



Desenvolvimento de um sistema de inspeção de painéis solares autónomo baseado em técnicas de processamento de imagem e uso de UAVs

André Guimarães Borbon

Universidade do Minho
Escola de Engenharia





Universidade do Minho
Escola de Engenharia

André Guimarães Borbon
(pg47017)

**Desenvolvimento de um Sistema de
inspeção de painéis solares autónomo
baseado em técnicas de processamento de
imagem e uso de UAVs**

Dissertação de Mestrado
Mestrado em Engenharia Mecânica
AE em Sistemas Mecatrónicos

Trabalho efetuado sob a orientação de
Professor Doutor Eurico Augusto Rodrigues Seabra

DIREITOS DE AUTOR

Este é um trabalho académico que pode ser utilizado por terceiros desde que respeitadas as regras e boas práticas internacionalmente aceites, no que concerne aos direitos de autor e direitos conexos.

Assim, o presente trabalho pode ser utilizado nos termos previstos na licença abaixo indicada. Caso o utilizador necessite de permissão para poder fazer um uso do trabalho em condições não previstas no licenciamento indicado, deverá contactar o autor, através do RepositóriUM da Universidade do Minho.



Atribuição-NãoComercial-SemDerivações

CC BY-NC-ND

<https://creativecommons.org/licenses/by-nc-nd/4.0/>

AGRADECIMENTOS

Neste marco da minha jornada acadêmica, quero expressar a minha sincera gratidão a todos que desempenharam papéis cruciais na realização deste trabalho.

Ao Professor Eurico Seabra, meu orientador, agradeço pela sua orientação perspicaz e comprometimento em moldar este trabalho.

À equipa da ESI Robotics, minha empresa de estágio, agradeço pela oportunidade e experiência valiosa que me proporcionaram.

Aos meus amigos, pela constante motivação e apoio ao longo deste percurso, agradeço imensamente.

À minha namorada, o meu porto seguro, obrigado pelo apoio inabalável.

E, por último, mas não menos importante, à minha família, cuja crença inabalável nas minhas capacidades e cujo apoio incansável foram as bases sólidas que tornaram este trabalho possível. Sem a vossa presença constante, amor e incentivo, esta jornada não teria sido possível.

Este trabalho é fruto do esforço coletivo de todos vocês.

A minha mais sincera gratidão.

DECLARAÇÃO DE INTEGRIDADE

Declaro ter atuado com integridade na elaboração do presente trabalho académico e confirmo que não recorri à prática de plágio, nem a qualquer forma de utilização indevida ou falsificação de informações ou resultados em nenhuma das etapas conducente à sua elaboração.

Mais declaro que conheço e que respeitei o Código de Conduta Ética da Universidade do Minho.

RESUMO

Desenvolvimento de um Sistema de inspeção de painéis solares autónomo baseado em técnicas de processamento de imagem e uso de UAVs

Este projeto teve como objetivo desenvolver um modelo baseado em deep learning para a deteção de sujidade em painéis solares, empregando técnicas de processamento de imagens. O projeto abrangeu a criação de um conjunto de dados diversificado, o treino de modelos de redes neurais, a análise dos resultados e a delimitação de perspetivas futuras.

Um conjunto de dados robusto foi meticulosamente criado, apresentando imagens de painéis solares com sujidade gerada artificialmente. Esse conjunto de dados foi fundamental para treinar modelos capazes de reconhecer uma ampla variedade de padrões de sujidade, simulando cenários do mundo real.

No entanto, o desempenho observado durante o treino não se traduziu diretamente para situações de campo. O otimizador "adam" exibiu variabilidade, sugerindo a necessidade de uma exploração aprofundada para otimizar as escolhas de hiperparâmetros e a arquitetura do modelo.

Para trabalhos futuros, a expansão do conjunto de dados para abranger um espectro mais amplo de condições, locais e tipos de painéis solares é imperativa. Estratégias para lidar com desequilíbrios nos dados também merecem atenção.

Este projeto representa um possível avanço na deteção de sujidade em painéis solares, destacando a importância da sinergia entre a ciência de dados e a indústria solar. Pesquisa contínua e a busca por soluções mais eficazes no campo da deteção de sujidade são essenciais para maximizar a eficiência da energia solar e minimizar as perdas de eficiência.

Palavras chave: Base de Dados, Deep Learning, Deteção de Sujidade, Painéis Solares, Processamento de Imagens.

ABSTRACT

Development of an autonomous solar panel Inspection system based on image processing techniques and the use of UAVs

This research aimed to develop a deep learning-based model for dirt detection on solar panels by employing image processing techniques. The project encompassed the creation of a diverse dataset, training neural network models, analyzing results, and outlining future prospects.

A robust dataset was meticulously created, featuring images of solar panels with artificially generated dirt. This dataset was instrumental in training models capable of recognizing a wide array of dirt patterns, simulating real-world scenarios.

However, the performance observed during training did not directly translate to field situations. The optimizer "adam" displayed variance, suggesting the need for in-depth exploration to optimize hyperparameter choices and model architecture.

For future work, expanding the dataset to encompass a broader spectrum of conditions, locations, and solar panel types is imperative. Strategies for addressing data imbalances also warrant attention.

This project represents a possible advancement in dirt detection on solar panels, underscoring the significance of synergy between data science and the solar industry. Continuous research and the quest for more effective solutions in the domain of dirt detection are essential for maximizing solar energy efficiency and minimizing efficiency losses.

Keywords: Data Base, Deep Learning, Dirt Detection, Image Processing, Solar Panels.

ÍNDICE

Direitos de autor	iii
Agradecimentos	iv
Declaração de integridade	v
Resumo.....	vi
Abstract	vii
Lista de abreviaturas/Siglas.....	xi
Lista de figuras.....	xii
Lista de símbolos	xiii
1. Introdução.....	1
1.1 Enquadramento	1
1.2 Objetivo da dissertação	2
1.3 Metodologia de investigação	3
1.4 Estrutura da dissertação	4
2. Revisão Literária.....	6
2.2 Evolução da importância da energia solar a nível Mundial	12
2.3 Problemas encontrados na produção de energia solar	17
2.4 UAV na indústria solar.....	20
3. Contextualização da Empresa	23
3.1 ESI Robotics	23
3.1.1 Investigação e desenvolvimento.....	24
4. Criação de uma base de dados	26
4.1 Base de dados inicial	27
4.2 Melhorias à base de dados	27

4.2.1	Transformações efetuadas	28
4.2.2	Transformação em binário.....	29
4.2.3	Sujidade artificial.....	32
4.2.4	Curva de Bézier	32
4.2.5	Preenchimento das formas criadas	36
4.2.6	Criação da Mesh.....	38
4.2.7	Criação da base de dados final	39
5.	Algoritmo utilizado.....	42
5.1	Divisão dos dados.....	42
5.2	Escolha da Biblioteca.....	42
5.3	Treino do modelo.....	44
5.4	Análise dos Resultados e Ajustes	46
6.	Conclusões Finais e Trabalhos Futuros	48
	Bibliografia	50
	Anexo A	53

LISTA DE ABREVIATURAS/SIGLAS

API	Application Programming Interface/Interface de Programação de Aplicativos
BCE	Banco Central Europeu
BIPV	Building-integrated Photovoltaics/Sistemas Fotovoltaicos Integrados em Edifícios
CAE	Contratos de Aquisição de Energia
CE	Comissão Europeia
CNN	Convolutional Neural Network/Rede Neural Convolucional
CPU	Central Processing Unit/Unidade Central de Processamento
CSP	Concentrated Solar Power/Energia Solar Concentrada
DGEG	Direção-Geral de Energia e Geologia
FMI	Fundo Monetário Internacional
GPU	Graphics Processing Unit/Unidade de Processamento Gráfico
IoT	Internet of Things/Internet das Coisas
ISA	International Solar Alliance/Aliança Solar Internacional
LCOE	Levelized Cost of Electricity/Custo Nivelado da Eletricidade
MIBEL	Mercado Ibérico de Electricidade
PNEC	Plano Nacional de Energia e Clima
RESP	Rede Eléctrica de Serviço Público
SEN	Sistema Eléctrico Nacional
TPU	Tensor Processing Unit/Unidade de Processamento de Tensor
UAV	Unmanned Aerial Vehicle/Veículo Aéreo não Tripulado
UE	União Europeia

LISTA DE FIGURAS

Figura 1 - Irradiação solar na europa. Fonte (Solargis)	1
Figura 2- Processo da metodologia investigação-ação. Adaptado de Methodology (n.d.).....	4
Figura 3 - Produção energética em Portugal 2023. Fonte(REN, APREN)	6
Figura 4 - Evolução da Potência Instalada em Portugal em MW. Fonte (DGEG, APREN).....	11
Figura 5 - Produção de energia renovável a nível Mundial. Fonte (IEA).....	12
Figura 6 - centrais de energia solar concentrada: (i) parabolic dish, (ii) solar tower, (iii) parabolic trough, (iv) Fresnel system. Fonte:(Milidonis et al., 2023)	15
Figura 7-Células solares com deposição de poeira. Imagem do parque solar estudado.	17
Figura 8 - Adaptação da framework da pesquisa realizada por Yao et al.,2022.....	18
Figura 9 - Células solares com excrementos de aves. Imagem do parque solar estudado.	19
Figura 10 - Drone otimizado para a utilização autónoma. Fonte (DJI).	20
Figura 11 - Logo da empresa ESI Robotics.	23
Figura 12- Código responsável pelo recorte e pela rotação respetivamente.....	29
Figura 13- Código responsável pela transformação binária	31
Figura 14- Forma criada dentro de eixos com a biblioteca Matplotlib.....	33
Figura 15- Forma criada sem eixos com a biblioteca Matplotlib.....	34
Figura 16- Código responsável pela criação das formas através da curva de Bézier	36
Figura 17- Sujidade preenchida.....	37
Figura 18- Código responsável pelo preenchimento e alteração do tamanho das formas.....	37
Figura 19- Nível 1 de sujidade	38
Figura 20- Nível 7 de sujidade	38
Figura 21- Código responsável pela criação das máscaras utilizadas	39
Figura 22- Imagem de um painel real.	40
Figura 23- Imagem de um painel criado artificialmente.....	40
Figura 24- Código utilizado na criação de painéis solares sujos artificiais.....	41
Figura 25- Estrutura do Tensorflow	43
Figura 26- Treino do modelo em fase inicial com apenas 65 epochs.....	46
Figura 27- Código relativo ao treino do modelo.....	53

LISTA DE SÍMBOLOS

€ Euro

GW Gigawatt

MWh Megawatt-Hora

TWh Terawatt-Hora

1. INTRODUÇÃO

1.1 Enquadramento

Com a eminente exaustão dos combustíveis fósseis e a urgente necessidade de regular e abordar as emissões de carbono, tem se observado uma grande mudança no paradigma dos sistemas de produção de energia, enfatizando as fontes de energia renováveis como possível solução (Hannan et al., 2019). Entre essas fontes, a energia solar revelou-se como uma opção altamente promissora como se pode observar na figura 1. Os parques fotovoltaicos oferecem diversas vantagens tendo como o único condicionante a exposição solar, ganhando assim grande popularidade e importância para atender às demandas energéticas globais (Mesloub et al., 2020).

Com a crescente adesão à energia solar, novos problemas surgiram. Fatores ambientais como a acumulação de poeiras, variações de temperatura e flutuações de irradiação impactam significativamente o funcionamento e desempenho destes sistemas. Mais concretamente, a acumulação de particular de poeira nos painéis resulta na obstrução da luz solar incidente, reduzindo a quantidade de energia produzida. De acordo com (Institute of Electrical and Electronics Engineers et al., n.d.), a perda anual de energia causada pela deposição de poeira varia habitualmente de 5% a 30%.

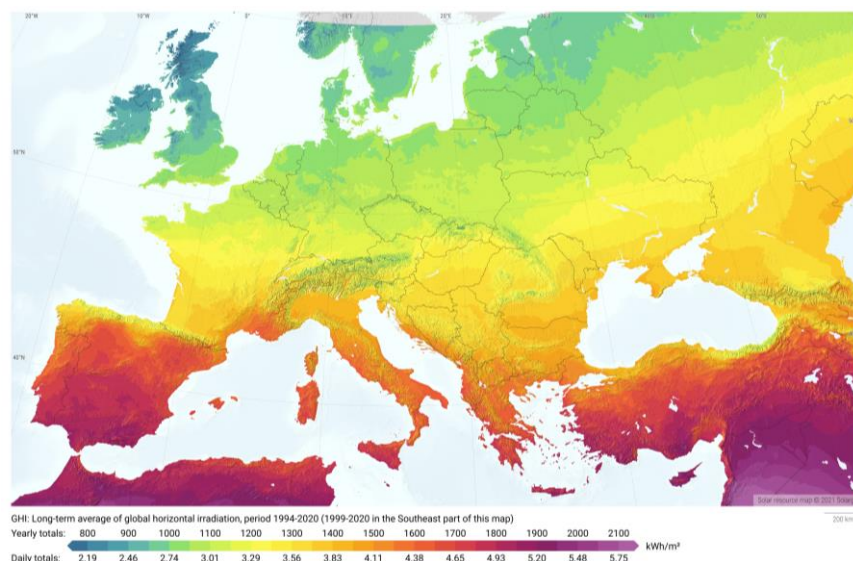


Figura 1 - Irradiação solar na europa. Fonte (Solargis)

Um método rudimentar para detecção de poeira e sujidade é a observação física feita por profissionais. Esse método é demorado e financeiramente caro, tornando assim importante estudar o equilíbrio entre o custo de limpeza e a perda energética aceitável para uma gestão eficiente do parque.

Desta forma, o desenvolvimento e implementação de novos métodos de monitorização eficiente tornou-se essencial para a rentabilizar o investimento inicial e reduzir os custos de manutenção (Ghosh, 2020).

A detecção e limpeza automática de poeira utilizando sistemas robóticos têm se demonstrado mais eficazes do que outros métodos. A utilização de câmaras de alta resolução montadas em Unmanned Aerial Vehicles (UAV) e *drones* permite captar imagens detalhadas dos painéis solares (Baskaran & Balachander, 2019). Além disso, métodos avançados de processamento de imagem podem ser utilizados para transformar essas imagens e analisá-las para detetar poeira e sujidades. Essas abordagens permitem uma detecção oportuna, permitindo uma resposta e manutenção rápida e eficiente.

1.2 Objetivo da dissertação

O objetivo principal desta dissertação é avaliar a viabilidade da utilização de um algoritmo de *machine learning* para a detecção de poeiras e excrementos de aves em painéis solares. As imagens serão captadas por um *drone* durante uma rotina de voo autónoma. A questão central a ser investigada é a viabilidade, tanto do ponto de vista tecnológico quanto económico.

Como referido anteriormente, os painéis solares requerem uma superfície limpa para manter uma eficiência ótima na geração de energia. O acúmulo de poeiras, excrementos de aves e sujidades pode prejudicar significativamente o seu desempenho. Portanto, desenvolver um método eficiente e automatizado para detetar e lidar com esses problemas é de extrema importância.

As principais questões que esta dissertação visa responder são as seguintes:

Os algoritmos de *machine learning* podem detetar e distinguir com eficácia a poeira e os excrementos de aves em painéis solares usando imagens captadas por um *drone* durante uma rotina de voo autónoma?

Qual é a viabilidade tecnológica da implementação de um sistema de detecção baseado em *machine learning* para a manutenção de painéis solares?

A adoção de um sistema de detecção baseado em *machine learning* e UAVs é economicamente viável em comparação com os métodos tradicionais de inspeção manual?

Para responder a tais questões, os seguintes objetivos específicos serão perseguidos:

Coleta e seleção de um conjunto de dados composto por imagens de painéis solares captadas por *drone*, exibindo diferentes níveis de sujidade.

Treino e implementação de um algoritmo de *machine learning* capaz de detetar e classificar com precisão a poeira e os excrementos, com base no conjunto de dados fornecido.

Avaliação do desempenho e da precisão do algoritmo, comparando os resultados com as inspeções manuais.

Avaliação dos requisitos e considerações tecnológicas para a implementação do sistema, incluindo *hardware*, *software* e recursos computacionais.

Realização de uma análise de custos abrangente para determinar a viabilidade económica e as possíveis economias de custo associadas à adoção do sistema em comparação com os métodos tradicionais de inspeção manual.

Esta dissertação visa contribuir significativamente para o campo da manutenção de painéis solares, explorando a aplicação de algoritmos de *machine learning*. Os resultados desta pesquisa têm o potencial de melhorar a eficiência e a viabilidade da produção energética dos painéis solares, levando em consideração também os aspetos económicos da sua implementação.

O próximo subcapítulo fornecerá uma visão geral da metodologia utilizada para abordar as questões e alcançar os objetivos estabelecidos.

1.3 Metodologia de investigação

Em qualquer estudo de investigação ou começo de um novo projeto é necessário recorrer a uma metodologia de investigação para perceber o fio condutor que permite levar a um objetivo final, através das técnicas e ferramentas disponíveis para o efeito. Uma metodologia de investigação é um plano lógico e sistemático que visa explicar o decorrer de uma investigação para resolver um determinado problema, detalhando a abordagem de um investigador para garantir resultados válidos que atendam aos seus objetivos (Indeed Editorial Team, 2021).

Nesta dissertação, a metodologia aplicada é a investigação-ação, do inglês *action research*. O lema principal desta metodologia destaca-se como sendo o *learning by doing*, ou seja, aprender a fazer (O'brien, 2001). Segundo (Ramirez, 1986), “a investigação-ação visa contribuir tanto para as preocupações práticas das pessoas numa situação problemática como para promover os objetivos da ciência social, simultaneamente. (...) A realização deste duplo objetivo requer a colaboração ativa do investigador e cliente e, assim, enfatiza a importância da coaprendizagem como um aspeto primordial do processo de investigação.”.

O processo da investigação-ação é composto por quatro fases distintas que se podem observar na figura 2 (Methodology, n.d.).



Figura 2- Processo da metodologia investigação-ação. Adaptado de Methodology (n.d.)

Inicialmente, o problema é identificado e é desenhado o plano para solucioná-lo. Após este planeamento, a solução é posta em ação para ser possível observar os resultados que se irão obter. Finalmente, é analisada a viabilidade da solução previamente implementada e, caso os resultados não sejam os expectáveis, todo o processo deverá ser repetido.

1.4 Estrutura da dissertação

Esta dissertação está estruturada em seis capítulos distintos, cada um desempenhando um papel essencial na abordagem do tópico central deste trabalho. Essa organização permite uma progressão clara das ideias e uma abordagem sistemática ao assunto.

No primeiro capítulo, é fornecida uma introdução que estabelece o contexto geral da dissertação. Nesta secção inicial, são delineados os principais princípios.

O segundo capítulo concentra-se na revisão literária. Aqui, encontra-se um aprofundamento nas fontes académicas e científicas que fundamentam todas as decisões e abordagens

adotadas ao longo do projeto. Questões pertinentes, como energias renováveis, o estado atual da tecnologia dos painéis solares e aplicações autônomas de UAV, são abordadas. Essa revisão é fundamental para estabelecer uma base teórica sólida e contextualizar o trabalho que segue.

No terceiro capítulo, é fornecido um contexto e enquadrados à empresa no centro da pesquisa. Este passo é crucial para entender o cenário real em que as soluções propostas serão aplicadas, permitindo uma análise mais precisa e relevante.

O quarto capítulo é dedicado à criação da base de dados. Aqui, é descrito o processo de coleta, organização e tratamento de dados, que serve como base para análises subsequentes. As fontes dos dados, a metodologia de coleta e as ferramentas utilizadas para garantir a qualidade e integridade dos dados coletados é fornecida.

No quinto capítulo, é explorado o algoritmo utilizado no projeto. São apresentadas as suas características, funcionamento e relevância. Este capítulo é crucial para entender como os dados são processados e analisados para atingir os objetivos da dissertação.

Finalmente, o sexto e último capítulo fornece uma conclusão abrangente para todo o trabalho desenvolvido ao longo desta dissertação. Além disso, este capítulo lança luz sobre potenciais alterações futuras, apontando caminhos que podem ser explorados em trabalhos subsequentes.

Essa estrutura de seis capítulos fornece uma abordagem sistemática e lógica da dissertação, garantindo que os leitores possam acompanhar claramente a evolução do pensamento.

2. REVISÃO LITERÁRIA

A presente dissertação, como mencionado anteriormente, irá abranger a implementação de um sistema de monitorização de centrais energéticas de painéis solares. Desta forma, neste capítulo serão abordados e devidamente explicados alguns temas relativos à energia solar e ao tratamento de imagem. Este capítulo começa com uma explicação da evolução da energia solar em Portugal, sendo posteriormente efetuada uma contextualização desta realidade a nível mundial e quais os problemas encontrados. Além disso, é apresentado um breve introdução à visão artificial e aos algoritmos utilizados ao longo deste projeto. Por fim é demonstrado um estudo que justifica a necessidade deste projeto como meio de melhor rentabilizar a produção da energia solar.

2.1 Evolução da energia solar em Portugal

Portugal tem-se demonstrado um dos mercados mais promissores para o desenvolvimento da energia solar fotovoltaica na Europa. Na figura 3 pode-se observar as fontes de produção energética em Portugal em 2023.




Figura 3 - Produção energética em Portugal 2023. Fonte(REN, APREN)

Este facto deve-se à sua localização geográfica privilegiada em termos de irradiação solar como recurso renovável, bem como à sua visão estratégica para o desenvolvimento das energias renováveis incluída no Plano Nacional de Energia e Clima para 2030 (PNEC 2030). No entanto, no final de 2019, a potência solar fotovoltaica existente no país (cerca de 900 MW) representava apenas uma pequena fração do consumo nacional de eletricidade, representando apenas 2,3%, num cenário em que a eletricidade renovável no seu conjunto já representava cerca de 53% da procura (Amaral Jorge, 2020).

Esta realidade coloca o foco na tecnologia solar fotovoltaica como tendo o maior potencial de desenvolvimento no país, mas estando ainda muito longe da meta para 2030. É importante olhar para trás e perceber o percurso e as decisões tomadas até à data para o desenvolvimento do sector e avaliar de forma crítica e estratégica as opções do caminho que o país deve seguir para o desenvolvimento de um sector com benefícios significativos para a economia, ambiente e sociedade.

Numa perspetiva histórica, a promoção da eletricidade renovável na Europa, incluindo Portugal, iniciou-se em 2001 com a publicação da primeira Diretiva Europeia sobre a promoção da eletricidade produzida a partir de fontes de energia renováveis. Esta diretiva impôs quotas específicas para a incorporação de energias renováveis, com base numa política estratégica que visava o cumprimento dos compromissos assumidos no âmbito do Protocolo de Quioto.

Numa primeira fase, o compromisso europeu teria de passar, inequivocamente, pela criação de economias de escala para a integração de tecnologias de produção de eletricidade a partir de fontes renováveis no mercado interno, abrindo a porta à aplicação de mecanismos que permitam apoiar, direta ou indiretamente, os produtores de eletricidade renovável. Este apoio é uma necessidade absoluta para que as instituições financeiras e os bancos considerem o financiamento destes projetos.

Nos anos seguintes, todos os Estados-Membros introduziram regimes de apoio à promoção da eletricidade de origem renovável, na sua maioria baseados em tarifas fixas para a produção de eletricidade, designadas por "*feed-in tariffs*". Portugal, à semelhança de alguns países europeus, já tinha reconhecido a figura do produtor independente de eletricidade com regras aplicáveis às energias renováveis. O objetivo era promover a diversificação das fontes, reduzindo a dependência energética externa.

Para responder ao novo contexto e estratégia europeia, Portugal reviu a legislação existente, introduzindo novas tecnologias renováveis em desenvolvimento e expansão, como a eólica e a solar. Foram estabelecidas tarifas *feed-in* diferenciadas, tendo em conta fatores como a disponibilidade de recursos endógenos, o valor do investimento, os custos dos equipamentos, os custos de construção das centrais renováveis, os custos de operação e manutenção, a valorização ambiental, entre outros. Neste âmbito, em 2006, foi criada a primeira central solar fotovoltaica em Portugal, a central fotovoltaica de Hércules, em Serpa, com 11 MW de potência, promovida por um consórcio de três empresas. Posteriormente, em 2007, começaram a surgir as primeiras pequenas unidades de produção descentralizada, conhecidas como centrais de micro geração, otimizando os recursos energéticos e considerando a evolução natural do mercado de eletricidade e a escalabilidade da tecnologia solar.

No entanto, apesar das políticas existentes, Portugal chegou a 2010 com apenas 134 MW de capacidade instalada, uma vez que a tecnologia solar era considerada imatura, com elevados custos de produção (LCOE), e mais focada em instalações locais, o que a tornava menos competitiva face à tecnologia solar térmica em expansão na altura. Em contrapartida, assistiu-se a uma proliferação significativa de sistemas fotovoltaicos e da indústria fotovoltaica na Europa, atingindo uma capacidade instalada de cerca de 30 GW em 2010.

Neste contexto, em 2010, Portugal tentou expandir o sector, lançando um leilão para atribuição de 150 MVA de capacidade de injeção na rede para centrais solares fotovoltaicas convencionais e concentradas, bem como para centrais solares térmicas. Este leilão baseou-se na licitação de lotes de capacidade, atribuídos com base na maior contrapartida financeira oferecida ao Estado, aplicando o regime de tarifa *feed-in* existente sem qualquer outra recompensa específica. Dezassete empresas nacionais e estrangeiras, na sua maioria pequenas e médias empresas, participaram neste leilão, gerando mais de 100 milhões de euros de contrapartidas para o Estado.

Contudo, nesta altura, Portugal encontrava-se numa profunda recessão económica em resultado da crise financeira de 2008-2009. Em 2011, Portugal foi forçado a procurar assistência financeira externa e, em 5 de maio desse ano, a Troica, composta pela Comissão Europeia (CE), o Banco Central Europeu (BCE) e o Fundo Monetário Internacional (FMI), apresentou o programa de assistência financeira a Portugal.

Neste novo contexto económico e financeiro, em 2012, foi revogado o regulamento que promovia as energias renováveis de grande escala em Portugal e foi introduzido um novo quadro legislativo, que estabelecia que a nova capacidade deveria entrar no regime geral ou no regime garantido, atribuído por um processo de concurso. No entanto, todo o sector das renováveis ficou sem qualquer concurso durante 7 anos, mantendo-se apenas o apoio à pequena produção. Este cenário, sem qualquer plano ou visibilidade para a promoção do sector, levou a uma completa estagnação do crescimento do sector e mesmo à extinção de algumas empresas. Assim, num período de 10 anos (2006-2016), o sector solar fotovoltaico assistiu à instalação de apenas 600 MW de capacidade (potência instalada), dos quais cerca de metade eram centrais de grande dimensão distribuídas por pequenas e médias empresas. No entanto, apesar do pacote 20-20-20 que marcou a nova década da política energética e climática para a Europa, esta foi também profundamente abalada pelas crises financeira e da dívida soberana. O investimento no sector solar sofreu quebras significativas, enquanto outros mercados se expandiram e abraçaram plenamente o fabrico da tecnologia, o que resultou numa redução disruptiva dos preços dos equipamentos (de cerca de 7 euros/ Watt-pico para 0,5 euros/ Watt-pico)(Amaral Jorge, 2020) em apenas 10 anos, tornando-a a tecnologia de produção de eletricidade mais competitiva no mercado global.

Por outro lado, em linha com a estratégia europeia de harmonização e unificação do mercado interno de eletricidade da UE, o sistema elétrico sofreu uma profunda transformação com a liberalização do sector. Em Portugal e Espanha, o Mercado Ibérico de Eletricidade entrou em pleno funcionamento em 2007. Como consequência, as tarifas *feed-in* começaram a ser criticadas ao longo dos anos como um mecanismo paralelo que complementa o mercado grossista estabelecido, criando uma perceção errada do papel das tarifas *feed-in* na Europa. Além disso, verificou-se uma falta de sensibilidade na interpretação do impacto das energias renováveis na redução dos preços da eletricidade num mercado grossista marginalista concebido para tecnologias com custos variáveis significativos de produção de eletricidade. Apesar das críticas, este mecanismo de apoio serviu de base necessária para que a Europa criasse uma carteira invejável de tecnologias renováveis, posicionando-a como um continente modelo e líder neste sector.

Voltando então ao sector solar e continuando a linha temporal, em 2017, a Europa começou a preparar o novo Pacote de Energia Limpa para 2030, numa altura em que Portugal estava

visivelmente a recuperar da crise, atraindo cada vez mais o interesse de investidores, nomeadamente na energia solar fotovoltaica. Com a disrupção tecnológica, os leilões tornaram-se uma prática comum em toda a Europa, atingindo preços recorde de 38 €/MWh (IRENA, 2018). Portugal, dada a sua posição geográfica e irradiação solar anual, atraiu vários promotores interessados em desenvolver projetos no país. No entanto, até ao início de 2019, Portugal ainda não tinha definido um quadro específico para a promoção de projetos de energias renováveis por um calendário de leilões. No entanto, com os preços da eletricidade no Mercado Ibérico de Eletricidade (MIBEL) a ultrapassarem os do mercado da Europa Central, os projetos tornaram-se rentáveis através de contratos de aquisição de energia (CAE) de longo prazo, conduzindo a um ponto de viragem no setor, como se pode observar na figura 4. Consequentemente, verificou-se um aumento progressivo dos pedidos de licenciamento de projetos solares, reintroduzindo um problema antigo: a disponibilidade e capacidade da Rede Elétrica de Serviço Público (RESP). A par da evolução das renováveis em Portugal, o investimento na rede tinha estagnado durante os anos de crise, e a existência de pontos de injeção de nova capacidade era escassa, tornando-os um ativo económico importante e transacionável no mercado, proporcionando uma vantagem competitiva muito apelativa a quem conseguisse obter um título de reserva.

Até 2018, a Direção-Geral de Energia e Geologia (DGEG) acumulou cerca de 4 GW de pedidos de licenciamento de projetos solares fotovoltaicos "não subsidiados" ou sem *feed-in tariff*. Destes projetos, foram licenciados cerca de 800 MW, e para os restantes projetos, como a quantidade excedia a capacidade dos nós de rede, o Governo decidiu realizar um sorteio para selecionar os pedidos de licenciamento nestas circunstâncias, atribuindo a capacidade disponível e colocando em lista de espera os projetos em nós de rede que se prevê que sejam objeto de reforço.

Esta decisão, em 2018, foi amplamente contestada por estar a ser atribuída capacidade de forma aleatória num setor chave para a economia, sem que fosse realizado um processo de validação baseado na qualidade, no mérito e no valor acrescentado para o consumidor.

Em 2019, com uma primeira versão do Plano Nacional de Energia e Clima (PNEC) 2030, o Roteiro para a Neutralidade Carbónica até 2050, bem como o pacote legislativo europeu, Portugal estabeleceu o quadro legal para leilões competitivos para atribuição de capacidade, deixando também em aberto a possibilidade de submissão de projetos através do mercado.

O Governo identificou os leilões como a melhor forma de responder à elevada procura do mercado e acelerar o investimento em nova capacidade, dando prioridade aos projetos que proporcionassem maiores benefícios ao Sistema Elétrico Nacional (SEN). Isto abriu caminho para o leilão solar fotovoltaico em julho de 2019, que produziu preços historicamente baixos, superando as expectativas da maioria dos atores do setor.

É importante notar que apesar dos excelentes resultados do leilão, é indispensável refletir mais uma vez sobre se uma estratégia de leilão baseada principalmente num único critério financeiro de preço deve ser complementada com outros critérios como a sustentabilidade ambiental, a incorporação de valor local e nacional, mesmo que estes tragam benefícios mais transversais para o SEN.

Tendo tudo isto em conta, pode-se concluir que o “setor solar fotovoltaico necessita de uma estratégia coerente assente em pilares que proporcionem uma transição energética justa para a sociedade, reduzindo custos e promovendo um setor gerador de cadeias de valor sustentáveis”(Amaral Jorge, 2020).




Figura 4 - Evolução da Potência Instalada em Portugal em MW. Fonte (DGEG, APREN)

2.2 Evolução da importância da energia solar a nível Mundial

A produção de energia solar sofreu uma transformação significativa nos últimos anos, emergindo como um fator-chave no panorama energético global. A produção de energia solar fotovoltaica, em particular, registou um crescimento notável, com 2021 a constituir um marco ao ultrapassar os 1 000 Terawatt-Hora (TWh), demonstrando um aumento recorde de 179 TWh em comparação com o ano anterior. Este aumento na produção de energia solar fotovoltaica, um aumento de 22%, ficou atrás apenas da energia eólica em termos de crescimento absoluto entre as tecnologias renováveis. Toda esta evolução pode ser observada na figura abaixo.




Figura 5 - Produção de energia renovável a nível Mundial. Fonte (IEA)

A redução drástica dos custos da energia solar fotovoltaica tem sido uma força motriz por detrás da sua rápida implantação. Esta é agora a opção mais barata para a produção de eletricidade em muitas partes do mundo, o que a torna um investimento atrativo para os intervenientes públicos e privados. A diminuição dos custos dos módulos fotovoltaicos,

combinada com a melhoria da eficiência e os avanços tecnológicos, contribuiu para a competitividade da energia solar fotovoltaica como fonte de energia dominante.

Para atingir o ambicioso objetivo do projeto Net Zero Emissions até 2050, é necessária uma taxa de crescimento anual média de 25% na produção de energia fotovoltaica entre 2022 e 2030. Isto traduz-se num aumento para o triplo da capacidade anual de implantação, o que exige esforços substanciais em termos de política, regulamentação, financiamento e integração na rede. Estes desafios são particularmente significativos nos países emergentes e em desenvolvimento, onde a expansão da infraestrutura fotovoltaica pode contribuir tanto para o crescimento económico como para o desenvolvimento sustentável.

A China desempenhou um papel crucial na condução do crescimento da geração solar fotovoltaica em 2021, representando aproximadamente 38% do aumento total. Isso deveu-se principalmente a acréscimos de capacidade em grande escala feitos em 2020 e 2021. Seguiram-se os Estados Unidos e a União Europeia, com o segundo e o terceiro maiores crescimentos de produção, respetivamente. Apesar das perturbações causadas pela pandemia de COVID-19, a energia solar fotovoltaica manteve-se resiliente e alcançou outro aumento recorde de capacidade, atingindo quase 190 Gigawatt (GW).

A implantação da capacidade solar fotovoltaica tem sido diversificada em vários segmentos. As centrais à escala dos serviços públicos representaram 52% das adições de capacidade global em 2021, enquanto os sectores residencial e comercial/industrial contribuíram com 28% e 19%, respetivamente (*Solar Panels, IEA Report, 2022*). Nomeadamente, a percentagem de centrais à escala de serviços públicos foi a mais baixa desde 2012, principalmente devido ao rápido crescimento da capacidade fotovoltaica distribuída. Os generosos incentivos políticos na China, nos Estados Unidos e na União Europeia impulsionaram as instalações fotovoltaicas distribuídas, tornando-as uma opção cada vez mais atrativa para os consumidores, especialmente face ao aumento dos preços dos combustíveis e da eletricidade. Embora a energia fotovoltaica à escala dos serviços públicos continue a ser a fonte mais competitiva de produção fotovoltaica mundialmente, o desenvolvimento de instalações em grande escala enfrenta desafios para encontrar locais adequados. Em consequência, as instalações fotovoltaicas distribuídas ganharam popularidade, especialmente em zonas urbanas e regiões onde o acesso à rede é limitado. Estas instalações podem ser integradas nas estruturas dos edifícios via sistemas fotovoltaicos integrados em edifícios (BIPV), em que os

painéis solares são perfeitamente incorporados em telhados, fachadas e janelas. O BIPV não só aumenta o potencial de produção de energia como também melhora a estética dos edifícios, promovendo a adoção generalizada da energia solar fotovoltaica.

Para acelerar o progresso em direção ao Cenário Net Zero, é necessário um aumento anual da capacidade solar fotovoltaica de aproximadamente 600 GW até 2030. Para tal, é necessário apoiar e investir tanto na energia solar fotovoltaica distribuída como na de grande escala, adaptada ao potencial e às necessidades de cada país. Além disso, os avanços contínuos na tecnologia solar fotovoltaica são fundamentais para melhorar a eficiência e o desempenho. Os esforços de investigação e desenvolvimento centram-se nas células solares da próxima geração, como as células solares de perovskite e as células solares de junção múltipla, que se revelaram promissoras para alcançar eficiências de conversão mais elevadas e expandir o mercado da energia solar fotovoltaica.

Já o apoio político tem sido um fator essencial para o crescimento da implantação da energia solar fotovoltaica em todo o mundo. Vários instrumentos políticos, incluindo leilões, tarifas de alimentação, medição líquida e contratos por diferença, têm desempenhado um papel fundamental no incentivo às instalações fotovoltaicas. Estas políticas criam um ambiente de investimento favorável, reduzem os riscos de investimento e proporcionam segurança de receitas a longo prazo aos promotores de projetos. Além disso, os quadros regulamentares que racionalizam os procedimentos administrativos e simplificam os processos de ligação à rede são cruciais para facilitar a integração da energia solar fotovoltaica no sistema elétrico.

A colaboração internacional e a partilha de conhecimentos também contribuíram para o crescimento da produção de energia solar. Plataformas como a Aliança Solar Internacional (ISA) têm sido fundamentais para promover a cooperação entre países, em especial aqueles com elevado potencial solar. A ISA procura mobilizar 1 bilião de dólares em investimentos até 2030 e facilitar a implantação de 1 000 GW de capacidade de energia solar mundialmente. Mediante parcerias, iniciativas de reforço de capacidades e transferências de tecnologia, a ISA procura acelerar a adoção da energia solar e apoiar os países em desenvolvimento na sua transição para sistemas energéticos limpos e sustentáveis.

As tecnologias de armazenamento de energia solar também registaram avanços significativos, respondendo a um dos principais desafios da produção intermitente de energia solar fotovoltaica. Os sistemas de armazenamento de energia, como as baterias de íões de lítio e o

armazenamento hídrico por bombagem, desempenham um papel crucial na estabilização do fornecimento de energia solar e permitem a sua integração na rede. Estas tecnologias permitem que o excesso de energia solar seja armazenado e utilizado durante períodos de baixa produção ou de elevada procura, aumentando a fiabilidade da rede e maximizando a utilização das instalações solares fotovoltaicas.

Para além dos sistemas solares fotovoltaicos tradicionais, estão a surgir abordagens inovadoras à produção de energia solar das quais algumas se podem observar na figura abaixo. As centrais de energia solar concentrada (CSP), por exemplo, utilizam espelhos ou lentes para concentrar a luz solar num recetor, gerando calor que aciona uma turbina e produz eletricidade. As centrais CSP oferecem a vantagem do armazenamento de energia térmica, permitindo a produção de eletricidade mesmo quando o sol não está a brilhar. Esta tecnologia tem demonstrado grande potencial, particularmente em regiões com elevada irradiação direta normal, como o Médio Oriente e o Norte de África.

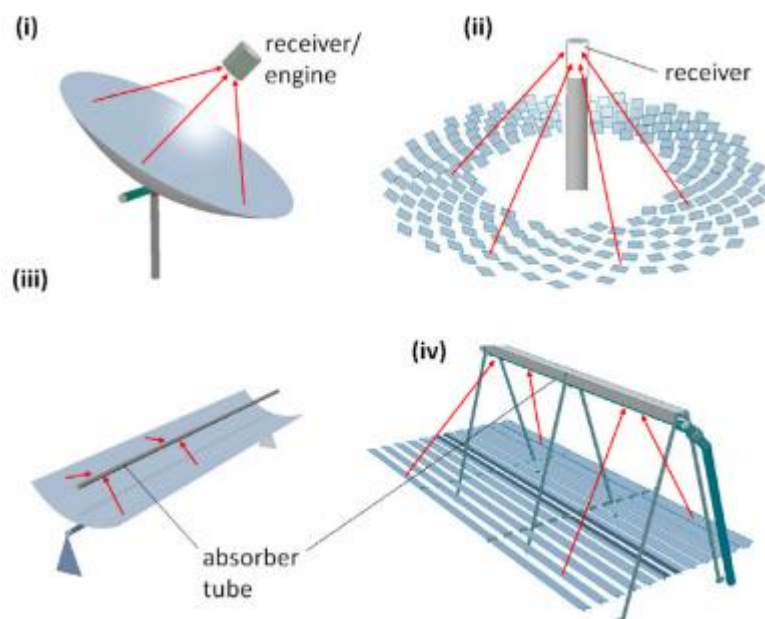


Figura 6 - centrais de energia solar concentrada: (i) parabolic dish, (ii) solar tower, (iii) parabolic trough, (iv) Fresnel system.
Fonte:(Milidonis et al., 2023)

Outro desenvolvimento promissor é a integração da energia solar fotovoltaica nos materiais de construção. Como referido, o BIPV permite que os painéis solares sejam perfeitamente integrados nos edifícios, transformando estruturas inteiras em ativos geradores de energia. Esta integração não só reduz o impacto visual das instalações solares, como também maximiza o potencial de produção de energia através da utilização de superfícies subutilizadas. As

tecnologias BIPV estão a ganhar força na indústria da construção, oferecendo uma mistura de funcionalidade e sustentabilidade.

Para apoiar o crescimento da capacidade fotovoltaica, são essenciais investimentos em infraestruturas de fabrico. O estabelecimento de cadeias de abastecimento robustas e escaláveis pode garantir um fornecimento adequado de módulos e componentes solares fotovoltaicos a preços competitivos. Vários países estão a investir estrategicamente nas capacidades de fabrico nacionais para reduzir a dependência das importações e criar oportunidades de emprego local. Estes esforços contribuem para o crescimento global da indústria solar fotovoltaica e promovem o desenvolvimento económico.

Outro aspeto fundamental da produção de energia solar é o seu impacto ambiental. Os sistemas solares fotovoltaicos são conhecidos pela sua baixa pegada de carbono, uma vez que produzem eletricidade sem emissões diretas de gases com efeito de estufa. No entanto, os processos de fabrico dos módulos solares fotovoltaicos e a sua eliminação no final do seu ciclo de vida podem ter implicações ambientais. Para atenuar estes impactos, estão a ser desenvolvidos esforços para melhorar a sustentabilidade do fabrico de módulos solares fotovoltaicos, aumentar as taxas de reciclagem e desenvolver princípios de economia circular para a indústria.

Concluindo, a produção de energia solar a nível mundial registou um crescimento notável e uma competitividade de custos. “Os avanços tecnológicos, o apoio político e a colaboração internacional têm sido fundamentais para impulsionar a implantação da energia solar fotovoltaica mundialmente. As tecnologias de armazenamento de energia, as abordagens inovadoras como o BIPV e a CSP, e os esforços de investigação e desenvolvimento em curso estão a aumentar o potencial da energia solar. À medida que os países esforçam-se por atingir os seus objetivos em matéria de energias renováveis e fazer a transição para sistemas energéticos sustentáveis, a energia solar continuará a desempenhar um papel vital na satisfação da procura de energia, atenuando simultaneamente as alterações climáticas.” (*Solar Panels, IEA Report, 2022*).

2.3 Problemas encontrados na produção de energia solar

As grandes centrais de energia solar são predominantemente instaladas em regiões semiáridas e desertas, e enfrentam um obstáculo significativo: a elevada taxa de deposição de poeiras, como se observa no exemplo presente na figura 7.



Figura 7-Células solares com deposição de poeira. Imagem do parque solar estudado.

Essa deposição não apenas prejudica o rendimento energético, como também desafia a capacidade da central de manter as suas capacidades projetadas. Para garantir um desempenho desejado, os módulos fotovoltaicos precisam de uma eficiência de transmissão de luz superior a 90%, enquanto as CSP dependem de uma reflexão especular eficaz (Sayyah et al., 2014). Infelizmente, a combinação de alta umidade relativa, altas temperaturas de superfície e residência prolongada de poeira degrada gradualmente os coletores solares. Com o tempo, forma-se um revestimento resistente semelhante a lama, aderindo firmemente aos módulos fotovoltaicos e espelhos concentradores, exigindo uma limpeza cuidadosa. Para entender melhor esses efeitos, (Yao et al., 2022) efetuou diversos estudos em ambiente controlado. O seu trabalho utilizou uma *framework* eficiente, presente na figura 8, que possibilitou comprovar estes entraves.

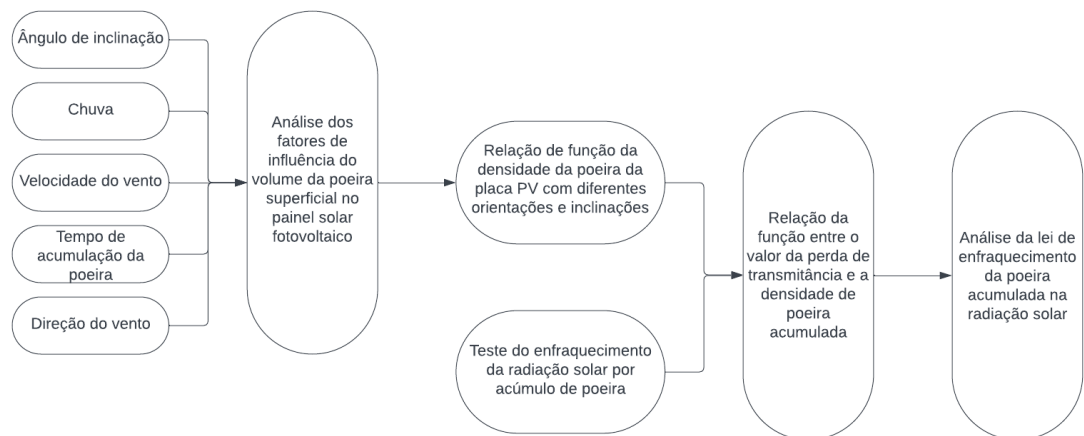


Figura 8 - Adaptação da framework da pesquisa realizada por Yao et al., 2022.

Após estudos extensos, concluiu-se que a limpeza frequente é obrigatória.

No entanto, com o aumento previsto da produção global de energia solar para níveis elevados de terawatts (TW) apareceram preocupações quanto à sustentabilidade dos processos de limpeza dependentes da água.

Além dos desafios relacionados à poeira, as excreções de aves exacerbam a situação. As fezes de pássaros que se acumulam na superfície dos módulos fotovoltaicos, reduzem a transmissão de luz e criam pontos quentes localizados, “Hotspots”, que degradam o desempenho do módulo (Yao et al., 2022). Essas fezes também contêm elementos corrosivos que podem comprometer a integridade dos painéis solares. Conseqüentemente, a resolução eficaz desse problema é essencial para garantir a eficiência a longo prazo das instalações solares fotovoltaicas. Na figura 9 pode ser observado um exemplo deste problema.




Figura 9 - Células solares com excrementos de aves. Imagem do parque solar estudado.

São inúmeros os fatores que influenciam a deposição de poeiras nos módulos solares fotovoltaicos. A escolha dos materiais assume um papel significativo, uma vez que certos materiais atraem e retêm mais partículas de poeira. Além disso, o ângulo de instalação dos painéis fotovoltaicos tem impacto na sua acumulação, sendo que os ângulos mais inclinados beneficiam de um efeito natural de autolimpeza facilitado pela precipitação. As condições meteorológicas locais, que incluem a velocidade e direção do vento e a precipitação, exercem uma influência direta na quantidade de poeira acumulada. Além disso, as condições atmosféricas e as atividades humanas, como a construção nas proximidades ou os processos industriais, introduzem partículas de poeira adicionais no ambiente (Jiang et al., 2011).

A acumulação de poeira nos módulos fotovoltaicos manifesta-se em efeitos prejudiciais na eficiência do sistema. A poeira obstrui a transmissão de luz para as células fotovoltaicas, diminuindo assim a radiação solar recebida pelos módulos e reduzindo subsequentemente a produção de energia. Mesmo uma fina camada de poeira pode gerar um declínio notável no rendimento energético, sublinhando a importância da limpeza e manutenção regulares. Consequentemente, o desenvolvimento de estratégias eficazes para atenuar a deposição de poeiras assume a maior importância na otimização da produção de energia.

As estratégias de mitigação destinadas a resolver o problema da deposição de poeiras incluem o desenvolvimento de revestimentos antisujidade avançados para módulos fotovoltaicos e CSP. Estes revestimentos possuem propriedades que repelem as partículas de poeira, minimizam a adesão e até facilitam a autolimpeza quando sujeitos à chuva ou ao vento. Além disso, os sistemas de limpeza automatizados, como os métodos robóticos, são promissores na redução da sujidade sem o consumo de água, aumentando simultaneamente a eficiência da limpeza. Ao empregarem tecnologias de sensores de ponta, estes sistemas podem ainda visar com precisão áreas com elevada acumulação de pó, otimizando o processo de limpeza global (Institute of Electrical and Electronics Engineers et al., n.d.).

Para enfrentar o desafio colocado pelas fezes das aves, são indispensáveis estratégias eficazes de dissuasão das aves. A utilização de barreiras físicas, sinais visuais e dissuasores sonoros pode ajudar a mitigar a sua presença perto de instalações solares fotovoltaicas, salvaguardando assim a integridade do sistema e otimizando a produção de energia. A

implementação de planos abrangentes de gestão de aves assume uma importância crítica na minimização do seu impacto adverso.

2.4 UAV na indústria solar

As últimas duas décadas testemunharam avanços notáveis em vários domínios tecnológicos, tais como micro controladores de baixo consumo (Yemelyev et al., 2021), sensores miniaturizados (R. Herschel et al., 2018), motores sem escovas (Zhang et al., 2022), tecnologias de comunicação remota (Sharma et al., 2020), sistemas de localização espacial (Couturier & Akhloufi, 2021) e baterias (Townsend et al., 2020). Estes avanços abriram caminho para o rápido desenvolvimento e utilização de UAV, vulgarmente conhecidos como "drones", que representam um dos avanços tecnológicos mais significativos do nosso tempo. Os UAV integram tecnologias de diversos domínios para criar plataformas aéreas com capacidades versáteis que podem ser adaptadas e configuradas para uma vasta gama de missões e aplicações. Na figura abaixo está representado o drone desejado para este projeto.



Figura 10 - Drone otimizado para a utilização autónoma. Fonte (DJI).

Simultaneamente, as tecnologias da Internet das Coisas (IoT) têm transformado a nossa sociedade, tornando-se parte integrante da nossa vida quotidiana. Com as suas características únicas, os UAV estão a ser cada vez mais reconhecidos como plataformas remotas dinâmicas e equipadas com sensores no âmbito das redes IoT. Podem comunicar sem problemas com outros UAV ou com sensores e dispositivos terrestres, contribuindo para a flexibilidade e a

funcionalidade melhorada das redes IoT. Esta integração abre novas possibilidades e cenários, particularmente na obtenção de dados e informações a longas distâncias, em áreas inacessíveis ou em zonas perigosas.

Embora os UAV estivessem tradicionalmente associados a aplicações militares dispendiosas, a redução significativa do custo dos componentes impulsionou a sua adoção generalizada nos sectores comercial e civil. Encontram aplicações em diversas indústrias, incluindo agricultura, construção, vigilância, operações de busca e salvamento, geociências e até atividades recreativas. A sua versatilidade torna-os ferramentas inestimáveis em vários domínios, revolucionando a forma como as tarefas são executadas e contribuindo para uma maior eficiência e rentabilidade.

Não é de surpreender que a sua utilização, tanto como plataformas de deteção aéreas autónomas como dispositivos integrados em redes IoT, tenha ganho uma força significativa no sector das energias renováveis. Os UAV provaram ser altamente benéficos para melhorar o funcionamento autónomo dos sistemas de energias renováveis, reduzindo os custos operacionais, de monitorização e de manutenção, otimizando a eficiência operacional e ajudando na fase de conceção. Oferecem capacidades únicas que as redes IoT terrestres, por si só, não podem proporcionar. Exemplos de aplicações de UAV no sector das energias renováveis incluem as centrais elétricas de energias renováveis, onde os UAV ajudam em tarefas específicas, como a monitorização e a inspeção, e a gestão de cenários radiológicos em emergências de centrais nucleares.

A utilização de UAVs no sector das energias renováveis traz várias vantagens. Quando equipados com sensores avançados podem realizar inspeções aéreas de infraestruturas de energias renováveis, incluindo parques solares e turbinas eólicas, permitindo uma monitorização e manutenção eficientes. Podem detetar e identificar potenciais problemas, como painéis danificados ou componentes defeituosos, permitindo intervenções atempadas e evitando perdas de produção de energia. Os UAV também contribuem para a otimização dos sistemas de energias renováveis, recolhendo dados sobre fatores ambientais, como os padrões de vento ou a irradiação solar, facilitando uma melhor gestão dos recursos e maximizando a produção de energia.

Além disso, os UAV desempenham um papel crucial no reforço da segurança das instalações de energias renováveis. Podem efetuar vigilância e monitorização do perímetro, identificando

acessos não autorizados ou potenciais perigos. No caso de emergências ou catástrofes naturais, podem ainda avaliar rapidamente os danos e fornecer um conhecimento da situação em tempo real, ajudando na resposta a catástrofes e nos esforços de recuperação.

Como referido anteriormente, a integração de UAVs em redes IoT permite a comunicação e a troca de dados entre UAVs e outros dispositivos conectados. Esta interconexão melhora o controlo e a coordenação do sistema, permitindo uma gestão eficiente da energia, a manutenção preditiva e a tomada de decisões otimizadas. Os UAVs podem recolher dados de locais remotos e desafiantes, expandindo o âmbito dos projetos de energias renováveis e permitindo a tomada de decisões informadas com base em informações abrangentes e precisas.

À medida que o sector das energias renováveis continua a crescer e a evoluir, espera-se que a utilização de UAVs em conjunto com as tecnologias IoT desempenhe um papel cada vez mais significativo. “Os avanços contínuos nas capacidades dos UAV, nas tecnologias de sensores e nos sistemas de comunicação aumentarão a sua eficácia e aplicabilidade na resposta aos complexos desafios enfrentados pelo sector das energias renováveis. Além disso, o desenvolvimento de regulamentos e orientações específicas para as operações de UAV no sector das energias renováveis garantirá uma utilização segura e responsável.”(Milidonis et al., 2023)

3. CONTEXTUALIZAÇÃO DA EMPRESA

3.1 ESI Robotics

A ESI Robotics (figura 11) é uma empresa tecnológica conceituada especializada no desenvolvimento e implementação de soluções avançadas que aumentam a competitividade e a rentabilidade das empresas. Com um foco incansável na inovação, vasta experiência e tecnologias de ponta, fornece serviços personalizados para atender às necessidades exclusivas dos clientes.



Figura 11 - Logo da empresa ESI Robotics.

A gama abrangente de serviços fornecidos pela ESI Robotics engloba a resolução de problemas, automação de processos e produtividade acelerada. Estudos meticolosos de produção são conduzidos para identificar áreas de melhoria, resultando em reduções de custos e na criação de valor significativo para os clientes. São criadas soluções industriais à medida para impulsionar aumentos notáveis de produtividade em vários sectores.

Possuem ainda um departamento de investigação e desenvolvimento dedicado, composto por uma equipa de engenheiros qualificados com experiência em engenharia mecânica, automação industrial e robótica. Esta experiência permite a criação e entrega de soluções inovadoras. Abraçando os princípios da Indústria 4.0, a empresa fornece serviços de ponta a ponta que abrangem a conceção do projeto, a produção, a instalação e um apoio pós-venda abrangente.

A abordagem multidisciplinar da empresa serve uma vasta gama de indústrias, incluindo a alimentar, automóvel, metalomecânica, médica, polímeros, construção, madeira, cortiça e cerâmica. Esta ampla exposição facilita a acumulação de valiosos conhecimentos interindustriais e a transferência contínua de tecnologia, oferecendo aos clientes soluções e perspectivas únicas.

A ESI Robotics também oferece serviços de consultoria, incluindo a conceção de instalações industriais e a gestão abrangente de projectos. Desde a fase de seleção e aquisição até à instalação e funcionamento, os clientes são orientados em todas as etapas do processo, garantindo resultados bem sucedidos e operações eficientes. O compromisso inabalável da empresa com a satisfação do cliente impulsiona o fornecimento de produtos e serviços de qualidade superior.

3.1.1 Investigação e desenvolvimento

A criação do Departamento de Investigação e Desenvolvimento (I&D) na ESI marcou um ponto de viragem significativo na trajetória da empresa, impulsionando-a também para o domínio da inovação tecnológica. Este movimento estratégico abriu novos caminhos para a empresa expandir o seu portfólio e oferecer soluções de ponta a várias indústrias, incluindo o sector da energia solar.

Com a formação do Departamento de I&D, a ESI embarcou numa viagem de exploração e descoberta, aproveitando a sua experiência e *know-how* para desenvolver soluções robóticas adaptadas às necessidades específicas de diferentes indústrias. No âmbito desta iniciativa, a empresa reconheceu o imenso potencial da robótica para revolucionar o panorama da energia solar, o que levou à proposta do tema desta dissertação.

Impulsionada por um compromisso com soluções energéticas sustentáveis, a ESI canalizou os seus recursos e conhecimentos para o desenvolvimento de sistemas robóticos que pudessem melhorar a eficiência e a eficácia da produção de energia solar. Ao incorporar a robótica na indústria solar, a ESI pretendia ultrapassar os desafios associados à manutenção, monitorização e otimização dos parques solares.

Reconhecendo o potencial impacto da integração da robótica nos sistemas de energia solar, a empresa procurou explorar melhor a otimização e a automatização dos parques solares através desta investigação.

Como resultado, a dissertação investiga o desenvolvimento e a implementação de visão artificial de sistemas robóticos para parques solares, centrando-se no aumento da eficiência operacional, na manutenção preditiva e na análise de dados. Ao tirar partido dos conhecimentos especializados da ESI e ao colaborar com as partes interessadas do sector, a

investigação visa descobrir novas perspectivas e soluções que possam impulsionar o avanço das tecnologias de energia solar.

4. CRIAÇÃO DE UMA BASE DE DADOS

A criação de um algoritmo robusto de processamento de imagem requer o desenvolvimento de uma base de dados abrangente que descreva com exatidão as classes pretendidas e as suas respectivas características. Através da metodologia anteriormente descrita, foram meticulosamente construídas e rigorosamente testadas numerosas bases de dados, de modo a atenuar os erros e a obter uma precisão ótima nos resultados obtidos.

Visando aperfeiçoar o desempenho do algoritmo, foi utilizada uma série de processos iterativos para aumentar a precisão e a fiabilidade da base de dados. Foram efetuados testes rigorosos e procedimentos de validação para garantir a integridade do conjunto de dados e a sua adequação ao objetivo pretendido.

O processo de criação da base de dados envolveu uma abordagem sistemática para capturar e representar as complexidades das classes alvo. Foram utilizadas técnicas avançadas, como a extração de características, a redução da dimensão e o reconhecimento de padrões, para destilar a informação relevante e encapsulá-la na base de dados.

Para garantir a eficácia da base de dados, foram implementadas extensas medidas de controlo de qualidade. Estas medidas abrangeram a limpeza completa dos dados, a deteção de valores atípicos e a análise estatística para identificar e retificar quaisquer anomalias ou inconsistências que possam ter prejudicado o desempenho do algoritmo.

Além disso, a base de dados foi submetida a um rigoroso processo de validação e foi comparada com normas estabelecidas e conjuntos de dados de referência. A este respeito, os conjuntos de dados de referência incluíam imagens reais recolhidas pelo aluno, o que permitiu testar e verificar exhaustivamente o desempenho do algoritmo. É importante notar que estas imagens de referência não foram incluídas na própria base de dados, servindo apenas como um recurso de validação externo para avaliar e validar os resultados do algoritmo.

4.1 Base de dados inicial

Para uma fase inicial foram utilizadas diversas imagens recolhidas na *internet*. Apesar de apresentar uma baixa fiabilidade, é possível distinguir as diversas imagens a olho humano e assim caracterizá-las como limpas ou sujas para as colocar nas respetivas classes da base de dados.

Com esta primeira abordagem rapidamente se percebeu que seria necessário um número de imagens muito superior ao disponível, com maior qualidade e com maior rigor nas características presentes, desde a luminosidade ao ângulo da imagem. Desta forma, a empresa disponibilizou a possibilidade do aluno se deslocar a um parque solar de um dos seus parceiros e, desta forma, captar imagens para a sua base de dados. Todas as imagens desta fase foram captadas através de um drone, o Dji mini 2, disponibilizado pela empresa.

Já com as imagens captadas foi necessário proceder a uma seleção rigorosa das mesmas. Mesmo com agora imagens de maior qualidade e mais parametrizadas, rapidamente se percebeu com alguns testes que existia um número muito reduzido de imagens de painéis solares sujos. Por esta altura existiam 5000 imagens de painéis solares limpos e apenas 120 de painéis solares sujos.

Tendo isto em conta e, não existindo a possibilidade de deslocação a um novo parque solar, rapidamente se chegou a conclusão de que seria necessária uma nova abordagem.

É também importante referir, que por esta altura, mesmo com uma luminosidade controlada conforme o possível, os painéis demonstravam tonalidades bastante distintas, o que estava a confundir o modelo treinado.

4.2 Melhorias à base de dados

Conforme foi referido anteriormente, não havia muitos painéis solares sujos, tanto em termos do número de fotografias disponíveis como na variedade de sujidade, que poderia incluir pó ou excrementos de aves com diferentes formas e padrões. Como resultado, era essencial encontrar novas ideias para expandir o conjunto de dados de treino. O uso de fotos binárias para considerar as luminosidades variáveis, recorte e rotação de imagens, e até mesmo a

geração de sujidade artificial são algumas das abordagens utilizadas nessas estratégias para superar as limitações impostas pela escassez de imagens do mundo real do campo.

4.2.1 Transformações efetuadas

Para obter uma compreensão abrangente da eficácia de várias transformações de dados, foi feito um esforço deliberado para categorizar essas transformações com base na extensão das alterações que introduziam, bem como na complexidade envolvida na sua implementação.

Num primeiro momento, as estratégias iniciais empregadas para enriquecer a nossa base de dados incluíram a aplicação de rotação e recorte aleatório ao repositório de imagens existente. Essas transformações cuidadosamente selecionadas desempenharam um papel fundamental em ampliar a variedade da base de dados sem a indesejável redundância que a repetição poderia trazer. Isso harmonizou-se perfeitamente com o objetivo principal, que estava centrado na diversificação dos tipos de sujidade.

No que diz respeito à rotação de imagens, foi preferida uma abordagem calculada em detrimento da aleatoriedade. Essa escolha criteriosa determinou que as imagens fossem rodadas em ângulos especificados pelo utilizador, evitando, assim, a geração de imagens caracterizadas por mudanças drásticas na orientação. A lógica subjacente era assegurar que o processo de aprendizado do modelo permanecesse coerente e livre de confusões. Portanto, a rotação foi limitada a um intervalo estreito de ângulos, especificamente dentro da faixa de -3 a 3 graus.

A aplicação de recorte aleatório adotou uma metodologia sistemática, mas aleatória. Neste contexto, as imagens passaram por recortes espontâneos, embora dentro de limites predefinidos. A essência dessa abordagem estava na sua capacidade de criar uma variedade de imagens com nuances visuais diferentes, todas derivadas de uma imagem base comum. O resultado foi uma expansão exponencial da base de dados. Para fornecer um contexto mais específico, os limites de recorte variavam de 5% a 15% das dimensões originais da imagem, garantindo que as células fotovoltaicas representadas na imagem não fossem completamente obscurecidas ou excluídas.

Código em Python

Na figura abaixo pode-se observar o código desta secção.

```
n=0
images = Path("C:/Users/Asus/Downloads/MODELO/roda/Rod_Cort").glob("*.png")
image_strings = [str(p) for p in images]
for images in image_strings:
    img = Image.open(images)
    imge = cv2.imread(images)

    x, y = img.size
    sample = 3
    for i in range(sample):
        matrix = x-(round(x*random.uniform(0.05, 0.15)))
        matrix2 = y -(round(y*random.uniform(0.05, 0.15)))
        x1 = randrange(0, x - matrix)
        y1 = randrange(0, y - matrix2)
        im1=img.crop((x1, y1, x1 + matrix, y1 + matrix2))
        im1.save("C:/Users/Asus/Downloads/MODELO/roda/Rod_Cort/cortadas_a"+str(n)+".png")
        n+=1

n=0
images = Path("C:/Users/Asus/Downloads/MODELO/roda/Rod_Cort").glob("*.png")
image_strings = [str(p) for p in images]
for images in image_strings:
    img = Image.open(images)
    imge = cv2.imread(images)

    w=img.width
    h=img.height
    rotate = -3
    for i in range(7):
        print(rotate)
        img2=img.resize((round(w*1.3),round(h*1.3)),Image.LANCZOS)
        x, y = img2.size
        matrix = x-(round(x*0.1))
        matrix2 = y -(round(y*0.1))
        x1 = x - matrix
        y1 = y - matrix2
        img1=img2.rotate(rotate, expand=True,fillcolor=None)
        im3=img1.crop((x1, y1, x1 + matrix, y1 + matrix2))
        im4=im3.resize((w,h),Image.LANCZOS)
        im4.save("C:/Users/Asus/Downloads/MODELO/roda/lat"+str(n)+".jpg")
        n+=1
        rotate+= 1
```

Figura 12- Código responsável pelo recorte e pela rotação respetivamente

4.2.2 Transformação em binário

As transformações anteriores contribuíram significativamente para lidar com a escassez de imagens na base de dados. No entanto, o problema persistente da luminosidade e tonalidade variáveis nas fotografias continuou a ser um desafio. Uma vez que os painéis solares usados podiam apresentar diferentes tonalidades dependendo do seu local de produção e do

desgaste, e uma vez que obter fotografias perfeitamente iluminadas no terreno nem sempre é viável, buscou-se uma solução para resolver esse problema.

A solução elaborada envolveu a transformação de todas as imagens da base de dados em imagens binárias, com píxeis tendo valores de $[0, 0, 0]$ e $[255, 255, 255]$ representando preto e branco, respetivamente. Inicialmente, várias funções disponíveis em bibliotecas como OpenCV ou Skimage foram aplicadas para essa transformação.

No entanto, rapidamente ficou claro que essas funções predefinidas não eram uma solução viável. As variações entre as imagens significam que com um valor de *threshold* universal os resultados obtidos são muito diferentes, com algumas imagens retendo os detalhes desejados, enquanto outras ficariam desprovidas de detalhes ou exibiriam ruído visual excessivo.

Consequentemente, uma metodologia alternativa foi adotada. Este método dependia do uso do histograma das imagens para estabelecer classes entre as mesmas, que depois orientariam um processo manual de transformação de píxeis. Esta abordagem é mais prática, envolvendo tentativa e erro na criação de intervalos personalizados para os diferentes histogramas obtidos. No entanto, uma vez que esses intervalos foram definidos, tornou-se possível obter resultados superiores em comparação com quaisquer funções predefinidas disponíveis nas bibliotecas. Além disso, essa solução permite ajustar esses intervalos, se necessário.

Com a implementação dessas transformações, os resultados melhoraram significativamente. Tornou-se viável identificar aproximadamente 70% das imagens de teste, incluindo imagens da base de dados e aquelas retiradas antes da criação do algoritmo. Dado o objetivo de identificar todas as imagens selecionadas, foram consideradas mais estratégias para diversificar ainda mais a base de dados. Com isso em mente, foram aplicadas outras alterações, conforme discutido abaixo.

Código em Python

Na figura abaixo pode-se observar o código desta secção.

```

n=0
images = Path("C:/Users/Asus/Downloads/MODELO/roda").glob("*.JPG")
image_strings = [str(p) for p in images]
for images in image_strings:
    img = Image.open(images)
    imge = cv2.imread(images)
    colors = ("red", "green", "blue")

    for channel_id, color in enumerate(colors):
        histogram, bin_edges = np.histogram(imge[:, :, channel_id], bins=256, range=(0, 256))

    x=statistics.mean(histogram)
    print(n)
    print("feito:" + str(x))

    if x<=700:

        im3 = img.filter(ImageFilter.UnsharpMask(radius=3, percent=350))
        im2=im3.filter(ImageFilter.RankFilter(3, 4))

    elif 700<x<=950:
        im4=img.filter(ImageFilter.BoxBlur(radius=2))
        im3 = im4.filter(ImageFilter.UnsharpMask(radius=3, percent=550))
        im2=im3.filter(ImageFilter.RankFilter(3, 3))

    elif 2500<=x<5900:
        im4=img.filter(ImageFilter.BoxBlur(radius=2))
        im3 = im4.filter(ImageFilter.UnsharpMask(radius=20, percent=250))
        im2=im3.filter(ImageFilter.RankFilter(3, 2))

    elif x >=5900:
        im4=img.filter(ImageFilter.BoxBlur(radius=6.5))
        im3 = im4.filter(ImageFilter.UnsharpMask(radius=15 ,percent=650))
        im2=im3.filter(ImageFilter.RankFilter(3, 1))

    else:
        im4=img.filter(ImageFilter.BoxBlur(radius=1.5))
        im3 = im4.filter(ImageFilter.UnsharpMask(radius=6, percent=350))
        im2=im3.filter(ImageFilter.RankFilter(3, 3))

pix=im2.load()

for i in range(img.size[0]):
    for j in range(img.size[1]):
        (r,g,b) = pix[i,j]
        if (0,0,0) <= (r,g,b) <=(70,70,70):
            pix[i,j] = (50,50,100)
        if (90,90,90) <= (r,g,b) <=(255,255,255):
            pix[i,j] = (255,255,255)
ope = np.array(im2)
gray = cv2.cvtColor(ope, cv2.COLOR_BGR2GRAY)
_, binary = cv2.threshold(gray, 225, 255, cv2.THRESH_BINARY_INV)
pil_image = Image.fromarray(binary)
pix=pil_image.load()
for i in range(img.size[0]):
    for j in range(img.size[1]):
        b = pix[i,j]
        if 0 <= b <=5:
            pil_image.putpixel((i, j), 0)
        else:
            pil_image.putpixel((i, j), 255)
im3 = pil_image.filter(ImageFilter.UnsharpMask(radius=3, percent=250))

im3.save("C:/Users/Asus/Downloads/MODELO/roda/preto"+str(n)+"a"+" .jpg")
n+=1

```

Figura 13- Código responsável pela transformação binária

4.2.3 Sujidade artificial

O próximo passo lógico no processo foi abordar a necessidade de maior diversidade nos tipos de sujidade presentes na base de dados. Neste ponto, o desafio não era a quantidade de imagens de painéis solares sujos, mas sim a diversidade dos tipos de sujidade.

Para alcançar essa diversidade, foi desenvolvido um método para criar sujidade artificial que se assemelhasse real. Este método envolveu a criação de uma máscara que representava o padrão de sujidade desejado, seguido pela fusão dessa máscara com uma imagem aleatoriamente selecionada de um painel solar limpo.

Esta abordagem visava simular eficazmente a sujidade do mundo real, imitando como a sujidade pode acumular-se em painéis solares em vários padrões e densidades. O uso de máscaras permitia um controlo preciso sobre a aparência da sujidade, permitindo criar uma ampla gama de tipos de sujidade. Este processo não apenas aumentou a diversidade dentro da base de dados, mas também expandiu a própria, gerando novas imagens que combinavam imagens reais de painéis com sujidade sintética.

Ao introduzir esta metodologia, a base de dados tornou-se mais robusta e inclusiva de diferentes tipos de sujidade, garantindo que o modelo treinado estaria melhor preparado para reconhecer e lidar com a ampla variedade de padrões e condições de sujidade que poderia encontrar na prática. Essa abordagem melhorou significativamente a capacidade do modelo em cenários do mundo real.

4.2.4 Curva de Bézier

Para a criação das máscaras desejadas, foram empregadas curvas de Bézier para gerar formas aleatórias com um certo nível de controlo. Nomeadas em homenagem ao engenheiro francês Pierre Bézier, as curvas Bézier desempenham um papel crucial na criação de formas suaves e precisas. Essas curvas são definidas por um conjunto de pontos de controlo que determinam a forma e o comportamento da curva. Comumente, as curvas Bézier existem em variações de dois, três e quatro pontos de controlo.

No entanto, neste projeto, para ter mais controlo sobre as variáveis e criar *loops* fechados, foram utilizadas curvas Bézier periódicas, também conhecidas como curvas cíclicas. A característica definidora das curvas Bézier periódicas é a inclusão de um ponto de controlo

adicional conhecido como ponto de controle de encerramento. Este ponto de controle é colocado estrategicamente para garantir uma transição suave entre o final e o início da curva, formando um *loop* contínuo. Essas curvas funcionam de maneira semelhante às curvas polinomiais, permitindo especificar o número desejado de pontos de controle.

É importante ressaltar que, à medida que a ordem da curva aumenta, a complexidade e a dificuldade de controle também aumentam. Portanto, é importante considerar cuidadosamente o número de pontos de controle. Além disso, um parâmetro de suavidade foi introduzido para governar a suavidade, variando de 0 a 1, sendo 0 o valor que resulta na curva mais suave. Neste projeto, foram geradas formas com apenas cinco pontos de controle e uma suavidade de 0.

Com a formulação matemática incorporada explicitamente no código, a biblioteca Matplotlib foi utilizada para criar as figuras gráficas desejadas. É importante destacar que, sem ajustes, o Matplotlib exportaria figuras com ambos os eixos x e y visíveis, portanto, medidas foram tomadas para ocultá-los.

A utilização das curvas Bézier permitiu a geração de padrões de sujeira diversos e intrincados, imitando condições de sujeira do mundo real, ao mesmo tempo que proporcionava controle preciso e repetibilidade na aparência da sujeira. Isso contribuiu significativamente para a diversidade de dados na base de dados. Exemplos de formas com e sem eixos podem ser observados nas figuras abaixo.




Figura 14- Forma criada dentro de eixos com a biblioteca Matplotlib




Figura 15- Forma criada sem eixos com a biblioteca Matplotlib

Noto que para uma maior compreensão da formulação matemática sobre as curvas de Bézier periódicas deve-se consultar o trabalho de (Ramanantoanina & Hormann, 2023).

Código em Python

Na figura abaixo pode-se observar o código desta secção.

```
bernstein = Lambda n, k, t: binom(n,k)* t**k * (1.-t)**(n-k)

def bezier(points, num=200):
    N = len(points)
    t = np.linspace(0, 1, num=num)
    curve = np.zeros((num, 2))
    for i in range(N):
        curve += np.outer(bernstein(N - 1, i, t), points[i])
    return curve

class Segment():
    def __init__(self, p1, p2, angle1, angle2, **kw):
        self.p1 = p1; self.p2 = p2
        self.angle1 = angle1; self.angle2 = angle2
        self.numpoints = kw.get("numpoints", 100)
        r = kw.get("r", 0.3)
        d = np.sqrt(np.sum((self.p2-self.p1)**2))
        self.r = r*d
        self.p = np.zeros((4,2))
        self.p[0,:] = self.p1[:]
        self.p[3,:] = self.p2[:]
        self.calc_intermediate_points(self.r)

    def calc_intermediate_points(self,r):
        self.p[1,:] = self.p1 + np.array([self.r*np.cos(self.angle1),
                                          self.r*np.sin(self.angle1)])
        self.p[2,:] = self.p2 + np.array([self.r*np.cos(self.angle2+np.pi),
                                          self.r*np.sin(self.angle2+np.pi)])
        self.curve = bezier(self.p,self.numpoints)

def get_curve(points, **kw):
    segments = []
    for i in range(len(points)-1):
        seg = Segment(points[i,:2], points[i+1,:2], points[i,2],points[i+1,2],**kw)
        segments.append(seg)
    curve = np.concatenate([s.curve for s in segments])
    return segments, curve

def ccw_sort(p):
    d = p-np.mean(p,axis=0)
    s = np.arctan2(d[:,0], d[:,1])
    return p[np.argsort(s),:]

def get_bezier_curve(a, rad=0.2, edgy=0):
    """ given an array of points *a*, create a curve through
    those points.
    *rad* is a number between 0 and 1 to steer the distance of
    control points.
    *edgy* is a parameter which controls how "edgy" the curve is,
    edgy=0 is smoothest."""
    p = np.arctan(edgy)/np.pi+.5
    a = ccw_sort(a)
    a = np.append(a, np.atleast_2d(a[0,:]), axis=0)
    d = np.diff(a, axis=0)
    ang = np.arctan2(d[:,1],d[:,0])
    f = Lambda ang : (ang>=0)*ang + (ang<0)*(ang+2*np.pi)
    ang = f(ang)
    ang1 = ang
    ang2 = np.roll(ang,1)
    ang = p*ang1 + (1-p)*ang2 + (np.abs(ang2-ang1) > np.pi )*np.pi
    ang = np.append(ang, [ang[0]])
    a = np.append(a, np.atleast_2d(ang).T, axis=1)
    s, c = get_curve(a, r=rad, method="var")
    x,y = c.T
    return x,y, a
```

```

def get_random_points(n=5, scale=0.8, mindst=None, rec=0):
    """ create n random points in the unit square, which are *mindst*
    apart, then scale them."""
    mindst = mindst or .7/n
    a = np.random.rand(n,2)
    d = np.sqrt(np.sum(np.diff(ccw_sort(a), axis=0), axis=1)**2)
    if np.all(d >= mindst) or rec>=200:
        return a*scale
    else:
        return get_random_points(n=n, scale=scale, mindst=mindst, rec=rec+1)

n=0

for i in range(10):
    fig=plt.figure(frameon=False)
    fig.set_size_inches(4,4)
    ax = plt.Axes(fig, [0, 0, 1, 1])
    ax.set_axis_off()
    fig.add_axes(ax)
    a = get_random_points()
    x,y, _ = get_bezier_curve(a)
    plt.plot(x,y)
    plt.savefig('C:/Users/andre/Downloads/roda2/roda2/pintas/foo'+str(n)+"a"+" .jpg")
    n+=1

```

Figura 16- Código responsável pela criação das formas através da curva de Bézier

4.2.5 Preenchimento das formas criadas

Para tornar as formas criadas mais realistas, um passo crucial foi o seu preenchimento, uma vez que, os padrões de sujidade estudados consistiam principalmente em formas arredondadas e preenchidas. Para realizar isso, foi empregada a função predefinida 'floodFill' da biblioteca OpenCV.

A função 'floodFill' é uma ferramenta poderosa para preencher uma área contínua numa imagem com uma cor específica. Ela inicia o processo de preenchimento a partir de um ponto de partida e depois se propaga para preencher píxeis vizinhos que se assemelham à cor de partida.

Noto que, para os propósitos deste projeto, não foi apenas usada a função 'floodFill' para preencher diferentes padrões de sujidade, mas também existiu a criação de três tamanhos diferentes de sujidade (0,04, 0,05, 0,06). Esses parâmetros de tamanho são relativos às dimensões da imagem original e foram determinados por meio de técnicas de observação para imitar de perto os padrões de sujidade do mundo real.

Essa abordagem permitiu a geração de padrões de sujidade preenchidos e realistas que se assemelhavam de perto ao que poderia ser encontrado na prática. A capacidade de criar

padrões de sujidade em diferentes tamanhos acrescentou uma camada adicional de complexidade e diversidade à base de dados, o que se mostrou inestimável para treinar um modelo a reconhecer e lidar eficazmente com diferentes tipos de padrões. Na figura 17 pode-se observar um exemplo.



Figura 17- Sujidade preenchida

Código em Python

Na figura abaixo pode-se observar o código desta secção.

```
n=0
l=[0.04,0.05,0.06]
images = Path("C:/Users/andre/Downloads/roda2/roda2/pintas").glob("*.JPG")
image_strings = [str(p) for p in images]
for images in image_strings:
    img = Image.open(images)
    imge = cv2.imread(images)

    th, im_th = cv2.threshold(imge, 200, 255, cv2.THRESH_BINARY_INV)
    im_floodfill = im_th.copy()
    h, w = im_th.shape[:2]
    mask = np.zeros((h+2, w+2), np.uint8)
    cv2.floodFill(im_floodfill, mask, (0,0), (255,255,255))

    ope = np.array(img)
    gray = cv2.cvtColor(ope, cv2.COLOR_BGR2GRAY)
    _, binary = cv2.threshold(im_floodfill, 225, 255, cv2.THRESH_BINARY_INV)
    pil_image = Image.fromarray(im_floodfill)

    pix=pil_image.load()
    for i in range(img.size[0]):
        for j in range(img.size[1]):
            r,g,b = pix[i,j]
            if (0,0,0) <= (r,g,b) <=(0,0,0):
                pil_image.putpixel((i, j), (0,0,0))
            else:
                pil_image.putpixel((i, j), (255,255,255))
    for tamanho in l:
        hl=round(h*tamanho)
        wl=round(w*tamanho)
        im3=pil_image.resize((wl,hl), Image.Resampling.LANCZOS)
        im3.save("C:/Users/andre/Downloads/roda2/roda2/pintas/"+str(n)+".jpg")
        n+=1
```

Figura 18- Código responsável pelo preenchimento e alteração do tamanho das formas.

4.2.6 Criação da Mesh

Com todas as formas necessárias criadas, o próximo passo foi combinar essas formas para gerar máscaras que poderiam ser aplicadas às imagens de painéis solares limpos disponíveis. Para manter a aleatoriedade e garantir que a base de dados não consistisse apenas em painéis com a mesma quantidade de sujidade, a abordagem adotada foi criar um número igual de máscaras para 1 a 7 manchas de sujidade.

Essa abordagem permitiu um alto grau de flexibilidade e variabilidade no processo de geração da base de dados. O programa divide automaticamente o número desejado de máscaras pelas sete categorias de sujidade. Isso significa que o programa pode criar uma ampla variedade de combinações de sujidade, garantindo aleatoriedade e possibilitando a criação de uma base de dados do tamanho desejado.

A figura a seguir fornece um exemplo de uma máscara com 1 mancha de sujidade e outra com 7 manchas de sujidade:



Figura 19- Nível 1 de sujidade



Figura 20- Nível 7 de sujidade

Essa metodologia facilita gerar bases de dados diversas e dinâmicas inestimáveis para treinar modelos de *machine learning* a reconhecer e lidar com imagens de painéis solares com diferentes padrões de sujidade. O nível de controle que oferece, com sua capacidade de garantir dados aleatórios e variados, desempenha um papel fundamental na construção de modelos robustos.

Código em Python

Na figura abaixo pode-se observar o código desta secção.

```
n=0
l=[]
images = Path("C:/Users/andre/Downloads/roda2/roda2/pintas").glob("*.JPG")
image_strings = [str(p) for p in images]
for images in image_strings:
    l.append(images)
vezes=160000 # número de imagens pretendidas
numero=1 #numero de sujidades a utilizar
divisao=round(vezes/8)
a = 0

for i in range(vezes):
    array = np.full((700, 700, 3), 255, dtype = np.uint8)
    pil_image = Image.fromarray(array)
    if a>=divisao:
        numero+=1
        a=0
    for i in range(numero):
        rand=random.choice(l)
        img = Image.open(rand)
        imge = cv2.imread(rand)
        h, w = imge.shape[:2]
        x = random.randint(0, 700-10)
        y = random.randint(0, 700-10)
        pil_image.paste(img, (x, y, x+w, y+h))

    im3 = pil_image.filter(ImageFilter.UnsharpMask(radius=3, percent=250))
    im3.save("C:/Users/andre/Downloads/roda2/roda2/Mesh/Mesh"+str(n)+".jpg")
    n+=1
    a+=1
```

Figura 21- Código responsável pela criação das máscaras utilizadas

4.2.7 Criação da base de dados final

Finalmente, após a criação das máscaras, o último passo é aplicar essas máscaras às imagens de painéis solares limpos disponíveis. Para fazer isso, foi utilizado um código simples para sobrepor as máscaras às imagens processadas, que são as imagens geradas por meio de recorte, rotação e transformação binária. As figuras a seguir ilustram a semelhança entre uma foto originalmente suja e uma criada artificialmente:




Figura 22- Imagem de um painel real.




Figura 23- Imagem de um painel criado artificialmente.

Como é possível observar, as imagens criadas ao usar esta abordagem de facto parecem idênticas a painéis sujos reais, demonstrando o sucesso do processo na criação de padrões de sujidade realistas. Este método permite gerar uma abundância de combinações, garantindo uma base de dados do tamanho desejado.

É crucial notar que, embora este processo forneça automação e escalabilidade, um grau de supervisão humana ainda é essencial. A intervenção humana é necessária para evitar a aplicação de máscaras em painéis já sujos e para garantir que as máscaras criadas não produzam sobreposições dos padrões de sujidade. Embora a probabilidade desses problemas ocorrerem seja relativamente baixa, eles ainda são possíveis, e abordá-los é uma área potencial para futuras melhorias no programa.

Essa combinação da criação automatizada e controle de qualidade humano é uma abordagem prudente para gerar bases de dados para *machine learning*, encontrando um equilíbrio entre eficiência e precisão. É um testemunho da natureza iterativa e adaptativa de projetos de ciência de dados, onde o refinamento e a melhoria contínuos são essenciais.

Código em Python

Na figura abaixo pode-se observar o código desta secção.

```
n=0
l=[]
images = Path("C:/Users/Asus/Downloads/MODELO/roda/Rod_Cort").glob("*.PNG")
image_strings = [str(p) for p in images]

data = Path("C:/Users/Asus/Downloads/MODELO/roda/Data_Set/Mesh").glob("*.JPG")
data_strings = [str(p) for p in data]
for data in data_strings:
    l.append(data)

for i in range(11):
    for images in image_strings:
        imge = cv2.imread(images)
        img = Image.open(images)
        h, w = imge.shape[:2]
        dset = cv2.imread(random.choice(l))
        pil = Image.fromarray(dset)
        im3=pil.resize((w,h), Image.Resampling.LANCZOS)
        ope = np.array(im3)
        result1 = cv2.bitwise_and(imge, ope)
        pil_image = Image.fromarray(result1)
        im4=pil_image.filter(ImageFilter.BoxBlur(radius=1.5))
        im3 = im4.filter(ImageFilter.UnsharpMask(radius=3, percent=550))
        ope = np.array(im3)
        gray = cv2.cvtColor(ope, cv2.COLOR_BGR2GRAY)
        _, binary = cv2.threshold(gray, 225, 255, cv2.THRESH_BINARY)
        pil_image = Image.fromarray(binary)
        pix=pil_image.load()
        for i in range(img.size[0]):
            for j in range(img.size[1]):
                b = pix[i,j]
                if 0 <= b <=5:
                    pil_image.putpixel((i, j), 0)
                else:
                    pil_image.putpixel((i, j), 255)
        im4 = pil_image.filter(ImageFilter.UnsharpMask(radius=3, percent=250))
        im4.save("C:/Users/Asus/Downloads/MODELO/roda/Data_Set/juntar/juntas"+str(n)+".png")
        n+=1
```

Figura 24- Código utilizado na criação de painéis solares sujos artificiais.

5. ALGORITMO UTILIZADO

Com a base de dados preparada, o próximo passo envolve o desenvolvimento de um algoritmo eficaz para identificar sujidade em painéis solares. Vários passos essenciais estão envolvidos neste processo de desenvolvimento. Esses passos incluem:

1. Divisão de Dados
2. Escolha da Biblioteca
3. Treino do Modelo
4. Análise dos Resultados e Ajustes
5. Novo Treino

Esses passos formam coletivamente a base do desenvolvimento de qualquer algoritmo eficaz. A natureza iterativa desse processo, envolvendo ajustes e novos treinos, garante que o modelo evolua e se torne cada vez mais preciso no seu reconhecimento de padrões de sujidade.

5.1 Divisão dos dados

Para criar um algoritmo de *machine learning*, é essencial dividir a base de dados nas classes que desejamos estudar, neste caso, painéis sujos e painéis limpos. Embora existam várias maneiras de obter esses dados automaticamente, como mencionado no capítulo anterior, todas as imagens foram criadas localmente. Portanto, a seleção manual e a separação de todas as imagens são imperativas.

No caso de imagens geradas manualmente, é necessário realizar a tarefa de rotular cada imagem como "limpa" ou "suja". Esse processo de rotulagem garante que a base de dados seja categorizada corretamente, permitindo que o algoritmo aprenda a distinção correta.

Uma vez que os dados estão rotulados, é possível prosseguir com as etapas seguintes conforme previamente delineado.

5.2 Escolha da Biblioteca

Com a divisão de dados feita, o próximo passo envolveu escolher a biblioteca a ser utilizada. Para este projeto, várias bibliotecas foram consideradas, como PyTorch, Scikit-learn, Keras e TensorFlow. Após uma análise cuidadosa, a decisão de trabalhar com uma combinação de TensorFlow e Keras foi tomada. Essa escolha baseou-se em vários fatores, incluindo a facilidade de uso e a integração com os servidores do Google. O último ponto foi particularmente importante, pois a empresa demonstrou a sua disposição em apoiar o projeto e fornecer acesso a estes, dependendo dos resultados obtidos nas fases iniciais.

O TensorFlow é uma plataforma poderosa de *machine learning* com ferramentas convenientes para desenvolver e testar arquiteturas. Ele fornece uma API para várias linguagens de programação, incluindo Python, Java e C#. Uma das principais vantagens desta biblioteca é a sua estrutura em camadas, onde uma API de baixo nível interage com *hardware*, como CPU, GPU e TPU, como demonstrado na Figura 25.



Figura 25- Estrutura do Tensorflow

A API de baixo nível permite que os operadores do TensorFlow sejam executados em recursos de GPU e TPU, acelerando assim o treino e utilização dos modelos. Outra vantagem é a capacidade de dimensionar o trabalho em diferentes dispositivos, como várias GPUs simultaneamente.

Por outro lado, o Keras é uma biblioteca conhecida por enfatizar a usabilidade e a experiência do desenvolvedor. Oferece uma interface intuitiva para definir e treinar redes neurais, tornando assim todo o processo da criação dos modelos mais ágil e direta. Como pelo seu desenvolvedor “It was developed with a focus on enabling fast experimentation. Being able to go from idea to result as fast as possible is key to doing good research.”(<https://keras.io/about/>, n.d.)

A combinação de TensorFlow e Keras fornece uma estrutura robusta e amigável para o desenvolvimento de modelos de *machine learning* e, neste contexto, para identificar eficientemente sujidade em painéis solares.

5.3 Treino do modelo

A próxima fase envolve a integridade do projeto, mais especificamente, o treino do modelo desenvolvido. É importante notar que, para uma compreensão mais abrangente deste subcapítulo, deve ser lido em conjunto o Anexo A, onde o código do modelo é fornecido.

Em primeiro lugar, os dados precisam ser importados e divididos adequadamente em conjuntos de treino, validação e teste. Essa divisão estratégica aloca 70% dos dados para treino, 20% para validação e 10% para teste. Conforme delineado por (Tao et al., 2020), é crucial adaptar essa divisão à natureza dos dados, e é aconselhável experimentar diferentes percentagens para determinar a distribuição ideal.

Posteriormente, devido às capacidades computacionais do computador fornecido, foi realizada uma operação de redimensionamento para reduzir todas as imagens para um formato de 600x600 píxeis.

Avançando para a arquitetura específica do modelo, uma Rede Neural Convolutiva (CNN) é construída sequencialmente, incorporando seis camadas, cada uma com um papel distinto no processo de aprendizagem das características e da sua classificação. É essencial reconhecer que, embora a maioria dessas camadas empregue a função de ativação 'relu', um método amplamente utilizado e eficaz até o momento, este apresenta graves problemas quanto à fiabilidade dos seus resultados e, referindo (Parisi et al., n.d.), está em desenvolvimento uma alternativa que seria posteriormente adaptada a este projeto.

A camada inicial, uma camada de convolução (Conv2D), emprega filtros 3x3 para analisar as imagens de entrada. Com 16 filtros nesta camada, ela aprende as características iniciais da imagem, e a função de ativação 'relu' introduz não linearidade nas ativações.

Em seguida, é aplicada uma camada de Max-Pooling 2D para reduzir a dimensionalidade da saída da camada de convolução. Esta camada opera em janelas pequenas, mantendo os valores máximos, preservando assim as características mais salientes.

O fluxo arquitetónico continua com outra camada de convolução, desta vez incorporando 32 filtros, o que aprofunda ainda mais o aprendizado de características complexas nas imagens. Mais uma vez, é usada uma camada de Max-Pooling 2D para reduzir a dimensão.

Uma terceira camada de convolução com 16 filtros segue, facilitando o processo contínuo de aprendizado de características, e é sucedida por outra camada de Max-Pooling 2D. Essa redução de dimensão é vital para evitar o sobre ajuste.

Após a conclusão da fase de convolução, os mapas de características são convertidos num vetor unidimensional por meio de uma camada de Flattening. Essa etapa prepara os dados para camadas densas subsequentes.

Duas camadas densas são subsequentemente integradas à rede. A camada densa inicial acomoda 256 “neurónios” e utiliza a função de ativação 'relu' para introduzir não linearidade. A segunda camada densa, servindo como camada de saída, consiste em um único “neurónio” e utiliza a função de ativação 'sigmoid'. Esta camada produz uma saída binária, indicando a probabilidade de pertencer a uma classe específica.

Todo o processo envolve várias iterações, *Epochs*, com cada iteração processando todo o conjunto de dados para garantir a inclusão de todos os detalhes relevantes e aprimorar a eficiência do modelo. Também é crucial estabelecer um tamanho de lote, *batch size*, apropriado. O tamanho do lote refere-se ao tamanho do conjunto de dados processado em cada passo da iteração, e o seu valor ideal depende da capacidade computacional do sistema e da natureza do projeto. Para modelos de processamento de imagens, geralmente é preferível um tamanho de lote maior.

Como passo final, a escolha do otimizador desempenha um papel crítico na eficácia e na rapidez com que o modelo aprende a partir dos dados. O otimizador escolhido, "adam", é um dos otimizadores mais amplamente utilizados e reconhecido. Combina características do algoritmo de otimização do gradiente estocástico (SGD) com técnicas adicionais para melhorar a convergência e a eficácia do treino.

Após o treino, resta apenas salvar o modelo para uma utilização posterior.

É digno de nota que, embora um número fixo de 100 *epochs* tenha sido utilizado, o tamanho do lote flutuou devido ao uso de diferentes computadores com processadores e placas gráficas variadas. Além disso, a fase de treino ocorre na GPU, enquanto as fases de validação e teste ocorrem na CPU. Essa divisão de tarefas simplifica o processo e protege o sistema contra o sobreaquecimento dos componentes. Na figura seguinte é possível observar-se um exemplo de um treino em execução.

```

Epoch 46/65
4850/4850 [=====] - 1325s 273ms/step - loss: 1.0595e-12 - accuracy: 1.0000 - val_loss: 0.0731 - val_accuracy: 0.9960
Epoch 47/65
4850/4850 [=====] - 1329s 274ms/step - loss: 1.0966e-12 - accuracy: 1.0000 - val_loss: 0.0723 - val_accuracy: 0.9960
Epoch 48/65
4850/4850 [=====] - 1330s 274ms/step - loss: 1.0544e-12 - accuracy: 1.0000 - val_loss: 0.0683 - val_accuracy: 0.9963
Epoch 49/65
4850/4850 [=====] - 1327s 274ms/step - loss: 7.3325e-13 - accuracy: 1.0000 - val_loss: 0.0711 - val_accuracy: 0.9961
Epoch 50/65
4850/4850 [=====] - 1328s 274ms/step - loss: 7.7046e-13 - accuracy: 1.0000 - val_loss: 0.0731 - val_accuracy: 0.9960
Epoch 51/65
4850/4850 [=====] - 1329s 274ms/step - loss: 8.9505e-13 - accuracy: 1.0000 - val_loss: 0.0745 - val_accuracy: 0.9959
Epoch 52/65
4850/4850 [=====] - 1328s 274ms/step - loss: 1.0619e-12 - accuracy: 1.0000 - val_loss: 0.0756 - val_accuracy: 0.9959
Epoch 53/65
4850/4850 [=====] - 1328s 274ms/step - loss: 9.2044e-13 - accuracy: 1.0000 - val_loss: 0.0735 - val_accuracy: 0.9960
Epoch 54/65
4850/4850 [=====] - 1326s 273ms/step - loss: 8.2086e-13 - accuracy: 1.0000 - val_loss: 0.0744 - val_accuracy: 0.9960
Epoch 55/65
4850/4850 [=====] - 1326s 273ms/step - loss: 2.8607e-09 - accuracy: 1.0000 - val_loss: 0.0348 - val_accuracy: 0.9976
Epoch 56/65
4850/4850 [=====] - 1327s 274ms/step - loss: 0.0027 - accuracy: 0.9998 - val_loss: 0.0367 - val_accuracy: 0.9954
Epoch 57/65
4850/4850 [=====] - 1324s 273ms/step - loss: 0.0022 - accuracy: 0.9997 - val_loss: 0.0265 - val_accuracy: 0.9954
Epoch 58/65
4850/4850 [=====] - 1326s 273ms/step - loss: 0.0011 - accuracy: 0.9998 - val_loss: 0.0295 - val_accuracy: 0.9965
Epoch 59/65
4850/4850 [=====] - 1325s 273ms/step - loss: 0.0017 - accuracy: 0.9998 - val_loss: 0.0290 - val_accuracy: 0.9968
Epoch 60/65
4850/4850 [=====] - 1328s 274ms/step - loss: 0.0017 - accuracy: 0.9998 - val_loss: 0.0570 - val_accuracy: 0.9932
Epoch 61/65
4850/4850 [=====] - 1315s 271ms/step - loss: 3.6749e-04 - accuracy: 0.9999 - val_loss: 0.0377 - val_accuracy: 0.9963
Epoch 62/65
4850/4850 [=====] - 1329s 274ms/step - loss: 0.0015 - accuracy: 0.9998 - val_loss: 0.0546 - val_accuracy: 0.9959
Epoch 63/65
4850/4850 [=====] - 1324s 273ms/step - loss: 4.3233e-08 - accuracy: 1.0000 - val_loss: 0.0578 - val_accuracy: 0.9958
Epoch 64/65
4850/4850 [=====] - 1328s 274ms/step - loss: 8.6781e-09 - accuracy: 1.0000 - val_loss: 0.0691 - val_accuracy: 0.9956
Epoch 65/65
4850/4850 [=====] - 1327s 273ms/step - loss: 1.2284e-09 - accuracy: 1.0000 - val_loss: 0.0775 - val_accuracy: 0.9955

```

Figura 26- Treino do modelo em fase inicial com apenas 65 epochs.

5.4 Análise dos Resultados e Ajustes

Após o treino do modelo, o próximo passo é testar os resultados. Ao longo deste projeto, um total de 12 modelos foram desenvolvidos, dos quais foram tiradas duas conclusões já a partir dos modelos iniciais. A primeira conclusão foi que, quando o modelo está a convergir, consistentemente alcança um valor de alta precisão, conforme ilustrado na Figura 26, mesmo quando, na realidade, a precisão pode ser tão baixa quanto 10%. A outra conclusão foi que o resultado é apresentado como um valor numérico em vez do nome da classe atribuída. Este valor numérico varia de 1 a 0, sendo um valor mais próximo de 1 indicativo de uma maior probabilidade de a imagem representar um painel sujo.

A análise foi estabelecida e padronizada para todos os testes realizados. Isso envolveu a avaliação dos resultados obtidos a partir de um conjunto de 50 imagens pré-selecionadas, em colaboração com a empresa.

Conforme mencionado anteriormente, um total de 12 modelos foram produzidos durante o projeto, permitindo os ajustes necessários e subsequente treino do modelo após cada teste. Ao longo dessas iterações do modelo, as mudanças mais significativas foram observadas no conjunto de dados em si. Quando o projeto teve início, o conjunto de dados consistia apenas de 20 imagens obtidas da *internet* para testes de viabilidade para a empresa. No entanto, no

último teste realizado, o conjunto de dados expandiu-se para incluir 500.000 imagens de painéis solares reais de um parque solar fornecido e painéis artificiais, como explicado anteriormente.

É fundamental notar que, mesmo no último teste, o modelo ainda não tinha atingido os parâmetros estabelecidos pela empresa, especificamente, uma precisão superior a 95%. No entanto, isso representou o teste final devido a limitações de equipamento e financiamento.

6. CONCLUSÕES FINAIS E TRABALHOS FUTUROS

Este estudo foi realizado com o objetivo de desenvolver um modelo avançado para a detecção de sujidade em painéis solares, aproveitando as técnicas de deep learning e metodologias de processamento de imagens. A importância desta pesquisa reside nas suas implicações diretas para o campo da energia solar, onde o acúmulo de sujidade e detritos nos painéis pode comprometer severamente a sua eficiência e desempenho. Sendo assim, a criação de um modelo seguro para a detecção não é apenas uma tarefa técnica, mas também um passo decisivo na promoção da eficiência e sustentabilidade dos sistemas de energia solar.

Ao longo deste projeto, vários procedimentos e considerações cruciais foram meticulosamente abordados. Uma das tarefas primárias e fundamentais envolveu a construção de uma base de dados completa e diversificada. Essa base abrangeu uma ampla variedade de imagens que representam painéis solares com sujidade gerada, ou não, artificialmente. Essa seleção foi intencional e essencial para o desenvolver do projeto, uma vez que permitiu o treino de modelos capazes de reconhecer uma maior gama de padrões de sujidade, simulando cenários do mundo real.

Conforme o trabalho realizado para o treino do modelo, tornou-se evidente que a precisão alcançada durante a fase de treino não se traduzia perfeitamente para situações práticas no campo. Essa observação ressaltou a complexidade do problema e revelou os desafios inerentes em garantir a robustez do modelo em ambientes diversos e dinâmicos. Em particular, o desempenho do otimizador "Adam" apresentou algum grau de variabilidade, exigindo uma investigação mais aprofundada para otimizar a escolha dos hiperparâmetros e da arquitetura do modelo.

Como foi referido no capítulo anterior, o projeto teve que ser dado por terminado, por falta de financiamento, sem que o objetivo tivesse sido alcançado, tornando assim impossível aplicar num caso real.

Ao considerar as direções futuras do trabalho, reconhece-se a necessidade de expansão e aprimoramento contínuos. A expansão da base de dados para abranger um espectro mais amplo de condições, locais geográficos e diversos tipos de painéis solares é um passo crucial para aprimorar a adaptabilidade e eficácia do modelo. Além disso, como trabalho futuro, seria necessário considerar a otimização da taxa de aprendizagem (learning rate). A informação

pretendida deve ser estudada em mais detalhe, e acredita-se que a escolha do valor do learning rate não tenha sido totalmente explorada neste trabalho. A investigação aprofundada desse parâmetro pode contribuir significativamente para a otimização do treino do modelo e sua capacidade de detecção.

BIBLIOGRAFIA

- Amaral Jorge, P. (2020). *Evolução do Solar PV em Portugal: Mitos e factos*.
- Baskaran, T. S. H., & Balachander, B. (2019). Real time object detection system. *International Journal of Engineering and Advanced Technology*, 8(6), 59–62. <https://doi.org/10.35940/ijeat.E7440.088619>
- Couturier, A., & Akhloufi, M. A. (2021). A review on absolute visual localization for UAV. In *Robotics and Autonomous Systems* (Vol. 135). Elsevier B.V. <https://doi.org/10.1016/j.robot.2020.103666>
- Ghosh, A. (2020). Soiling Losses: A Barrier for India's Energy Security Dependency from Photovoltaic Power. *Challenges*, 11(1), 9. <https://doi.org/10.3390/challe11010009>
- Hannan, M. A., Lipu, M. S. H., Ker, P. J., Begum, R. A., Agelidis, V. G., & Blaabjerg, F. (2019). Power electronics contribution to renewable energy conversion addressing emission reduction: Applications, issues, and recommendations. In *Applied Energy* (Vol. 251). Elsevier Ltd. <https://doi.org/10.1016/j.apenergy.2019.113404>
- <https://keras.io/about/>. (n.d.). *Keras*.
- Indeed Editorial Team. (2021). *What Is Research Methodology?* <https://www.indeed.com/career-advice/career-development/research-methodology>.
- Institute of Electrical and Electronics Engineers, IEEE Photovoltaic Specialist Conference 42 2015.06.14-19 Tampa, Fla., IEEE Photovoltaic Specialists Conference 42 2015.06.14-19 Tampa, Fla., & PVSC 42 2015.06.14-19 Tampa, Fla. (n.d.). *2015 IEEE 42nd Photovoltaic Specialist Conference (PVSC) 14-19 June 2015, New Orleans, LA*.
- Jiang, H., Lu, L., & Sun, K. (2011). Experimental investigation of the impact of airborne dust deposition on the performance of solar photovoltaic (PV) modules. *Atmospheric Environment*, 45(25), 4299–4304. <https://doi.org/10.1016/j.atmosenv.2011.04.084>
- Mesloub, A., Ghosh, A., Touahmia, M., Albaqawy, G. A., Noaime, E., & Alsolami, B. M. (2020). Performance analysis of photovoltaic integrated shading devices (Pvsds) and semi-transparent photovoltaic (stp) devices retrofitted to a prototype office building in a hot desert climate. *Sustainability (Switzerland)*, 12(23), 1–18. <https://doi.org/10.3390/su122310145>

- Methodology, B. R. (n.d.). *Action Research*. https://Research-Methodology.Net/Research-Methods/Action-Research/#_ftn1.
- Milidonis, K., Eliades, A., Grigoriev, V., & Blanco, M. J. (2023). Unmanned Aerial Vehicles (UAVs) in the planning, operation and maintenance of concentrating solar thermal systems: A review. In *Solar Energy* (Vol. 254, pp. 182–194). Elsevier Ltd. <https://doi.org/10.1016/j.solener.2023.03.005>
- O'Brien, R. (2001). *Um exame da abordagem metodológica da pesquisa ação [An Overview of the Methodological Approach of Action Research]*. www.web.ca/~robrien/papers/arfinal.html
<http://www.web.ca/~robrien/papers/arfinal.html>
- Parisi, L., Neagu, D., Ma, R., Campean, F., Parisi, L., Neagu, D., Ma, R., Campean -Qrelu And, F., & Keras, M.-Q. (n.d.). *QReLU and m-QReLU: Two novel quantum activation functions to aid medical diagnostics*.
- R. Herschel, G. Briese, & V. Nolden. (2018). *Miniaturized radar sensors supporting next generation UAVs*.
- Ramanantoanina, A., & Hormann, K. (2023). Shape control tools for periodic Bézier curves. *Computer Aided Geometric Design*, 103. <https://doi.org/10.1016/j.cagd.2023.102193>
- Ramirez, R. (1986). *Action Based Modes of Inquiry and the Host-Researcher Relationship*. <https://www.researchgate.net/publication/232603154>
- Sayyah, A., Horenstein, M. N., & Mazumder, M. K. (2014). Energy yield loss caused by dust deposition on photovoltaic panels. *Solar Energy*, 107, 576–604. <https://doi.org/10.1016/j.solener.2014.05.030>
- Sharma, A., Vanjani, P., Paliwal, N., Basnayaka, C. M. W., Jayakody, D. N. K., Wang, H. C., & Muthuchidambaranathan, P. (2020). Communication and networking technologies for UAVs: A survey. In *Journal of Network and Computer Applications* (Vol. 168). Academic Press. <https://doi.org/10.1016/j.jnca.2020.102739>
- Solar panels, IEA report*. (2022). <https://www.iea.org/reports/solar-pv>
- Tao, H., Al-Sulttani, A. O., Salih Ameen, A. M., Ali, Z. H., Al-Ansari, N., Salih, S. Q., & Mostafa, R. R. (2020). Training and Testing Data Division Influence on Hybrid Machine Learning Model Process: Application of River Flow Forecasting. *Complexity*, 2020. <https://doi.org/10.1155/2020/8844367>

- Townsend, A., Jiya, I. N., Martinson, C., Bessarabov, D., & Gouws, R. (2020). A comprehensive review of energy sources for unmanned aerial vehicles, their shortfalls and opportunities for improvements. In *Heliyon* (Vol. 6, Issue 11). Elsevier Ltd. <https://doi.org/10.1016/j.heliyon.2020.e05285>
- Yao, W., Han, X., Huang, Y., Zheng, Z., Wang, Y., & Wang, X. (2022). Analysis of the influencing factors of the dust on the surface of photovoltaic panels and its weakening law to solar radiation — A case study of Tianjin. *Energy*, 256. <https://doi.org/10.1016/j.energy.2022.124669>
- Yemelyev, A. K., Moldamurat, K., & Seksenbaeva, R. B. (2021, April 28). Development and Implementation of Automated UAV Flight Algorithms for Inertial Navigation Systems. *SIST 2021 - 2021 IEEE International Conference on Smart Information Systems and Technologies*. <https://doi.org/10.1109/SIST50301.2021.9465965>
- Zhang, B., Song, Z., Zhao, F., & Liu, C. (2022). Overview of Propulsion Systems for Unmanned Aerial Vehicles. *Energies*, 15(2). <https://doi.org/10.3390/en15020455>

ANEXO A

Na figura abaixo pode-se observar o código referente ao treino do modelo.

```
import tensorflow as tf
import os
import cv2
import imghdr
import numpy as np
from matplotlib import pyplot as plt
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Dense, Flatten, Dropout
from tensorflow.keras.metrics import Precision, Recall, BinaryAccuracy
from tensorflow.keras.models import load_model

gpus = tf.config.experimental.list_physical_devices('GPU')
if gpus:
    try:
        # Currently, memory growth needs to be the same across GPUs
        for gpu in gpus:
            tf.config.experimental.set_memory_growth(gpu, True)
        logical_gpus = tf.config.list_logical_devices('GPU')
        print(len(gpus), "Physical GPUs,", len(logical_gpus), "Logical GPUs")
    except RuntimeError as e:
        # Memory growth must be set before GPUs have been initialized
        print(e)

data_dir = './data'
image_exts = ['jpeg', 'jpg', 'bmp', 'png']
data = tf.keras.utils.image_dataset_from_directory('data', image_size=(600,600), color_mode="grayscale")
data_iterator = data.as_numpy_iterator()
batch = data_iterator.next()
data = data.map(Lambda(x,y: (x/255, y)))
data.as_numpy_iterator().next()
train_size = int(len(data)*.7)
val_size = int(len(data)*.2)
test_size = int(len(data)*.1)
train_size
with tf.device("CPU"):
    train = data.take(train_size)
    val = data.skip(train_size).take(val_size)
test = data.skip(train_size+val_size).take(test_size)
train_size
model = Sequential()
model.add(Conv2D(16, (3,3), 1, activation='relu', input_shape=(600,600,1)))
model.add(MaxPooling2D())
model.add(Conv2D(32, (3,3), 1, activation='relu'))
model.add(MaxPooling2D())
model.add(Conv2D(16, (3,3), 1, activation='relu'))
model.add(MaxPooling2D())
model.add(Flatten())
model.add(Dense(256, activation='relu'))
model.add(Dense(1, activation='sigmoid'))
model.compile('adam', loss=tf.losses.BinaryCrossentropy(), metrics=['accuracy'])
logdir='logs'
tensorboard_callback = tf.keras.callbacks.TensorBoard(log_dir=logdir)
for gpu in gpus:
    with tf.device("GPU"):
        hist = model.fit(train, epochs=65, validation_data=val, callbacks=[tensorboard_callback], batch_size=128)
pre = Precision()
re = Recall()
acc = BinaryAccuracy()
for batch in test.as_numpy_iterator():
    X, y = batch
    yhat = model.predict(X)
    pre.update_state(y, yhat)
    re.update_state(y, yhat)
    acc.update_state(y, yhat)
model.save(os.path.join('./models', 'so.h5'))
```

Figura 27- Código relativo ao treino do modelo.