura 3.8: Arquitetura de rede neuronal.

Desta forma, para treinar uma rede neuronal é necessário ter em conta as seguintes etapas [40]:

1. **Recolha de dados (*Data collection*):** Compilar informações sobre a potência, tensão de saída do painel e variáveis de entrada relevantes, tais como a temperatura e a irradiância.
2. **Pré-processamento dos dados (*Data pre-processing*):** Os dados devem ser pré-processados para eliminar ruídos e interferências, bem como para normalizar os dados.
3. **Treino da rede (*Network training*):** Utilizar os dados processados para treinar a ANN com uma estratégia de otimização adequada, como *backpropagation*.
4. **Validação da rede (*Network validation*):** Testar a precisão da rede treinada utilizando um conjunto de dados diferente.
5. **Implementação (*Implementation*):** Implementar a ANN treinada no sistema fotovoltaico para prever o MPP.

O fluxograma do processo de treino é ilustrado na Figura 3.9, onde $G(k)$ representa a irradiância atual, $T(k)$ a temperatura ambiente, a tensão (V_{pv}) e a potência (P_{pv}) prevista do painel fotovoltaico.

As redes neurais apresentam vantagens na rápida resposta, capacidade de processamento de sistemas não lineares e treino da rede, sendo utilizadas de diversas formas no MPPT em sistemas fotovoltaicos [37]. No entanto, o método de MPPT que utiliza redes neurais tem a desvantagem de aumentar o custo computacional, uma vez que requer um microcontrolador de alto desempenho em comparação com outros métodos.




Figura 3.9: Fluxograma do processo de treino para a técnica ANN (Adaptado de [40]).

3.5.2 DRL para Sistemas Fotovoltaicos

O DRL combina técnicas de *Reinforcement Learning* (RL) com arquiteturas de (*Deep Learning* (DL)). Desta forma, o RL é um método de aprendizagem automática não supervisionada, inspirada na interação entre estímulos e respostas num ambiente dinâmico, onde um agente aprende através da tentativa e erro [33]. Com os avanços na área da computação, o RL tornou-se uma ferramenta popular para resolver problemas de decisão sequencial, permitindo ao agente desenvolver uma estratégia que maximize a recompensa acumulada ao interagir com o ambiente. No contexto de sistemas fotovoltaicos, o DRL destaca-se pela capacidade de otimizar o MPPT em condições variáveis de irradiância, temperatura e sombra parcial (PSC).

Fundamentos do DRL

Os principais elementos que compõem o RL são o agente (*agent*) e o ambiente (*environment*), sendo este último responsável por representar o mundo com o qual o agente interage diretamente, tal como está ilustrado na Figura 3.10. Em cada

instante de tempo t , o agente observa o estado atual do ambiente, representado por s_t , e recebe simultaneamente um sinal de recompensa r_t , que fornece uma estimativa numérica da qualidade daquele estado em relação ao objetivo final da tarefa [41]. Com base nessas informações, o agente escolhe uma ação a_t que será executada sobre o ambiente. Desta forma, o objetivo do agente ao longo dessa interação, é desenvolver uma política de ações que maximize a recompensa acumulada ao longo do tempo.




Figura 3.10: Diagrama da interação agente-ambiente no RL.

Como ilustrado na Figura 3.11, existem dois tipos principais de métodos em RL, nomeadamente *model-based* e *model-free*. Nos métodos *model-based*, o modelo do ambiente é conhecido, destacando-se pela sua eficiência relativamente a amostras necessárias para a aprendizagem. Contudo, a complexidade computacional torna-se significativamente maior quando o modelo é demasiado complexo para ser aprendido com precisão.




Figura 3.11: Taxonomia dos algoritmos em RL [41].

Por outro lado, os métodos *model-free* não requerem um modelo explícito do ambiente para funcionarem de forma eficaz, porém apresentam uma complexidade computacional inferior. Desta forma, dentro dos métodos *model-free RL*, são divididas em abordagens *value-based* e *policy-based*. As técnicas *value-based* focam-se em melhorar iterativamente a função de valor até atingir a convergência, como é o caso do agente DQN. Por sua vez, os métodos *policy-based* trabalham diretamente com

a política do agente, que representa a estratégia de mapeamento de estados para ações, definindo como o agente deve agir em cada situação possível. Entre estes métodos, destaca-se o DDPG, um agente que combina as vantagens das abordagens *policy-based* com elementos *value-based* [41].

Markov Decision Process (MDP) para MPPT

Para implementar a abordagem DRL no controlo de MPPT de um sistema fotovoltaico, é necessário definir um modelo MDP do comportamento do sistema.

Um MDP é definido pela tupla (S, A, P, R, γ) , onde [33][42]:

- **Espaço de Estados (S):** Representa as condições de operação do sistema fotovoltaico, incluindo:
 - Tensão e corrente de saída do painel;
 - Níveis de irradiância;
 - Temperatura ambiente.
- **Espaço de Ações (A):** Corresponde às perturbações do *duty cycle* no conversor DC-DC para monitorizar o MPP.
- **Função de Transição (P):** Representa a dinâmica do sistema através da probabilidade $P(s'|s, a)$, que representa a probabilidade de transitar para o estado s' após executar a ação a no estado s . A probabilidade de transição do MDP de qualquer estado $s, s \in S$, no tempo t para um estado s' dada uma ação $a, a \in A(s)$, é descrita pela equação (3.6) [42]:

$$P_{ss'}^a = Pr\{s_{t+1} = s' \mid s_t = s, a_t = a\}. \quad (3.6)$$

- **Função de Recompensa (R):** Define a recompensa imediata $R(s, a, s')$ obtida ao transitar de s para s' através de a . A recompensa r_{t+1} é obtida quando a ação a_t é escolhida no estado do sistema s_t . Desta forma, a recompensa estimada $R_{ss'}^a$ está associada à probabilidade de transição definida pela equação (3.7)[42]:

$$R_{ss'}^a = E\{r_{t+1} \mid s_t = s, a_t = a, s_{t+1} = s'\}. \quad (3.7)$$

- **Fator de Desconto (γ):** Valor no intervalo $[0, 1]$ que determina o valor das recompensas futuras em comparação com recompensas imediatas.

Deep Q-Network (DQN)

No contexto do *machine learning*, os métodos de RL destacam-se como uma solução para problemas de controlo ótimo em cenários onde modelos precisos não estão

disponíveis. No entanto, em problemas com grandes dimensões, o RL enfrenta limitações devido à representação ineficiente de características, tais como o aumento do número de estados e ações, ou a complexidade dos problemas. Contudo, este problema é resolvido através da combinação do *Q-learning* com *Deep Learning*, resultando no DQN [33].

Com a substituição da *Q-table* por uma *Deep Neural Network* (*Q-network*), é possível mapear os estados do ambiente (*states*) para as ações do agente, utilizando uma rede neuronal profunda (*Q-network*) para aproximar a função Q , com o objetivo de estimar o retorno de recompensas futuras. Esta função é denotada por $Q(s, a|\theta)$ (onde θ representam os pesos da rede), e atua como um *critic*, que avalia a qualidade das ações em um dado estado. Durante o processo de aprendizagem, são usadas duas *Q-networks* independentes, nomeadamente a *predict Q-network* (com pesos θ) e a *target Q-network* (com pesos θ') [33][43][44].

Na DQN a função de perda (*loss function*) descrita na equação (3.8) é definida pelo erro quadrático entre o (*Q-target*) e o (*Q-predict*) [33]:

$$L(\theta) = E_{s,a} \left[(Q_{\text{target}} - Q_{\text{predict}})^2 \right] \quad (3.8)$$

$$Q_{\text{target}} = \underbrace{r}_{\text{reward}} + \underbrace{\gamma}_{\substack{\text{discount} \\ \text{factor}}} \max_a Q(s_{t+1}, a_{t+1}|\theta') \quad (3.9)$$

$$Q_{\text{predict}} = Q(s_t, a_t|\theta) \quad (3.10)$$

Durante o treino, a ação é selecionada de acordo com uma política ε -greedy, definida pelas seguintes funções [42][33]:

$$a_t = \begin{cases} \operatorname{argmax}_{a \in A} Q(s_t, a|\theta) & \text{com probabilidade } 1 - \varepsilon \\ \operatorname{random}(a_t \in A) & \text{com probabilidade } \varepsilon \end{cases}$$

Onde:

- A representa o espaço de ações disponíveis;
- $\varepsilon \in [0, 1]$ é a taxa de exploração (*exploration rate*).

Esta política é uma abordagem ε -greedy, na qual, com uma probabilidade ε , o agente escolhe uma ação aleatória, e com uma probabilidade $1 - \varepsilon$, escolhe a ação que maximiza o valor da função Q estimado pela *Q-network* (exploração do conhecimento adquirido). Desta forma, este processo permite ao agente aprender progressivamente uma política de controlo ótima, mesmo em ambientes complexos e de grandes dimensões [42][33].

O diagrama do agente DQN está representado na Figura 3.12.




Figura 3.12: Diagrama do agente DQN.

3.6 Comparação de Algoritmos MPPT

A seleção do algoritmo mais adequado desempenha um papel crucial, uma vez que os parâmetros de seleção do controlador MPPT fornecem informações essenciais para determinar qual método é mais eficaz para uma aplicação específica. É de notar que estes critérios são utilizados para comparar cada um dos algoritmos MPPT de diferentes categorias.

3.6.1 Critérios de Comparação

Para auxiliar a escolha dos algoritmos MPPT, é essencial estabelecer critérios de comparação que permitam avaliar o desempenho, a eficiência e a viabilidade de cada método em diferentes cenários. Na Tabela 3.5 estão apresentados os principais parâmetros utilizados nesta análise, abrangendo desde aspectos técnicos, tais como a complexidade, velocidade de convergência, e até considerações práticas, como o custo e necessidade de ajustes periódicos [45].

A análise comparativa dos algoritmos MPPT considerados neste estudo encontra-se sistematizada na Tabela 3.5, que retrata o desempenho de cada método relativamente aos critérios.

Tabela 3.5: Critérios de comparação de algoritmos MPPT [45].

Parâmetro de seleção	Descrição
Complexidade	A precisão de um algoritmo depende da sua complexidade e eficiência. Um método simples e de fácil implementação tende a ser mais atrativo para o utilizador, comparativamente a um método complexo.
Custo	As características do sistema, a complexidade de programação, o número de sensores necessários, e o custo do <i>hardware</i> influenciam o custo global do sistema de monitorização.
Dependência de parâmetros do painel fotovoltaico	Sem conhecimento sobre o tamanho do painel e as suas configurações, um algoritmo MPPT deve ser capaz de monitorizar o MPP. No entanto, alguns métodos, tais como as redes neuronais (ANN), dependem de parâmetros do painel fotovoltaico.
Treino prévio	Antes de executar a simulação do sistema, métodos como ANN e RL requerem treino e configurações prévias.
Velocidade de Convergência	Para além das variações na irradiância, temperatura ou sombra parcial, é essencial que um algoritmo apresente elevada velocidade de convergência para monitorizar o MPP.
Sensores Utilizados	Os sensores de tensão e corrente são essenciais para o funcionamento do controlador MPPT. No entanto, existem algoritmos que também necessitam de irradiância e temperatura.
Ajuste Periódico	Devido à degradação associada à sujidade, às variações de temperatura dos painéis fotovoltaicos, o desempenho dos métodos MPPT pode diminuir significativamente ao longo do tempo. Desta forma, dado que a vida útil expectável de um painel é cerca de 25 a 30 anos, alguns métodos poderão exigir ajustes periódicos para manter uma eficiência elevada.
Estabilidade	Nos métodos convencionais, o MPP tende a desviar-se do seu estado estável, provocando grandes alterações no valor de saída. Deste modo, a estabilidade é um parâmetro importante na seleção do método MPPT.
Eficiência	A eficiência das técnicas MPPT é avaliada com o quociente entre a potência de saída do conversor DC/DC e a potência de entrada proveniente do painel fotovoltaico.
Condições de Sombra Parcial (PSC)	Em situações de sombra parcial, a curva P-V do painel apresenta múltiplos pontos de MPP. Um algoritmo MPPT eficaz deve identificar e monitorizar o verdadeiro ponto GMPP, evitando a convergência em máximos locais.

3.6.2 Métricas de avaliação

Para avaliar o desempenho dos algoritmos MPPT implementados, foram utilizadas métricas de desempenho que permitem identificar a eficiência, precisão e velocidade de convergência de cada método. Estas métricas incluem:

- **Mean Absolute Error (MAE)**: Média dos erros absolutos entre a potência de entrada do painel fotovoltaico P_{in} e a potência de saída $P_{out}(t)$ ao longo do tempo, com objetivo de avaliar a precisão global do algoritmo.

$$MAE = \frac{1}{N} \sum_{t=1}^N |P_{in}(t) - P_{out}(t)| \quad (3.11)$$

- **Integral Absolute Error (IAE)**: Representa a soma acumulada dos erros absolutos ao longo do tempo. Ou seja, erros que persistem mais tempo durante a simulação, penalizam mais.

$$IAE = \int_0^T |P_{in}(t) - P_{out}(t)| dt \quad (3.12)$$

- **Mean Squared Error (MSE)**: É a erro quadrático médio entre $P_{in}(t)$ e o $P_{out}(t)$. Penaliza mais os erros maiores.

$$MSE = \frac{1}{N} \sum_{t=1}^N (P_{in}(t) - P_{out}(t))^2 \quad (3.13)$$

- **Integral Squared Error (ISE)**: Avalia o erro acumulado ao longo do tempo com maior penalização para erros de maior magnitude. Um valor baixo de ISE indica que o algoritmo conseguiu manter $P_{out}(t)$ muito próximo de $P_{in}(t)$, com poucos desvios significativos.

$$ISE = \int_0^T (P_{in}(t) - P_{out}(t))^2 dt \quad (3.14)$$

- **η (Eficiência)**: É a razão entre a potência média extraída por P_{out} e P_{in} .

$$\eta = \frac{P_{out}}{P_{in}} \times 100\% \quad (3.15)$$

- **Tempo de convergência (t_{conv})**: Corresponde ao instante em que o erro do sistema entra dentro da zona estável em relação ao seu valor máximo, permanecendo estável até ao final da simulação. O cálculo foi realizado com base na média móvel do erro absoluto e na função `lsiminfo` do MATLAB, conforme descrito abaixo [46]:

1. **Cálculo da janela de suavização:** Considera-se uma janela temporal de duração T_{janela} (ex: 150 ms), e calcula-se o número de amostras dentro dessa janela:

$$N = \frac{T_{\text{janela}}}{\Delta t} \quad (3.16)$$

Onde Δt é o tempo médio entre amostras.

2. **Erro absoluto:** O erro entre a potência de entrada e a potência de saída é dado por:

$$e(t) = P_{\text{in}}(t) - P_{\text{out}}(t) \quad (3.17)$$

De seguida, calcula-se a média móvel do módulo desse erro:

$$e_{\text{média}}(t) = \frac{1}{N} \sum_{i=t-N+1}^t |P_{\text{in}}(i) - P_{\text{out}}(i)| \quad (3.18)$$

3. **Normalização:** A curva suavizada é normalizada ao intervalo $[0, 1]$:

$$e_{\text{norm}}(t) = \frac{e_{\text{média}}(t)}{\max(e_{\text{média}}(t))} \quad (3.19)$$

4. **Construção do sinal auxiliar:** Para utilizar a função `lsiminfo`, é necessário criar uma curva crescente:

$$s(t) = 1 - e_{\text{norm}}(t) \quad (3.20)$$

Esta inversão é necessária, uma vez que a função `lsiminfo` foi concebida para analisar sinais que convergem de forma crescente para um valor final (por exemplo, uma resposta a um degrau que atinge 1). Como o erro normalizado $e_{\text{norm}}(t)$ é uma curva tipicamente decrescente (o erro diminui com o tempo), é invertido o sinal para criar uma curva equivalente crescente, permitindo que o `lsiminfo` identifique corretamente o tempo de estabilização dentro de uma faixa de tolerância em torno de $s(t) = 1$.

5. **Cálculo do tempo de estabilização:** A função `lsiminfo` calcula o tempo em que $s(t)$ entra e permanece dentro de uma faixa de tolerância de ε (por exemplo, 2%) em torno do valor final ($s(t) = 1$) [46]:

$$t_{\text{conv}} = \text{lsiminfo}(s(t), t, \text{"SettlingTimeThreshold"}, \varepsilon) \quad (3.21)$$

Esta tolerância corresponde a uma faixa relativa ao intervalo entre os valores iniciais e finais do sinal, como ilustrado na equação (3.22) [46]:

$$|s(t) - s_{\text{final}}| \leq \varepsilon \times |s_{\text{final}} - s_{\text{init}}| \quad (3.22)$$

No caso em que $s_{\text{init}} = 0$ e $s_{\text{final}} = 1$, a faixa de tolerância fica:

$$|s(t) - 1| \leq 0,02 \quad (3.23)$$

Isto significa que o sinal pode variar até 2% para cima ou para baixo em relação ao valor final, ou seja:

$$0,98 \leq s(t) \leq 1,02 \quad (3.24)$$

Estas métricas permitem uma análise comparativa objetiva dos algoritmos, considerando não apenas a precisão na monitorização do MPP, mas também o desempenho em condições de irradiância e temperatura não uniformes.

Capítulo 4

Arquitetura do Sistema

Este capítulo descreve a arquitetura geral do sistema desenvolvido, desde a caracterização do painel fotovoltaico até ao dimensionamento dos conversores DC/DC e do controlo baseado em algoritmos de inteligência artificial. Serão abordadas as especificações dos painéis fotovoltaicos, os cálculos necessários para o correto dimensionamento dos componentes eletrónicos, e a lógica de controlo implementada no ambiente MATLAB/Simulink, de forma a garantir um funcionamento eficiente em diferentes condições de operação.

4.1 Arquitetura Geral do Sistema

A arquitetura do sistema fotovoltaico tem como objetivo a captação, conversão e armazenamento da energia proveniente do painel fotovoltaico. A estrutura do sistema é composta pelos seguintes elementos principais:

- **Painel Fotovoltaico:** Responsável pela conversão da energia solar em energia elétrica de corrente contínua (DC);
- **Controlador MPPT:** Implementa um algoritmo de monitorização do ponto de máxima potência MPPT, garantindo que o painel opera sempre no seu ponto ótimo, conforme as curvas do painel fotovoltaico;
- **Conversor DC/DC *Buck*:** Reduz a tensão gerada pelo painel, neste caso 36 V (tensão onde potência do painel é máxima) para uma tensão mais baixa, cerca de 20 V;

- **Carga:** Atua como elemento de carga resistiva.

A Figura 4.1 apresenta o diagrama de blocos do sistema, ilustrando a interação entre os diferentes componentes, nomeadamente, o painel fotovoltaico, conversor DC/DC *buck*, controlador MPPT e a carga.

O conversor *buck* é utilizado para reduzir os 36 V (Tensão MPPT do painel em STC) para aproximadamente 20 V.

O controlador MPPT desempenha um papel fundamental no sistema, atuando diretamente no conversor *buck* através do ajuste do *duty cycle* do sinal PWM aplicado ao MOSFET. Dependendo do algoritmo MPPT utilizado, o controlador efetua pequenos incrementos ou decrementos no *duty cycle* e avalia o seu impacto na potência extraída.




Figura 4.1: Diagrama de blocos do sistema MPPT.

4.2 Características do Painel Fotovoltaico

Nesta secção é apresentado o painel fotovoltaico escolhido representado na Figura 4.2, possui uma potência máxima de 30 W, que o torna uma opção bastante interessante para aplicações de pequena escala, tais como sistemas residenciais ou até mesmo para processo de testes e validações.

Este painel fotovoltaico, é do tipo policristalino, oferece um bom compromisso entre custo e desempenho, garantindo uma carga eficiente, estável e consistente em diferentes condições de luminosidade. Na Figura 4.3 é possível observar que na curva vermelha de ambos os gráficos I-V e P-V, estão presentes os valores de tensão e corrente de 36,00 V e 0,83 A, respetivamente, para o ponto de máxima potência do painel. Além disso, os coeficientes de temperatura permitem avaliar a influência da



Figura 4.2: SOLARPOWER XUNZEL 30W 24V [47].

variação térmica no desempenho do módulo, contribuindo para um dimensionamento mais preciso do sistema.




Figura 4.3: Curvas I-V e P-V do SOLARPOWER 30W 24V.

A Tabela 4.1 apresenta as especificações técnicas principais do painel fotovoltaico.

4.3 Cálculos Iniciais do Painel Fotovoltaico

Para determinar os parâmetros de operação do painel fotovoltaico, consideram-se os seguintes dados:

- Tensão de entrada (V_{in}): 36 V
- Tensão de saída (V_{out}): 20 V
- Potência de saída desejada (P_{out}): 26,89 W

Tabela 4.1: Especificações do painel fotovoltaico SOLARPOWER XUNZEL 30W 24V.

Parâmetro	Valor
Potência máxima (P_{max})	29,88 W
Número de células por módulo (N_{cell})	72
Tensão em circuito aberto (V_{oc})	43,20 V
Corrente de curto-circuito (I_{sc})	0,92 A
Tensão no ponto de máxima potência (V_{mp})	36,00 V
Corrente no ponto de máxima potência (I_{mp})	0,83 A
Coeficiente de temperatura da tensão ($\beta_{V_{oc}}$)	-0,27 %/°C
Coeficiente de temperatura da corrente ($\alpha_{I_{sc}}$)	+0,05 %/°C
Coeficiente de temperatura da potência ($\alpha_{P_{sc}}$)	-0,35 %/°C

A potência de entrada do painel é determinada pelo produto da tensão no ponto de máxima potência (V_{mpp}) e a respetiva corrente (I_{mpp}):

$$P_{in} = V_{mpp} \times I_{mpp} \quad (4.1)$$

Considerando $V_{mpp} = 36 \text{ V}$ e $I_{mpp} = 0,83 \text{ A}$:

$$P_{in} = 36 \times 0,83 = 29,88 \text{ W} \quad (4.2)$$

Assumindo uma eficiência (η) de 90% para o conversor:

$$P_{out} = \eta \times P_{in} \quad (4.3)$$

$$P_{out} = 0,90 \times 29,88 \approx 26,89 \text{ W} \quad (4.4)$$

A corrente de saída é calculada dividindo a potência de saída pela tensão de saída:

$$I_{out} = \frac{P_{out}}{V_{out}} \quad (4.5)$$

$$I_{out} = \frac{26,89}{20} \approx 1,34 \text{ A} \quad (4.6)$$

A resistência da carga é determinada por:

$$R_o = \frac{V_{out}^2}{P_{out}} \quad (4.7)$$

$$R_o = \frac{20^2}{26,89} \approx 14,88 \Omega \quad (4.8)$$

Os parâmetros do painel fotovoltaico calculados anteriormente estão apresentados na Tabela 4.2.

Tabela 4.2: Resultados dos cálculos do conversor.

Parâmetro	Valor
Tensão de entrada (V_{in})	36 V
Tensão de saída (V_{out})	20 V
Potência de entrada (P_{in})	29,88 W
Potência de saída (P_{out})	26,89 W
Eficiência do conversor (η)	90%
Corrente no ponto de máxima potência (I_{mpp})	0,83 A
Corrente de saída (I_{out})	1,34 A
Resistência da carga (R_o)	14,88 Ω

4.4 Dimensionamento dos Componentes do Conversor DC/DC Buck para Simulação

Nesta secção, é apresentado o processo de dimensionamento do conversor DC/DC do tipo *buck* representado na Figura 4.4, essencial para a simulação do sistema fotovoltaico proposto.




Figura 4.4: Diagrama conversor DC/DC buck.

Desta forma, para a simulação do conversor *buck* com uma tensão de saída de 20 V, foram realizados os cálculos apresentados nas subsecções seguintes.

4.4.1 Razão Cíclica (*Duty Cycle*)

A razão cíclica é determinada pela relação entre a tensão de saída e a tensão de entrada:

$$D = \frac{V_{out}}{V_{in}} \quad (4.9)$$

$$D = \frac{20}{36} \approx 0,555(5) \quad (4.10)$$

4.4.2 Cálculo do Indutor

O valor mínimo do indutor é calculado para garantir operação em CCM, utilizando a fórmula:

$$L_o \geq \frac{(V_{in} - V_{out}) \times D}{f_s \times \Delta I} \quad (4.11)$$

Onde:

- f_s : Frequência de comutação (20 kHz). A escolha de 20 kHz representa menos perdas por comutação, porém com um indutor de maior dimensão;
- ΔI : *Ripple* de corrente no indutor, definido como uma percentagem da corrente de saída. Desta forma, foi considerado 20% de I_{out} , ou seja, $\Delta I = 0,20 \times I_{out} \approx 0,268 \text{ A}$.

Substituindo os valores na equação, vem:

$$L_o \geq \frac{(36 - 20) \times 0,555}{20000 \times 0,268} \approx 1658,71 \mu\text{H} \quad (4.12)$$

4.4.3 Cálculo Condensador de Saída

O valor mínimo do condensador de saída é determinado para limitar o *ripple* de tensão a um valor aceitável, utilizando a fórmula:

$$C_o \geq \frac{\Delta I}{8 \times f_s \times \Delta V} \quad (4.13)$$

Onde ΔV é o *ripple* de tensão pretendido, neste caso um *ripple* de 1 mV para conseguir ter uma tensão de saída mais estável, de forma a obter para obter uma melhor precisão dos algoritmos MPPT.

$$C_o \geq \frac{0,268}{8 \times 20000 \times 0,001} \approx 1675 \mu\text{F} \quad (4.14)$$

Capítulo 5

Implementação

Este capítulo destaca a implementação dos modelos desenvolvidos no MATLAB/Simulink, focando na arquitetura dos sistemas de controlo MPPT. Desta forma, foram desenvolvidos dois modelos principais:

- Modelo com painel fotovoltaico com apenas um diódo *bypass*;
- Modelo com três grupos de células (acompanhado por três díodos *bypass*) fotovoltaicas conectadas em série para simular o efeito de sombra parcial.

Esta implementação integra algoritmos convencionais e técnicas de inteligência artificial, com um maior destaque nas redes neurais (ANN) e *Reinforcement Learning* (RL).

5.1 Controlo do Sistema MPPT com um Painel Fotovoltaico

O modelo ilustrado na Figura 5.1 representa a configuração do sistema fotovoltaico, constituído pelo painel SOLARPOWER XUNZEL 30W 24V, conversor DC/DC *buck* dimensionado para 20 V de saída, e algoritmos MPPT implementados.

Na Figura 5.2 estão representados os parâmetros definidos do painel fotovoltaico no bloco "PV Array" do Simulink, de acordo com as especificações do fabricante.




Figura 5.1: Modelo Simulink com painel fotovoltaico e conversor DC/DC.

5.2 Controlo do Sistema MPPT com Três Grupos de Células Fotovoltaicas Conectadas em Série

Para analisar o efeito de sombra parcial (PSC), foi desenvolvida uma configuração específica no modelo da Figura 5.3. Embora o painel fotovoltaico SOLARPOWER XUNZEL 30W 24V possua apenas um diodo de *bypass Schottky* conforme especificado no *datasheet* do fabricante [47], a versão simulada foi modificada para integrar três grupos de células em série independentes, cada um com o próprio diodo *bypass* de proteção. Esta abordagem utilizada teve como objetivo permitir o ajuste individual de irradiância e temperatura em cada grupo de células, permitindo simular diferentes cenários de efeito de sombra parcial (PSC).

Na Figura 5.4 estão representados os parâmetros definidos em cada grupo de células nos bloco "PV Array" do Simulink.

Module data	Model parameters
Module: User-defined	Light-generated current IL (A) 0.92376
Maximum Power (W) 29.88	Diode saturation current IO (A) 8.2963e-13
Cells per module (Ncell) 72	Diode ideality factor 0.84414
Open circuit voltage Voc (V) 43.20	Shunt resistance Rsh (ohms) 662.6979
Short-circuit current Isc (A) 0.92	Series resistance Rs (ohms) 2.7098
Voltage at maximum power point Vmp (V) 36.00	
Current at maximum power point Imp (A) 0.83	
Temperature coefficient of Voc (%/deg.C) -0.27	
Temperature coefficient of Isc (%/deg.C) 0.05	

Figura 5.2: Parâmetros do painel fotovoltaico definidos no Simulink.

5.3 Parâmetros de Simulação Simulink

As simulações foram realizadas no Simulink com uma base de tempo contínuo, utilizando um algoritmo de cálculo (*solver*) estável, o `ode23tb` [48][49]. Esta escolha foi fundamental para garantir a precisão dos resultados, especialmente em modelos com componentes passivos de pequenas dimensões, como é o caso de indutâncias e condensadores.

A utilização do tempo contínuo como foi referido, permite uma representação mais realista do sistema, ao contrário do tempo discreto, que pode introduzir erros de discretização e omitir detalhes importantes em transições rápidas. No entanto, esta abordagem tem um aumento significativo do tempo de simulação, especialmente quando são utilizados passos de simulação muito pequenos.

5.4 Algoritmos Convencionais

Na implementação dos algoritmos convencionais, nomeadamente o *Perturb and Observe* (P&O) e *Condutância Incremental* (InC), foram definidos parâmetros comuns e específicos em cada abordagem. Para ambos os algoritmos, foi utilizado um passo perturbação fixo apresentado na Tabela 5.1 designado por $\Delta(\Delta)$, permitindo uma boa resposta no sistema sem comprometer a estabilidade do conversor *Buck*. O *duty cycle* inicial foi definido como $D_{init} = 0,5555$, valor calculado com base na razão entre a tensão de saída (20 V) pretendida e a tensão no ponto MPP do painel fotovoltaico (36 V).

No algoritmo P&O, a decisão de aumentar ou diminuir o *duty cycle* baseia-se na comparação entre a potência e a tensão atuais e anteriores, sendo necessário armazenar os valores anteriores de potência e tensão (P_{old}, V_{old}) para determinar a direção da perturbação. Por outro lado, no caso do algoritmo InC, para além dos valores de tensão, são também armazenados os valores anteriores de corrente, permitindo calcular as derivadas de tensão e corrente (dV, dI). Por último, para o algoritmo InC, foi considerado como critério de convergência o cumprimento da




Figura 5.3: Modelo Simulink com três grupos de células fotovoltaicas conectadas em série.

condição $\left| \frac{dI}{dV} + \frac{I}{V} \right| < 10^{-6}$, significando que o sistema encontra-se próximo do ponto MPP, mantendo o *duty cycle* inalterado $Duty = duty_old$.

Module data	Model parameters
Module: User-defined	Light-generated current IL (A) 0.92376
Maximum Power (W) 9.96	Diode saturation current IO (A) 8.2963e-13
Cells per module (Ncell) 72/3 24	Diode ideality factor 0.84414
Open circuit voltage Voc (V) 43.20*24/72 14.4	Shunt resistance Rsh (ohms) 220.8993
Short-circuit current Isc (A) 0.92	Series resistance Rs (ohms) 0.90328
Voltage at maximum power point Vmp (V) 36.00*24/72 12	
Current at maximum power point Imp (A) 0.83	
Temperature coefficient of Voc (%/deg.C) -0.27	
Temperature coefficient of Isc (%/deg.C) 0.05	

Figura 5.4: Parâmetros em cada grupo de células fotovoltaicas definidos no Simulink.

Tabela 5.1: Parâmetros utilizados nas simulações dos algoritmos convencionais P&O e InC.

Parâmetro	Valor
Tamanho do passo (Δ)	125×10^{-6}
<i>Duty Cycle</i> inicial (D_{init})	0,5555
Limites do <i>duty cycle</i> (D_{min} / D_{max})	0 / 1
Tipo de simulação	Tempo contínuo

5.5 Lógica Difusa (FLC)

A implementação do algoritmo FLC para o sistema MPPT foi desenvolvida utilizando uma abordagem baseada no método de *Mamdani*, seguindo as três etapas principais, nomeadamente, fuzzificação, inferência e defuzzificação.

5.5.1 Fuzzificação

As entradas são o erro normalizado (E) e a derivada do erro normalizada (dE), calculadas conforme as equações:

$$E = \frac{\Delta P}{\Delta V} = \frac{P(k) - P(k-1)}{V(k) - V(k-1)} \quad (5.1)$$

$$dE = E(k) - E(k-1) \quad (5.2)$$

Estas grandezas são normalizadas para o intervalo $[-1, 1]$ através de:

$$E_{\text{norm}} = \text{sat} \left(\frac{E}{0,5} \right), \quad dE_{\text{norm}} = \text{sat} \left(\frac{dE}{0,2} \right) \quad (5.3)$$

Sendo $\text{sat}(x)$ a função de saturação que limita os valores ao intervalo $[-1, 1]$. Esta normalização serve para ajustar os valores do erro e da variação a um intervalo, facilitando a avaliação das funções de pertinência *fuzzy*. Os valores 0,5 e 0,2 foram

escolhidos, uma vez que representam os valores máximos esperados para estas grandezas, evitando que os dados fiquem fora do intervalo.

Para a fuzzificação, são utilizadas funções de pertinência triangulares (Figura 5.5) definidas pela equação (5.4):

$$\mu(x, a, b, c) = \max \left(\min \left(\frac{x - a}{b - a}, \frac{c - x}{c - b} \right), 0 \right) \quad (5.4)$$




Figura 5.5: Funções de pertinência triangulares para as variáveis de entrada: erro (E) e derivada do erro (dE)

Cada variável de estado possui cinco conjuntos *fuzzy*, nomeadamente, Negativo Grande (NL), Negativo Pequeno (NS), Zero (Z), Positivo Pequeno (PS) e Positivo Grande (PL).

5.5.2 Inferência *Fuzzy*

A base de regras com base no método de Mamdani, utiliza *min* para a implicação, conforme evidenciado no código:

```
1 w = min(muE(i), muDE(j)); % Operador AND como minimo
```

Listagem 5.1: Operador de implicação Mamdani no código

A Tabela 5.2 mostra a relação entre as entradas e as saídas, definindo a base de regras do sistema.

Apresentam-se alguns exemplos de definições das regras:


Tabela 5.2: Base de regras *fuzzy* para ΔD (variação do *duty cycle*) com variáveis linguísticas

$E \backslash dE$	NL	NS	Z	PS	PL
NL	PL	PL	PS	PS	Z
NS	PL	PS	PS	Z	NS
Z	PS	Z	Z	Z	NS
PS	Z	NS	NS	NS	NL
PL	NS	NS	NL	NL	NL


- Se E é NL e dE é NL, então ΔD é PL.
- Se E é Z e dE é Z, então ΔD é Z.
- Se E é PL e dE é PL, então ΔD é NL.

De acordo com os exemplos apresentados, observa-se que em situações nas quais o erro e a variação do erro revelam um desvio significativo relativamente ao ponto de máxima potência, o controlador aplica alterações mais acentuadas ao *duty cycle*. Em contrapartida, em condições próximas do ponto ótimo, os ajustes efetuados são mínimos ou nulos, garantindo a estabilidade durante a monitorização do MPP.

Cada elemento $ruleBase(i, j)$ corresponde à ação de controlo para a combinação das regras i (erro) e j (derivada do erro), dando origem à função de pertinência e superfície de controlo de saída ilustradas nas Figuras 5.6a e 5.6b, respetivamente.



(a)



(b)

Figura 5.6: (a) Função de pertinência de saída para a variação do *duty cycle* (ΔD) e (b) Superfície de controlo *fuzzy*

5.5.3 Defuzzificação

A defuzzificação (Figura 5.6a) é realizada pelo método do centro de gravidade (*Center of Gravity*) para a união dos conjuntos *fuzzy*, típico dos sistemas de inferência *fuzzy* do tipo *Mamdani*:

$$\Delta D_{\text{output}} = \frac{\sum_{i=1}^5 \sum_{j=1}^5 w_{ij} \cdot \Delta D_{ij}}{\sum_{i=1}^5 \sum_{j=1}^5 w_{ij}} \quad (5.5)$$

Onde:

- $w_{ij} = \min(\mu_E(i), \mu_{\dot{E}}(j))$ é o grau de ativação (peso) da regra *fuzzy* correspondente à combinação das entradas E (erro) e dE (derivada do erro);
- ΔD_{ij} o consequente da regra *fuzzy* na posição (i, j) , extraído da base de regras (`ruleBase`).

5.6 Algoritmos Híbridos

Os algoritmos híbridos combinam técnicas distintas para aproveitar as vantagens de cada abordagem, de forma a superar limitações individuais. Desta forma, nas seguintes subsecções, serão apresentados métodos híbridos para a otimização do MPP em sistemas fotovoltaicos, integrando métodos clássicos com outros tipos de algoritmos.

5.6.1 Perturbação Observação (P&O) com Algoritmo Genético (GA)

A integração entre o algoritmo P&O e o GA foi concebido para melhorar o desempenho do sistema de monitorização do ponto MPP em tempo real. A Figura 5.7 ilustra o fluxograma detalhado desta abordagem híbrida, onde o GA atua como um mecanismo de otimização, ajustando dinamicamente o parâmetro Δ (passo de perturbação) utilizado pelo P&O, enquanto este mantém a sua operação tradicional, porém com um valor de Δ otimizado.

Inicialmente, o passo de perturbação (Δ) é inicializado com um valor de 125×10^{-6} , com limites entre 0,00005 e 0,0002.

As medições da tensão e corrente do painel fotovoltaico, V_{pv} e I_{pv} , são suavizadas por um filtro de média móvel exponencial definido pela equação (5.6) [50][51]:

$$x_f(k) = \alpha \cdot x(k) + (1 - \alpha) \cdot x_f(k - 1), \quad (5.6)$$

Onde x representa as grandezas V_{pv} e I_{pv} , e $\alpha = 0,01$ é o coeficiente de suavização, tendo como objetivo reduzir o ruído nas medições, permitindo melhorar a estabilidade do algoritmo.

Em cada ciclo de execução, o GA gera uma população de 50 soluções candidatas para Δ , avaliando cada uma através de uma função *fitness* que considera a potência




Figura 5.7: Fluxograma do algoritmo GA+P&O.

instantânea ($V_{pv} \times I_{pv}$) penalizada por valores elevados de Δ . Durante 5 gerações, o GA aplica operadores genéticos, nomeadamente, a seleção por torneio (entre 3 candidatos), *crossover* com fator aleatório α , e mutação com probabilidade de 30%, tal como é mostrado na Tabela 5.3. Desta forma, o melhor Δ encontrado é então passado ao algoritmo P&O.

Relativamente à função de *fitness* representada na Tabela 5.3, foi desenvolvida para avaliar a qualidade dos passos de perturbação Δ no GA. Esta função tem dois objetivos principais, nomeadamente, maximizar a potência extraída do painel ($P_{pv} = V_{pv} \times I_{pv}$) e penalizar valores elevados de Δ através do termo $-5 \cdot \Delta$. Este fator de penalização 5 foi determinado empiricamente para encontrar o equilíbrio ideal entre velocidade de convergência e estabilidade do sistema. Assim, esta função faz com que o GA utilize soluções que combinem a potência elevada com pequenos passos de perturbação, garantindo assim uma operação estável, minimizando as oscilações do sistema fotovoltaico em condições variáveis.

A solução desenvolvida demonstra como técnicas de otimização como é o caso do GA podem ser acoplados a algoritmos MPPT clássicos, melhorando o desempenho global sem comprometer a eficiência computacional. É de notar que esta otimização

Tabela 5.3: Parâmetros do algoritmo genético.

Parâmetro	Valor
Tamanho da população	50 indivíduos
Número máximo de gerações	5
Limite inferior para Δ (lb)	0,00005
Limite superior para Δ (ub)	0,0002
Taxa de mutação	30 %
Tamanho do torneio (seleção)	3 indivíduos
Tipo de <i>crossover</i>	α aleatório
Função de <i>fitness</i>	$P = V_{pv} \times I_{pv} - \Delta \times 5$

dinâmica do parâmetro Δ supera a principal limitação do algoritmo P&O convencional, a utilização de um passo fixo, adaptando-se automaticamente às diferentes condições ambientais.

5.6.2 Condutância Incremental (InC) com Algoritmo Genético (GA)

Tal como descrito na abordagem anterior com o algoritmo P&O, o algoritmo genético (GA) foi integrado com o método da Condutância Incremental (InC), mantendo o mesmo objetivo de otimizar dinamicamente o parâmetro Δ (passo de perturbação). Além disso, os parâmetros do algoritmo genético, nomeadamente, população, número de gerações, função de *fitness* e operadores genéticos, permanecem inalterados, como listado na Tabela 5.3.

5.6.3 Condutância Incremental (InC) com Perturbação Observação (P&O)

Na implementação híbrida entre os algoritmos InC e P&O foi utilizado como critério de comutação entre os dois métodos a variação de tensão ($|dV|$), adotando o seguinte comportamento:

- O InC é executado quando $|dV| > 5 \times 10^{-4}$ V, sendo mais eficaz em condições dinâmicas devido ao cálculo preciso da derivada, permitindo uma convergência rápida para o ponto MPP;
- O P&O entra em execução para $|dV| \leq 5 \times 10^{-4}$ V, mostrando melhor desempenho em regime estável.

É de notar que a transição entre os algoritmos ocorre de forma contínua durante a execução, mantendo a mesma estrutura de variáveis para armazenamento dos valores anteriores de tensão, corrente e potência.

5.7 Algoritmo ANN

A tensão, a corrente e a potência máxima de um painel fotovoltaico são influenciadas pelas condições ambientais, nomeadamente a irradiância e a temperatura ambiente. Desta forma, a entrada da rede neuronal é composta por dados de temperatura e irradiância, enquanto a saída corresponde à tensão máxima V_{mp} prevista para essas condições, que serve como referência no sistema de controlo, atuando como *setpoint*, para depois ser comparado com a tensão real medida no painel fotovoltaico. A diferença entre a tensão prevista e a tensão real, denominada por erro, é então aplicada como entrada no controlador PI, onde é ajustado o sinal de controlo (neste caso, o *duty cycle*) de forma a otimizar o ponto de operação do painel, colocando-o mais próximo possível do ponto MPP. Na Figura 5.8 está ilustrado um diagrama de blocos do sistema de controlo descrito.




Figura 5.8: Diagrama de blocos do sistema de controlo baseado na rede neuronal e controlador PI.

5.7.1 Dataset

Para treinar a rede neuronal, foi criado um *dataset* que simula condições reais de operação de um painel fotovoltaico, incluindo variações de temperatura e irradiância

Os perfis foram definidos com um passo temporal de 1 ms ($T_s = 0,001$ s), formando 1 milhão de amostras para cada uma das variáveis ao longo de 1000 segundos. O número de amostras foi calculado pela relação:

$$N = \frac{\text{tempo_total}}{T_s} = \frac{1000}{0,001} = 1.000.000 \quad (5.8)$$

O vetor de tempo definido pela seguinte equação:

$$\text{tempo} = (0 : N - 1) \times T_s \quad (5.9)$$

Com a equação 5.9 é criada uma sequência de números inteiros que começa em 0 e termina em $N - 1$, ou seja, contém exatamente N elementos. Ao multiplicar esta sequência pelo passo de tempo T_s , é obtido o instante temporal correspondente a cada amostra.

Na Tabela 5.4 são apresentadas as estatísticas das variáveis meteorológicas simuladas.

Tabela 5.4: Estatísticas das variáveis em cada um dos gráficos.

Parâmetro	Temperatura (°C)	Irradiância (W/m²)
Nº de Amostras	1.000.000	1.000.000
Média	31,09	583,44
Desvio Padrão	10,11	272,92
Mínimo	15,00	1,00
Máximo	45,00	1000,00

Em primeiro lugar, foram introduzidas três janelas para obter dados em condições STC, nos instantes 200, 600 e 850 segundos, onde foi colocado mais peso na irradiância para 1000 W/m² e a temperatura para 25 °C.

Em segundo lugar, no restante período, para a irradiância foi aplicada uma função sinusoidal com oscilação entre 150 e 850 W/m², sobreposta com ruído gaussiano ($\sigma = 50$ W/m²) para simular variações naturais. O intervalo de temperatura foi definido entre 15 °C e 45 °C com ruído moderado ($\sigma = 1,5$ °C). As funções sinusoidais com adição de ruído gaussiano são representadas pelas seguintes expressões (5.10) e (5.11):

$$G(t) = G_{\text{médio}} + A_G \cdot \sin\left(\frac{2\pi t}{T_G}\right) + \mathcal{N}(0, \sigma_G^2) \quad (5.10)$$

$$T(t) = T_{\text{médio}} + A_T \cdot \sin\left(\frac{2\pi t}{T_T}\right) + \mathcal{N}(0, \sigma_T^2) \quad (5.11)$$

Onde:

- $G_{\text{médio}} = 500$ W/m², $A_G = 350$ W/m², $T_G = 300$ s;

- $T_{\text{médio}} = 30^\circ\text{C}$, $A_T = 15^\circ\text{C}$, $T_T = 600\text{ s}$;
- $\mathcal{N}(0, \sigma^2)$ representa ruído branco gaussiano com desvio padrão σ , sendo $\sigma_G = 50\text{ W/m}^2$ e $\sigma_T = 1,5^\circ\text{C}$.

O período da função sinusoidal associada à irradiância, $T_G = 300\text{ s}$, foi escolhido com objetivo de simular oscilações suaves a cada 5 minutos, refletindo variações típicas em condições de céu parcialmente nublado ao longo de um dia. Já a oscilação da temperatura foi definida com um período maior, $T_T = 600\text{ s}$, refletindo uma mudança mais lenta da temperatura.

Por último, os dados são guardados em ficheiros **G.mat** e **T.mat** com as variáveis **G_simulink** e **T_simulink**, respetivamente, para a utilização no Simulink através de blocos "From File", tal como está representado na Figura 5.10.

5.7.2 Treino da Rede Neuronal

Os dados obtidos na simulação mencionada na subsecção anterior, nomeadamente, irradiância (W/m^2), temperatura ($^\circ\text{C}$), tensão (V) e potência (W), foram exportados para o *workspace* do MATLAB para treinar a rede neuronal. Estes dados foram organizados em dois conjuntos distintos, as variáveis de entrada, constituído pela irradiância e temperatura, e as variáveis de saída, correspondentes à tensão e a potência máxima (V_{mp} e P_{mp}).

A arquitetura da rede, representada na Figura 5.11, consiste numa rede neuronal *feedforward* com as seguintes características:

- **Camadas:**
 - Camada de entrada: 2 neurónios (irradiância e temperatura);
 - Duas camadas ocultas: 20 neurónios na primeira camada e 10 neurónios na segunda, com função de ativação *tansig*, designada por tangente hiperbólica sigmoidal;
 - Camada de saída: 2 neurónios (V_{mp} e P_{mp}), com função de ativação *purelin*, designada por função linear.
- **Algoritmo de treino:** *Levenberg-Marquardt* (**trainlm**), definido implicitamente pelo *fitnet* no código.
- **Divisão dos dados:** 75% treino, 15% validação, 10% teste.

Os parâmetros de configuração da rede encontram-se detalhados na Tabela 5.5.




Figura 5.11: Arquitetura da rede neuronal no MATLAB.

Tabela 5.5: Parâmetros de configuração da rede neuronal.

Parâmetro	Valor
Número máximo de épocas	1 000
Tolerância de erro (<code>goal</code>)	1×10^{-5}
Função de divisão de dados	<code>dividerand</code>

Comparação do Número de Neurónios nas Camadas Ocultas

Durante a fase inicial de desenvolvimento da rede neuronal, foram testadas várias configurações para o número de neurónios nas camadas ocultas, com o objetivo de identificar a arquitetura com melhor desempenho. A Tabela 5.6 apresenta os resultados obtidos, incluindo o erro quadrático médio (MSE) e o tempo de treino (em minutos) associado a cada configuração escolhida.

Tabela 5.6: Comparação do erro quadrático médio (MSE) e tempo de execução para diferentes configurações de neurónios nas camadas ocultas.

Camada Oculta 1	Camada Oculta 2	MSE	Tempo de Treino (minutos)
5	5	0,9380	6,86
10	10	0,9299	17,26
15	15	0,9295	37,24
20	10	0,9295	30,31
20	20	0,9294	30,12

Desta forma, todas as configurações com 15 ou mais neurónios por camada atingem valores de MSE bastante semelhantes, com pequenas diferenças entre cada um dos valores. A configuração [20 10] utilizada, referida na secção 5.7.2, foi escolhida por apresentar um equilíbrio entre desempenho e tempo de treino, mantendo o MSE baixo (0,9295). No entanto, é importante referir que outras configurações, nomeadamente [15 15] e [20 20], também apresentaram desempenhos praticamente idênticos no MSE, pelo que poderiam igualmente ter sido selecionadas sem afetar a qualidade do treino. Além disso, o *hardware* utilizado para treinar a rede com as diferentes configurações está descrito na Tabela 6.1.

É de referir que a saturação do desempenho pode ser explicada principalmente pelo tamanho do conjunto de dados utilizado para o treino da rede. Com cerca de 1 milhão de amostras, abrangendo variáveis como irradiância, temperatura, tensão e potência, o *dataset* é suficientemente extenso para garantir que a rede aprende de forma eficaz o mapeamento entre as variáveis de entrada e saída. Consequentemente, o aumento ou diminuição do número de neurónios nas camadas ocultas não resultou em melhorias significativas no erro de previsão, uma vez que a rede já atinge uma boa generalização.

Desempenho da Rede Neuronal

Para validar o desempenho da rede neuronal, a Figura 5.12 apresenta os resultados principais do treino. O gráfico de desempenho (Figura 5.12a) mostra a evolução do erro ao longo das épocas, indicando que a melhor validação (0,94349) ocorreu na época 266. Por sua vez, o gráfico de regressão (Figura 5.12b) demonstra uma forte correlação entre os valores previstos e os valores reais, com um coeficiente $R=0,99575$ para os dados de teste, evidenciando uma boa generalização do modelo.

É de notar que no final do treino da rede, é gerado automaticamente um bloco em Simulink denominado por *Function Fitting Neural Network* para ser utilizado no modelo ilustrado na Figura 5.13.




Figura 5.12: Resultados do treino da rede neuronal: (a) Desempenho do treino com melhor validação (0,94349) na época 266; (b) Regressão do treino com $R \approx 0,996$.

Para avaliar a capacidade de generalização da rede neuronal, foram selecionadas aleatoriamente 10 amostras do conjunto de teste, correspondente a 10% dos dados reservados pela função `train`, dados que não foram utilizados no processo de treino nem de validação. As Tabelas 5.7 e 5.8 comparam os valores reais e previstos de V_{mp} e P_{mp} , realçando que a rede neuronal na maior parte dos testes realizados, apresentam erros relativos inferiores a 2% para V_{mp} e 4% para P_{mp} . Estes erros foram calculados com base nas equações (5.12) e (5.13), que definem o erro absoluto e o erro relativo, respetivamente.

$$\text{Erro absoluto} = |X_{\text{real}} - X_{\text{prev}}| \quad (5.12)$$

O erro absoluto representa a diferença em valor absoluto entre o valor real (X_{real}) e o valor previsto (X_{prev}).

$$\text{Erro relativo (\%)} = \left(\frac{|X_{\text{real}} - X_{\text{prev}}|}{X_{\text{real}}} \right) \times 100 \quad (5.13)$$

O erro relativo indica o erro absoluto em relação ao valor real, expresso em percentagem. É utilizado para avaliar a precisão relativa da previsão.




Figura 5.13: Modelo Simulink com rede neuronal.

Tabela 5.7: Resultados para Tensão (V_{mp})

Ponto Teste	Irrad. (W/m ²)	Temp. (°C)	Vmp Real (V)	Vmp Prev. (V)	Erro Abs. (V)	Erro Rel. (%)
1	477,21	31,58	18,20	18,56	0,36	2,00
2	163,71	23,19	6,52	6,44	0,08	1,25
3	597,23	43,73	22,79	23,14	0,35	1,54
4	433,10	42,56	16,71	16,99	0,28	1,70
5	868,99	18,45	32,66	32,73	0,06	0,19
6	531,06	32,95	20,60	20,58	0,02	0,07
7	797,51	17,32	30,52	30,01	0,50	1,65
8	856,85	23,42	32,94	32,47	0,47	1,43
9	883,10	43,10	33,58	33,15	0,43	1,27
10	294,77	44,72	11,80	11,66	0,13	1,13

Tabela 5.8: Resultados para Potência (P_{mp})

Ponto Teste	Irrad. (W/m ²)	Temp. (°C)	Pmp Real (W)	Pmp Prev. (W)	Erro Abs. (W)	Erro Rel. (%)
1	477,21	31,58	7,64	7,94	0,30	3,94
2	163,71	23,19	0,98	0,96	0,02	2,13
3	597,23	43,73	11,97	12,34	0,37	3,06
4	433,10	42,56	6,44	6,65	0,22	3,35
5	868,99	18,45	24,60	24,70	0,10	0,41
6	531,06	32,95	9,78	9,78	0,001	0,01
7	797,51	17,32	21,47	20,76	0,71	3,29
8	856,85	23,42	25,01	24,32	0,70	2,78
9	883,10	43,10	25,99	25,42	0,58	2,22
10	294,77	44,72	3,21	3,14	0,07	2,22

5.8 Algoritmo ANN em PSC

Para estender a aplicação da rede neuronal a condições PSC, a arquitetura da ANN foi adaptada para considerar múltiplos grupos de células fotovoltaicas. Em vez de duas entradas (irradiância e temperatura), a rede agora recebe seis entradas, correspondentes aos valores de irradiância e temperatura de cada um dos grupos de células.

5.8.1 Adaptação do *Dataset* para PSC

Com o objetivo de adaptar a rede neuronal a cenários PSC, foi criado um novo *dataset* com base em perfis utilizados nos testes dos algoritmos MPPT em PSC na Tabela 5.16 do Capítulo 5.

A temperatura foi mantida constante a 25 °C, enquanto à irradiância foi aplicado um pequeno ruído gaussiano para simular condições realistas em cada grupo de células. Na Figura 5.14 são apresentados os perfis de irradiância aplicados a cada grupo de células.

Conforme evidenciado na Tabela 5.9, as temperaturas mantiveram-se fixas (25 °C) em todos os cenários, enquanto as irradiâncias apresentaram algumas variações.

Tabela 5.9: Estatísticas das variáveis em cada um dos gráficos.

Parâmetro	T1 (°C)	G1 (W/m ²)	T2 (°C)	G2 (W/m ²)	T3 (°C)	G3 (W/m ²)
Nº Amostras	1.000.000	1.000.000	1.000.000	1.000.000	1.000.000	1.000.000
Média	25,00	508,99	25,00	490,99	25,00	462,49
Desvio Padrão	0,00	116,37	0,00	123,70	0,00	104,81
Mínimo	25,00	160,82	25,00	80,78	25,00	78,29
Máximo	25,00	1092,16	25,00	1213,45	25,00	500,00




Figura 5.14: Distribuição de irradiância nos três grupos de células em condições PSC, mantendo a temperatura a 25 °C: (a) Grupo de células 1, (b) Grupo de células 2, e (c) Grupo de células 3

Estes dados foram posteriormente utilizados no Simulink em tempo discreto, para cada um dos grupos de células, tal como está ilustrado na Figura 5.15.

5.8.2 Treino da Rede Neuronal para PSC

A rede neuronal foi novamente treinada com os novos *datasets*, mantendo a mesma estrutura de camadas (duas ocultas com 20 e 10 neurónios, respetivamente), mas com seis neurónios na camada de entrada. É de notar que o algoritmo de treino e os parâmetros permaneceram inalterados.

Para validar o desempenho da rede neuronal, a Figura 5.16 apresenta os resultados principais do treino. O gráfico de desempenho (Figura 5.16a) mostra a evolução do erro ao longo das épocas, indicando que a melhor validação ($9,3476 \times 10^{-6}$) ocorreu na época 192. Além disso, o gráfico de regressão (Figura 5.16b) demonstra uma forte correlação entre os valores previstos e os valores reais, evidenciando uma boa generalização do modelo.

Após o treino da rede, o bloco gerado é aplicado no modelo ilustrado na Figura 5.17.




Figura 5.15: Modelo Simulink para recolha dos dados de treino em PSC.

A Tabela 5.10 retrata os valores reais e previstos de V_{mp} e P_{mp} , demonstrando que a rede neuronal apresenta erros absolutos muito baixos nos cenários testados.




Figura 5.16: Resultados do treino da rede neuronal: (a) Desempenho do treino com melhor validação ($9,3476 \times 10^{-6}$) na época 192; (b) Resultados da regressão.




Figura 5.17: Bloco *Function Fitting Neural Network* aplicado no modelo.

5.9 Algoritmo DQN

O algoritmo DQN proposto para o sistema MPPT foi desenvolvido com base nos princípios do DRL, permitindo ao sistema aprender de forma autônoma a monitorizar o ponto MPP em diferentes condições de irradiância e temperatura.

A Figura 5.18 ilustra o modelo implementado no Simulink para o controlo MPPT utilizando um agente de RL, mais concretamente o algoritmo DQN. Este modelo é constituído por vários blocos, nomeadamente, a definição do estado do sistema a partir dos sensores, cálculo da recompensa, e o agente de decisão que determina a ação ótima (variação do *duty cycle*).

5.9.1 Arquitetura do Agente DQN

O agente DQN foi projetado com os seguintes parâmetros:

Tabela 5.10: Resultados das previsões de V_{mp} e P_{mp} para diferentes cenários.

Cen.	Irr1 (W/m ²)	Temp1 (°C)	Irr2 (W/m ²)	Temp2 (°C)	Irr3 (W/m ²)	Temp3 (°C)	V_{mp} (V) Real/Previsto	P_{mp} (W) Real/Previsto
1	900	25	1000	25	200	25	25,54/25,5408	15,04/15,0397
2	200	25	400	25	300	25	12,01/12,0054	3,32/3,3224
3	900	25	100	25	150	25	12,25/12,2519	3,46/3,4615
4	300	25	200	25	100	25	10,54/10,5422	2,56/2,5642

PV MPPT Control Based On Reinforcement Learning




Figura 5.18: Controle MPPT Baseado em RL.

- Espaço de Estados (S);
- Espaço de Ações (A);
- Função de Recompensa (R).

Espaço de Estados (S)

A observação, também designada pelo espaço de estados (S), é representado pela combinação da tensão do painel, corrente do painel, razão cíclica (*duty cycle*) e a perturbação, definido pelo conjunto S:

$$S = \{V_{pv}, I_{pv}, D, \Delta D\}$$

Onde:

- V_{pv} e I_{pv} são a tensão e corrente do painel fotovoltaico;
- D é o *duty cycle* atual do conversor DC/DC;
- ΔD é a perturbação aplicada ao *duty cycle*.

Espaço de Ações (A)

O espaço de ações (A) corresponde às perturbações no *duty cycle* positivas, negativas ou sem alteração, tal como está descrito no conjunto A:

$$A = \{-\Delta D, 0, +\Delta D\}$$

$$A = \{-0.03, -0.01, -0.005, -0.001, 0, 0.001, 0.005, 0.01, 0.03\} \quad (5.14)$$

Função de Recompensa (R)

A função de recompensa total é composta por sete componentes distintas que visam guiar o agente na maximização da potência extraída do painel fotovoltaico, de forma a evitar quedas significativas de potência, respeitando os limites de *duty cycle* e incentivando o aumento da potência. A equação geral da recompensa total é a seguinte:

$$R = r_1 + r_2 + r_3 + r_4 + r_5 + r_6 + r_7 \quad (5.15)$$

- r_1 : Potência relativa – recompensa base:

$$r_1 = \frac{P_{t+1}}{P_{MPP,STC}} \quad (5.16)$$

Onde P_{t+1} é a potência atual e $P_{MPP,STC}$ é a potência máxima esperada sob condições de teste padrão (STC), que neste caso é $P_{MPP} = 29,88 \text{ W}$ para $G = 1000 \text{ W/m}^2$ e $T = 25^\circ\text{C}$. Esta recompensa permite o agente distinguir entre máximos locais e globais, mantendo sempre que possível recompensas elevadas se o agente se mantiver no ponto GMPP.

- r_2 : Recompensa pelo aumento de potência:

$$r_2 = \begin{cases} \left(\frac{P_{t+1}}{P_{MPP,STC}}\right)^2, & \text{se } \Delta P > -\delta_1 \text{ (com } \delta_1 = 1) \\ -\left(\frac{P_{t+1}}{P_{MPP,STC}}\right)^2, & \text{se } \Delta P < -\delta_1 \text{ (com } \delta_1 = 1) \end{cases} \quad (5.17)$$

Este termo fornece uma recompensa positiva quando há um aumento significativo de potência (acima de $-\delta_1$), e penaliza quedas acentuadas ($\Delta P = P_{t+1} - P_t < -\delta_1$) com recompensas negativas, tal como está descrito na equação (5.17).

- r_3 : Penalização fora dos limites do *duty cycle*:

$$r_3 = \begin{cases} 0, & \text{se } 0 \leq D \leq 1 \\ -1, & \text{caso contrário} \end{cases} \quad (5.18)$$

Esta penalização tem como objetivo desencorajar ações que fazem com que o *duty cycle* ultrapasse os limites físicos aceitáveis, neste caso valores fora do intervalo $[0, 1]$, como está representado na equação (5.18).

- r_4 : Penalização proporcional para quedas significativas de potência (ΔP):

$$r_4 = \begin{cases} \Delta P \times \left(\frac{5}{P_{MPP,STC}} \right), & \text{se } \Delta P < -2 \\ 0, & \text{se } \Delta P \geq -2 \end{cases} \quad (5.19)$$

Quando há uma grande queda de potência ($\Delta P < -2$), a penalização é proporcional à queda relativa em relação à potência máxima esperada. O fator 5 foi selecionado para aumentar o impacto da penalização na recompensa total.

- r_5 : Recompensa por ganhos significativos de potência:

$$r_5 = \begin{cases} \frac{P_{t+1}}{P_{MPP,STC}}, & \text{se } \Delta P > 3 \\ 0, & \text{caso contrário} \end{cases} \quad (5.20)$$

Este termo visa incentivar aumentos expressivos de potência. É de notar que a recompensa só é atualizada se o valor atual de ΔP for superior a 3.

- r_6 : Recompensa pela estabilidade da corrente:

$$r_6 = \begin{cases} +0,5, & \text{se } |\Delta I| < 0,001 \\ -1,5 \cdot |\Delta I|, & \text{caso contrário} \end{cases} \quad (5.21)$$

Quando a variação da corrente $|\Delta I|$ entre dois instantes consecutivos é inferior a 0.001 A, considera-se que o sistema é estável, sendo atribuída uma pequena recompensa com o valor de 0,5. Caso contrário, é aplicada uma penalização proporcional à magnitude da variação, incentivando o agente a evitar oscilações indesejadas.

- r_7 : Recompensa exponencial com limiar de estabilidade:

$$r_7 = \begin{cases} \alpha \cdot \exp\left(-\frac{|\Delta P|}{\beta}\right), & \text{se } |\Delta P| < \delta_2 \\ 0, & \text{caso contrário} \end{cases} \quad (5.22)$$

Esta recompensa visa promover a estabilidade no ponto MPP. Desta forma, quando a variação de potência é pequena ($|\Delta P| < \delta_2$), é atribuída uma recompensa que decresce exponencialmente com a magnitude da variação. Os parâmetros utilizados são $\alpha = 1,5$ (recompensa máxima), $\beta = 0,05$ (suavidade da transição) e $\delta_2 = 0,005$ (limite para considerar a estabilidade do sistema).

5.9.2 Estrutura da *Critic Network*

A rede neuronal profunda utilizada no algoritmo DQN, ilustrada na Figura 5.19, tem como objetivo aproximar a função valor-ação (*Q-function*). Ainda assim, esta rede recebe como entrada o estado atual do sistema e resulta como saída os valores Q esperados para cada ação possível no espaço de ações discreto.




Figura 5.19: Estrutura *Critic Network*.

Desta forma, a *Critic Network* é composta por dois ramos principais, nomeadamente:

- **StatePath:** Recebe como entrada o estado observado do ambiente, onde é processado através de três camadas totalmente conectadas intercaladas com funções de ativação *ReLU*;
- **ActionPath:** Processa a ação do agente com uma única camada totalmente conectada;
- **CommonPath:** As saídas dos dois caminhos são somadas com uma *additionLayer*, seguidas de uma ativação *ReLU*. Por fim, é gerado como

output o valor estimado da função $Q(s, a|\theta)$, isto é, o valor da ação no estado atual.

Na Tabela 5.11 é apresentada a correspondência entre os nomes das camadas ilustradas anteriormente na Figura 5.19 e os respectivos elementos da rede implementados no código MATLAB.

A escolha de 200 neurónios nas camadas *state* da rede *critic* foi realizada com base em testes comparativos com diferentes dimensões da rede, onde foram realizadas simulações com 64, 200 e 800 neurónios por camada, com o objetivo de encontrar um equilíbrio entre desempenho e complexidade computacional. A configuração com 64 neurónios revelou-se insuficiente para captar a complexidade do ambiente, resultando em recompensas baixas e elevadas oscilações durante o treino. Por outro lado, a utilização de 800 neurónios aumentou significativamente o tempo de treino, introduzindo maior instabilidade, devido à dificuldade de convergência em redes mais profundas. Por último, a rede com 200 neurónios apresentou o melhor desempenho, evidenciando uma melhoria progressiva e consistente das recompensas ao longo dos episódios, com um comportamento mais estável.

Tabela 5.11: Correspondência entre os nomes das camadas e código da rede do crítico.

Parâmetro	Código
observation	imageInputLayer
CriticStateFC1	fullyConnectedLayer(200)
CriticRelu1	reluLayer
CriticStateFC2	fullyConnectedLayer(200)
CriticRelu2	reluLayer
CriticStateFC3	fullyConnectedLayer(100)
action	imageInputLayer
CriticActionFC1	fullyConnectedLayer(100)
add	additionLayer(2)
CriticCommonRelu	reluLayer
output	fullyConnectedLayer(1)

No que diz respeito ao ramo da ação na rede crítica, representado pela camada **CriticActionFC1**, possui apenas 100 neurónios, uma vez que corresponde ao *duty cycle* aplicado ao conversor, ou seja, uma variável contínua e escalar, de baixa complexidade, tal como foi definido na equação (5.14). Assim sendo, uma única camada totalmente conectada é suficiente para transformar esta entrada antes da combinação com as características extraídas do *state*.

Além disso, a camada **CriticStateFC3** possui também 100 neurónios para garantir a compatibilidade dimensional com a camada da ação. Deste modo, esta igualdade no número de neurónios é necessária para que a operação de soma (**additionLayer**) aconteça entre os dois ramos da rede, permitindo a integração adequada da informação do estado (*state*) e da ação (*action*) na rede crítica.

5.9.3 Parâmetros de simulação DQN

A definição dos parâmetros do agente é essencial no processo de RL, uma vez que influencia diretamente a eficiência e a estabilidade do treino. Na Tabela 5.12 são apresentados os principais parâmetros utilizados na configuração do agente DQN, incluindo o tempo de amostragem, a política de exploração *epsilon-greedy*, e a estrutura de aprendizagem aplicada à rede crítica (rede neuronal). É de salientar que inicialmente, o parâmetro *Epsilon* (ϵ) é inicializado com um valor elevado (valor definido como 1), permitindo uma exploração intensa do espaço de ações. À medida que o treino progride, uma função de decaimento reduz gradualmente o valor de ϵ , aumentando assim a exploração de ações ótimas aprendidas.

Tabela 5.12: Parâmetros de configuração do agente DQN.

Parâmetro	Valor
Tempo de amostragem do agente (SampleTime)	0,01 s
Tempo de simulação	0,5 s
Fator de desconto (DiscountFactor)	0,9
(MiniBatchSize)	64
Tamanho do <i>buffer</i> de experiência (ExperienceBufferLength)	1×10^6
Exploração inicial (Epsilon)	1
Exploração mínima (EpsilonMin)	0,001
Decaimento de exploração (EpsilonDecay)	0,0001
Utilização de <i>Double</i> DQN (UseDoubleDQN)	<i>True</i>
Otimizador do crítico	<i>Adam</i>
Taxa de aprendizagem do crítico	0,0001

Relativamente à configuração do agente, os parâmetros de treino determinam o comportamento do processo de aprendizagem ao longo dos episódios. Desta forma, na Tabela 5.13 são apresentados os principais parâmetros utilizados durante o treino do agente, tais como o número máximo de episódios, os critérios de paragem, bem como as condições para o armazenamento do agente treinado.

Tabela 5.13: Parâmetros utilizados no treino do agente DQN.

Parâmetro	Valor
Número máximo de episódios	300
Número máximo de passos por episódio	50
Janela de média de recompensas	56
Critério de paragem do treino	Recompensa média
Valor de paragem do treino	10 000
Critério para guardar o agente	Recompensa do episódio
Valor mínimo para guardar o agente	150
Visualização do progresso do treino	Ativada
Execução paralela	<i>False</i>

Tal como foi referido anteriormente na Tabela 5.12, a simulação foi executada com um tempo total de 0,5 s por episódio e um passo de tempo de 0,01 s, ao longo de 300 episódios.

Para além dos parâmetros de configuração e treino do agente DQN, é importante referir que o *hardware* utilizado representado na Tabela 6.1 (Capítulo 6) tem um grande impacto, uma vez que influencia diretamente no tempo total da simulação e na estabilidade do mesmo.

Definição Aleatória das Condições de Irradiância e Temperatura na Simulação

De forma a garantir uma aprendizagem mais generalizada por parte do agente, foi implementada uma função de reinicialização personalizada no início de cada episódio. Esta função atribui valores de irradiância aos três painéis fotovoltaicos ("PV Array") do sistema através de um bloco "Constant" com base numa lógica probabilística que permite simular diferentes cenários. Os valores possíveis variam entre 150 W/m² e 1000 W/m², sendo a seleção ponderada para dar maior probabilidade à condição de 1000 W/m². De igual modo, também foi atribuída à temperatura ambiente valores aleatórios entre 15 °C e 45 °C, com maior probabilidade para 25 °C, representando uma condição típica de funcionamento.

É de notar que a lógica de seleção das condições segue a seguinte distribuição de probabilidades com base numa variável aleatória $r \sim \mathcal{U}(0, 1)$:

$$\begin{cases} r < 0,2 & \Rightarrow \text{Todos os painéis com a mesma irradiância (20\%)} \\ 0,2 \leq r \leq 0,4 & \Rightarrow \text{Dois painéis com a mesma irradiância, um diferente (20\%)} \\ r > 0,4 & \Rightarrow \text{Todos os painéis com irradiância diferente (60\%)} \end{cases}$$

em que $r = \text{rand}$ representa uma amostra da distribuição uniforme contínua no intervalo $[0, 1]$.

5.9.4 Processo de Treino com o Método DQN

Os resultados do treino do agente utilizando o método DQN estão ilustrados na Figura 5.20, onde a curva azul clara representa a recompensa por episódio (*Episode Reward*), enquanto a curva azul escura mostra a média das recompensas ao longo do treino. Além disso, a curva amarela representa a métrica *Episode Q0*, que fornece uma estimativa da recompensa futura que o agente pode obter ao tomar uma ação específica num determinado estado.




Figura 5.20: Processo de treino método DQN.

Na Tabela 5.14 é ilustrado um resumo dos principais resultados do treino, que teve uma duração total de aproximadamente duas horas.

É de notar que a convergência do método DQN torna-se evidente pela tendência de estabilização da recompensa média (linha azul escura) após cerca de 100 episódios, indicando uma melhoria progressiva no desempenho do agente ao longo do tempo.

Tabela 5.14: Resumo do treino com o agente *rlDQNAgent*.

Parâmetro	Valor
Passos por episódio (média)	50
Passos totais do agente	15 000
Recompensa média	28,73
Recompensa final do episódio	11,74
Episode Q0	3,89
Tempo total de execução	02:03:31

5.10 Cenários Simulados em Diferentes Condições Meteorológicas

Com o objetivo de avaliar o desempenho dos algoritmos MPPT implementados, foram definidos alguns cenários de simulação que contemplam diferentes condições meteorológicas em ambientes reais de operação de sistemas fotovoltaicos.


Foram consideradas variações em dois parâmetros principais, nomeadamente, a irradiância (G) e a temperatura ambiente (T). Estas variações descritas nos cenários apresentados nas Tabelas 5.15 e 5.16 permitem uma avaliação que consegue abranger situações de condições uniformes, dinâmicas e sob condições de sombra parcial.

Tabela 5.15: Cenários do painel fotovoltaico com apenas um diodo *bypass*.

Nº	Descrição do Cenário	Parâmetros Fixos
1	Irradiância uniforme de 1000 W/m ² .	T = 25 °C
2	Variação da irradiância (G).	T = 25 °C
3	Variação da temperatura (T).	G = 1000 W/m ²
4	Variação em simultâneo da temperatura e da irradiância.	—


Na Figura 5.21 são apresentados os gráficos dos perfis de temperatura e irradiância em cada um dos cenários.

Temperatura e Irradiância - Cenário 1




(a) Cenário 1

Temperatura e Irradiância - Cenário 2




(b) Cenário 2

Temperatura e Irradiância - Cenário 3



(c) Cenário 3

Temperatura e Irradiância - Cenário 4



(d) Cenário 4

Figura 5.21: Perfis de irradiância e temperatura nos cenários.

Nos quatro cenários PSC, foi mantida a temperatura constante a 25°C, considerando três grupos de células com diferentes níveis de irradiância, conforme ilustrado na Tabela 5.16.

Tabela 5.16: Cenários PSC do painel fotovoltaico com três díodos *bypass*.

Nº	Descrição dos Cenários PSC	Parâmetros Fixos
1	$G = [900, 1000, 200] \text{ W/m}^2$	$T = 25 \text{ }^\circ\text{C}$
2	$G = [200, 400, 300] \text{ W/m}^2$	$T = 25 \text{ }^\circ\text{C}$
3	$G = [900, 100, 150] \text{ W/m}^2$	$T = 25 \text{ }^\circ\text{C}$
4	$G = [300, 200, 100] \text{ W/m}^2$	$T = 25 \text{ }^\circ\text{C}$

Na Figura 5.22 são apresentados os gráficos dos perfis de temperatura e irradiância em cada um dos cenários PSC.






Figura 5.22: Perfis de irradiância em cenários de PSC com $T = 25 \text{ }^\circ\text{C}$.

5.10.1 Análise das Curvas I-V e P-V em Condições PSC


Para compreender a formação dos máximos locais de potência e do ponto de máxima potência global (GMPP), é necessário recorrer às curvas características I-V e P-V de cada um dos cenários que estão representadas na Figura 5.23.




(a) Cenário 1 PSC



(b) Cenário 2 PSC



(c) Cenário 3 PSC



(d) Cenário 4 PSC

Figura 5.23: Curvas características I-V e P-V obtidas para os quatro cenários PSC com temperatura constante a 25 °C, considerando três grupos de células com diferentes níveis de irradiância.

Capítulo 6

Testes e Análise de Resultados

Neste capítulo são apresentados os resultados obtidos através dos testes realizados com os diferentes algoritmos MPPT implementados em cenários com condições previamente descritas no Capítulo 5. A análise tem como objetivo avaliar e comparar o desempenho de cada um dos algoritmos, utilizando diversas métricas de avaliação referidas no Capítulo 3.

6.1 *Setup do Hardware*

Durante a realização das simulações no Simulink foi utilizado o *hardware* descrito na Tabela 6.1.

6.2 Testes e Análise de Resultados - Cenários com Apenas um Díodo *Bypass*

Os testes realizados nestes cenários incluem diferentes variações de temperatura e irradiância, tal como definido anteriormente. Além disso, com os resultados obtidos de cada algoritmo para cada um dos cenários, são calculadas as métricas de avaliação referidas no Capítulo 3.

Tabela 6.1: Especificações do *hardware* utilizado.

Componente	Especificação
Modelo do PC	HP ProDesk 600 G4 Mini PC
Processador	Intel® Core™ i7-7700T CPU @ 2.90 GHz
Memória RAM	16 GB DDR4 2400MHz
Armazenamento	SSD 512 GB
Sistema Operativo	Windows 10 Pro 64-bit
GPU integrada	Intel® HD Graphics 630
Execução paralela	Não utilizada
Aceleração por GPU	Não utilizada

6.2.1 Cenário 1

Neste cenário, ambos os algoritmos baseados em inteligência Artificial (ANN e DQN) apresentaram desempenho superior face aos métodos convencionais e híbridos. O algoritmo ANN evidenciou a melhor eficiência média (95,50%), com o menor tempo de convergência (0,1763 s), sendo particularmente eficaz na estabilização da potência de saída (P_o). Já o DQN, embora ligeiramente inferior na eficiência média (95,30%), manteve também uma excelente estabilidade ao longo do tempo.

A Figura 6.1 mostra comparativamente os tempos de convergência dos algoritmos ANN e DQN, mostrando que o ANN atinge mais rapidamente o regime permanente.




Figura 6.1: Tempos de convergência dos algoritmos ANN e DQN.

Na Figura 6.2, é ilustrada a evolução dos erros até 0,5 s para todos os algoritmos. Relativamente à Figura 6.3, é apresentada a evolução da potência de saída e da




Figura 6.2: Comparação tempos de convergência dos restantes algoritmos.

razão cíclica para os restantes algoritmos testados no Cenário 1. Nos métodos convencionais, tais como o P&O, o InC e o InC+P&O, são evidenciadas oscilações mais acentuadas, tanto na potência como na razão cíclica, comprometendo a estabilidade do sistema.

A Figura 6.4 compara o desempenho das curvas de potência de saída (a-b) e a razão cíclica (c-d) para os algoritmos ANN e DQN.




Figura 6.4: Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 1: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.

A Tabela 6.2 resume quantitativamente os resultados obtidos neste cenário, destacando-se o ANN por apresentar os menores valores de erro absoluto médio ($MAE = 1,2931$) e erro absoluto integral ($IAE = 13,4424$), bem como um MSE baixo ($3,3865$) e um tempo de convergência rápido ($0,1763$ s). Ainda assim, o DQN, mesmo com um desempenho ligeiramente inferior nestes parâmetros, demonstra uma excelente estabilidade evidenciada pelo MSE ainda mais baixo ($MSE = 2,7681$) e





Figura 6.3: Resultados do Cenário 1 para os restantes algoritmos: (a) Saída de potência (P_o); (b) *Duty Cycle*.

uma eficiência acima dos 95%, comprovando que está a seguir o ponto MPP com elevada precisão.

Tabela 6.2: Métricas de avaliação para o Cenário 1.

Algoritmo	MAE	IAE	MSE	ISE	Eficiência Média (%)	Tempo Convergência (s)
P&O	2,2740	23,6469	8,4456	96,7815	93,6013	0,2029
InC	2,2681	23,6453	8,4224	96,7687	93,6261	0,2029
Fuzzy	1,3028	13,5664	3,4857	45,5630	95,3713	0,2385
InC+P&O	2,2755	23,6486	8,4512	96,7889	93,5962	0,2030
InC+GA	1,3144	13,6370	2,7629	33,8812	95,3102	0,3783
P&O+GA	1,3124	13,6443	2,7561	33,8601	95,3165	0,3787
ANN	1,2931	13,4424	3,3865	45,5965	95,4995	0,1763
DQN	1,3396	14,2425	2,7681	43,0119	95,2981	0,2118

6.2.2 Cenário 2

A análise dos resultados, conforme apresentado na Tabela 6.3, revela que a ANN obteve o melhor desempenho global, destacando-se pela maior eficiência média (95,20%), menores erros absolutos, com um MAE de 0,94 e uma convergência rápida (0,1837 s). Por outro lado, o DQN demonstrou estabilidade e uma boa capacidade

de adaptação, embora com um desempenho ligeiramente inferior, registrando uma eficiência média de 93,77%, MAE de 1,38 e um tempo de convergência superior (0,2316 s) comparativamente ao ANN.

As restantes abordagens analisadas, nomeadamente os métodos (P&O, InC e InC+P&O), apresentaram resultados satisfatórios, com eficiências na ordem dos 92,50%, demonstrando ainda assim um desempenho aceitável. As técnicas híbridas (InC+GA e P&O+GA) e o controlo por lógica difusa revelaram um desempenho superior ao dos métodos anteriores, alcançando eficiências superiores a 94%. No entanto, as técnicas híbridas (InC+GA e P&O+GA) apresentaram um tempo de convergência mais lento (0,3749 s e 0,3892 s) relativamente aos restantes algoritmos.

Tabela 6.3: Métricas de avaliação para o Cenário 2.

Algoritmo	MAE	IAE	MSE	ISE	Eficiência Média (%)	Tempo Convergência (s)
P&O	2,0134	20,7350	7,1603	81,7637	92,4991	0,2008
InC	2,0333	20,7282	7,2322	81,7327	92,3735	0,2008
Fuzzy	1,2820	13,3091	3,5243	44,9620	94,2180	0,2370
InC+P&O	1,9957	20,7619	7,0857	81,8770	92,6808	0,2010
InC+GA	1,3113	13,5763	3,2909	38,6606	94,0737	0,3749
P&O+GA	1,3100	13,5586	3,2617	38,3420	94,0772	0,3892
ANN	0,9426	9,9433	2,7069	38,8351	95,2038	0,1837
DQN	1,3796	14,1881	3,5495	42,8869	93,7760	0,2316

A Figura 6.5 ilustra as curvas de potência de saída e razão cíclica para ambos os algoritmos ANN e DQN, mostrando uma boa estabilidade.




Figura 6.5: Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 2: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.

6.2.3 Cenário 3

Neste cenário, o algoritmo ANN destacou-se pelo menor tempo de convergência (0,1773 s), enquanto o DQN apresentou o tempo mais longo (0,2017 s). Contudo, conforme os dados da Tabela 6.4 revelam, o DQN obteve menores valores no MSE (2,9612) e uma melhor eficiência média (95,19%), porém com um tempo de convergência mais elevado (0,2017 s).

Os algoritmos P&O, InC e InC+P&O demonstraram desempenhos semelhantes, com eficiências médias próximas de 93,50%. No entanto, ambos apresentaram valores elevados de MAE (acima de 2,2), IAE (acima de 23) e MSE (abaixo de 3), indicando oscilações significativas durante o processo de monitorização do ponto MPP. O tempo de convergência foi de aproximadamente 0,20 segundos para ambos.

Os algoritmos híbridos InC+GA e P&O+GA apresentaram resultados muito próximos do Fuzzy, com eficiências superiores a 95,3%.

Tabela 6.4: Métricas de avaliação para o Cenário 3.

Algoritmo	MAE	IAE	MSE	ISE	Eficiência Média (%)	Tempo Convergência (s)
P&O	2,2901	23,5039	8,4903	95,9163	93,5644	0,2026
InC	2,3020	23,4960	8,5452	95,8738	93,4919	0,2026
Fuzzy	1,2914	13,4304	3,4588	45,2618	95,4024	0,2389
InC+P&O	2,2737	23,5271	8,4134	96,0351	93,6665	0,2027
InC+GA	1,3036	13,5125	2,9062	35,2575	95,3384	0,3754
P&O+GA	1,3040	13,5121	2,9491	35,6423	95,3367	0,3759
ANN	1,3586	14,1022	3,5430	47,3818	95,1503	0,1773
DQN	1,3499	14,2418	2,9612	43,0156	95,1882	0,2017

A Figura 6.6 mostra as curvas de potência de saída e a razão cíclica para ambos os algoritmos ANN e DQN, demonstrando uma boa estabilidade com oscilações reduzidas em ambos os parâmetros.




Figura 6.6: Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 3: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.

6.2.4 Cenário 4

Neste cenário, o algoritmo ANN destacou-se novamente pelo menor tempo de convergência (0,1746 s), enquanto o DQN apresentou o tempo mais longo (0,2272 s). Contudo, conforme os dados da Tabela 6.5 revelam, o ANN obteve valores significativamente melhores em MAE (0,8227) e IAE (8,8244), além da maior eficiência média (94,90%), superando o segundo melhor algoritmo, o *Fuzzy*, com 94,05%.

Os algoritmos P&O, InC e InC+P&O demonstraram desempenhos semelhantes, com eficiências médias próximas de 92,5%. No entanto, ambos apresentaram valores elevados de MAE (acima de 1,8), IAE (acima de 19), ISE (acima de 71) e MSE (acima de 6), indicando oscilações consideráveis durante a simulação. O tempo de convergência foi de 0,1937 segundos para ambos.

Os algoritmos híbridos InC+GA e P&O+GA apresentaram resultados intermédios, com eficiências superiores a 93,8%, demonstrando uma ligeira melhoria em relação aos métodos convencionais, porém ainda abaixo do desempenho do ANN.

Tabela 6.5: Métricas de avaliação para o Cenário 4.

Algoritmo	MAE	IAE	MSE	ISE	Eficiência Média (%)	Tempo Convergência (s)
P&O	1,9080	19,5159	6,3287	71,3833	92,3418	0,1937
InC	1,8832	19,5411	6,2348	71,4879	92,5729	0,1937
Fuzzy	1,2264	12,6995	3,0669	38,7689	94,0541	0,2303
InC+P&O	1,9232	19,5131	6,3794	71,3694	92,2290	0,1937
InC+GA	1,2610	13,0040	2,8422	33,0738	93,8670	0,3717
P&O+GA	1,2561	12,9948	2,8414	33,1874	93,8860	0,3747
ANN	0,8227	8,8244	2,1729	34,3348	94,8967	0,1746
DQN	1,3351	13,8548	2,8987	38,8920	93,2006	0,2272

A Figura 6.7 apresenta as curvas de potência de saída (a-b) e a razão cíclica (c-d) para os algoritmos ANN e DQN. É possível observar que ambos demonstram bons resultados, porém o ANN destacou-se particularmente pela melhor estabilidade e menores oscilações evidenciadas pelas métricas.




Figura 6.7: Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 4: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.

Na Figura 6.8, todos os algoritmos, exceto o Fuzzy, exibem oscilações visíveis na potência de saída, com variações mais acentuadas nos métodos convencionais (P&O e InC) e nos híbridos (InC+GA e P&O+GA).




Figura 6.8: Potência de saída dos algoritmos.

6.3 Testes e Análise de Resultados - Cenários PSC

Nesta seção são apresentados os resultados obtidos para os cenários de sombra parcial (PSC), que foram previamente definidos e caracterizados no Capítulo 5. Tal

como realizado anteriormente, foram utilizados os mesmos algoritmos e métricas de avaliação.

6.3.1 Cenário PSC 1

No Cenário PSC 1, os dados da Tabela 6.6 mostram que o algoritmo Fuzzy destacou-se com o menor IAE (6,4607), além de uma eficiência média elevada (96,30%). Os algoritmos híbridos InC+GA e P&O+GA apresentaram desempenhos muito próximos ao Fuzzy, com eficiências superiores a 96%, indicando que a combinação de técnicas convencionais com a otimização pelo algoritmo genético melhora significativamente a capacidade de monitorização do ponto MPP neste cenário PSC.

O algoritmo ANN obteve um tempo de convergência de 0,1582 s, sendo mais rápido que o DQN (0,1973 s), e com uma eficiência média superior (94,70% contra 93,01% do DQN). Os algoritmos P&O, InC e InC+P&O apresentaram resultados semelhantes, com eficiências próximas de 94,40%, mas com valores de MAE, IAE, MSE e ISE mais elevados.

Tabela 6.6: Métricas de avaliação para o Cenário PSC 1.

Algoritmo	MAE	IAE	MSE	ISE	Eficiência Média (%)	Tempo Convergência (s)
P&O	1,2470	12,7990	2,4616	27,0702	94,3909	0,2261
InC	1,2474	12,8019	2,4625	27,0762	94,3890	0,2254
Fuzzy	0,6244	6,4607	0,8937	11,1054	96,3035	0,1891
InC+P&O	1,2473	12,8012	2,4623	27,0758	94,3897	0,2259
InC+GA	0,6362	6,5798	0,7684	9,5713	96,2199	0,4076
P&O+GA	0,6361	6,5806	0,7636	9,5218	96,2209	0,4116
ANN	0,7540	7,8210	0,9840	13,8583	94,7047	0,1582
DQN	0,9174	9,1121	1,5140	16,2580	93,0104	0,1973

Com base nos gráficos obtidos para os diferentes algoritmos MPPT, a grande parte obteve desempenhos semelhantes. O ponto GMPP da curva característica P-V ilustrada na Figura 5.23a do Capítulo 5, situa-se nos 18 W, servindo de referência para a análise do desempenho dos algoritmos. Assim sendo, nos gráficos da potência gerada pelo painel fotovoltaico (P_{PV}), verifica-se que os algoritmos apresentados na Figura 6.9 conseguiram alcançar rapidamente valores próximos do GMPP, evidenciando uma boa capacidade de monitorização do ponto MPP.

Os algoritmos InC (Algoritmo 4), P&O (Algoritmo 5) e INC+P&O (Algoritmo 1) apresentam oscilações visíveis na potência de saída, que se traduziram em perdas, reduzindo a eficiência média (94%) do sistema ao longo do tempo.

Por outro lado, os algoritmos híbridos, como o INC+GA (Algoritmo 3) e o P&O+GA (Algoritmo 6), demonstram uma resposta muito mais estável, com melhor eficiência média (96%) e mantendo a potência de saída no ponto GMPP praticamente constante ao longo da simulação, com oscilações mínimas. O algoritmo Fuzzy (Algoritmo 2) também apresentou um desempenho muito semelhante e com estabilidade na potência de saída.





Figura 6.9: (a) Dados de P_o e (b) Dados da potência de entrada P_{pv} separados no Cenário 4.

Adicionalmente, os algoritmos ANN e DQN, evidenciaram desempenhos razoáveis neste cenário. O algoritmo ANN foi capaz de manter uma potência de saída estabilizada próxima dos 15 W (Figura 6.10b), com a convergência mais rápida. Já o algoritmo DQN apresentou uma grande variação da potência de saída, com oscilação entre 10 W e 15 W (Figura 6.10a).




Figura 6.10: Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 1 PSC: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.

6.3.2 Cenário PSC 2

Neste segundo cenário, os dados da Tabela 6.7 mostram que o algoritmo DQN destacou-se com o menor MAE, IAE, MSE e ISE, além da melhor eficiência média (93,92%), demonstrando a superioridade em lidar com condições complexas de sombra parcial. O algoritmo ANN também apresentou bom desempenho, com eficiência de 92,77% e tempo de convergência de 0,1816 s (Figura 6.11a), sendo mais rápido que o DQN (0,2866 s) (Figura 6.11b). É de notar que ambos os algoritmos baseados em inteligência artificial evidenciaram tempos de convergência significativamente inferiores aos restantes algoritmos testados.




Figura 6.11: Comparação dos erros: (a) ANN e (b) DQN no intervalo de 0,5 segundos.

O algoritmo Fuzzy apresentou resultados intermédios, com uma eficiência de 84,07%, enquanto os métodos híbridos InC+GA e P&O+GA demonstraram desempenhos superiores, alcançando eficiências próximas de 89,33%. Os algoritmos P&O, InC e InC+P&O obtiveram os piores resultados, com eficiências em torno de 83%, além dos valores elevados de MAE, IAE, MSE e ISE, evidenciando a dificuldade em lidar com os perfis deste cenário.

Tabela 6.7: Métricas de avaliação para o Cenário PSC 2.

Algoritmo	MAE	IAE	MSE	ISE	Eficiência Média (%)	Tempo Convergência (s)
P&O	1,0843	11,5210	1,9253	22,4451	83,5914	0,4561
InC	1,1220	11,5138	2,0071	22,4282	82,9441	0,4557
Fuzzy	1,0036	10,4573	1,3136	15,5130	84,0660	0,9092
InC+P&O	1,0929	11,5257	1,9405	22,4593	83,4341	0,4559
InC+GA	0,6162	6,3335	0,4283	4,7474	89,3252	0,5825
P&O+GA	0,6160	6,3309	0,4308	4,7676	89,3285	0,5809
ANN	0,5115	5,2931	0,3810	4,9916	92,7658	0,1816
DQN	0,2014	2,0017	0,0645	0,6281	93,9154	0,2866

A Figura 6.12 ilustra o comportamento dos algoritmos DQN e ANN.




Figura 6.12: Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 2 PSC: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.

6.3.3 Cenário PSC 3

Neste cenário, os dados da Tabela 6.8 revelam que os algoritmos P&O, InC, Fuzzy, InC+P&O, InC+GA e P&O+GA obtiveram o melhor desempenho, com uma eficiência média a rondar os 98,50%. No entanto, o InC+GA e P&O+GA têm os tempos de convergência mais lentos (0,5854 s e 0,5760 s, respetivamente) comparativamente aos restantes algoritmos.

Os algoritmos baseados em inteligência artificial, ANN e DQN, tiveram resultados inferiores neste terceiro cenário PSC. O ANN apresentou a menor eficiência média (91,42%) entre todos os algoritmos testados, com um tempo de convergência de 0,4003 s, enquanto o DQN obteve uma melhor eficiência (96,28%), com um tempo de resposta mais rápido (0,2341 s).

Tabela 6.8: Métricas de avaliação para o Cenário PSC 3.

Algoritmo	MAE	IAE	MSE	ISE	Eficiência Média (%)	Tempo Convergência (s)
P&O	0,1014	1,0773	0,0627	0,8993	98,5042	0,1958
InC	0,1017	1,0796	0,0628	0,8996	98,5004	0,1958
Fuzzy	0,0977	1,0385	0,0633	0,9023	98,5554	0,1988
InC+P&O	0,0983	1,0369	0,0623	0,8938	98,5481	0,1933
InC+GA	0,0738	0,7924	0,0549	0,8245	98,8231	0,5854
P&O+GA	0,1084	1,1356	0,0598	0,8733	98,3324	0,5760
ANN	0,2525	2,5886	0,0983	1,3707	91,4206	0,4003
DQN	0,2559	2,5900	0,1370	1,5501	96,2822	0,2341

A Figura 6.13 ilustra o comportamento dos algoritmos DQN e ANN, onde é possível observar que a potência de saída obtida é mais baixa relativamente aos restantes algoritmos que apresentam valores em torno dos 7,94 W (Figura 6.14) obtido na curva de característica da Figura 5.23c do Capítulo 5.




Figura 6.13: Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 3 PSC: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.

6.3.4 Cenário PSC 4

Neste último cenário, os dados da Tabela 6.9 mostram uma clara distinção entre os algoritmos, destacam-se o InC+GA, P&O+GA, ANN e DQN com o melhor




Figura 6.14: Dados de P_o separados no Cenário 3.

desempenho global, apresentando uma eficiência superior a 91%. No entanto, o InC+GA e P&O+GA obtiveram um tempo de convergência lento (0,4035 s e 0,4025 s, respetivamente).

Os algoritmos P&O, InC e InC+P&O e o Fuzzy apresentaram os piores resultados, com uma eficiência média em torno de 85% e tempos de convergência lentos.

Os algoritmos baseados em inteligência artificial, ANN e DQN, obtiveram desempenhos similares, com eficiências próximas de 91,7%. Contudo, o ANN mostrou um tempo de convergência consideravelmente menor (0,1938 s), enquanto o DQN foi o que obteve o tempo de convergência mais lento, com um valor de 0,9375 s.

Tabela 6.9: Métricas de avaliação para o Cenário PSC 4.

Algoritmo	MAE	IAE	MSE	ISE	Eficiência Média (%)	Tempo Convergência (s)
P&O	0,5829	6,1757	0,5657	6,4031	85,5496	0,3757
InC	0,5959	6,1727	0,5790	6,3991	85,1847	0,3751
Fuzzy	0,5532	5,6450	0,3808	4,1320	85,6871	0,5335
InC+P&O	0,6064	6,1711	0,5899	6,3964	84,8987	0,3748
InC+GA	0,1988	2,0226	0,0479	0,5239	91,9530	0,4035
P&O+GA	0,1992	2,0277	0,0515	0,5599	91,9349	0,4025
ANN	0,2053	2,0980	0,0538	0,6348	91,7499	0,1938
DQN	0,2043	2,0352	0,0596	0,5909	91,6215	0,9375

Com base nos resultados obtidos deste cenário, observa-se que os algoritmos convencionais, como o InC, P&O e a combinação InC+P&O, mantêm a potência do painel fotovoltaico (P_{PV}) próxima dos 4 W (Figura 6.15b), valor correspondente ao ponto GMPP da curva medida, ilustrada na Figura 5.23d do Capítulo 5. No entanto, a potência de saída fornecida à carga (P_o) apresenta oscilações significativas tal como é evidenciado nos gráficos da Figura 6.15a. É notório que estas oscilações são traduzidas numa menor eficiência média (cerca de 85%), conforme apresentado na Tabela 6.9, uma vez que parte da energia produzida não é eficientemente transferida para a carga ao longo da simulação.

Por outro lado, os algoritmos híbridos, INC+GA e P&O+GA, apresentaram uma potência de saída estabilizada em torno de 2,5 W. Embora este valor esteja abaixo do





Figura 6.15: (a) Dados de P_o e (b) Dados da potência de entrada P_{pv} separados no Cenário 4.

máximo gerado pelo painel, a entrega de potência é mais estável e consistente, com menores oscilações e erro acumulado, refletindo numa eficiência média superior (cerca de 92%). O mesmo acontece para os algoritmos baseados em inteligência artificial, ANN e DQN, que também mantiveram uma potência de saída em torno de 2,5 W e oscilação reduzida do *duty cycle* (Figura 6.16).




Figura 6.16: Comparação entre os algoritmos DQN (esquerda) e ANN (direita) no Cenário 4 PSC: (a-b) potência de saída e (c-d) razão cíclica ao longo do tempo.

6.4 Análise Comparativa dos Algoritmos

Com o objetivo de avaliar o desempenho dos algoritmos implementados, foi realizada uma comparação qualitativa com base em vários critérios. A Tabela 6.10 resume as principais características dos algoritmos MPPT.

- **Métodos Convencionais:** Algoritmos como P&O, InC e InC+P&O apresentaram tempos de convergência razoáveis, mas revelaram-se menos eficientes principalmente em cenários PSC, ficando frequentemente retidos em máximos locais, o que se refletiu em eficiências médias inferiores a 85%.
- **Métodos baseados em Lógica Difusa:** O algoritmo Fuzzy apresentou melhor desempenho que os métodos convencionais, com eficiências médias superiores a 84%, mas inferior aos algoritmos de inteligência artificial. Embora tenha demonstrado boa estabilidade e tempos de resposta aceitáveis, mostrou limitações em cenários com PSC, onde teve maior dificuldade em localizar o ponto GMPP.
- **Métodos baseados em Inteligência Artificial:** Com base nos resultados obtidos nos diferentes cenários testados, incluindo condições uniformes e de PSC, verificou-se que os algoritmos ANN e DQN, apresentaram o melhor desempenho global e boa estabilidade. Estes algoritmos evidenciaram uma elevada eficiência média superior a 91%, garantindo uma rápida convergência na maior parte dos cenários para o ponto MPP, mesmo em condições com múltiplos máximos locais.

- **Métodos Híbridos:** InC+GA e P&O+GA, demonstraram melhorias face aos métodos convencionais, atingindo maior precisão na monitorização do MPP, embora com tempos de convergência mais elevados devido ao processamento adicional inerente ao algoritmo genético.

Tabela 6.10: Comparação dos Algoritmos MPPT.

Algoritmo	Critérios de Avaliação								PSC
	Comp.	Custo	Ind. Par.	Teino	Vel. Conv.	Sens.	Ajuste	Estab.	
P&O	Baixa	Médio	Sim	Não	Rápida	V,I	Não	Baixa	Fraco
InC	Média	Médio	Sim	Não	Rápida	V,I	Não	Baixa	Fraco
FLC	Alta	Médio	Sim	Não	Rápida	V,I	Não	Alta	Bom
InC+P&O	Média	Médio	Sim	Não	Rápida	V,I	Não	Baixa	Fraco
InC+GA	Alta	Alto	Sim	Não	Lenta	V,I	Não	Média	M.Bom
P&O+GA	Alta	Alto	Sim	Não	Lenta	V,I	Não	Média	M.Bom
ANN	Alta	Alto	Não	Sim	M.Ráp.	V,I,G,T	Sim	Alta	Exc.
DQN (RL)	Alta	Alto	Não	Sim	Rápida	V,I,G,T	Sim	Alta	Exc.

Notas:

- Abrev.: Comp. = Complexidade, Ind. Par. = Independência de parâmetros, Vel. Conv. = Velocidade de Convergência, Sens. = Sensores
- Estab.: Baixa (oscilações), Média (pequenas variações), Alta (estável)
- PSC: Fraco (oscilações), Mod. (moderado), Bom, M.Bom, Exc. (Excelente)
- Sensores: V = Tensão, I = Corrente, G = Irradiância, T = Temperatura

6.4.1 Análise dos Tempos de Simulação

Na Tabela 6.11 apresentam-se os tempos de execução durante 10 segundos dos diferentes algoritmos MPPT no MATLAB, em minutos. Estes dados revelam algumas diferenças significativas na duração dos modelos simulados entre as abordagens realizadas.

Tabela 6.11: Tempos de execução dos algoritmos MPPT ordenados (valores em minutos)

Algoritmo	Tempo (minutos)
P&O	5,80
InC	5,92
ANN	5,93
Fuzzy	5,99
InC+P&O	6,23
DQN	8,25
InC+GA	58,39
P&O+GA	58,80

Os resultados da Tabela 6.11 permitem concluir que:

- Métodos convencionais (P&O e InC) são os mais rápidos (aproximadamente 6 minutos);
- ANN, Fuzzy e InC+P&O também mantêm um tempo de execução baixo (aproximadamente 6 minutos);
- DQN tem um tempo ligeiramente superior (8,25 minutos);
- InC+GA e P&O+GA são significativamente mais lentos (aproximadamente 58 minutos), sendo que a diferença para o tempo de execução dos métodos convencionais é de aproximadamente 10 vezes superior.

Capítulo 7

Conclusões

Esta dissertação teve como objetivo principal a aplicação de algoritmos de inteligência artificial na monitorização do ponto de máxima potência (MPPT) de sistemas fotovoltaicos, com recurso a simulações desenvolvidas em MATLAB/Simulink. Desta forma, foram estudadas e comparadas diferentes abordagens, desde algoritmos MPPT convencionais até metodologias mais avançadas baseadas em redes neurais (ANN) e *Deep Reinforcement Learning* (DRL).

Os resultados obtidos demonstraram que os algoritmos baseados em inteligência artificial apresentam um desempenho e estabilidade superior face aos restantes métodos utilizados em grande parte dos cenários, especialmente em cenários PSC, onde a existência de múltiplos máximos locais podem comprometer a eficiência.

7.1 Trabalho Futuro

Apesar dos avanços alcançados, existem várias possibilidades em relação a trabalhos futuros. Para enriquecer o sistema seria interessante realizar a implementação de um conversor DC/DC bidirecional do tipo *Buck-Boost*, conforme ilustrado na Figura 7.1, permitindo a integração de uma bateria, possibilitando não só o carregamento através da energia produzida pelos painéis fotovoltaicos, como também a descarga da bateria para alimentação de cargas sempre que necessário.

Este tipo de configuração tornaria o sistema mais versátil no contexto de aplicações tanto em modo *on-grid* como *off-grid*, permitindo uma gestão inteligente da energia armazenada.




Figura 7.1: Diagrama de blocos do sistema MPPT.

Ainda assim, destacam-se alguns tópicos que poderão ser explorados em trabalhos futuros no desenvolvimento desta área:

- A validação dos algoritmos em ambiente real, através da implementação de um protótipo físico que integre os componentes principais do sistema, nomeadamente painéis fotovoltaicos, conversores DC/DC (incluindo o conversor bidirecional *Buck-Boost*), microcontroladores, sensores de corrente, tensão, irradiância, temperatura, e as respetivas cargas;
- O desenvolvimento de sistemas híbridos com múltiplas fontes renováveis (eólica e solar).

Referências

- [1] *Energia Solar Off-Grid: o que é e como funciona?* pt-pt. URL: <https://www.mcagroup.com/artigo/energia-solar-off-grid-o-que-e-e-como-funciona/>. [Citado nas páginas 6, 7]
- [2] *Best off-grid solar systems*, en-AU. URL: <https://www.cleanenergyreviews.info/blog/best-off-grid-solar-system>. [Citado na página 6]
- [3] L. Scholtz, K. Muluadzi, K. Kritzing, M. Mabaso e S. Forder, «Renewable Energy: Facts and Futures The energy future we want,» rel. téc., jan. de 2017. [Citado na página 7]
- [4] P.-H. Chen, W.-S. Chen, C.-H. Lee e J.-Y. Wu, «Comprehensive Review of Crystalline Silicon Solar Panel Recycling: From Historical Context to Advanced Techniques,» *Sustainability*, vol. 16, n.º 1, p. 60, dez. de 2023, ISSN: 2071-1050. DOI: <https://doi.org/10.3390/su16010060>. [Citado nas páginas 8, 9]
- [5] D. M. C. Torres, «Sistemas Fotovoltaicos: Desenvolvimento de uma ferramenta de apoio ao projectista e de um manual de instalação,» por, tese de mestrado, Faculdade de Ciências e Tecnologia da Universidade de Coimbra, jan. de 2009. URL: <https://estudogeral.uc.pt/handle/10316/20420> (acedido em 11/03/2025). [Citado nas páginas 9, 11–13]
- [6] N. Guerra, M. Guevara, C. Palacios e F. Crupi, «Operation and physics of photovoltaic solar cells: an overview,» *I+D Tecnológico*, vol. 14, n.º 2, pp. 84–95, dez. de 2018, ISSN: 1680-8894. DOI: <https://doi.org/10.33412/idt.v14.2.2077>. [Citado na página 10]
- [7] I. F. d. Figueiredo, «Desenvolvimento e implementação de sistema fotovoltaico para aplicação em situação empresarial,» por, tese de mestrado, mar. de 2022. URL: <https://repositorium.sdum.uminho.pt/handle/1822/83168>. [Citado nas páginas 10–12]
- [8] jenkins2026, *Types of Solar Panels: Monocrystalline vs Polycrystalline vs Thin-film*, en-US, jan. de 2024. URL: <https://green.org/2024/01/30/types-of-solar-panels-monocrystalline-vs-polycrystalline-vs-thin-film/>. [Citado nas páginas 11–13]

- [9] *Monocrystalline Silicon Cells: efficiency and manufacturing*, en. URL: <https://sinovoltaics.com/learning-center/solar-cells/monocrystalline-silicon-cells/>. [Citado na página 11]
- [10] *The advantages and disadvantages of mono, poly silicon and amorphous silicon cells - Knowledge - Jensys Power Technology Co., Limited*, en. URL: <https://www.jensysenergy.com/info/the-advantages-and-disadvantages-of-mono-poly-31639000.html>. [Citado nas páginas 12, 13]
- [11] A. Pedroza-Díaz, P. M. Rodrigo, Ó. Dávalos-Orozco, E. De-la-Vega e Á. Valera-Albacete, «Review of explicit models for photovoltaic cell electrical characterization,» *Renewable and Sustainable Energy Reviews*, vol. 207, p. 114979, jan. de 2025, ISSN: 1364-0321. DOI: <https://doi.org/10.1016/j.rser.2024.114979>. [Citado na página 14]
- [12] H. Attia e S. Ulusoy, «A new perturb and observe MPPT algorithm based on two steps variable voltage control,» *International Journal of Power Electronics and Drive Systems (IJPEDS)*, vol. 12, n.º 4, p. 2201, dez. de 2021, ISSN: 2088-8694. DOI: <http://doi.org/10.11591/ijpeds.v12.i4.pp2201-2208>. [Citado na página 14]
- [13] J. P. P. T. Marques, «Modelação e controlo de conversor DC/AC para interligação de painéis fotovoltaicos à rede,» por, 2009. URL: <https://repositorio-aberto.up.pt/handle/10216/59728>. [Citado nas páginas 15, 16, 24, 25, 27]
- [14] *Single Diode Equivalent Circuit Models*, en-US. URL: <https://pvpmc.sandia.gov/modeling-guide/2-dc-module-iv/single-diode-equivalent-circuit-models/>. [Citado nas páginas 15, 16]
- [15] H. G. G. Nunes, F. A. L. Morais, J. A. N. Pombo, S. J. P. S. Mariano e M. R. A. Calado, «Bypass diode effect and photovoltaic parameter estimation under partial shading using a hill climbing neural network algorithm,» *Frontiers in Energy Research*, vol. 10, ago. de 2022, ISSN: 2296-598X. DOI: <https://doi.org/10.3389/fenrg.2022.837540>. [Citado na página 17]
- [16] R. Vieira, F. de Araújo, M. Dhimish e M. Guerra, «A Comprehensive Review on Bypass Diode Application on Photovoltaic Modules,» *Energies*, vol. 13, n.º 10, p. 2472, mai. de 2020, ISSN: 1996-1073. DOI: <https://doi.org/10.3390/en13102472>. [Citado na página 16]
- [17] P. Education, *Bypass Diodes*, 2023. URL: <https://www.pveducation.org/pvcdrom/modules-and-arrays/bypass-diodes>. [Citado nas páginas 16, 17]
- [18] Administrator, *Solar Cell I-V Characteristic and the Solar Cell I-V Curve*, en-GB, set. de 2024. URL: <https://www.alternative-energy-tutorials>.

- com/photovoltaics/solar-cell-i-v-characteristic.html. [Citado na página 18]
- [19] C. S. B. S. Pinto, «Validação Experimental do Modelo cinco Parâmetros e um Díodo de Painéis Fotovoltaicos,» por, tese de mestrado, mai. de 2016. [Citado nas páginas 18, 19]
- [20] W. De Soto, «Improvement and Validation of a Model for Photovoltaic Array Performance,» en, tese de mestrado, 2004. URL: <https://minds.wisconsin.edu/handle/1793/7602>. [Citado nas páginas 19, 20]
- [21] P. A. D. d. Oliveira, «Algoritmos GMPPT (Global Maximum Power Point Tracking) para aplicação em sistemas de produção de energia fotovoltaica.,» por, tese de mestrado, set. de 2021. URL: <http://hdl.handle.net/10400.26/37668>. [Citado nas páginas 19–21, 23]
- [22] S. Rajput, M. Averbukh, A. Yahalom e T. Minav, «An Approval of MPPT Based on PV Cell's Simplified Equivalent Circuit During Fast-Shading Conditions,» *Electronics*, vol. 8, n.º 9, p. 1060, set. de 2019, ISSN: 2079-9292. DOI: <https://doi.org/10.3390/electronics8091060>. [Citado na página 22]
- [23] *Planning and Installing Photovoltaic Systems: A Guide for Installers, Architects and Engineers [2nd ed.]* 1844074420, 9781844074426, 9781435616226, en. URL: <https://dokumen.pub/planning-and-installing-photovoltaic-systems-a-guide-for-installers-architects-and-engineers-2ndnbsped-1844074420-9781844074426-9781435616226.html>. [Citado na página 23]
- [24] *Fundamentals and Innovations in Solar Energy* / *springerprofessional.de*, de. URL: <https://www.springerprofessional.de/fundamentals-and-innovations-in-solar-energy/19059052>. [Citado na página 23]
- [25] *Laboratory manual for pulse-width modulated DC-DC power converters [Second edition]* 9781119009597, 1119009596, 9781119052753, 1119052750, 9781119009542, en. URL: <https://dokumen.pub/laboratory-manual-for-pulse-width-modulated-dc-dc-power-converters-second-edition-9781119009597-1119009596-9781119052753-1119052750-9781119009542.html>. [Citado nas páginas 24–29]
- [26] *Understanding Buck Power Stages Mode Power Supplies - slva057*. URL: https://www.ti.com/lit/an/slva057/slva057.pdf?ts=1740525233676&ref_url=https%253A%252F%252Fwww.google.com%252F. [Citado nas páginas 24, 25]

- [27] *Buck Converter 3-1-1 Circuit Diagram and Key Waveforms / PDF*, pt. URL: <https://www.scribd.com/doc/46439305/Analysis-Converter-Buck>. [Citado na página 26]
- [28] *Microsoft Word - Topic6JQ.doc - Topic 6 - DC-DC Power Conversion and System Design Considerations for Battery Operated System*. URL: <https://www.ti.com/download/trng/docs/seminar/Topic%206%20-%20DC-DC%20Power%20Conversion%20and%20System%20Design%20Considerations%20for%20Battery%20operated%20System.pdf>. [Citado nas páginas 25, 27]
- [29] *Basic Calculation of a Buck Converter's Power Stage (Rev. B) - slva477b*. URL: https://www.ti.com/lit/an/slva477b/slva477b.pdf?ts=1740369413739&ref_url=https%253A%252F%252Fwww.google.com%252F. [Citado nas páginas 27, 28]
- [30] C. Lapsongphon e S. Nualyai, «A Comparison of MPPT Solar Charge Controller techniques: A Case for Charging Rate of Battery,» pp. 278–281, set. de 2021. DOI: <https://doi.org/10.1109/RI2C51727.2021.9559787>. [Citado nas páginas 29, 30, 34, 35, 37]
- [31] K. J e F. SY, «Modeling of a Photovoltaic Array in MATLAB Simulink and Maximum Power Point Tracking Using Neural Network,» *Journal of Electrical and Electronic Systems*, vol. 07, n.º 03, 2018, ISSN: 2332-0796. DOI: [10.4172/2332-0796.1000263](https://doi.org/10.4172/2332-0796.1000263). [Citado na página 30]
- [32] L. F. Giraldo, J. F. Gaviria, M. I. Torres, C. Alonso e M. Bressan, «Deep reinforcement learning using deep-Q-network for Global Maximum Power Point tracking: Design and experiments in real photovoltaic systems,» *Heliyon*, vol. 10, n.º 21, e37974, nov. de 2024, ISSN: 2405-8440. DOI: <https://doi.org/10.1016/j.heliyon.2024.e37974>. [Citado na página 31]
- [33] B. C. Phan, Y.-C. Lai e C. E. Lin, «A Deep Reinforcement Learning-Based MPPT Control for PV Systems under Partial Shading Condition,» *Sensors*, vol. 20, n.º 11, p. 3039, mai. de 2020, ISSN: 1424-8220. DOI: <https://doi.org/10.3390/s20113039>. [Citado nas páginas 31, 45, 47, 48]
- [34] D. Remoaldo e I. Jesus, «Analysis of a Traditional and a Fuzzy Logic Enhanced Perturb and Observe Algorithm for the MPPT of a Photovoltaic System,» *Algorithms*, vol. 14, n.º 1, p. 24, jan. de 2021, ISSN: 1999-4893. DOI: <https://doi.org/10.3390/a14010024>. [Citado na página 31]
- [35] M. L. Katche, A. B. Makokha, S. O. Zachary e M. S. Adaramola, «A Comprehensive Review of Maximum Power Point Tracking (MPPT) Techniques Used in Solar PV Systems,» *Energies*, vol. 16, n.º 5, p. 2206, fev. de 2023, ISSN: 1996-1073. DOI: <https://doi.org/10.3390/en16052206>. [Citado na página 32]

- [36] A. K. Sharma, R. K. Pachauri, S. Choudhury et al., «Role of Metaheuristic Approaches for Implementation of Integrated MPPT-PV Systems: A Comprehensive Study,» *Mathematics*, vol. 11, n.º 2, p. 269, jan. de 2023, ISSN: 2227-7390. DOI: <https://doi.org/10.3390/math11020269>. [Citado na página 32]
- [37] J.-S. Ko, J.-H. Huh e J.-C. Kim, «Overview of Maximum Power Point Tracking Methods for PV System in Micro Grid,» *Electronics*, vol. 9, n.º 5, p. 816, mai. de 2020, ISSN: 2079-9292. DOI: <https://doi.org/10.3390/electronics9050816>. [Citado nas páginas 36, 38, 40, 44]
- [38] M. Y. Baramadeh, M. A. A. Abouelela e S. M. Alghuwainem, «Maximum Power Point Tracker Controller Using Fuzzy Logic Control with Battery Load for Photovoltaics Systems,» *Smart Grid and Renewable Energy*, vol. 12, n.º 10, pp. 163–181, 2021, ISSN: 2151-4844. DOI: <https://doi.org/10.4236/sgre.2021.1210010>. [Citado nas páginas 39, 40]
- [39] F. M. de Oliveira, M. H. M. Brandt, F. Salvadori, J. E. E. Izquierdo, M. R. Cavallari e O. H. Ando Junior, «Development of an MPPT-Based Genetic Algorithm for Photovoltaic Systems versus Classical MPPT Techniques in Scenarios with Partial Shading,» *Inventions*, vol. 9, n.º 3, p. 64, mai. de 2024, ISSN: 2411-5134. DOI: <https://doi.org/10.3390/inventions9030064>. [Citado na página 41]
- [40] A. F. Abouzeid, H. Eleraky, A. Kalas, R. Rizk, M. M. Elsakka e A. Refaat, «Experimental validation of a low-cost maximum power point tracking technique based on artificial neural network for photovoltaic systems,» *Scientific Reports*, vol. 14, n.º 1, ago. de 2024, ISSN: 2045-2322. DOI: <https://doi.org/10.1038/s41598-024-67306-0>. [Citado nas páginas 44, 45]
- [41] *spinningup-openai-com-en-latest*. URL: https://spinningup.openai.com/_/downloads/en/latest/pdf/. [Citado nas páginas 46, 47]
- [42] M. Dirani, Z. Altman e M. Salaun, «Autonomics in Radio Access Networks,» pp. 141–166, 2011. DOI: <https://doi.org/10.1016/B978-0-12-382190-4.00007-3>. [Citado nas páginas 47, 48]
- [43] T. P. Lillicrap, J. J. Hunt, A. Pritzel et al., «Continuous control with deep reinforcement learning,» 2015. DOI: <https://doi.org/10.48550/arXiv.1509.02971>. [Citado na página 48]
- [44] J. Wu, H. He, J. Peng, Y. Li e Z. Li, «Continuous reinforcement learning of energy management with deep Q network for a power split hybrid electric bus,» *Applied Energy*, vol. 222, pp. 799–811, jul. de 2018, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2018.03.104>. [Citado na página 48]

-
- [45] A. K. Podder, N. K. Roy e H. R. Pota, «MPPT methods for solar PV systems: a critical review based on tracking nature,» *IET Renewable Power Generation*, vol. 13, n.º 10, pp. 1615–1632, mai. de 2019, ISSN: 1752-1424. DOI: <http://dx.doi.org/10.1049/iet-rpg.2018.5946>. [Citado nas páginas 49, 50]
- [46] *lsiminfo - Compute linear response characteristics - MATLAB*, en. URL: <https://www.mathworks.com/help/ident/ref/lsiminfo.html>. [Citado nas páginas 51, 52]
- [47] *SOLARPOWER 30W 24V*, en-US. URL: <https://www.xunzel.com/store/en/producto/solarpower-30w-24v/>. [Citado nas páginas 57, 62]
- [48] M. Hosea e L. Shampine, «Analysis and implementation of TR-BDF2,» *Applied Numerical Mathematics*, vol. 20, n.º 1–2, pp. 21–37, fev. de 1996, ISSN: 0168-9274. DOI: [https://doi.org/10.1016/0168-9274\(95\)00115-8](https://doi.org/10.1016/0168-9274(95)00115-8). [Citado na página 63]
- [49] *ode23tb - Solve stiff differential equations — trapezoidal rule + backward differentiation formula - MATLAB*, en. URL: <https://www.mathworks.com/help/matlab/ref/ode23tb.html>. [Citado na página 63]
- [50] J. Martins, S. Spataru, D. Sera, D.-I. Stroe e A. Lashab, «Comparative Study of Ramp-Rate Control Algorithms for PV with Energy Storage Systems,» *Energies*, vol. 12, n.º 7, p. 1342, abr. de 2019, ISSN: 1996-1073. DOI: <https://doi.org/10.3390/en12071342>. [Citado na página 68]
- [51] H. Tajiri e T. Kumano, «Input filtering of MPPT control by exponential moving average in photovoltaic system,» pp. 372–377, dez. de 2012. DOI: <https://doi.org/10.1109/PECon.2012.6450240>. [Citado na página 68]