



UNIVERSIDADE ESTADUAL DE CAMPINAS

Faculdade de Engenharia Mecânica

ESTEBAN ANDRES CUÑEZ BENALCAZAR

Deteccção e rastreamento de dunas barcanas usando inteligência artificial

Campinas

2024

ESTEBAN ANDRES CUÑEZ BENALCAZAR

Deteccção e rastreamento de dunas barcanas usando inteligência artificial

Dissertação de Mestrado Acadêmico apresentada à Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Mecânica, na Área de Térmica e Fluidos.

Orientador: Prof. Dr. Erick de Moraes Franklin

ESTE TRABALHO CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO DE MESTRADO ACADÊMICO DEFENDIDA PELO ALUNO ESTEBAN ANDRES CUÑEZ BENALCAZAR, E ORIENTADA PELO PROF. DR. ERICK DE MORAES FRANKLIN.

Campinas

2024

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

C914d Cuñez Benalcazar, Esteban Andres, 1998-
Detecção e rastreamento de dunas barcanas usando inteligência artificial /
Esteban Andres Cuñez Benalcazar. – Campinas, SP : [s.n.], 2024.

Orientador: Erick de Moraes Franklin.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade
de Engenharia Mecânica.

1. Dunas. 2. Inteligência artificial. 3. Aprendizado profundo. 4. Detecção. 5.
Rastreamento (posição). I. Franklin, Erick de Moraes, 1974-. II. Universidade
Estadual de Campinas. Faculdade de Engenharia Mecânica. III. Título.

Informações Complementares

Título em outro idioma: Detection and tracking of barchan dunes using artificial intelligence

Palavras-chave em inglês:

Dunes

Artificial intelligence

Deep learning

Detection

Tracking (Position)

Área de concentração: Térmica e Fluídos

Titulação: Mestre em Engenharia Mecânica

Banca examinadora:

Erick de Moraes Franklin [Orientador]

Arthur Vieira da Silva Oliveira

Renato Fuzaro Miotto

Data de defesa: 05-03-2024

Programa de Pós-Graduação: Engenharia Mecânica

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0002-4335-7777>

- Currículo Lattes do autor: <http://lattes.cnpq.br/4651979693230222>

**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA**

DISSERTAÇÃO DE MESTRADO ACADÊMICO

**Detecção e rastreamento de dunas barcanas usando
inteligência artificial**

Autor: Esteban Andres Cuñez Benalcazar

Orientador: Prof. Dr. Erick de Moraes Franklin

A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação de Mestrado Acadêmico:

Prof. Dr. Erick de Moraes Franklin

Departamento de Energia/Faculdade de Engenharia Mecânica/Universidade Estadual de Campinas

Prof. Dr. Arthur Vieira da Silva Oliveira

Departamento de Engenharia Mecânica/Escola de Engenharia de São Carlos/Universidade de São Paulo

Dr. Renato Fuzaro Miotto

Departamento de Energia/Faculdade de Engenharia Mecânica/Universidade Estadual de Campinas

A Ata de Defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

Campinas, 05 de Março de 2024

DEDICATÓRIA

Dedico esse trabalho aos meus pais Hugo e Rocío por seu imenso carinho, dedicação e apoio ao longo da minha vida.

Ao meu irmão David por confiar em mim e me inspirar a ser melhor.

A Flavia por seu amor e apoio nos momentos mais difíceis.

A minha avó Rosita por sempre me cuidar desde o céu.

AGRADECIMENTOS

Primeiro quero agradecer a Deus, por me proteger e me cuidar ao longo da minha vida.

Aos meus pais Hugo e Rocío, que me ensinaram a conquistar meus sonhos e aproveitar as oportunidades que a vida oferece. Obrigado pelo seu apoio e seu carinho.

Ao meu irmão David, por sempre me incentivar a ser uma melhor pessoa e me mostrar que nada é impossível. Este sucesso é nosso.

A minha companheira Flavia, por seu amor, apoio, ajuda e compreensão durante este processo. Obrigado por estar do meu lado sempre e alegrar minha vida com suas brincadeiras.

Ao meu orientador, Professor Dr. Erick de Moraes Franklin, por me orientar no desenvolvimento desse trabalho, pela confiança depositada em mim e pelo apoio dentro e fora da faculdade.

A Nicole, por sua amizade e apoio ao longo dos anos.

Aos meus colegas do laboratório, pela amizade, apoio, ajuda e momentos vividos ao longo desse trajeto.

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo 2021/11470-4.

Agradezco a mi familia,
por nunca dejarme solo,
por siempre estar conmigo
Dios y ustedes siempre en mí.
Custodia

RESUMO

As dunas barcanas são comumente encontradas na superfície de planetas como a Terra e Marte, desempenhando um papel importante na evolução de paisagens e ecossistemas. Nas últimas décadas, as imagens de sensoriamento remoto têm sido uma ferramenta valiosa para investigar a morfodinâmica das barcanas. Ainda assim, suas interações e transformações complexas os tornam às vezes difícil de detectar. Neste estudo, utilizamos os recursos da Inteligência Artificial (IA) e das redes neurais para desenvolver um modelo preciso e eficiente para a detecção e rastreamento automático de dunas em diferentes ambientes (aquático, terrestre e marciano). Primeiro, coletamos um conjunto de imagens de dunas barcanas aquáticas usando uma bancada experimental com uma seção transversal retangular, e dunas eólicas e marcianas usando os satélites disponíveis nos sites de Google Earth e HiRISE. Posteriormente, com o uso da plataforma CVAT estas imagens foram rotuladas e classificadas usando as classes: *Barchan* para detectar regiões de dunas e *Not a barchan* para formas que não correspondem a uma barcana. Assim, este conjunto de dados foi usado para treinar e avaliar a precisão do nosso modelo, baseado na rede neural convolucional YOLOv8 (You Only Look Once-YOLO) por segmentação, que pode detectar uma imagem que contém dunas com uma precisão estimada (C_s) acima de 70%. Finalmente, calculamos os parâmetros principais das dunas barcanas como: dimensões, formas, e outras propriedades importantes da sua morfologia. A partir desta técnica, o conjunto de dados obtido neste estudo pode ser utilizado para futuros estudos e aplicações relacionadas à detecção de dunas em locais remotos, fornecendo um recurso valioso para pesquisadores. No geral, nossa investigação mostra o potencial da inteligência artificial (IA) e das redes neurais convolucionais (CNN) nas áreas da Física e das Geociências, e como podem ser utilizadas para superar os desafios do estudo de fenômenos naturais complexos na Terra e em outros corpos celestes como Marte. O uso da CNN YOLO destinado para identificar, rastrear e estudar as dunas com precisão pode melhorar nossa compreensão dos processos de superfície importantes para moldar nossa paisagem.

Palavras-chave: Duna barcana, Inteligência artificial, YOLOv8, Detecção, Rastreamento.

ABSTRACT

Barchan dunes are commonly found on the surface of planets such as Earth and Mars, playing an important role in the evolution of landscapes and ecosystems. Over the last few decades, imagery from remote sensing has been a valuable tool for investigating the morphodynamics of barchans. Still, their complex interactions and transformations make them sometimes difficult to detect. In this study, we use the capabilities of Artificial Intelligence (AI) and neural networks to develop an accurate and efficient model for the automatic detection and tracking of barchan in different environments (Aquatic, eolian, and martian). First, we collected a dataset of aquatic barchan dunes using an experimental setup with a rectangular cross-section, and Aeolian and Martian barchan dunes using the satellites available on Google Earth and HiRISE websites. Subsequently, with the use of the CVAT platform, these images were labeled and classified using the classes: *Barchan* to detect dune regions and *Not a barchan* for shapes that do not correspond to a barchan. Thus, this dataset was used to train and evaluate the accuracy of our model, based on the YOLOv8 (You Only Look Once-YOLO) convolutional neural network for segmentation, which can detect barchan dunes with a confidence score (Cs) above 70%. Finally, we calculated the main parameters from the automatic detection of dunes such as dimensions, shapes, and other main morphology properties. From this technique, the dataset obtained in this work can be used for further studies and applications related to dune detection in remote locations, providing a valuable resource for researchers. Overall, our research shows the potential of artificial intelligence and convolutional neural networks (CNN) in the fields of Physics and Geoscience, and how they can be used to overcome the challenges of studying complex natural phenomena on Earth and other celestial bodies. Using a CNN (YOLO) intended to identify, track and study dunes accurately can improve our understanding of surface processes that are important to shape our landscape.

Keywords: Barchan dune, Artificial intelligence, YOLOv8, Detection, Tracking.

LISTA DE ILUSTRAÇÕES

Figura 2.1 – Campos de dunas barcanas presentes em diferentes ecossistemas e experimentos. a) Dunas barcanas na superfície de Marte. Cortesia: NASA/JPL-Caltech/UArizona. b) Dunas barcanas no deserto de Catar. Cortesia: Google Earth c) Dunas barcanas criadas experimentalmente, imagem obtida de (Cunhez; Franklin, 2023c).	27
Figura 2.2 – Duna barcana e suas propriedades. a) Vista lateral de uma duna barcana localizada em Florianópolis, Brasil. b) Propriedades da duna barcana, imagem modificada de (Hersen, 2004)	29
Figura 2.3 – Morfologia da duna barcana adotada nos estudos de (Alvarez; Franklin, 2017; Assis; Franklin, 2020)	29
Figura 2.4 – <i>Snapshots</i> das interações binárias de dunas barcanas. Os experimentos foram desenvolvidos com grãos de vidro usando partículas vermelhas e brancas, e direção do fluxo de água é de esquerda para direita. Os cinco diferentes padrões são: <i>chasing</i> (I), <i>merging</i> (II), <i>exchange</i> (III), <i>fragmentation-chasing</i> (IV) e <i>fragmentation-exchange</i> (V). a) Configuração alinhada. b) Configuração desalinhada. Imagem adaptada de (Assis; Franklin, 2020)	32
Figura 2.5 – Métodos de extração manuais sobre a migração de dunas barcanas em diferentes localizações a) Migração assimétrica de barcanas no deserto de Namibe (13°17054.6300E; 20°2104.8300S), imagem adaptada de (Bourke, 2010). b) Migração de dunas barcanas no Noroeste de China, imagem adaptada de (Zhang <i>et al.</i> , 2018)	34
Figura 2.6 – Detecção automática de dunas em Marte usando as imagens disponíveis de HiRISE, cortesia de NASA/JPL/University of Arizona. a) Detecção de dunas barcanas usando <i>Support Vector machine</i> , imagem adaptada de (Azzaoui <i>et al.</i> , 2016). b) Detecção de dunas barcanas usando a rede neural convolucional (Mask R-CNN), imagem adaptada de (Rubanenko <i>et al.</i> , 2021)	36
Figura 2.7 – Hierarquia da Inteligência Artificial, imagem adaptada de (Rosebrock, 2017)	39
Figura 2.8 – Arquitetura básica das redes neurais convolucionais, imagem adaptada de (Jiang <i>et al.</i> , 2019)	40

Figura 2.9 – Arquitetura básica da rede YOLO, imagem adaptada de (Soylu; Soylu, 2023)	42
Figura 3.1 – Esquema da bancada experimental.	49
Figura 3.2 – Dispositivo experimental localizado na Faculdade de Engenharia Mecânica da Universidade de Campinas. a) Foto composta pelo tanque de água, as duas bombas centrífugas, válvulas, filtro, o medidor de fluxo e o retificador (convergente/divergente). b) Foto da seção de testes, disposição dos grãos, sistema de translação e a câmara na parte superior. c) Foto geral do canal retangular de acrílico conetado ao tanque de decantação.	50
Figura 3.3 – Câmera Convencional Nikon.	52
Figura 3.4 – Sistema de translação.	53
Figura 3.5 – Disposição dos elementos do experimento.	54
Figura 3.6 – Aquisição da base de dados usando o programa <i>HiView</i>	56
Figura 3.7 – Arquitetura e esquema de funcionamento da rede YOLO v8 para detectar dunas barcanas.	57
Figura 3.8 – Rotulado das imagens com CVAT.	58
Figura 3.9 – Esquema para delinear os contornos das barcanas.	61
Figura 3.10 – Parâmetros morfológicos de estudo.	62
Figura 4.1 – Perda vs épocas no caso de dunas subaquáticas	64
Figura 4.2 – Predição média de detecção vs épocas (laboratório)	65
Figura 4.3 – Detecção, classificação, segmentação e rastreamento de um caso <i>Exchange</i> , figura extraída de Cúñez e Franklin (Scientific Reports, under review). . . .	67
Figura 4.4 – Resultados da morfologia do caso <i>Exchange</i> , figura extraída de Cúñez e Franklin (Scientific Reports, under review).	68
Figura 4.5 – Detecção ao longo do tempo da Figura 4.3.	68
Figura 4.6 – Detecção, classificação, segmentação e rastreamento de um caso <i>Chasing</i> , figura extraída de Cúñez e Franklin (Scientific Reports, under review). . . .	69
Figura 4.7 – Resultados da morfologia do caso <i>Chasing</i> , figura extraída de Cúñez e Franklin (Scientific Reports, under review).	70
Figura 4.8 – Detecção ao longo do tempo da Figura 4.6.	71
Figura 4.9 – Detecção, classificação, segmentação e rastreamento de um caso <i>Fragmentation-chasing</i> alinhada, figura extraída de Cúñez e Franklin (Scientific Reports, under review).	72

Figura 4.10–Resultados da morfologia do caso <i>Fragmentation-chasing</i> alinhada, figura extraída de Cúñez e Franklin (Scientific Reports, under review).	73
Figura 4.11–Detecção ao longo do tempo da Figura 4.9.	73
Figura 4.12–Detecção, classificação, segmentação e rastreamento de um caso <i>Fragmentation-chasing</i> desalinhada, figura extraída de Cúñez e Franklin (Scientific Reports, under review).	74
Figura 4.13–Resultados da morfologia do caso <i>Fragmentation-chasing</i> desalinhada, figura extraída de Cúñez e Franklin (Scientific Reports, under review).	75
Figura 4.14–Detecção ao longo do tempo da Figura 4.12.	75
Figura 4.15–Perda vs épocas (Satélite)	77
Figura 4.16–Predição média de detecção vs épocas (Satélite)	77
Figura 4.17–Detecção de dunas na superfície de Marte: 3.190° latitude (centrado) e 339.585° longitude (Leste), altitude da sonda 287,3 km. Cortesia: NASA/JPL-Caltech/UArizona, figura extraída de Cúñez e Franklin (Scientific Reports, under review).	79
Figura 4.18–Detecção de dunas na superfície de Marte: 41.488° latitude (centered), 44.589° longitude (East), <i>spacecraft</i> altitude 253,8 km. Cortesia: NASA/JPL-Caltech/UArizona, figura extraída de Cúñez e Franklin (Scientific Reports, under review).	80

LISTA DE TABELAS

Tabela 2.1 – Comparação entre as redes neurais convolucionais Mask R-CNN e YOLO na detecção de objetos, tabela adaptada de: Yue <i>et al.</i> (2023)	41
Tabela 4.1 – Dados morfológicos extraídos da Figura 4.17, tabela extraída de Cúñez e Franklin (Scientific Reports, under review).	78
Tabela 4.2 – Dados morfológicos extraídos da Figura 4.18, tabela extraída de Cúñez e Franklin (Scientific Reports, under review).	81

LISTA DE ABREVIATURAS E SIGLAS

AP	Média de precisão de segmentação (Average Precision of Segmentation)
CNN	Redes Neurais Convolucionais (Convolutional Neural Network)
C	Camada convolucional
CMOS	Câmera do tipo semicondutor de óxido metálico complementar
CTX	Câmera de Contexto (Context Camera)
DL	Aprendizado Profundo (Deep Learning)
FP	Falsos Positivos
FN	Falsos negativos
HiRISE	Experimento científico de imagens de alta resolução (High Resolution Imaging Science Experiment)
IoU	Interseção sobre União
GAN	Redes Generativas Adversárias (Generative Adversarial Networks)
IA	Inteligência Artificial
LED	Diodo Emissor de Luz
ML	Aprendizado de Máquina (Machine Learning)
mAP	Média de Precisão (Mean Average Precision)
P	Pirâmide da cabeça da rede neural convolucional YOLO
RNN	Redes Neurais Recorrentes (Recurrent Neural Networks)
ROI	Região de interesse
SAM	Módulo de Atenção Espacial
SSD	Unidade de Estado Sólido (Solid State Drive)

SPP	Pirâmide espacial pooling
SVM	Máquina de Vetores de Suporte (Support Vector Machines)
TP	Verdadeiros Positivos
YOLO	You Only Look Once

LISTA DE SÍMBOLOS

Letras Latinas

A	Área da duna
C	Celeridade da duna
Cs	Precisão estimada
d	Diâmetro da partícula
$F1$	Pontuação
g	Aceleração da gravidade
L	Comprimento da duna
L_{drag}	Comprimento de inércia
L_{eq}	Comprimento em equilíbrio da duna
$\overline{L_h}$	Comprimento médio dos chifres
L_{hl}	Comprimento do chifre esquerdo
L_{hr}	Comprimento do chifre direito
L_{sat}	Comprimento de saturação
m	Massa
N	Número de classes
P_c	Probabilidade de classe
Pr	Precisão
P_y	Posicionamento da duna
R	Recall

Re	Número de Reynolds
t	Tempo
T	Temperatura
t_c	Tempo característico
$\overline{U}$	Velocidade média do fluido
u_*	Velocidade de atrito
u_{th}	Velocidade limite do fluido
W	Largura da duna
(W/L)	Razão de Aspecto

Letras gregas

δ	Altura média do canal
ρ	Densidade do fluido
ρ_s	Densidade da partícula
μ	Viscosidade dinâmica do fluido
θ	Número de Shields

SUMÁRIO

1	Introdução	20
1.1	Objetivos	22
1.1.1	Objetivo geral	22
1.1.2	Objetivos específicos	22
1.2	Publicações relacionadas com a dissertação	23
2	Revisão da literatura	24
2.1	Dunas	24
2.2	Dunas barcanas	25
2.2.1	Morfologia das dunas barcanas	28
2.2.2	Interação entre as dunas barcanas	30
2.2.3	Deteção e classificação das dunas barcanas usando sensoriamento remoto	33
2.3	Inteligência artificial e redes neurais convolucionais	37
2.3.1	Redes neurais convolucionais (CNN)	38
2.3.1.1	YOLO (You Only Look Once)	42
3	Metodologia	47
3.1	Criação da base de dados sobre dunas barcanas	47
3.1.1	Dunas barcanas subaquáticas	48
3.1.1.1	Descrição da bancada experimental	48
3.1.1.2	Características dos grãos	51
3.1.1.3	Aquisição de imagens experimentais	51
3.1.1.3.1	Câmera	51
3.1.1.3.2	Sistema de translação	52
3.1.1.3.3	Softwares para a aquisição de imagens	52
3.1.1.4	Ensaio	53
3.1.1.4.1	Preparação do material granular	53
3.1.1.4.2	Desenvolvimento dos ensaios	54
3.1.2	Dunas barcanas terrestres e marcianas	54
3.1.2.1	Aquisição de imagens com satélites	55
3.1.2.1.1	Softwares para a aquisição de imagens	56

3.2	Treinamento da rede YOLOv8	56
3.2.1	Rotulado das imagens	57
3.2.2	Preparação dos dados e do entorno	58
3.2.3	Parâmetros do treinamento	59
3.2.4	Extração dos dados morfológicos	60
4	Resultados	63
4.1	Treinamento da rede usando imagens experimentais	63
4.1.1	Resultados de aprendizagem da rede	63
4.1.2	Resultados de detecção, classificação, rastreamento e segmentação das dunas barcanas	65
4.1.2.1	Resultados para uma configuração do tipo <i>Exchange</i>	66
4.1.2.2	Resultados para uma configuração do tipo <i>Chasing</i>	69
4.1.2.3	Resultados para uma configuração do tipo <i>Fragmentation-chasing</i> alinhada	71
4.1.2.4	Resultados para uma configuração do tipo <i>Fragmentation-chasing</i> desalinhada	73
4.2	Treinamento da rede usando imagens de satélite	75
4.2.1	Resultados de aprendizagem da rede	76
4.2.2	Resultados de detecção, classificação e segmentação das dunas barcanas	78
5	Conclusões e trabalhos futuros	82
5.1	Conclusões	82
5.2	Trabalhos futuros	83
	Referências	84

1 INTRODUÇÃO

As dunas barcanas são formações geológicas arenosas encontradas em zonas desérticas, semidesérticas e na superfície de corpos celestes como Marte. Em geral, são avistadas em regiões com escoamento predominantemente unidirecional, e apresentam uma quantidade limitada de grãos (Bagnold, 1941). As barcanas têm um formato de lua crescente com uma crista alta e inclinações íngremes em ambos lados (*chifres*), e são geradas pelas interações entre o escoamento imposto, uma quantidade de partículas, e colisões entre elas (Hersen *et al.*, 2002).

O estudo das dunas barcanas permite obter uma quantidade significativa de informações sobre sua morfologia por meio da coleta de dados no campo, e desenvolve diversas técnicas para extrair esses dados. Isso inclui análises detalhadas da distribuição de sedimentos, a identificação de padrões de erosão e deposição, a compreensão dos processos de migração das dunas e a avaliação do impacto das atividades humanas e das mudanças climáticas na dinâmica costeira. No entanto, este tipo de métodos ainda requerem a extração manual de dados obtidos no campo ou em imagens (Merwe *et al.*, 2022). Para estudar e classificar as dunas é importante a análise morfológica que permite entender os aspectos envolvidos na formação desses corpos; onde a assimetria da duna têm um papel muito importante. Nesse contexto, Sauermann *et al.* (2000) e Moosavi *et al.* (2014) apontam o comprimento, largura e comprimento dos dois chifres, como os parâmetros que podem ser analisados para estudar a morfologia. Outros pesquisadores, como Lee e Thomas (1995), Bourke (2010) e Hugenholtz e Barchyn (2012) determinaram que além da análise morfológica, os parâmetros que ajudam a ter um amplo conhecimento sobre o comportamento das barcanas são: direção do vento, colisão das dunas e a influência da topografia inclinada.

Definindo a maioria dos fenômenos a serem estudados sobre as dunas barcanas, Bagnold (1941), Norris (1966) e Hugenholtz e Barchyn (2012) mencionam que este tipo de trabalho de campo é caro e demorado, já que tais observações, não conseguem trazer informações completas das interações das barcanas. Isto se deve à escala de tempo e comprimento; sendo na ordem de décadas e metros na Terra, e na ordem de milênios e quilômetros em Marte. Porém, nos últimos anos vários pesquisadores como Hersen (2005), Charru e Franklin (2012a), Alvarez e Franklin (2017) e Bristow *et al.* (2018) realizaram vários experimentos aquáticos controlados para replicar a criação de dunas barcanas eólicas neste entorno, conseguindo assim reduzir a

escala de tempo e comprimento para minutos e centímetros. Por outro lado, Assis e Franklin (2020) desenvolveram vários experimentos controlados com dunas aquáticas configurando diferentes interações binárias. Para reproduzir esses ensaios, os autores usaram diferentes tamanhos e cores de dunas que posteriormente foram colocadas em posições alinhadas e desalinhadas. Dessa forma, estes resultados conseguiram aprofundar e complementar o estudo dinâmico e morfológico das dunas a uma escala menor, com a identificação de 5 diferentes tipos de interações e comportamentos entre as barcanas, nomeadas como: *Chasing*, *Merging*, *Exchange*, *Fragmentation-chasing* e *Fragmentation-exchange* (do inglês). Este tipo de resultados permite ter uma ideia mais compacta sobre como as dunas barcanas são formadas na Terra e em outros corpos celestes.

Com o propósito de entender os fenômenos físicos inclusos no comportamento das dunas barcanas na terra e em Marte, diversos pesquisadores, como Tsoar *et al.* (1979) e Zhang *et al.* (2018) escolheram realizar a detecção manual de dunas utilizando imagens de satélites em órbita desses corpos celestes. Esses estudos conseguiram monitorar, identificar e classificar as dunas com uma razoável precisão por meio de algoritmos especialmente desenvolvidos para esses fins. Porém, com o avanço moderno do aprendizado de máquina (ML) (*Machine Learning*; do inglês), a detecção automática de objetos tornou-se mais comum, permitindo que as redes artificiais revolucionassem esta área (Azzaoui *et al.*, 2016). Recentemente, Rubanenko *et al.* (2021) usaram a Rede Neural Convolucional *Mask R-CNN* para detectar dunas barcanas em Marte e na Terra, usando como base de dados um campo de dunas do mosaico global *Context Camera* (CTX), atingindo uma precisão na detecção entre os 50% e 77%. Este método detecta e gera uma máscara de segmentação para classificar e delinear automaticamente dunas barcanas isoladas.

Mais tarde, Yue *et al.* (2023) analisaram que a detecção de objetos evoluiu com os avanços modernos, resultando em abordagens cada vez mais complexas, utilizando redes como SSD, R-CNN, Mask R-CNN e suas variantes. Desse modo, nos últimos anos têm havido um interesse crescente na exploração e desenho de arquiteturas de redes neurais profundas altamente eficientes, sendo uma delas a rede *YOLO* (You Only Look Once). Segundo Redmon e Farhadi (2018), esta CNN reduz notoriamente os tamanhos dos modelos e melhora o desempenho de detecção, sendo muita mais rápida que outras redes neurais, já que utiliza um método multi-escala para seu treinamento, em conjunto de uma rede pre-treinada CSPDarknet 53 (Wong *et al.*, 2019).

Este trabalho tem o objetivo de enriquecer a análise morfológica das dunas em diferentes paisagens (Terra, Marte e experimentos aquáticos), e aprimorar os estudos anteriores sobre a detecção das dunas barcanas, usando ferramentas de Aprendizado de máquina (Machine learning). Dessa forma, se utiliza a rede neural convolucional (YOLOv8) para detectar, classificar, segmentar, rastrear e delinear as dunas barcanas em diferentes configurações, desenvolvendo dois treinamentos robustos que realizem essas atividades. A divisão dos estudos é devido às escalas de tempo e comprimento apresentadas nas diferentes paisagens. Onde, a primeira rede considera um conjunto de imagens de dunas aquáticas obtidas de experimentos controlados e do estudo conduzido por Assis e Franklin (2020), e a segunda utiliza um conjunto de imagens de dunas barcanas terrestres e marcianas, utilizando os satélites disponíveis tanto na Terra como em Marte. Para finalizar, são extraídos os parâmetros morfológicos ao longo do tempo das dunas barcanas detectadas, consolidando uma abordagem profunda desses parâmetros nos distintos cenários.

1.1 Objetivos

1.1.1 Objetivo geral

- Desenvolver uma rede neural que permita detectar, classificar, segmentar, rastrear e delinear o contorno das dunas barcanas nas diferentes paisagens (aquáticas, terrestres e marcianas) para extrair a morfologia das barcanas detectadas de forma automatizada, a partir de imagens de ensaios ou satélites.

1.1.2 Objetivos específicos

- Melhorar e aumentar a eficiência na detecção e predição das dunas barcanas nos diferentes ecossistemas apresentados.
- Delinear o contorno das barcanas para extrair as propriedades morfológicas das dunas, tais como: largura, comprimento, comprimento meio dos chifres e o posicionamento ao longo do tempo.
- Estudar e analisar a morfologia da duna barcana em função do tempo para compreender o comportamento e as interações presentes nos estudos prévios.

1.2 Publicações relacionadas com a dissertação

A parte teórica e os resultados apresentados neste dissertação levaram para as seguintes publicações em revistas e anais de conferências:

- Cúñez, E.A. & Franklin, E.M. Detection and tracking of barchan dunes using Artificial Intelligence. Scientific Reports, under review (2023).
- Cúñez, E.A. & Franklin, E.M. Automatic detection and tracking of barchan dunes using Artificial Intelligence: A review. In: American Geophysical Union (AGU). Poster session, 2023, San Francisco/USA.
- Cúñez, E.A. & Franklin, E.M. Machine Learning for barchan dune detection: A review. In: 27th International Congress of Mechanical Engineering (COBEM). Oral presentation, 2023, Florianópolis/Brazil.

2 REVISÃO DA LITERATURA

Neste capítulo, são abordados os conceitos fundamentais das dunas barcanas, analisando sua morfologia e os padrões decorrentes das colisões e interações entre elas. Exploramos também diversas técnicas utilizadas na extração de dados e no sensoriamento remoto em diferentes cenários, introduzindo o tema da Inteligência Artificial (IA). Dentro desse contexto, apresentamos os conceitos básicos de IA e redes neurais convolucionais (CNN). Além disso, apresenta-se uma análise teórica sobre qual é a rede neural convolucional (CNN) mais capacitada para realizar tarefas como detecção, classificação, segmentação e rastreamento automático de objetos personalizados, chegando à conclusão de que a CNN YOLO (You Only Look Once) é a escolha mais adequada, pelo qual, sua metodologia e arquitetura serão discutidas.

2.1 Dunas

As dunas são uma formação geológica composta de grãos de areia soltos, presentes em diferentes ambientes, tanto na natureza quanto em contextos industriais. Essas formações geomorfológicas podem ser encontradas em regiões desérticas, ao longo de regiões costeiras e rios (Bagnold, 1941). Elas são o resultado do transporte de areia pela ação do vento, e podem ser vistas em diferentes formas e tamanhos devido a fatores como: a direção do fluxo, velocidade do fluxo, quantidade e cobertura de areia. O vento desempenha um papel fundamental ao transportar e elevar os grãos de areia, assim, quando a velocidade do vento diminui, ocorre a deposição desses grãos, formando assim a estrutura característica de uma duna (Bagnold, 1941; Herrmann; Sauermann, 2000). Nesse contexto, Bagnold (1941), desenvolveu um túnel de vento com o objetivo de aprofundar o estudo e a compreensão do comportamento e da complexa interação envolvida na formação das dunas no deserto de Líbia. Seu trabalho aporta um valioso conhecimento tanto em medições de campo quanto às condições experimentais controladas, chegando a ser considerado como uma referência crucial para a resolução de vários estudos.

Devido à vasta diversidade de dunas, sua classificação torna-se uma tarefa complexa, podendo ser categorizadas com base em três fatores principais, sendo dois de natureza climática e um relacionado à sedimentação. Esses fatores são a intensidade do vento, a presença de cobertura vegetal e o tamanho do grão (Pye; Tsoar, 2008). Além disso, as dunas podem ser classificadas com base em seu movimento, sendo categorizadas como migratórias, alongadas e

acumuladas (Tsoar, 2001). Assim, na primeira classificação, as dunas são categorizadas como barcanas, parabólicas, estrela, longitudinais, transversais, entre outras. A duna barcana destaca-se como a mais conhecida devido a sua forma característica de lua crescente, e pelas condições físicas envolvidas em seu processo de formação (Hersen *et al.*, 2002).

2.2 Dunas barcanas

As barcanas são dunas livres conhecidas por sua forma característica de lua crescente e por possuir uma crista alta com inclinações íngremes em ambos lados; conhecidas como (*chifres*) que apontam na direção do fluxo dominante. Estas formações geológicas se formam em regiões com a presença de um escoamento predominante unidirecional e são geradas pelas interações e colisões entre as partículas (Bagnold, 1941; Hersen *et al.*, 2002).

Vale destacar, que as dunas barcanas podem ser encontradas em diferentes regiões desérticas e vários corpos celestes como Marte, aumentando o interesse dos pesquisadores para encontrar similitudes entre estes ecossistemas; sendo a segregação, movimentação das partículas e a morfologia os tópicos mais estudados (Alvarez *et al.*, 2021). Dessa forma, Bourke (2010) menciona que, para compreender os fenômenos físicos inclusos na formação das barcanas, deve-se analisar os parâmetros como a direção do escoamento, as colisões entre elas e a topografia inclinada. No entanto, vários autores como Bagnold (1941), Norris (1966) e Hugenholz e Barchyn (2012) observaram que para extrair e estudar essas informações em um campo de dunas barcanas, requer equipamento muito custoso e demorado. Devido a isso, a aquisição dessas informações está limitada. Devido a isso, a aquisição dessas informações está limitada, tornando o estudo dos fenômenos físicos e morfológicos das dunas ainda um desafio. Este problema é ocasionado pelas escalas de tempo e comprimento: lidando com décadas e metros na Terra, e na ordem de milênios e quilômetros no Marte. Porém, nos últimos anos, diversas ferramentas em ambientes subaquáticos foram desenvolvidas para acelerar esses processos, obtendo resultados eficientes na análise do comportamento das dunas nos diferentes ecossistemas (Herrmann; Sauermann, 2000).

Aproveitando os conhecimentos experimentais e de campo fornecidos por Bagnold (1941), nos últimos anos, vários pesquisadores como Hersen (2005), Charru e Franklin (2012a), Alvarez e Franklin (2017) e Bristow *et al.* (2018) desenvolveram experimentos controlados em ambientes aquáticos. Esses estudos conseguiram replicar a formação e reprodução de dunas barcanas, reduzindo significativamente as escalas de tempo e comprimento envolvidas para mi-

nutos e centímetros. No entanto, para reproduzir as dunas aquáticas e relacioná-las com as terrestres ou marcianas é crucial analisar o tamanho crítico em sua formação, já que no trabalho de campo, não há registro de dunas com comprimento e altura na crista inferiores a 10 m e 1 m, respectivamente. Portanto, para compreender a origem das dunas nos diferentes ecossistemas, devem-se analisar a disposição de areia, a saturação e a erosão da areia. Introduzindo o conceito de comprimento de saturação l_{sat} e um escoamento sobre a superfície, busca-se entender como os grãos atingem as condições de equilíbrio com um fluxo variável. Nesse contexto, os grãos reorganizam-se, colidem e iniciam a saltação (*saltation*; do inglês), com a distância percorrida variando conforme a inércia do fluido (Sauermann *et al.*, 2000; Charru; Franklin, 2012b; Alvarez; Franklin, 2017), dando como resultado o comprimento de inércia L_{drag} . Segundo Sauermann *et al.* (2000) saltação é o processo de transporte de grãos de areia pelo escoamento em pequenos saltos, desempenhando um papel crucial na formação e evolução das dunas e outros relevos sedimentares,

$$L_{drag} = \frac{\rho_s \cdot d}{\rho} \quad (2.1)$$

onde, ρ é a densidade do fluido, ρ_s é a densidade das partículas, e d é o diâmetro das partículas.

No contexto de reproduzir dunas barcanas em escalas pequenas e controladas (experimentos), é essencial reduzir o tamanho do coeficiente L_{drag} para dimensionar as dunas a proporções mais gerenciáveis. No entanto, devido às grandes dimensões das dunas barcanas, é difícil reduzir significativamente esse tamanho. Portanto, considera-se alterar a relação entre as densidades dos grãos e do escoamento como uma alternativa viável. Assim, para diminuir consideravelmente o L_{drag} pode-se utilizar água como fluxo, tornando-se na ordem de grandeza do tamanho da partícula. Devido a essas considerações é possível desenvolver as dunas aquáticas com dimensões relativamente pequenas (Alvarez; Franklin, 2017; Wenzel, 2018). Assim, na Figura 2.1 apresentam-se os campos de dunas barcanas nos diferentes ecossistemas (Terra, Marte e experimentos). Além, de observar as dimensões predominantes, pode-se ver a forma característica de meia-lua e os chifres apontando na direção do escoamento.

Por outro lado, destacando o estudo de dunas barcanas subaquáticas em ambientes controlados (experimentos) de Alvarez e Franklin (2017), se descobriu que a formação e deslocamento das barcanas é dada pelas escalas de tempo característico t_c , e dependem do material e do tamanho das partículas usadas para reproduzir uma duna subaquática. Dessa forma, para calcular o tempo característico da duna, se calcula a relação entre: o comprimento no equilíbrio

da formação da duna L_{eq} , e a celeridade C . O L_{eq} é definido como a distância desde a ponta da duna até a crista quando a barcana está desenvolvida, e C é a velocidade com que uma perturbação se propaga mediante um meio específico, e mede-se em unidades de comprimento por unidade de tempo.

$$t_c = \frac{L_{eq}(\rho_s/\rho)(\rho_s/\rho - 1)gd}{(u_*^2 - u_{th}^2)^{3/2}} \quad (2.2)$$

onde, u_* é a velocidade de atrito, u_{th} é a velocidade limite do fluido utilizado nos experimentos, e g é a aceleração da gravidade.

Nesse contexto, os autores Alvarez e Franklin (2017) destacam que para partículas de vidro determinaram que as escalas de tempo são: $0,5 t_c$ e $2,5 t_c$ para o surgimento das barcanas e o equilíbrio no desenvolvimento das barcanas (apresentando a forma característica), respectivamente.

Explorando os fenômenos físicos e mecanismos inclusos no desenvolvimento e deslocamento das barcanas aquáticas ao longo do tempo, o estudo de Alvarez e Franklin (2018) desempenha um papel fundamental, revelando informação primordial ao analisar as trajetórias percorridas pelos grãos durante a formação dos chifres, descobrindo que realmente as partículas chegam de distintas regiões da montante da pilha inicial. Dessa forma, os autores mostraram que os grãos apresentam deslocamentos transversais por deslizamento e rolamento, marcando uma diferença muito importante no entendimento das barcanas. Estes avanços contrastam a forma de analisar os crescimentos dos chifres, pois se entendia, que eles se formavam pelo avanço das partículas nas laterais da barcana.




Figura 2.1 – Campos de dunas barcanas presentes em diferentes ecossistemas e experimentos. a) Dunas barcanas na superfície de Marte. Cortesia: NASA/JPL-Caltech/UArizona. b) Dunas barcanas no deserto de Catar. Cortesia: Google Earth c) Dunas barcanas criadas experimentalmente, imagem obtida de (Cuneez; Franklin, 2023c).

2.2.1 Morfologia das dunas barcanas

Nos últimos anos, com o propósito de entender e estudar as barcanas, a análise morfológica tem ganhado uma importância significativa. Este estudo desempenha um papel crucial na compreensão das mudanças nas barcanas ao longo do tempo, proporcionando informações valiosas sobre os fenômenos físicos e suas interações. Devido ao interesse dos pesquisadores por conseguir essas informações, foram-se desenvolvendo várias técnicas de monitoramento que permitiram a extração e reconstrução desses eventos. Essa abordagem se torna relevante para compreender as condições ambientais do entorno, onde a duna está presente (Bagnold, 1941; Herrmann; Sauermann, 2000; Sauermann *et al.*, 2000).

O estudo morfológico das dunas barcanas permite desvendar quais são os processos intrincados nas formações destas formas geológicas singulares. Embora, as barcanas destaquem pela sua forma de meia-lua, também desempenham um papel vital na compreensão dos fatores físicos e ambientais no presente e no passado. Esta análise, não se limita somente a estudar as dimensões das dunas, mas também permite compreender a dinâmica complexa que governa estas formações (Haynes, 1989; Lee; Thomas, 1995). Em termos gerais, a morfologia das barcanas é relativamente simples, consistindo em uma crista e uma face mais íngreme na direção oposta. Além disso, as barcanas possuem uma relação com a quantidade de sedimentos disponíveis e a velocidade do vento. Assim, os grãos de areia podem deixar a duna pela borda dos chifres, mas não pelo corpo da barcana. Isto se deve à recirculação que acontece no escoamento após passar pela borda da fase de deslizamento; sendo os grãos retidos neste ponto (Hersen, 2004). Este processo e as propriedades principais das barcanas, podem ser vistos na Figura 2.2.

Nas últimas décadas, vários pesquisadores como Sauermann *et al.* (2000), Moosavi *et al.* (2014), Lee e Thomas (1995), Bourke (2010) e Hugenholtz e Barchyn (2012) realizaram estudos importantes para decifrar os fenômenos físicos e naturais das barcanas. Nestes trabalhos se analisaram os parâmetros como: a direção do vento, colisão das dunas, influência do estudo topográficos e a análise da assimetria. Nesse sentido, os parâmetros a serem estudados para compreender a morfologia da barcana são: comprimento, largura e o comprimento dos chifres; sendo estes últimos medidos a partir da crista (Sauermann *et al.*, 2000; Moosavi *et al.*, 2014). Adaptando esses parâmetros morfológicos, trabalhos recentes de Alvarez e Franklin (2017), Assis e Franklin (2020) e Assis e Franklin (2021) identificaram que para estudar a morfologia das dunas em ambientes subaquáticos, pode-se considerar o esquema e a nomenclatura da Figura 2.3, onde a direção dos chifres aponta na direção do fluxo.




Figura 2.2 – Duna barcana e suas propriedades. a) Vista lateral de uma duna barcana localizada em Florianópolis, Brasil. b) Propriedades da duna barcana, imagem modificada de (Hersen, 2004)




Figura 2.3 – Morfologia da duna barcana adotada nos estudos de (Alvarez; Franklin, 2017; Assis; Franklin, 2020)

O estudo contínuo nesta área, não somente enriquece nossa compreensão essencial da morfologia, mas também possibilita a investigação dos parâmetros envolvidos no comportamento e interações entre as barcanas. Dessa forma, para compreender o surgimento das dunas assimétricas, é necessário investigar a colisão que ocorre entre elas; sendo o tamanho e a presença de chifres, indicativos das diversas interações em um campo de dunas (Norris, 1966).

2.2.2 Interação entre as dunas barcanas

A dinâmica das dunas barcanas, ao migrarem na direção do fluxo, é uma resposta intrincada aos processos de transporte de sedimentos, que incluem a erosão no lado oposto ao fluxo e a deposição no lado de deslizamento. A regulação do tamanho das barcanas está diretamente vinculada à sua taxa de migração, a qual se mostra inversamente proporcional ao volume de sedimentos transportados (Andreotti *et al.*, 2002). Essa interação complexa entre os processos erosivos e deposicionais destaca a dinâmica fascinante das dunas barcanas, revelando as intrincadas relações que moldam sua morfologia ao longo do tempo.

Ao longo dos anos, investigar as interações e colisões entre as barcanas terrestres tem sido um desafio significativo. Isso se deve à falta de dados em séries temporais completas e às restrições econômicas que se necessitam para realizar esse tipo de medições no campo. Compreender o comportamento dessas interações é crucial para decifrar os padrões de movimento das barcanas e entender suas implicações nos ecossistemas (Bagnold, 1941; Norris, 1966). Nesse contexto, os estudos de campo revelam que as dunas menores tendem a se deslocar mais rapidamente do que as maiores. Isso se deve, em parte, ao fato de que a velocidade da duna aumenta à medida que ela perde partículas ao longo do tempo, um fenômeno observado na dinâmica das dunas em várias escalas. Além, as colisões em um campo de dunas proporcionam o aumento de tamanho das barcanas. Estas interações observadas na natureza são acompanhadas pela análise física e dinâmica entre o escoamento e o transporte dos grãos (condições naturais), mas também respondem a um comportamento coletivo das barcanas (Bourke, 2010; Lee; Thomas, 1995). Desse modo, a interação das barcanas tornou-se um fenômeno impressionante devido às dinâmicas complexas que governam a formação e evolução das barcanas.

Na atualidade, existem vários estudos enfocados em compreender os comportamentos e padrões das interações entre as barcanas. Assim, Schwämmle e Herrmann (2003) desenvolveram vários modelos numéricos, nos quais, observaram que a colisão e interação entre uma duna pequena e uma grande têm o potencial de ejetar uma terceira duna. Além disso,

notaram que ao variar a altura da duna e a velocidade de deslocamento, é possível alongá-la ou encurtá-la. Nesse contexto, Hugenholtz e Barchyn (2012) comprovaram que essas evidências geomorfológicas podem ser vistos por meio de imagens de satélites multi temporais.

Por outro lado, para comprovar esses parâmetros e entender as colisões entre uma duna montante e uma jusante em escalas de tempo e comprimento menores, Endo *et al.* (2004) conduziram uma série de experimentos em um canal de recirculação reproduzindo dunas barcanas aquáticas. Nesses experimentos, conseguiram observar diversas interações binárias entre as dunas e controlaram as configurações de alinhamento, o posicionamento entre as dunas e o tamanho da pilha de grãos, observando três padrões distintos, aos quais denominaram: *Absorption*, *ejection* e *Split* (do inglês). Em geral, este estudo demonstrou que como resultado das colisões e interações entre as dunas, ejeta-se uma duna menor, apresentando o mesmo comportamento das dunas terrestres.

Nesse sentido, para aprimorar esses estudos, propôs-se a análise de parâmetros fundamentais, tais como as configurações iniciais de alinhamento e espaçamento entre as dunas, bem como as variações nas massas e propriedades dos grãos, conforme proposto por Assis e Franklin (2020). Neste estudo, os autores conduziram experimentalmente a replicação de dunas aquáticas utilizando um canal retangular com escoamento de água turbulento e partículas de vidro e zircônio, onde todos os componentes formam um circuito fechado. Os experimentos foram realizados controladamente, posicionando cuidadosamente as pilhas de grãos em diversas posições e alinhamentos (centrados e desalinhados). Além disso, usaram diferentes condições iniciais (colocando dunas barcanas desenvolvidas a jusante e uma pilha de grãos a montante). Desse modo, identificaram cinco diferentes padrões entre as interações binárias das dunas e denominaram como: *Chasing*, *merging*, *exchange*, *fragmentation-chasing* e *fragmentation-exchange* (do inglês). Estas configurações podem ser observadas na Figura 2.4.

Ademais, essa nova classificação das interações depende da razão entre o número de grãos de cada duna, o número de Shields θ e o alinhamento. Esses parâmetros proporcionaram uma compreensão mais clara do comportamento das barcanas em um campo de dunas. Esse estudo, também, se complementa com a análise dos aspectos morfológicos das barcanas. Desse modo, os autores calcularam o comprimento L , a largura W , o comprimento médio dos chifres ($\overline{L_h}$) e a área de superfície A das barcanas utilizando um código de detecção elaborado em MATLAB.

Na Figura 2.4, são definidas as cinco configurações como: *chasing* (I) A duna montante não consegue alcançar a duna jusante; *merging* (II) A duna montante junta-se com a jusante e se misturam; *exchange* (III) As duas dunas juntam-se, misturam-se e finalmente ejetam uma pequena duna; *fragmentation-chasing* (IV) A duna jusante ejeta outra duna e não são alcançadas pela montante; *fragmentation-exchange* (V) As dunas juntam-se e ejetam uma pequena duna, mas não se misturam (Assis; Franklin, 2020).




Figura 2.4 – *Snapshots* das interações binárias de dunas barcanas. Os experimentos foram desenvolvidos com grãos de vidro usando partículas vermelhas e brancas, e direção do fluxo de água é de esquerda para direita. Os cinco diferentes padrões são: *chasing* (I), *merging* (II), *exchange* (III), *fragmentation-chasing* (IV) e *fragmentation-exchange* (V). a) Configuração alinhada. b) Configuração desalinhada. Imagem adaptada de (Assis; Franklin, 2020)

Adicionalmente, para complementar o trabalho prévio, Assis e Franklin (2021) realizaram um enfoque nos movimentos dos grãos ao longo dessas interações binárias. Neste estudo, eles aprofundam na parte morfodinâmica dos padrões observados. Assim, os autores conseguiram analisar o tamanho das barcanas ao longo da colisão, a velocidade de deslocamento e como os grãos são deslocados nas diferentes configurações. Em geral, esses resultados representam um passo em direção à compreensão da evolução e divisão das barcanas, seleção de

tamanho e variabilidade das formas encontradas em ambientes aquáticos, atmosféricos e outros ambientes planetários.

2.2.3 Detecção e classificação das dunas barcanas usando sensoriamento remoto

Ao longo dos anos, a análise de campo das barcanas tem sido estudada, já que representa uma abordagem fundamental na compreensão dos elementos morfológicos e geológicos das dunas no ecossistema. Os primeiros estudos foram impulsionados com a utilização de imagens de sensoriamento remoto, ajudando a estabelecer um campo de estudo no mapeamento das barcanas (McKee, 1979). Posteriormente, o sensoriamento remoto auxiliou a identificar correlações entre os tipos de dunas, a direção do vento e a disponibilidade de areia (Hugenholtz; Barchyn, 2012). Mais recentemente, com os avanços modernos nesta área, a atenção dos pesquisadores foi direcionada ao estudo de barcanas individuais, utilizando análises espaciais para entender as relações entre as formas geológicas e os padrões produzidos na interação de dunas nas diferentes escalas de tempo de comprimento (Zhang *et al.*, 2018; Azzaoui *et al.*, 2016).

Nas últimas décadas, o monitoramento de dunas em corpos celestes, tem sido aprimorado com o lançamento e órbita de satélites de maior resolução. Em particular, a detecção das dunas na Terra e em Marte com base no uso de imagens de satélite tem sido amplamente empregada. Os primeiros trabalhos de detecção de barcanas utilizavam detecção manual, identificando, classificando e extraíndo as informações das barcanas com o desenvolvimento de várias ferramentas para esses fins (Bourke, 2010; Zhang *et al.*, 2018). Desse modo, Bourke (2010) destaca a relevância das morfologias assimétricas das dunas como indicadores potenciais do regime de ventos formativos em superfícies planetárias. Para isso, o autor analisa a assimetria das barcanas mostrando a diversidade de causas subjacentes que podem produzir essas formas usando sensoriamento remoto para estudar a migração das dunas ao longo dos anos. Consequentemente, ele classifica as extremidades das dunas como lineares, curvadas e torcidas; fornecendo uma abordagem valiosa para entender esses fenômenos morfológicos. Em geral, o sensoriamento remoto desempenhou um papel crucial ao fornecer acesso às imagens de satélite e à capacidade de realizar estudos a longa distância. Esse estudo permitiu coletar dados detalhados sobre a forma, orientação e comportamento das dunas e auxiliou na compreensão dos processos geológicos e atmosféricos que as afetam. Por outro lado, Zhang *et al.* (2018) utilizando a plataforma de Google Earth, realizaram uma análise das condições assimétricas das barcanas no Noroeste da China. Os pesquisadores exploraram as interações e condições

simétricas das dunas nesse campo, revelando que à medida que as dunas avançam a favor do vento, as interações entre elas impactam a barcana de distintas formas, de acordo ao deslocamento. Os resultados indicaram que a taxa média de migração varia entre 8 e 53 metros por ano. Na Figura 2.5 podemos observar como os estudos de Bourke (2010) e Zhang *et al.* (2018) realizaram a extração de dados manuais para entender a migração de dunas ao longo dos anos.




Figura 2.5 – Métodos de extração manuais sobre a migração de dunas barcanas em diferentes localizações a) Migração assimétrica de barcanas no deserto de Namibe ($13^{\circ}17'05.4''E$; $20^{\circ}21'04.8''S$), imagem adaptada de (Bourke, 2010). b) Migração de dunas barcanas no Noroeste de China, imagem adaptada de (Zhang *et al.*, 2018)

No entanto, nesses estudos, os pesquisadores apontam a importância de conduzir observações em campos adicionais e de realizar trabalhos de modelagem para aprofundar as pesquisas de campo sobre as barcanas na Terra e em Marte. Isso se deve ao fato de que as observações disponíveis atualmente não são tão precisas, apresentando desafios na obtenção de dados detalhados sobre as dunas. Portanto, a busca por métodos mais aprimorados de coleta de dados e o desenvolvimento de modelos mais refinados são fundamentais para avançar no entendimento das complexas interações das barcanas e melhorar a precisão das análises morfológicas e dinâmicas em diferentes ambientes planetários. Nesse sentido o aprendizado de máquina (*Machine Learning*; do inglês), aprendizado profundo (*Deep Learning*; do inglês), máquina de vetores de suporte (*Support Vector Machine*; do inglês) e redes neurais convolucionais são algumas das ferramentas mais comuns para detectar, classificar e segmentar dunas barcanas (Azzaoui *et al.*, 2016; Carrera *et al.*, 2019; Rubanenko *et al.*, 2021; Merwe *et al.*, 2022).

Trabalhos recentes, como o de Azzaoui *et al.* (2016) desenvolveram um método para detectar barcanas em imagens de satélite de alta resolução usando o instrumento *High*

Resolution Imaging Science Experiment (HiRISE). O processo envolveu três etapas-chave. Inicialmente, priorizaram a imagem aplicando equalização de histograma e filtros de redução de ruído. Posteriormente, na segunda etapa, eliminaram as texturas não relacionadas com as dunas, fornecendo uma máscara, que foi empregada para reduzir a área de pesquisa. Na terceira etapa, uma janela deslizante na máscara foi utilizada para examinar características das barcanas usando Máquina de Vetores de Suporte (*SVM*) para identificar possíveis dunas barcanas. Consequentemente, as barcanas detectadas foram determinadas pela fusão de dunas sobrepostas. Assim, os resultados evidenciaram um alto nível de desempenho tanto em relação ao tempo de processamento quanto à precisão alcançada. Por outro lado, Rubanenko *et al.* (2021) utilizaram uma rede neural convolucional regional (*Mask R-CNN*), que identifica objetos enquanto gera simultaneamente uma máscara de segmentação. Essa metodologia permitiu a detecção, classificação e traçado automático de dunas barchan em Marte e na Terra com um mAP=77% (Mean average precision; do inglês). Essa abordagem avançada permitiu o mapeamento de extensas regiões da superfície marciana, revelando que cerca de 60% dos campos de dunas no hemisfério norte são cobertos por barcanas, enquanto apenas 30% dos campos no hemisfério sul possuem essa cobertura. Na Figura 2.6 pode-se observar os resultados de detecção de dunas barcanas usando diferentes técnicas de *Support Vector machine* e redes neurais convolucionais.




Figura 2.6 – Detecção automática de dunas em Marte usando as imagens disponíveis de Hi-RISE, cortesia de NASA/JPL/University of Arizona. a) Detecção de dunas barcanas usando *Support Vector machine*, imagem adaptada de (Azzaoui *et al.*, 2016). b) Detecção de dunas barcanas usando a rede neural convolucional (Mask R-CNN), imagem adaptada de (Rubanenko *et al.*, 2021)

Embora trabalhos recentes, especialmente o de Rubanenko *et al.* (2021), tenham acrescentado a precisão na detecção e contorno de dunas barcanas individuais em imagens de satélite, as variações na forma, influenciadas pelas interações entre as dunas e o fluxo de vento, e a presença de outros tipos de dunas curvas, como as dunas parabólicas, tornam desafiadora a detecção automática e o traçado em muitos casos. Por outro lado, no trabalho de Merwe *et al.* (2022) demonstraram que com ajuda das redes neurais convolucionais é possível classificar e analisar a morfologia das dunas barcanas. Os autores implementaram modelos de classificação como Coeficiente de correlação de Matthew (MCC) e arquiteturas como ResNet50 e VGG16 conseguindo exceder os 80% de precisão para classificar e analisar a morfologia das dunas. Em geral, as redes neurais treinadas atualmente não conseguem detectar com sucesso grupos de dunas interagindo, principalmente quando estão se colidindo ou se sobrepondo. Desse modo, ainda falta explorar se as redes neurais convolucionais (CNN) conseguem rastrear as dunas barcanas detectadas e atualizar o traçado do contorno ao longo de uma sequência de imagens ou filmes; sendo o principal enfoque a se desenvolver nesta dissertação.

2.3 Inteligência artificial e redes neurais convolucionais

O termo *inteligência artificial* (IA) foi primeiramente definido por John McCarthy em 1956, indicando que seu objetivo é desenvolver máquinas que se comportem como se fossem inteligentes (Andresen, 2002). Essa definição inicial ressoa até os dias atuais, orientando o desenvolvimento e a compreensão dessa área em constante evolução. A inteligência artificial é frequentemente descrita como a habilidade dos computadores realizarem atividades que normalmente requerem inteligência humana. Assim, pode-se conceituá-la como a capacidade das máquinas de utilizar algoritmos, aprender com dados e aplicar esses aprendizados na tomada de decisões, simulando o comportamento humano (Rouhiainen, 2018; Ertel, 2019; Rodríguez-García *et al.*, 2020). No entanto, a diferença crucial entre máquinas e seres humanos reside no fato de que dispositivos que utilizam Inteligência Artificial não necessitam de descanso e podem processar grandes volumes de informações simultaneamente, reduzindo significativamente a taxa de erros em comparação com os humanos (Ertel, 2019). Nesse contexto, as tecnologias baseadas em (IA), estão sendo amplamente utilizadas para proporcionar melhorias significativas e aumentar a eficiência em diversos aspectos da vida cotidiana. Assim, esta ferramenta encontra aplicação em uma variedade de situações, destacando-se em áreas como: reconhecimento de imagens, classificação, detecção e segmentação de objetos personalizados, sendo ferramentas úteis em diversas indústrias, áreas de estudo e pesquisa (Andresen, 2002; Rouhiainen, 2018; Gunning *et al.*, 2019; Rodríguez-García *et al.*, 2020).

Nas últimas décadas, a Inteligência Artificial redefine os limites sobre as atividades que podemos realizar, deixando um mundo aberto de possibilidades a serem aplicadas no dia a dia. Isso deve-se a que máquinas e computadoradoras aprendem e melhoram seu rendimento nos diferentes ambientes de estudo. Consequentemente, a (IA) consegue fornecer novas ideias para o desenvolvimento de novos campos de estudo, focados no aprimoramento dos resultados de aprendizagem nesses cenários, tais como: o aprendizado de máquina (*Machine Learning*; do inglês) e do aprendizado profundo (*Deep Learning*; do inglês) (Rouhiainen, 2018; Gunning *et al.*, 2019; Rodríguez-García *et al.*, 2020; Iliadis *et al.*, 2023). Nesse contexto, vários autores como Ertel (2019) definem ao aprendizado de máquina (ML) como um campo de estudo da inteligência artificial que se dedica ao desenvolvimento de algoritmos que permitem aumentar o desempenho autônomo de trabalho das máquinas. Esse aumento ocorre a partir do aprendizado constante sobre o conhecimento de experiências passadas. Isso é feito adotando uma base de dados de volumes grandes para a resolução de problemas complexos. Desse modo, Rouhiainen

(2018), Rodríguez-García *et al.* (2020) mencionam que o (ML) permite que as máquinas aprendam e se capacitem sem a necessidade de que estejam programadas para uma tarefa específica ou alguma situação particular, aumentando no desempenho na hora de abordar novos problemas e como resolvê-los. Por outro lado, Rosebrock (2017), Gunning *et al.* (2019) definem ao aprendizado profundo (DL) como um subcampo do aprendizado de máquina, que proporciona uma abordagem avançada, devido a que está inspirada com a arquitetura neural do cérebro humano. Assim, o (DL) utiliza as redes neurais como modelos para a resolução de problemas extremamente difíceis. As redes neurais apresentam a capacidade de aprender uma infinidade de coisas, ajustando os parâmetros de treinamento, o que aumenta cada vez que as vantagens do seu uso sejam ilimitadas. Nesse contexto, as redes neurais, apresentam distintas capacidades e aplicações, destacando redes como: redes neurais convolucionais (CNN), recorrentes (RNN) e as generativas adversárias (GAN). Cada rede neural encontra-se desenhada para desafios específicos nas diferentes aplicações da Inteligência Artificial (Rouhiainen, 2018; Iliadis *et al.*, 2023; Haddawy *et al.*, 2023). Nesse contexto, o uso das redes dependem muito das aplicações nas que vão se desenvolver, no entanto, as redes neurais convolucionais destacam-se nos cenários de detecção e tratamento de imagens. O qual permite melhorar o rendimento e desenvolvimento de novas tecnologias dirigidas à pesquisa (Xiao *et al.*, 2023). Finalmente, para entender esta área de estudo, pode-se observar a hierarquia da Inteligência Artificial e seus campos de estudo na Figura 2.7. Onde as redes neurais (NN) representam as ferramentas integradas no contexto do aprendizado profundo (DL). Este, por sua vez, é classificado como uma subdivisão do aprendizado de máquina (ML).

2.3.1 Redes neurais convolucionais (CNN)

As redes neurais convolucionais (CNN) surgem da necessidade de resolver problemas muito complexos na área de aprendizado profundo, sendo consideradas um dos melhores algoritmos para a compreensão do conteúdo de imagens, demonstrando um alto desempenho em realizar tarefas relacionadas com a detecção, classificação, segmentação e rastreamento de objetos personalizados (Khan *et al.*, 2020). O termo das redes neurais convolucionais é usado para descrever uma arquitetura para a aplicação de redes neurais a matrizes bidimensionais (imagens) e foi introduzido por primeira vez por Fukushima no ano 1998 (Browne *et al.*, 2008; Dhillon; Verma, 2020). O uso das redes (CNN) não só está focado na área acadêmica, mas também às empresas reconhecidas como Google, Microsoft e Facebook que têm grupos de pesquisa para




Figura 2.7 – Hierarquia da Inteligência Artificial, imagem adaptada de (Rosebrock, 2017)

explorar e desenvolver novas arquiteturas enfocadas na resolução de problemas (Khan *et al.*, 2020). As redes neurais convolucionais alimentam-se por meio de um conjunto de núcleos convolucionais, unidades de processamento não lineares e camadas de *pooling* (do inglês) (Jiang *et al.*, 2019). O qual se pode observar com mais detalhe na Figura 2.8. Consequentemente, vários autores como Khan *et al.* (2018) e Dhillon e Verma (2020) determinam que as (CNN) são uma classe útil de redes neurais que complementam a aprendizagem supervisionada e não supervisionada. Nesse sentido, nos mecanismos de aprendizado encontram-se a detecção, classificação e segmentação de imagens como uma tarefa de aprendizagem supervisionada, onde se desenvolvem características discriminativas para prever a categoria certa de uma imagem de entrada. Assim, as redes neurais convolucionais conseguem aprender uma extensa representação das imagens a partir dos píxeis brutos das imagens, que auxiliam na aprendizagem contínua de atributos, padrões e características do problema a estudar, ganhando popularidade principalmente à sua capacidade hierárquica de extração de recursos. (Dhillon; Verma, 2020). Nesse contexto, Khan *et al.* (2018) mencionam que dentro das CNN destacam-se três arquiteturas ideais como: campos receptivos locais, pesos compartilhados (média ponderada dos pesos) e, frequentemente, subamostragem espacial. Por outro lado, Rosebrock (2017) menciona que para treinar uma rede (CNN) se destacam quatro elementos fundamentais, tais como: um conjunto de dados, uma arquitetura de modelo, uma função de perda e um método de otimização; sendo a escolha da arquitetura do modelo o parâmetro mais significativo para treinar um conjunto de dados. Em geral, a aplicação dessas tecnologias abrem as portas aos desenvolvimentos de novos

avanços científicos e significativos em diferentes áreas, sendo a detecção, classificação e segmentação as mais utilizadas. Estas tarefas permitem aos pesquisadores explorar e adentrar-se a novas áreas de estudos.




Figura 2.8 – Arquitetura básica das redes neurais convolucionais, imagem adaptada de (Jiang *et al.*, 2019)

Por outro lado, para analisar e validar o desempenho de uma rede neural convolucional, Akhtar *et al.* (2023), Soylu e Soylu (2023) e Yue *et al.* (2023) destacam-se como as métricas de estudo mais reconhecidas e implementadas em algumas redes, as seguintes: precisão (Pr), rechamada (R) (*Recall*; do inglês), pontuação (F_1), média de precisão (mAP) (mean average precision; do inglês) e o tempo de inferência.

A precisão (Pr) é a métrica que permite medir a proporção entre os verdadeiros positivos (TP) com os falsos positivos (FP); sendo a capacidade do modelo em não confundir os falsos positivos com os verdadeiros positivos.

$$Pr = \frac{TP}{TP + FP} \quad (2.3)$$

Recall é conhecido pela relação entre os verdadeiros positivos (TP) com os falsos negativos (FN); sendo a capacidade que tem o modelo para identificar todos os positivos detectados.

$$R = \frac{TP}{TP + FN} \quad (2.4)$$

A pontuação (F_1) relaciona a precisão e a rechamada da rede. Esta métrica é muito importante ao introduzir um desequilíbrio nas diferentes classes a treinar e detectar.

$$F_1 = \frac{2 \cdot P \cdot R}{P + R} \quad (2.5)$$

O *mean precision average* (mAP) calcula as médias para o máximo valor de precisão nos diferentes níveis de rechamada, considerando o número de classes (N) treinadas na rede. Onde, AP é a média de predição de segmentação (average precision of segmentation; do inglês); $AP = Pr/N$.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP \quad (2.6)$$

Finalmente, o tempo de inferência é o tempo que o modelo treinado demora para processar uma instância de dados. Este tempo é importante quando se trata de aplicações em tempos reais.

Na atualidade, há uma grande variedade de redes neurais convolucionais disponíveis que realizam atividades de detecção, classificação e segmentação de objetos. Dessa forma, Dhillon e Verma (2020) e Yue *et al.* (2023) destacam que as seguintes redes (CNN) podem realizar essas atividades: Faster R-CNN (Rede neural convolucional baseada em detectar por regiões), YOLO (You only look once; do inglês), Mask R-CNN (regiões com segmentação) e SSD (Single shot multibox detector; do inglês). Para saber que rede neural convolucional deve-se escolher, devemos analisar a aplicação e o tipo de informação que se quer extrair de uma forma eficiente e robusta. Assim, Redmon e Farhadi (2018) e Yue *et al.* (2023) mencionam que entre todas as opções disponíveis mencionadas anteriormente, a rede que mais destaca é a YOLO. Essa rede consegue reduzir significativamente o tamanho dos modelos, melhorando o desempenho em tempo real na detecção, classificação e segmentação de objetos. Isso se deve ao seu método multiescala para aprendizado contínuo na rede, produzindo que seja mais rápida que as outras redes, como a Mask R-CNN. Essas análises podem ser observadas na Tabela 2.3.1, onde se compraram as redes em função das métricas.

Tabela 2.1 – Comparação entre as redes neurais convolucionais Mask R-CNN e YOLO na detecção de objetos, tabela adaptada de: Yue *et al.* (2023)

Método	Precisão	Recall	Pontuação F1	Segmento	Tempo de inferência
...	(%)	(%)	(%)	$mAP@0,5$	ms
Mask R-CNN	89,8	85,5	87,6	0,915	90
YOLOv8-Seg	90,3	85,4	87,7	0,898	3,1

2.3.1.1 YOLO (You Only Look Once)

A rede neural convolucional YOLO é um algoritmo de detecção de objetos em tempo real em imagens ou sequências de imagens (vídeo). Esta CNN consegue dividir a imagem de entrada em várias regiões para analisá-las nas camadas convolucionais da rede, predizendo os objetos marcados por caixas delimitadoras, pontuações de confiança (mAP) e a probabilidade das classes (dependendo do caso de treinamento). Dessa forma, esta rede consegue extrair os recursos dos objetos detectados, classificados e segmentados (se for o caso) (Akhtar *et al.*, 2023; Soylu; Soylu, 2023). Na inferência, este algoritmo processa a imagem mediante um método multi-escala e uma rede pré-treinada, aumentando o desempenho e a taxa de detecção de objetos. Finalmente, este algoritmo gera previsões em tempo real e aplica a supressão de não-máximos para eliminar resultados redundantes e melhorar a precisão, fazendo desta rede uma das mais rápidas e eficazes (Dhillon; Verma, 2020; Yue *et al.*, 2023).

Na última década, foram desenvolvidas oito versões de YOLO (cada uma trazendo melhoras significativas) conseguindo aumentar as áreas de aplicação usando a detecção de objetos. A versão original YOLOv1 foi desenvolvida no ano 2015, enquanto a versão mais recente, YOLOv8 Ultralytics, foi lançada no ano 2023. Ao longo desses anos, foram apresentadas várias melhoras significativas, tais como: maior precisão, maior velocidade, maior desempenho, detecção de objetos pequenos e por último o rastreamento nativo (Soylu; Soylu, 2023; Yue *et al.*, 2023; Terven; Cordova-Esparza, 2023). No entanto, com estas melhoras significativas que se obtiveram ao longo dessas oito versões, conseguiram manter a arquitetura da rede pré-treinada, mas, ao longo das atualizações, a estrutura da rede foi evoluindo. Na Figura 2.9 apresenta-se a estrutura básica da rede YOLO.




Figura 2.9 – Arquitetura básica da rede YOLO, imagem adaptada de (Soylu; Soylu, 2023)

Nesse contexto, a YOLOv8 disponível no site de Ultralytics apresenta a versão mais nova e melhorada, que permite detectar e rastrear objetos de uma forma mais rápida. Além disso, consegue segmentar os objetos detectados colocando uma máscara, a qual, permite

obter todas as informações em questão de milissegundos. A arquitetura da última versão consta de uma camada de entrada, uma rede principal pre-treinada CSPDarknet53, um módulo de atenção espacial (SAM) e um módulo SPP (Pirâmide espacial ou *Spatial Pyramid Pooling*; do inglês). Estes parâmetros permitem melhorar a detecção de objetos em diferentes tamanhos escalas, chegando a redimensionar as imagens para 640 x 640 pixels brutos (Khan *et al.*, 2019). Cabe ressaltar, que esta CNN consegue ser mais eficiente e robusta na hora de detectar, já que utiliza uma métrica de intersecção sobre união (IoU). Este parâmetro avalia a qualidade das caixas delimitadoras que prevê, sendo a razão entre a área de intersecção e a área de união da caixa delimitadora, conseguindo assim, medir a sobreposição dos objetos detectados (Terven; Cordova-Esparza, 2023).

$$IoU = \frac{\text{Área de intersecção}}{\text{Área de união}} \quad (2.7)$$

Por outro lado, Khan *et al.* (2019) e Terven e Cordova-Esparza (2023) destacam que o valor de predição de objetos apresentado sobre a caixa delimitadora é a precisão estimada (*Cs*) (*Confidence score*; do inglês). Este valor é obtido da multiplicação entre a intersecção sobre união, precisão e a probabilidade da classe (*Pc*).

$$Cs = Pc \cdot P \cdot IoU \quad (2.8)$$

Ao treinar a rede YOLOv8, é importante analisar vários argumentos técnicos que garantem o sucesso do treinamento na detecção de objetos personalizados em tempo real. De acordo com Khan *et al.* (2019), Zhang *et al.* (2023) e Yue *et al.* (2023), os aspectos a serem considerados incluem à aquisição do conjunto de dados (*dataset*), rotulado das imagens, seleção da rede pré-treinada e da arquitetura em função da aplicação, e a configuração dos hiper-parâmetros de treinamento. A escolha apropriada desses elementos contribui numa melhora ao desempenho da rede para detectar os objetos.

Nesse contexto, para treinar a rede YOLO. Primeiro, à aquisição de dados deve ser realizada de forma controlada e com um volume grande de imagens. Rosebrock (2017), Aboah *et al.* (2023), Yue *et al.* (2023), Zhang *et al.* (2023) e Soyly e Soyly (2023) treinaram uma rede YOLO com um aproximado de 1000 a 5000 imagens abarcando as distintas classes que serão detectadas. No caso que o conjunto de dados seja pequeno, podem-se utilizar diferentes técnicas que permitam incrementá-lo, como o aumento da base de dados (*data augmentation*;

do inglês), que consiste em acrescentar as imagens por meio de várias modificações como: girá-las, recortá-las e piorá-las em termos de resolução. O uso dessas técnicas permite garantir que a rede aprenda mais comportamentos ou observações específicas dos objetos (Aboah *et al.*, 2023).

Na atualidade, existe uma infinidade de programas que ajudam a rotular as imagens e as diferentes classes a serem treinadas, no entanto, com o avanço moderno da inteligência artificial destacam-se algumas ferramentas de etiquetado de acesso livre como: LabelImg, CVAT, Landing AI e SAM. A escolha correta desses softwares está associada à facilidade de uso, a forma de instalar e a rapidez do rotulado. Sendo as mais atrativas CVAT e SAM, devido a que trabalham com inteligência artificial que permite realizar o rotulado das imagens de uma forma mais rápida (Rosebrock, 2017; Soylu; Soylu, 2023). Por outro lado, para escolher a rede pré-treinada e a estrutura de YOLO, dependerá muito da aplicação na que a rede trabalhará. Na última versão de YOLO criada por ultralytics apresenta e dispõe várias redes pré-treinadas para detecção, classificação, segmentação, rastreamento. Essas CNN estão estruturadas com uma arquitetura CSPDarknet53 e uma metodologia de multiescala para o treinamento (Soylu; Soylu, 2023).

Finalmente, a configuração dos hiper-parâmetros de treinamento é a parte mais crucial que garante o sucesso da aprendizagem constante da rede. Entre os mais conhecidos e utilizados temos: o número de épocas, número de lote (*batch*; do inglês), umbrais de confiança (*iou*), taxa de aprendizagem, instâncias. O número de épocas corresponde ao número de iterações completas que o conjunto de dados atravessa a rede, aprendendo assim os padrões de treinamento. O número de lotes são os subconjuntos de dados de treinamento, usados para uma iteração (época). Os umbrais de confiança permitem ao modelo prever ou rejeitar as detecções em base à confiança colocada. A taxa de aprendizagem determina a velocidade de ajuste dos pesos. Finalmente, a instância está relacionada com a quantidade de objetos individuais presentes no conjunto total de dados (Rosebrock, 2017; Khan *et al.*, 2019; Yue *et al.*, 2023).

Cabe mencionar, que YOLO implementa um conjunto de técnicas de regularização, que ajuda a evitar o Sobreajuste (*Overfitting*; do inglês), o qual é o fenômeno de treinamento onde o modelo não apenas aprende as configurações e os padrões, mas também consegue capturar ruído, dando como resultado que a rede não consiga detectar dados que não estiveram presentes no treinamento (Rosebrock, 2017). Como conclusão, é importante analisar que a escolha dos hiper-parâmetros dependerá das capacidades técnicas do computador, sendo re-

comendado uma máquina com características avançadas e modernas para o desenvolvimento correto da rede.

Até agora, nosso foco tem se centrado em como escolher a rede neural convolucional e como treiná-la, mas, de acordo com Rosebrock (2014), Suarez (2013), mencionam que para extrair a informação de detecções das CNN pode-se utilizar Python e suas bibliotecas, tais quais como: OpenCV, PyTorch e TensorFlow, e ajudam com sua versatilidade para extrair e tratar as informações obtidas mediante o uso das redes neurais convolucionais. Desse modo, com o trabalho em conjunto de Python e YOLO, podemos criar um ecossistema robusto e eficaz que permita desenvolver novas ferramentas de detecção, segmentação e rastreamento de objetos.

O uso de OpenCV permite realizar uma infinidade de tarefas, que vão desde girar e suavizar imagens, até delinear o contorno dos objetos. Segundo Rosebrock (2014), para conseguir extrair informações de objetos detectados, devem-se analisar os seguintes tópicos: processamento de imagens, suavização e desfoque dos resultados, filtros limiar (*threshold*; do inglês), traçado dos contornos. Consequentemente, os dados podem ser extraídos com o uso de bibliotecas como Pandas e Matplotlib, que estão destinadas ao desenvolvimento de uma base de dados(informações) e figuras, respectivamente.

Por outro lado, para tratar as imagens detectadas e delinear os contornos, Rosebrock (2014) e Rosebrock (2017) mencionam que a imagem necessita ser binarizada para posteriormente colocar filtros que permitam suavizar e eliminar o ruído dos contornos. Nesse contexto, o limiar (*threshold*) permite a binarização da imagem, enquanto, aos filtros temos: o gaussiano, mediano e bilateral. Essas configurações permitem corrigir o umbral de luz e melhorar a suavização dos contornos das formas identificadas.

Finalmente, para desenhar os contornos dos objetos está associado a quais propriedades ou padrões se quer extrair, sendo os métodos mais usados: a detecção de eixos (*Canny*; do inglês) e o traçado de contornos. A escolha dessas ferramentas será em função da aplicação de estudo. Por um lado, *Canny* permite obter os contornos de uma forma menos detalhada à comparação do método dos contornos. Nesse contexto, o traçado de contornos oferece uma representação direta e precisa sobre os contornos no perímetro do objeto, enquanto, a detecção de eixos permite obter informações externas, mas apresenta ruído no contorno das superfícies.

Com o objetivo de aprimorar os resultados morfodinâmicos e detecção automática de dunas barcanas, no presente estudo, utilizamos a rede neural YOLOv8 como ferramenta principal para detectar e estudar as dunas barcanas. Essa escolha estratégica nos permite ex-

plorar duas fontes distintas de dados: imagens aquáticas experimentais que se complementam com as imagens da pesquisa de Assis e Franklin (2020), e imagens de dunas capturadas por satélite; ambos cenários rotulados com a ferramenta CVAT. A aplicação da rede YOLOv8 não se limitará à detecção, mas se estenderá à classificação, segmentação, rastreamento e traçado dessas formações geológicas complexas.

3 METODOLOGIA

Neste capítulo, apresenta-se a metodologia para realizar o treinamento da rede YOLOv8 por segmentação. Inicialmente, destacamos a aquisição diversificada de imagens de dunas, envolvendo ensaios controlados para obter imagens aquáticas de dunas mediante o uso de uma bancada experimental. Dessa forma, apresentam-se os diferentes componentes que conformam a bancada experimental, o funcionamento, aquisição das imagens, as características dos grãos e o desenvolvimento dos diferentes ensaios para a obtenção das imagens. Enquanto, as imagens de dunas terrestres e marcianas foram obtidas através do uso de imagens de satélite fornecidas pelo site HiRISE, e para elaborar uma base de imagens abrangente, utilizou-se o programa HiView permitindo uma variedade de campos de dunas em diferentes locais dos satélites. Em seguida, abordamos a metodologia aplicada ao treinamento da CNN YOLOv8. Inicialmente, as imagens provenientes de experimentos e satélites foram rotuladas usando a ferramenta CVAT, atribuindo duas etiquetas principais: "*Barchan*" e "*Not a barchan*". Consequentemente, carregamos a rede pré-treinada de segmentação (*yolov8n.pt*) e configuramos os hiper-parâmetros do treinamento em função dos componentes principais do computador. Para finalizar, desenvolveu-se um código Python para extrair informações morfodinâmicas das dunas detectadas com YOLOv8, proporcionando uma compreensão aprofundada sobre a interação de dunas longo do tempo. Dessa forma, este estudo estabelece uma sólida base de informações para a detecção, classificação, segmentação, rastreamento e traçado de dunas barcanas por meio da inteligência artificial.

3.1 Criação da base de dados sobre dunas barcanas

Nesta seção, serão apresentados os diferentes métodos para a aquisição de imagens de dunas barcanas nos diferentes cenários. Desse modo, expõe-se a metodologia utilizada para desenvolver dunas aquáticas controladas experimentalmente, e os diferentes componentes da bancada experimental que serviram para a obtenção e produção das dunas. Também, detalha-se quais foram os passos utilizados para obter dunas barcanas marcianas e terrestres mediante o uso de satélites. Em geral, a geração dessa base abrangente de dunas barcanas permite um treinamento robusto e eficaz na detecção dessas formas geológicas. Vale ressaltar que foram realizados dois treinamentos distintos. O primeiro concentrou-se na detecção e rastreamento

de dunas aquáticas, explorando a morfologia e as interações ao longo do tempo. O segundo, teve como foco a análise de dunas barcanas terrestres e marcianas. Essa divisão nos treinamentos se justifica pela ausência temporal das informações necessárias para rastrear as dunas ao longo do tempo nas imagens obtidas pelos satélites, já que tal limitação decorre das escalas de tempo e comprimento. Além disso, queremos analisar se as informações obtidas com as dunas subaquáticas são escaláveis com as dunas marcianas e terrestres.

3.1.1 Dunas barcanas subaquáticas

As dunas barcanas aquáticas representam o primeiro caso de estudo a ser treinado pela rede YOLOv8. Essa escolha é motivada pelo fato de que as escalas de tempo e comprimento associadas a esse tipo de dunas são menores, conforme discutido na seção 2.2. Além disso, observamos que o fundo das imagens obtidas é predominantemente preto, criando uma clara distinção em relação aos ecossistemas encontrados na Terra e em Marte. Essa característica facilita a detecção e segmentação de objetos, em comparação com os cenários naturais onde a presença de vegetação, nuvens e outras formas geológicas torna o processo mais complexo. O sucesso da metodologia empregada neste treinamento para detectar, rastrear e delinear as dunas subaquáticas pode potencialmente estabelecer um precedente para a realização das mesmas atividades utilizando aprendizado profundo para dunas terrestres e marcianas.

Para a aquisição de imagens das dunas barcanas aquáticas, foram realizados vários ensaios controlados, utilizando grãos com diferentes materiais, tamanhos e cores. Nesse cenário, apresenta-se a bancada experimental como peça fundamental para a condução desses estudos. Adicionalmente, fornecemos detalhes sobre o funcionamento do dispositivo experimental, as características das partículas empregadas no desenvolvimento das dunas, e a obtenção de imagens. Para concluir, abordamos os passos adotados para a preparação do material granular e a execução dos ensaios. A obtenção desse conjunto de imagens permite complementar os casos de estudo apresentados por Assis e Franklin (2020), obtendo uma base robusta para o treinamento da rede.

3.1.1.1 Descrição da bancada experimental

A bancada experimental utilizada para o desenvolvimento dos ensaios de dunas barcanas aquáticas está composta de um tanque de água, duas bombas centrífugas, um medidor e retificador de fluxo (convergente/divergente), uma seção de teste e um tanque de decantação.

Dessa forma, todos esses componentes formam um sistema fechado, sendo realimentado por uma linha de retorno. Esta bancada foi projetada para impor um fluxo de água gerado por pressão no circuito fechado, seguindo a ordem mencionada. O canal possui uma seção transversal retangular de acrílico transparente para facilitar a visualização, e consta com 160 *mm* de largura e 50 *mm* de altura, e 1 *m* de comprimento. Na Figura 3.1 se pode ver uma representação gráfica da bancada experimental, enquanto, na Figura 3.2, se observa um esquema composto por fotografias do dispositivo experimental. A estrutura da seção transversal de acrílico tem 5 *m* de comprimento, no entanto, para garantir que o escoamento esteja completamente desenvolvido, a distância de entrada do canal tem que ter 3 *m* de comprimento, equivalente a 40 diâmetros hidráulicos.




Figura 3.1 – Esquema da bancada experimental.

Referente ao funcionamento do dispositivo experimental, o fornecimento contínuo do escoamento de água é garantido pela capacidade total de 1000 litros do tanque e pela linha de retorno integrada à bancada. O escoamento é impulsionado pelas duas bombas centrífugas, cada uma com uma potência nominal de 0,75 *hp*. O fluxo de água se movimenta através das mangueiras de 2 polegadas, conectadas a um filtro que evita a retenção das partículas usadas em prévios ensaios. A regulação da vazão de água é realizada por meio de um medidor de fluxo modelo *Optiflux 2010C*. Esse dispositivo permite o controle preciso da vazão com uma capacidade máxima de 20 m^3/h , mas para garantir a formação de barcanas se utiliza na faixa entre 6 e 10 m^3/h . Para garantir uma distribuição de fluxo uniforme ao longo do canal experimental, incorporamos o retificador de fluxo na montante do canal. Este dispositivo possui um injetor convergente-divergente sendo preenchido com partículas de vidro de 3 *mm* de diâmetro. A presença dessas partículas visa criar um ambiente propício para o desenvolvimento de um fluxo turbulento antes de atingir a seção de teste. Esse cuidado específico assegura que as condições




Figura 3.2 – Dispositivo experimental localizado na Faculdade de Engenharia Mecânica da Universidade de Campinas. a) Foto composta pelo tanque de água, as duas bombas centrífugas, válvulas, filtro, o medidor de fluxo e o retificador (convergente/divergente). b) Foto da seção de testes, disposição dos grãos, sistema de translação e a câmara na parte superior. c) Foto geral do canal retangular de acrílico conetado ao tanque de decantação.

turbulentas sejam estabelecidas eficazmente para os experimentos subsequentes. Ao concluir a seção de teste, o fluxo de água é direcionado para o tanque de decantação. Este tanque desempenha um papel crucial na separação e divisão dos grãos utilizados nos ensaios, evitando assim a acumulação de partículas ou impurezas ao longo da linha de retorno da bancada experimental. Este projeto é fundamental para garantir resultados precisos e confiáveis durante a realização dos experimentos.

É importante destacar que todo o experimento foi conduzido utilizando água, e as propriedades físicas e de massa serão avaliadas a uma temperatura constante de 20°C . A velocidade média ($\bar{U}$) é calculada pela relação entre a vazão e a área transversal do canal, e encontra-se na faixa de 0,243 e 0,278 m/s. Consequentemente, o número de Reynolds foi calculado em função da altura do canal (2δ) situando-se na faixa de $(1,22 \text{ e } 1,39 \cdot 10^4)$. Esses parâmetros proporcionam informações fundamentais para compreender o escoamento que têm as dunas barcanas na seção de testes. O número de Reynolds é definido como:

$$Re = \frac{\rho \cdot \bar{U} \cdot 2 \cdot \delta}{\mu} \quad (3.1)$$

onde ρ é a densidade do fluido, δ altura média do canal e μ a viscosidade dinâmica do fluido.

3.1.1.2 Características dos grãos

Para desenvolver os experimentos controlados foram utilizadas várias partículas redondas de vidro e de zircônio, com densidades de ($\rho_s = 2500 \text{ kg/m}^3$) e ($\rho_s = 4100 \text{ kg/m}^3$), respectivamente. Desse modo, os diâmetros dos grãos variaram inicialmente entre 0,15 mm e 0,25 mm utilizando partículas de vidro, e posteriormente entre 0,4 mm e 0,6 mm empregando esferas de zircônio. Por outro lado, foram consideradas diferentes cores para as partículas de vidro, tais quais como: branca, vermelha, azul e verde, abrangendo uma extensa quantidade de imagens de dunas barcanas aquáticas.

3.1.1.3 Aquisição de imagens experimentais

Nesta etapa se empregou um sistema de translação, uma câmara, um sistema de iluminação e um computador para extrair as informações dos ensaios realizados. Dessa forma, na parte superior do sistema de translação, coloca-se uma câmara de alta velocidade ou convencional. Tanto a câmara como o sistema de translação foram controlados por um computador, desse modo, o campo de visão e a região de interesse (ROI) foram configurados de acordo com: a área de trabalho, o número de dunas e a velocidade dos grãos. Em alguns cenários de estudo, o deslocamento desses dispositivos é necessário para capturas as diferentes interações das barcanas.

3.1.1.3.1 Câmera

A sequência de imagens dos experimentos foram obtidos por uma câmara de alta velocidade e outra câmara convencional (CMOS). Ambos aparatos permitem a obtenção das imagens de dunas barcanas em altas resoluções. Assim, a câmara rápida dispõe de uma resolução máxima de 2560 x 1600 px com 800 Hz, enquanto, a câmara convencional de marca Nikon atinge uma resolução máxima de 1920 x 1080 px a 60 Hz. Além disso, na câmara Nikon foi colocado uma lente de distância focal de 60 mm com uma abertura máxima de F2,8. Consequentemente, com a disposição da câmara na parte superior do sistema de translação, teve-se

controle sobre a região de interesse (ROI). O ajuste do foco e da abertura foram escolhidos manualmente conforme à luz providenciada do sistema de lâmpadas LED. Na Figura 3.3 pode-se observar a câmera convencional usada nos ensaios.



Figura 3.3 – Câmera Convencional Nikon.

3.1.1.3.2 Sistema de translação

O sistema de translação é um dos elementos mais importantes na aquisição de dados, já que permite desenvolver vários estudos na seção de testes. Na parte superior, este elemento possui um suporte de aço que permite utilizar desde câmeras convencionais até lasers. O sistema de translação está composto por 2 trilhos de translação, 2 motores a passo que permitem movimentar os dois eixos e os suportes para as câmeras. Os trilhos de translação possibilitam regular o deslocamento da câmera de forma transversal e longitudinal. Esta movimentação pode ser configurado pelo software *DaVis* aceitando uma translação entre 1 e 500 *mm* garantindo que a câmera possa ser posicionada nas diferentes áreas de interesse. Desse modo, com o controle do posicionamento este elemento favorece e facilita que os ensaios sejam reprodutíveis e eficazes. Na Figura 3.4 pode-se observar o sistema de translação utilizado nos ensaios.

3.1.1.3.3 Softwares para a aquisição de imagens

Para adquirir imagens das dunas barcanas aquáticas, foi utilizado um computador conectado a uma câmera convencional. Desenvolveu-se um código em Python para capturar imagens ou vídeos em diferentes momentos, garantindo a continuidade dos ensaios sem interrupções. Essa configuração computador-câmera possibilita avaliar se os ensaios estão ocorrendo



Figura 3.4 – Sistema de translação.

em condições ideais, além de permitir o armazenamento direto das imagens geradas no computador. Isso viabiliza a realização de vários ensaios sem sobrecarregar a memória da câmera. Essas configurações técnicas otimizam o processo de aquisição das imagens das dunas.

3.1.1.4 Ensaios

Ao longo deste trabalho, foram desenvolvidos seis ensaios que complementam as imagens obtidas por Assis e Franklin (2020). Dessa forma, detalhamos a preparação dos grãos e os parâmetros considerados para realizar os experimentos controladamente. Assim, pode-se garantir que as dunas barcanas se desenvolvam certamente nas diferentes interações mencionadas na seção 2.2.2.

3.1.1.4.1 Preparação do material granular

A preparação do material granular é muito importante para a criação de dunas barcanas aquáticas, já que o desenvolvimento da barcana está relacionado com a relação entre as densidades das partículas e do escoamento. Os grãos usados nos diferentes ensaios controlados foram definidos na seção 3.1.1.2. Nessa seção detalhamos o processo para preparar o material granular. Primeiro dividimos as partículas por tamanho, material e cor. Depois, o material é medido numa balança métrica, colocando entre 4 e 5 gramas em um recipiente higienizado e seco.

O peso das massas dependerá do caso de interação que se deseja desenvolver. Esta balança tem uma precisão de 0,005 g com um incremento de 0,01 g.

3.1.1.4.2 Desenvolvimento dos ensaios

Para realizar os ensaios controlados das dunas barcanas, colocamos as pilhas de grãos na seção de testes, onde a inserção do material é feita de forma controlada e gravitacional. Assim, quando o canal está completamente cheio de água e desligado, abrimos a janela de deposição para colocar as partículas na seção de testes. Consequentemente, formam-se várias pilhas cônicas em posições alinhadas e desalinhadas. Dessa forma, quando o fluxo é imposto, cada uma das pilhas de grãos se deforma e as barcanas são criadas e interagem entre si. Os ensaios foram desenvolvidos ao longo de 10 *min* com as condições físicas mencionadas na seção 3.1.1.1. Cabe mencionar que, ao colocarmos os grãos na seção de teste, colocamos uma folha milimetrada que permite obter as dimensões reais no instante zero dos ensaios. Assim, podemos saber se as dimensões obtidas com a rede são as corretas. Na Figura 3.5, podemos observar a disposição dos elementos para realizar os ensaios



Figura 3.5 – Disposição dos elementos do experimento.

3.1.2 Dunas barcanas terrestres e marcianas

Para ampliar os conhecimentos adquiridos com as dunas barcanas aquáticas, desenvolvemos uma rede de aprendizado profundo que utiliza imagens de dunas obtidas por satélites.

Para o segundo treinamento da rede YOLOv8, utilizamos esse conjunto de dados, porém, o rastreamento das barcanas detectadas não foi incluso devido às escalas de tempo e comprimento. A obtenção de dados de dunas barcanas por meio de satélites apresenta vários desafios, pois o acesso a essas informações é limitado, dada a restrição em alguns satélites. Contornando essa limitação, obtivemos imagens de dunas terrestres e marcianas através dos sites Google Earth e HiRISE, respectivamente. Desse modo, este treinamento está aberto para futuras melhorias que visem incluir imagens de áreas terrestres e marcianas adicionais. É relevante mencionar que os resultados apresentados na seção 4.2 para este estudo são de Marte, devido à alta resolução e disponibilidade das imagens fornecidas pelo site HiRISE. Este enfoque se justifica pela riqueza e detalhes presentes nas imagens marcianas, proporcionando uma base sólida para a análise das características das dunas barcanas.

3.1.2.1 Aquisição de imagens com satélites

Obter imagens das dunas barcanas em cenários terrestres e marcianos é um desafio complexo, principalmente devido à quantidade de imagens limitadas por alguns satélites gratuitos. Outro problema enfrentado nesse treinamento é encontrar informações passadas temporais sobre as interações das dunas barcanas nesses cenários. Nesse contexto, o satélite previsto HiRISE permite observar detalhadamente dunas barcanas em diferentes localizações marcianas e terrestres, também, essa plataforma fornece informações essenciais como os parâmetros ambientais do lugar e a distância que esteve o satélite. Essas configurações contribuem para uma compreensão detalhada da morfologia, pois permitem calcular os tamanhos das barcanas nesses cenários.

Além disso, HiRISE trabalha em conjunto com o programa HiView (desenvolvidos pela Universidade de Arizona) para o entendimento a mais detalhe das formações geológicas marcianas. Esta ferramenta permite uma exploração mais profunda dos mapas, permitindo escolher uma área de estudo em específica para acrescentar a base de dados sobre dunas barcanas marcianas. Essa abordagem proporciona a extração de imagens com diversas dimensões e interações de barcanas, enriquecendo ainda mais o conjunto de dados disponível para o treinamento da rede YOLOv8.

3.1.2.1.1 Softwares para a aquisição de imagens

Um total de 225 mapas de dunas barcanas estão disponíveis no site de HiRISE. No entanto, através do uso do HiView, conseguimos extrair um volume ainda maior de imagens. Essa ferramenta permite a seleção de diversas áreas de estudo, essenciais para enriquecer nosso conjunto de dados. O HiView não apenas amplia e analisa as dunas existentes, senão, também possibilita ao desenvolvimento de novos campos de dunas, contribuindo para a diversificação e robustez do conjunto de dados. A Figura 3.6 fornece uma visão detalhada de como HiView realiza essas atividades. Na esquerda, observamos o mapa obtido pelo HiRISE, enquanto, na direita, vemos como se pode gerar um conjunto de dados extenso, selecionando diversas áreas de estudo. Esse processo é vital para garantir uma base de dados robusta para treinar a rede YOLOv8. Para finalizar, considera-se a extração de imagens que contenham campos de dunas com barcanas isoladas e em colisões, criando cenários diversos que permitam a detecção correta das barcanas em diferentes situações e ecossistemas.




Figura 3.6 – Aquisição da base de dados usando o programa *HiView*.

3.2 Treinamento da rede YOLOv8

Nesta seção, serão apresentados os diferentes passos para treinar uma rede YOLOv8 usando imagens de dunas barcanas aquáticas, terrestres e marcianas. Dessa forma, criou-se um conjunto de dados contendo imagens de dunas barcanas, detalhado na seção 3.1. Depois,

as imagens foram rotuladas usando a plataforma CVAT, utilizando o método de segmentação e polígonos. Durante o processo de rotulação, foram consideradas duas etiquetas principais. Consequentemente, organizamos os dados em conjuntos de treinamento e validação com base nas imagens marcadas. Posteriormente, para treinar a rede YOLOv8 carregaram-se as redes pré-treinadas de segmentação. Então, se modificaram os hiper-parâmetros que permitam um aprendizado eficiente e robusto. Para aprofundar a parte morfológica das dunas, se desenvolveu um código em Python que permite extrair os valores numéricos da morfologia das dunas barcanas para concluir com a análise da geometria das dunas barcanas ao longo do tempo. Cabe mencionar, que esta metodologia utilizada será a mesma para treinar a segunda rede para detectar, classificar, segmentar e contornar dunas barcanas marcianas e terrestres. No entanto, esses treinamentos se diferenciam pelo número de imagens adquiridas e do rastreamento ao longo do tempo (interações entre dunas). Nesse contexto, na Figura 3.7 pode-se observar a arquitetura e o esquema metodológico usados no treinamento da rede YOLO.




Figura 3.7 – Arquitetura e esquema de funcionamento da rede YOLO v8 para detectar dunas barcanas.

3.2.1 Rotulado das imagens

O sucesso do treinamento não está apenas vinculado à arquitetura da rede neural, mas também à qualidade do conjunto de imagens adquiridas e ao processo meticuloso de rotulação. O processo de rotulação é o passo mais demorado no treinamento de uma rede (CNN), mas permite identificar as características principais de vários objetos (etiquetas), desempenhando um papel fundamental na classificação e na segmentação. Dessa forma, foram marcadas 7455 imagens contendo dunas aquáticas (Caso 1) e 1187 imagens com dunas terrestres e marcianas (Caso 2). A ferramenta escolhida para esse processo foi o CVAT, que permite segmentar os contornos dos objetos por meio de polígonos. Cabe destacar, que esta plataforma também oferece a opção

de marcação tradicional, utilizando caixas limitadoras para objetos. Em geral, CVAT destaca-se como uma ferramenta inovadora que utiliza Inteligência Artificial para rotular automaticamente as formas, tornando o processo mais eficiente e rápido. Além disso, esta plataforma por estar disponível de forma online, facilita a execução do trabalho em diferentes máquinas. A Figura 3.8 ilustra o processo de rotulação empregado neste estudo, onde os contornos em rosa representam a etiqueta "*Barchan*", enquanto os contornos em vermelho representam a etiqueta "*Not a barchan*". Esse procedimento meticuloso é crucial para garantir a identificação correta das formas e a precisão de segmentação (máscaras) no treinamento da rede.




Figura 3.8 – Rotulado das imagens com CVAT.

Concluída a etapa de rotulação, o CVAT possibilita a obtenção dos dados marcados em diversas extensões. No entanto, optou-se por exportar os dados em um formato de segmentação e máscaras, sendo o foco do treinamento com YOLO. As máscaras desempenham um papel fundamental neste estudo, permitindo à rede obter as superfícies das dunas marcadas. Essa abordagem torna-se particularmente relevante, pois, ao delinear a superfície de certas formas, o fundo muitas vezes representa um desafio considerável, já que contem informações irrelevantes que estão na área de detecção. Essa escolha estratégica visa garantir uma análise mais precisa e focalizada nas características morfológicas das dunas, eliminando possíveis interferências desnecessárias do ambiente circundante na hora de detectar dunas barcanas.

3.2.2 Preparação dos dados e do entorno

Após concluir os processos de aquisição e rotulação de imagens, passamos à preparação do conjunto de imagens destinado ao treinamento. Nesta etapa, empregam-se técnicas

como o aumento de dados (*data augmentation*; do inglês), que envolve a rotação e corte das imagens, mudar o tamanho da imagem, adição de ruído, etc. Essa abordagem permite aumentar a base de dados utilizada para treinar a rede, proporcionando um aprendizado mais profundo e robusto para identificar as diferentes geometrias. Em geral, no treinamento das imagens experimentais não utilizamos o *data augmentation*, enquanto, para as imagens de satélite, essa técnica foi adotada devido à escassez de imagens obtidas. Em seguida, as máscaras geradas pelo CVAT são convertidas em polígonos, resultando em um arquivo .txt contendo todos os pontos ao redor da superfície, juntamente com as classes atribuídas; onde 0 representa a classe *Barchan* e 1 a classe *Not a barchan*.

Para concluir, estrutura-se o ambiente de trabalho, consistindo em duas pastas, uma para as imagens e outra para os valores dos polígonos das etiquetas (*Labels*; do inglês). Cada pasta é subdividida em duas e são destinadas ao treinamento e à validação da rede. No cenário experimental, foram utilizadas 876 imagens para validação, enquanto, para o caso de satélite, considerou-se um conjunto de 270 imagens. Estes valores oscilam entre os 10% e 20% da base total de imagens, proporcionando uma abordagem equilibrada para o treinamento e avaliação da rede.

3.2.3 Parâmetros do treinamento

Na seleção dos parâmetros de treinamento, é fundamental associá-la com as características técnicas do computador que será utilizado para o processo de treino. Neste estudo, se utilizou um computador que trabalha com um ecossistema de Ubuntu 20 equipado com um processador Intel Core i9, uma placa gráfica RTX 2070, uma unidade de estado sólido (*SSD*) de 512 GB e duas unidades internas de 4TB. Além, recomenda-se a utilização da GPU para otimizar o desempenho técnico da rede ao longo do aprendizado, exigindo a instalação dos pacotes da Nvidia (CUDA 11.5 e cudnn toolkits 8.8.0) compatíveis com as características da placa gráfica.

Dessa forma, procede-se à instalação da versão 8 da rede YOLO através da seguinte linha de comando no terminal: `pip install ultralytics==8.0.58`. Adicionalmente, foi utilizado o peso pré-treinado de segmentação (*yolov8n.pt*) disponível no site oficial da Ultralytics. Na fase final, os hiper-parâmetros foram ajustados conforme à capacidade técnica do computador, fixando um número de épocas em 300 e um tamanho de lote (*batch*) de 7. Os demais parâmetros de treinamento foram configurados automaticamente pela rede. Com essas considerações, o

primeiro treinamento, utilizando imagens experimentais, durou cerca de 8 horas para atingir o número planejado de épocas. Em contraste, o segundo treinamento, com imagens de satélite, levou aproximadamente 2 horas. Essa diferença no tempo está relacionada à quantidade de imagens processadas em cada uma das épocas, refletindo a complexidade dos conjuntos de dados utilizados.

Para avaliar o sucesso do treinamento na aprendizagem e detecção das dunas barcanas, a rede YOLOv8 gera um arquivo .txt contendo diversos parâmetros ao longo das 300 épocas. Esse arquivo proporciona informações cruciais, incluindo a análise dos parâmetros de perda durante o treinamento, a média de precisão (mAP), a taxa de *recall*, entre outros. Adicionalmente, a rede fornece gráficos da matriz de confusão para duas ou mais classes, permitindo uma compreensão mais detalhada do desempenho do modelo em termos de classificação e detecção. Esses recursos analíticos são essenciais para uma avaliação abrangente do desempenho da rede para detectar e classificar as dunas barcanas.

3.2.4 Extração dos dados morfológicos

O treinamento da rede YOLOV8 proporciona uma caixa delimitadora, a etiqueta de classificação, o Id de rastreamento da duna, a porcentagem da precisão estimada (Cs) mencionada na seção 2.3.1.1 e a máscara de segmentação da superfície do objeto detectado. Isso pode-se observar a mais detalhe na segunda imagem da Figura 3.9. Cabe ressaltar, que esta versão de YOLO realiza o rastreamento das dunas nativamente, pelo qual, não precisa se adaptar algum código adicional de rastreamento de objetos.

Para extrair os dados morfológicos das dunas barcanas detectadas pela rede YOLO, se desenvolveu um código de Python com bibliotecas como: *OpenCV* para colocar os diferentes filtros que permitiram processar a máscara a uma escala binária para delinear o contorno da forma e salvar os resultados das imagens, *NumPy* para criar os arranjos que contém todas as informações da superfície da duna, e *Pandas* para criar um arquivo de dados que contenha as diferentes informações da morfologia da duna ao longo do tempo.

Na Figura 3.9, é possível observar o processo realizado para delinear o contorno da duna utilizando a máscara de segmentação fornecida pela rede YOLOv8. Em primeiro lugar, nota-se que a rede solicita uma imagem de entrada a ser detectada e retorna uma máscara de segmentação vermelha, em conjunto de uma caixa delimitadora, a classe e a precisão estimada da detecção. Posteriormente, a máscara é convertida de RGB para escala binária e redimensionada

para aplicar um filtro limiar (*threshold*; do inglês) para binarizá-la e um filtro mediano (*median*) que suaviza o contorno da duna. Após a aplicação desses filtros, o contorno é delineado. Esse processo é demonstrado ao longo da sequência de imagens da Figura 3.9. Vale ressaltar que os filtros utilizados foram implementados com OpenCV, sendo definido um valor de limiar de 250 com uma relação binária, enquanto para o filtro mediano, foi utilizado um valor de 11.




Figura 3.9 – Esquema para delinear os contornos das barcanas.

O contorno da duna barcana proporciona todos os pontos ao longo da barcana espaçados com uma distância de $0,00005 \text{ px}$, permitindo calcular várias informações como: a área e a inércia do corpo para calcular seus centroides. Dessa forma, com o uso da biblioteca *NumPy*, se criou um arranjo que contenha todas as coordenadas dos pontos referentes ao contorno da duna. Para analisar a morfologia da barcana, são necessários quatro pontos importantes, conforme detalhado na Figura 3.10. O primeiro ponto a ser obtido é o ponto superior (P_0). Em seguida, os pontos dos extremos correspondentes aos chifres são localizados usando funções de máximos e mínimos (P_1) (P_3). Finalmente, para calcular o ponto correspondente à face de deslizamento (P_2), foram utilizadas duas linhas retas que delimitam uma nova área de interesse formando um triângulo desde o ponto superior e os extremos, conforme realizado no trabalho de Merwe *et al.* (2022).

Para analisar os parâmetros da morfologia da duna barcana se calculam em função dos pontos obtidos: o comprimento (L), a largura (W) e os comprimentos dos chifres (L_{hl}) e (L_{hr}) para o lado esquerdo e direito, respectivamente. Essas informações podem ser visualizadas na Figura 3.10. Além das propriedades morfológicas, nessa Figura podemos visualizar a precisão estimada Cs , a classificação *Barchan*, o contorno da duna em verde, e o Id de rastreamento *Shape 1*. Se escolheu a palavra *Shape* para referenciar as duas etiquetas.




Figura 3.10 – Parâmetros morfológicos de estudo.

Por outro lado, para calcular o valor do comprimento se utiliza $(P_2 - P_0)$, para a largura usa-se o valor da caixa delimitadora no eixo x , e os comprimentos dos chifres calculam-se com $(P_2 - P_3)$ e $(P_2 - P_1)$ para cada extremo. Cabe ressaltar que neste estudo utilizamos o comprimento médio dos chifres ($\overline{L_h}$). Para obter as dimensões reais das dunas, deve-se colocar uma conversão de pixels para as medidas em m ou mm . Sendo na ordem de milímetros para as dunas subaquáticas, e de metros para as dunas terrestres e marcianas. No entanto, para as formas (*Shape*) que não correspondem a uma barcana, para a obtenção dos parâmetros morfológicos, consideraram-se as dimensões da caixa delimitadora prevista pela rede.

Finalmente, para extrair os valores sobre a morfologia da duna, se utilizou a biblioteca *Pandas*, que permitiu criar um arquivo de dados que contenha estas informações ao longo do tempo. Esse arquivo não apenas organizou os dados obtidos, mas também registrou outras propriedades, como precisão de detecção, classe identificada, posicionamento, área e os valores da morfologia calculados previamente. Dessa forma, para compreender e analisar as interações e colisões das dunas aquáticas ao longo do tempo, normalizamos a largura pelo comprimento, obtendo assim a razão de aspecto (W/L). Os resultados da análise morfológica neste estudo incluem a razão de aspecto (W/L), posicionamento (P_y), comprimento médio dos chifres ($\overline{L_h}$), a área (A), e a detecção da rede ao longo do tempo. Por outro lado, no caso das dunas terrestres e marcianas, apresentamos os valores morfológicos, devido a que não temos acesso a eventos passados dessas dunas nesses cenários.

4 RESULTADOS

Neste capítulo, serão apresentados os resultados obtidos no treinamento da rede neural YOLOv8. Inicialmente, serão detalhados os resultados do treinamento para o caso experimental (dunas aquáticas), abordando a análise da eficiência e a média de predição (mAP) da detecção obtida pela rede ao longo das 300 épocas. Em seguida, discutem-se os resultados relativos à detecção, classificação e rastreamento das dunas, considerando os diferentes padrões apresentados no estudo de Assis e Franklin (2020). Além disso, são apresentados os resultados obtidos da morfologia das dunas em diversas interações identificadas. Posteriormente, apresenta-se os resultados do segundo treinamento para detectar e classificar dunas barcanas terrestres e marcianas, fornecendo novos dados de detecção e classificação das formas. Esses resultados são acompanhados por uma análise das dimensões das dunas detectadas. É importante ressaltar que os conteúdos e arquivos apresentados neste trabalho, como as redes neurais treinadas, os códigos desenvolvidos para a detecção de dunas e as imagens utilizadas nos treinamentos, estão disponíveis nos repositórios abertos: (Cunez; Franklin, 2023a), (Cunez; Franklin, 2023b) e (Cunez; Franklin, 2023c).

4.1 Treinamento da rede usando imagens experimentais

Nesta seção, aprofundaremos na análise dos resultados obtidos pela rede neural YOLOv8 ao utilizar as imagens adquiridas durante os experimentos conduzidos no laboratório, conforme descrito na seção 3. Além disso, apresenta-se o desempenho da rede ao processar e detectar as características das imagens de dunas subaquáticas. Dessa forma, examinamos a detecção, classificação, segmentação e rastreamento das dunas barcanas nos diferentes padrões mencionados na seção 2.2.2. Finalmente, discutem-se os resultados obtidos da rede para analisar a morfologia das dunas.

4.1.1 Resultados de aprendizagem da rede

No contexto de melhorar a identificação de dunas, foi desenvolvida uma nova rede neural (YOLOv8), que incorpora informações específicas sobre os cinco padrões de interações binárias de barcanas discutidos na seção 2.2.2. O conjunto de treinamento incluiu 7.455 imagens, enquanto o conjunto de validação compreendeu 876 imagens, abrangendo dunas subaquá-

ticas de diferentes tipos, tamanhos e cores, e imagens obtidas por Assis e Franklin (2020). Essas escolhas resultaram em um desempenho eficiente da rede, permitindo uma detecção, classificação, segmentação e rastreamento precisos das dunas barcanas, contribuindo para uma detecção mais precisa, robusta e confiável.

Na Figura 4.1, são apresentados os resultados das perdas da rede em relação ao número de épocas obtidas durante o treinamento. Observa-se que o treinamento demonstra uma alta eficácia na detecção de ambas as classes ("*Barchan*" e "*Not a barchan*"), conforme evidenciado pelos baixos valores de perda ao longo do processo. Essas perdas representam a discrepância entre as previsões do modelo e as verdadeiras etiquetas dos objetos nos dados de treinamento, sendo usadas para ajustar os pesos do modelo durante o treinamento, de modo que as previsões se aproximem cada vez mais das etiquetas reais. As curvas de perda para o conjunto de treinamento e validação exibem comportamentos semelhantes, indicando que o modelo consegue detectar dados não vistos. Além disso, esta Figura revela que o valor inicial da perda é aproximadamente 1,2 e diminui consistentemente para cerca de 0,15, sem apresentar muitos picos ou variações abruptas. Consequentemente, com essas observações sugere-se que o treinamento é robusto e eficaz, alcançando uma convergência estável. Diante disso, para futuros treinamentos, considera-se o uso de 150 ou 200 épocas pode ser apropriado, pois esses são os pontos onde a convergência do treinamento começa a ocorrer, como indicado pela estabilização das curvas de perda.




Figura 4.1 – Perda vs épocas no caso de dunas subaquáticas

Por outro lado, na Figura 4.2, a média de precisão da rede no conjunto de treino para a detecção de dunas barcanas é evidenciada, atingindo um mAP (*mean average precision*) superior a 99%, assegurando resultados notáveis para a previsão e rastreamento das dunas. Observa-se, nos primeiros estágios do treinamento, que o mAP exibe vários picos de ruído, variando de maior a menor. No entanto, essa métrica melhora e se estabiliza a partir da época 120, o que significa que o modelo está aprendendo corretamente os padrões relevantes no treinamento e indica uma convergência efetiva dos resultados.




Figura 4.2 – Predição média de detecção vs épocas (laboratório)

4.1.2 Resultados de detecção, classificação, rastreamento e segmentação das dunas barcanas

Para avaliar a capacidade da rede YOLOv8 em desempenhar as tarefas de detecção, classificação, segmentação e rastreamento ao longo do tempo, são apresentados diversos resultados referentes a diferentes configurações e interações de dunas, conforme investigado por Assis e Franklin (2020). Nesse contexto, analisamos a eficácia de detecção e classificação da CNN em diferentes cenários e condições. Os resultados apresentados pela rede incluem a precisão estimada (Cs), as classes ("*Barchan*" e "*Not a barchan*"), a identificação de rastreamento (*Shape I*), a caixa delimitadora e o delineamento das superfícies para calcular os valores dos parâmetros morfológicos das dunas evidenciados na seção 3.2.4. Dessa forma, são apresentadas as análises dos resultados da morfologia conforme discutido na seção 2.2.1. Esta análise aborda quatro casos diferentes de estudo e pretende avaliar a precisão na detecção e rastreamento das posições e contornos das barchans, calculando-se os aspectos morfológicos que permitam iden-

tificar se as dimensões estão na literatura de estudos prévios. Os parâmetros calculados são: o comprimento L , a largura W , o comprimento médio dos chifres ($\overline{L_h}$) e a área de superfície A das barcanas. Esses cálculos seguem as definições estabelecidas na seção 3.2.4.

4.1.2.1 Resultados para uma configuração do tipo *Exchange*

Na Figura 4.3, são apresentadas diversas sequências de imagens (*snapshots*) de uma interação do tipo *exchange*, destacando a colisão entre uma duna vermelha e uma duna branca. A fim de compreender essa interação, são exibidos sete instantes de tempo (t1-t7), marcando os pontos mais relevantes do ensaio. Inicialmente, o experimento inicia com uma barchan desenvolvida a jusante e uma pilha de grãos vermelhos colocada a montante. Aos 98 segundos, ocorre a colisão e fusão das dunas, e posteriormente, aos 198 segundos, a duna branca proeminente ejeta outra barchan, que se desloca mais rápido. Desse modo, pode-se observar que a CNN consegue detectar de forma precisa e eficiente, com uma precisão estimada (C_s) acima de 90% para ambas as classes ao longo das interações (colisões e fusões); neste caso, podemos ver como a etiqueta "*Not a barchan*" é usada para detectar as pilhas de grãos e as formações que não correspondem a uma barchan.

Adicionalmente, nota-se que a etiqueta de rastreamento da duna permanece constante para a duna principal *Shape 1*, enquanto a pilha de grãos vermelhos é rotulada como *Shape 2* e a nova duna ejitada como *Shape 3*. Esse resultado demonstra que o rastreamento consegue seguir todas as formas presentes no experimento. É importante destacar que a CNN treinada consegue identificar corretamente como uma única barcana a duna inicialmente fundida nos tempos ($t = 98$ a 130 s), mesmo quando os grãos vermelhos mantêm uma forma semelhante à de uma barcana. Este é um resultado significativo devido a que outras redes têm dificuldade em identificar este tipo de interações.

Por outro lado, complementando os resultados obtidos de detecção, classificação, rastreamento e segmentação, realizamos a análise morfológica para esse caso. Os resultados deste estudo podem ser observados nas Figuras 4.4 a-d, que mostram a evolução temporal da relação de aspecto W/L , comprimento médio dos chifres ($\overline{L_h}$), posição longitudinal P_y , e a área projetada A ao longo do tempo de ensaio. Além, destacam-se os intervalos de tempo definidos na Figura 4.3. Dessa forma, procede-se a detalhar as informações morfológicas obtidas das 3 dunas.




Figura 4.3 – Detecção, classificação, segmentação e rastreamento de um caso *Exchange*, figura extraída de Cúñez e Franklin (Scientific Reports, under review).

Na Figura 4.4a, destaca-se como a relação de aspecto possibilita a análise da mudança na morfologia ao longo do tempo, indicando se a duna está se alongando. Os resultados do *Shape 2* mostram que a forma não evoluiu para uma duna barchana, enquanto o *Shape 1* revela a relação de aspecto de uma duna desenvolvida, obtendo valores menores que 1, e o *Shape 3* mostra como a duna ejetada variou sua morfologia, tornando-se menos alongada no final.

A Figura 4.4b permite analisar o comportamento dos chifres. Notavelmente, a duna 1 no instante t5 ($t = 198$ s) se deforma devido à ejeção da outra duna, resultando no aumento do comprimento dos chifres. Nos instantes finais, em t7 ($t = 290$ s) o chifre da esquerda apresenta um comprimento maior, reduzindo o valor nesse tempo, depois desse tempo podemos ver como o valor do comprimento oscila, o que significa que qualquer dos dois chifres se alongou.

É importante mencionar que o posicionamento da duna foi determinado usando o centroide no eixo y, como evidenciado na Figura 4.4c, onde a duna branca apresenta uma redução devido à mudança de massa entre as dunas, ademais, esta figura permite obter informações físicas como a velocidade com a qual a duna foi se movimentando.

A análise da Figura 4.4d fornece informações sobre o intercâmbio de massa entre as dunas. Por exemplo, em t2 ($t = 58$ s) a duna 1 aumenta sua área devido à colisão e fusão com a duna 2, enquanto, durante a ejeção da duna 3, observa-se uma redução na área.

Para finalizar, a análise do caso *Exchange*, a Figura 4.5 foi elaborada para oferecer informações detalhadas sobre como a rede YOLOv8 classificou e detectou as formações aquáticas ao longo do tempo. Assim, utilizamos bolhas vermelhas para representar a classe

"Barchan" e formas azuis (X) para "Not a barchan". Ao examinar essa Figura, pode-se ver que a CNN desempenhou um trabalho eficaz e preciso na detecção das duas classes nos diferentes instantes temporais, já que ajuda a compreender como as dunas foram mudando de morfologia ao longo das interações e colisões.




Figura 4.4 – Resultados da morfologia do caso *Exchange*, figura extraída de Cúñez e Franklin (Scientific Reports, under review).




Figura 4.5 – Detecção ao longo do tempo da Figura 4.3.

4.1.2.2 Resultados para uma configuração do tipo *Chasing*

Na Figura 4.6, são apresentadas diversas sequências de imagens (*snapshots*) em sete instantes de tempo (t_1 - t_7), de uma interação do tipo *chasing*, destacando o desenvolvimento de duas pilhas de grãos em dunas barcanas. Nesse ensaio se utilizaram uma configuração de partículas misturadas, sendo vermelho com branco para o *Shape 1* e azul com branco para o *Shape 2*. Da mesma forma, a CNN consegue detectar de forma precisa e eficiente ambas classes, com uma precisão estimada (C_s) acima de 90%. A detecção desse caso de estudo destaca porque as dunas foram detectadas como um corpo só, independentemente que na parte inferior (cresta) estejam partículas brancas. Além, o rastreamento realizado pela rede consegue manter os *Shape* das dunas, incluso ao incrementar a distância entre as duas barcanas.




Figura 4.6 – Detecção, classificação, segmentação e rastreamento de um caso *Chasing*, figura extraída de Cúñez e Franklin (Scientific Reports, under review).

A Figura 4.7a apresenta a relação de aspecto (W/L) para ambas dunas, destaca-se que os valores de este parâmetro mantêm-se constante. No caso do *Shape 1* tanto comprimento e largura são relativamente iguais, enquanto, no *Shape 2* a duna é alongada, o que faz que esta relação seja menor.

A Figura 4.7b mostra com mais detalhe o processo como uma duna barcana é desenvolvida mediante uma pilha de grãos. Desse modo, os valores apresentados dispõem de um incremento relacionado com a formação dos chifres da barcana. A partir de t_2 ($t = 100$ [s]) este valor tem uma tendência oscilatória entorno a um valor fixo, o que está relacionado como os grãos são depositados nos chifres quando a duna se desloca. A Figura 4.7c permite observar

que o movimento da barcana ao longo do tempo tende a ser linear. Isso, deve-se a que a vazão com a qual os ensaios foram desenvolvidos se manteve constante. No entanto, isso também está associado com a disposição das barcanas.

A Figura 4.7d mostra como a área das dunas aumenta com o desenvolvimento da duna. Assim, os valores baixos correspondem à pilha de grãos, enquanto que os valores altos estão associados ao alongamento da duna.

Para concluir a análise do caso *Chasing*, a Figura 4.8 foi criada para apresentar as detecções da CNN ao longo do tempo. Dessa forma, pode-se observar como a rede classificou a pilha de grãos como "Not a barchan" nos primeiros 30 segundos e quando a barcana foi desenvolvida colocou "Barchan". Essa informação é reveladora, já que indica que a rede pôde identificar a transição da pilha de grãos para uma barcana. Isso sugere que a rede conseguiu aprender a mudança na morfologia das formações ao longo do tempo.




Figura 4.7 – Resultados da morfologia do caso *Chasing*, figura extraída de Cúñez e Franklin (Scientific Reports, under review).




Figura 4.8 – Detecção ao longo do tempo da Figura 4.6.

4.1.2.3 Resultados para uma configuração do tipo *Fragmentation-chasing* alinhada

Na Figura 4.9 são apresentadas diversas sequências de imagens (*snapshots*) em sete instantes de tempo (t_1 - t_7), de uma interação do tipo *Fragmentation-chasing* alinhada, destacando a ejeção de uma nova duna barcana. Dessa forma, no início do experimento colocaram uma duna desenvolvida branca na jusante (*Shape 1*) e uma pilha de grãos vermelhos na montante (*Shape 2*) de forma alinhada. Ao longo do tempo pode-se observar como essas formações nunca chegam a colidir, no entanto, no tempo t_6 ($t = 510$ s) uma duna é ejetada (*Shape 3*).

Dessa forma, a CNN atinge uma precisão estimada (C_s) acima de 90% em todas as detecções. Além disso, aos 90 segundos, a rede consegue classificar corretamente a forma que não corresponde a uma barcana (*Shape 1*). Em seguida, no tempo t_3 ($t = 195$ s), essa forma volta a ser identificada como uma barcana, e a CNN acompanha esse processo. Surpreendentemente, entre os 195 e 300 segundos, a câmera e o sistema de translação foram deslocados para capturar outras informações do ensaio. Mesmo com esse retrocesso da câmera modificando as posições das dunas, a rede consegue rastreá-las, mantendo as etiquetas correspondentes para cada uma. Isso demonstra a robustez e eficiência da YOLOv8 em lidar com diversas situações. Entre os 405 e 510 segundos, observa-se como o comprimento do chifre esquerdo da duna aumenta, culminando na ejeção de outra duna. Nos últimos instantes de tempo as dunas mantêm a mesma alinação em comparação ao tempo de 510 segundos.




Figura 4.9 – Detecção, classificação, segmentação e rastreamento de um caso *Fragmentation-chasing* alinhada, figura extraída de Cúñez e Franklin (Scientific Reports, under review).

Na Figura 4.10 analisam-se os diferentes parâmetros da morfologia ao longo do tempo, os valores e os comportamentos são parecidos com os resultados obtidos na seção 4.1.2.1. No entanto, destaca-se a Figura 4.10c onde o chifre do lado esquerdo se alongou o suficiente como para ejetar outra duna, e se associa com a redução do valor numérico para o *Shape 1*. Enquanto as outras formas apresentam os valores padrões das barcanas. Por outro lado, nas Figuras 4.10c e 4.10d, fica evidente como os valores diminuem quando há uma troca de massa. No entanto, na análise da área, é possível observar que o valor numérico do *Shape 3* corresponde ao valor que *Shape 1* perde. Isso destaca a precisão do desenho dos contornos dos objetos. Para encerrar essa análise, a Figura 4.11 mostra o acompanhamento feito pela CNN. Nota-se que entre os 80 e 140 segundos, o *Shape 1* evoluiu para uma região que não se assemelha a uma barcana para depois tornar-se de novo em uma barcana, apresentando uma boa detecção da rede nas transições de ambas classes. Além disso, a rede conseguiu detectar e classificar todas as formas, mesmo com o deslocamento da câmera e do sistema de translação, e as diversas transições entre as duas classes. Isso demonstra o alto desempenho que têm YOLO para detectar e rastrear barcanas, já que permite seguir as formas independentemente da sua posição.




Figura 4.10 – Resultados da morfologia do caso *Fragmentation-chasing* alinhada, figura extraída de Cúñez e Franklin (Scientific Reports, under review).




Figura 4.11 – Detecção ao longo do tempo da Figura 4.9.

4.1.2.4 Resultados para uma configuração do tipo *Fragmentation-chasing* desalinhada

Na Figura 4.12 são apresentadas diversas sequências de imagens (*snapshots*) em sete instantes de tempo (t_1 - t_7), de uma interação do tipo *Fragmentation-chasing* desalinhada, destacando a alinação e a ejeção de uma nova barcana. Dessa forma, no início do experimento colocaram uma duna desenvolvida branca na jusante (*Shape 2*) e uma pilha de grãos vermelhos

na montante (*Shape 1*) de forma desalinhada. A diferença do caso analisado na seção 4.1.2.3 é a forma desalinhada na que foram colocadas as formas, e que a pilha de grãos apresenta uma quantidade maior de partículas. Devido a essas configurações, a barcana branca (*Shape 2*) mantém a configuração de barcana ao longo do ensaio. No entanto, aos 396 segundos é ejetada outra barcana de pequenas dimensões. Do mesmo modo, ao ser uma configuração da interação do tipo *Chasing*, as dunas não colidem, mas se diferenciam com o desprendimento da barcana, o qual não aconteceu nos resultados apresentados na Figura 4.6. Cabe ressaltar que a rede consegue detectar, classificar e rastrear dunas com dimensões muito pequenas correspondentes ao *Shape 3* com uma precisão estimada de 80% ao ejetar uma pequena nova duna, enquanto, com as outras formas, atingiu precisões acima de 90%.




Figura 4.12 – Detecção, classificação, segmentação e rastreamento de um caso *Fragmentation-chasing* desalinhada, figura extraída de Cúñez e Franklin (Scientific Reports, under review).

A análise dos parâmetros morfológicos apresentados na Figura 4.13 é semelhante à da Figura 4.10. Desse modo, os aspectos morfológicos que mais se destacam são o comprimento médio dos chifres, onde o *Shape 2*, reduz notoriamente o valor numérico devido à ejeção da terceira duna. Por outro lado, a área que desprende o *Shape 1* é a mesma que tem o *Shape 3*. Os parâmetros do *Shape 3* não podem ser analisados de forma profunda devido ao seu rápido deslocamento ao longo do teste.

Para concluir a análise desse caso, a Figura 4.14 apresenta a detecção da forma ejetada, que inicialmente não era uma duna desenvolvida, mas nos instantes seguintes se desenvolveu como uma barcana. Além disso, a rede consegue classificar corretamente as transições entre ambas as classes em pequenos intervalos de tempo, demonstrando novamente o desempenho eficiente da rede YOLOv8 em realizar essas tarefas.




Figura 4.13 – Resultados da morfologia do caso *Fragmentation-chasing* desalinhada, figura extraída de Cúñez e Franklin (Scientific Reports, under review).




Figura 4.14 – Detecção ao longo do tempo da Figura 4.12.

4.2 Treinamento da rede usando imagens de satélite

Após o sucesso dos resultados apresentados na seção 4.1, optamos por aplicar a mesma metodologia para treinar uma segunda rede com o objetivo de detectar, classificar e segmentar dunas barcanas em ecossistemas terrestres e marcianos, utilizando imagens obtidas por satélites. Essa abordagem amplia nosso conhecimento morfológico sobre diferentes ecos-

sistemas, ao permitir a detecção, classificação e rastreamento das dunas. No entanto, devido às limitações na obtenção de informações históricas, a análise ao longo do tempo torna-se desafiadora, dificultando a compreensão das interações das dunas.

Nesta seção, serão apresentados a análise dos resultados obtidos pela rede neural (YOLOv8) ao utilizar as imagens adquiridas por satélite (HiRISE), conforme descrito na seção 3. Além disso, discute-se o desempenho da rede ao processar e detectar as características das imagens de dunas barcanas na Terra e em Marte. Para concluir, abordaremos os resultados obtidos pela detecção, classificação e segmentação das dunas barcanas que permitem a extração das informações morfológicas em um determinado período.

4.2.1 Resultados de aprendizagem da rede

Para aprimorar a detecção de dunas barcanas discutida na seção 2.2.3, foi treinada uma nova rede neural (YOLOv8) para executar as mesmas tarefas especificadas na seção 4.1, com exceção do rastreamento ao longo do tempo. Este treinamento envolveu 1.187 imagens, enquanto o conjunto de validação contou com 270 imagens, englobando dunas marcianas e terrestres em diversas localizações, tamanhos e qualidades. Além disso, foi empregado o aumento de dados (*data augmentation*), conforme detalhado na seção 3.2.2, onde as imagens foram cortadas, giradas e também teve ruído adicionado. Durante o processo de treinamento, foram considerados os seguintes hiper-parâmetros: 300 épocas e um tamanho de lote (*batch*) igual a 7. Essas escolhas resultaram em um desempenho moderado da rede, possibilitando uma detecção, classificação, segmentação e rastreamento precisos das dunas barcanas nesses ecossistemas.

Na Figura 4.15, os resultados das perdas da rede em relação ao número de épocas durante o treinamento são apresentados. Observa-se que o treinamento demonstra uma eficácia significativa na detecção de ambas as classes, como indicado pelos baixos valores de perda ao longo do processo. As curvas de perda para o conjunto de treinamento e validação exibem comportamentos semelhantes, sugerindo que o modelo consegue generalizar bem para dados não vistos. Além disso, esta figura revela que o valor inicial da perda é aproximadamente 2 e diminui consistentemente para cerca de 0,4 sem apresentar muitos picos ou variações abruptas. Com base nessas observações, podemos visualizar que o treinamento é robusto na detecção de barcanas, embora não tenha convergido completamente. Essa limitação está relacionada ao número de imagens adquiridos, as poucas áreas de estudo e à resolução das mesmas. Portanto, sugere-se considerar treinamentos futuros com conjuntos de dados mais extensos e acrescentado




Figura 4.15 – Perda vs épocas (Satélite)

o número de épocas.




Figura 4.16 – Predição média de detecção vs épocas (Satélite)

Por outro lado, na Figura 4.16, destacam-se as médias de precisão da rede para a detecção de dunas barcanas, alcançando um mAP (*mean average precision*) de 80%. Esses resultados garantem um desempenho moderado para a detecção e rastreamento das dunas barcanas. Comparando o treinamento atual com o mencionado na seção 4.1, este parece convergir nos estágios finais do treinamento. No entanto, pretende-se melhorar esses valores com o aumento de imagens em diferentes cenários e resoluções.

Tabela 4.1 – Dados morfológicos extraídos da Figura 4.17, tabela extraída de Cúñez e Franklin (Scientific Reports, under review).

Shape	Classe	L	w	$\overline{L}_h$	A	P_x	P_y
...	...	m	m	m	m^2	m	m
1	Barchan	226,32	182,89	41,45	40179,19	1130	1781,58
2	Barchan	217,11	200,00	63,82	42255,89	1607	1573,68
3	Barchan	188,16	165,79	37,50	30440,62	674	1306,58
4	Barchan	221,05	194,74	46,71	39555,92	1825	1063,16
5	Barchan	218,42	196,05	53,95	40180,92	2522	1030,26
6	Barchan	188,16	196,05	50,66	37143,35	112	1330,26
7	Barchan	275,00	267,11	80,92	65984,25	2308	625,00
8	Barchan	213,16	200,00	56,58	41305,40	1387	1935,53
9	Barchan	250,00	250,00	83,55	61080,33	2041	392,11
10	Barchan	209,21	177,63	44,08	35578,25	868	1492,11
11	Barchan	213,16	150,00	34,87	32703,43	2637	1518,42
12	Barchan	238,16	194,74	61,18	43157,03	333	960,53

4.2.2 Resultados de detecção, classificação e segmentação das dunas barcanas

Para avaliar a eficácia do novo treinamento em detectar, classificar e segmentar as dunas barcanas nas paisagens de Marte, e compará-las com os estudos apresentados na seção 2.2.3, Esses resultados envolvem a detecção de um campo de dunas isoladas na superfície de Marte: 23.190° latitude (centrado) e 339.585° longitude (Leste), altitude da sonda 287,3 km. Além disso, consideramos um cenário com diferentes dunas interagindo em outra localização de Marte: -41.488° latitude (centrado), 44.589° longitude (Leste), altitude da sonda 253,8 km.

Assim, na Figura 4.17, é possível observar a detecção, classificação e segmentação de um campo de dunas barcanas isoladas. A rede YOLOv8 consegue identificar todas as barcanas com uma precisão estimada acima de 80%, demonstrando ser um treinamento robusto e eficaz para detectar dunas barcanas isoladas. Além disso, nota-se que o desenho dos contornos não apresentou dificuldades devido à segmentação do treinamento. No entanto, a obtenção desses contornos usando aprendizado profundo (*deep learning*) apresenta vários desafios, pelo fato, que o fundo contém informações valiosas sobre o ecossistema, como as crateras visíveis na figura. Por outro lado, este estudo é complementado pela obtenção dos parâmetros morfológicos, possível através do desenho dos contornos. Esses parâmetros incluem o comprimento (L), largura (w), comprimento médio dos chifres ($\overline{L}_h$), área (A) e os valores dos centroides (P_x e P_y) medidos a partir da origem da imagem. Os resultados desses dados em conjunto das detecções podem ser observados na Tabela 4.1.




Figura 4.17 – Detecção de dunas na superfície de Marte: 3.190° latitude (centrado) e 339.585° longitude (Leste), altitude da sonda 287,3 km. Cortesia: NASA/JPL-Caltech/UArizona, figura extraída de Cúñez e Franklin (Scientific Reports, under review).

Por outro lado, na Figura 4.18, é possível observar um campo de dunas que exhibe barcanas isoladas e colisões entre as dunas. Esta imagem representa um desafio considerável para a rede YOLOv8, devido à abundância de informações a serem detectadas, além das diversas interações apresentadas. Apesar da dificuldade de detecção, a rede CNN desenvolvida demonstra uma detecção, classificação e segmentação robustas, alcançando uma precisão estimada de 70%. No entanto, não é possível detectar outras formações de dunas barcanas interagindo. Com treinamentos futuros, é possível aprimorar a detecção das dunas que não foram identificadas pela rede.

É relevante destacar que a metodologia utilizada para desenhar os contornos é eficaz, visto que na caixa delimitadora do *Shape 1*, outras dunas estão colidindo (*Shape 29* e *Shape 31*). No entanto, a rede YOLOv8 e o código de segmentação desenvolvido: ver 3.2.4, permitiram a obtenção dos contornos dessas dunas sem problemas, mesmo com as informações cruciais que o fundo tem sobre o cenário de Marte. Da mesma forma, os aspectos morfológicos das formas detectadas são apresentados na Tabela 4.2.




Figura 4.18 – Detecção de dunas na superfície de Marte: 41.488° latitude (centered), 44.589° longitude (East), *spacecraft* altitude 253,8 km. Cortesia: NASA/JPL-Caltech/UArizona, figura extraída de Cúñez e Franklin (Scientific Reports, under review).

Tabela 4.2 – Dados morfológicos extraídos da Figura 4.18, tabela extraída de Cúñez e Franklin (Scientific Reports, under review).

Shape	Classe	L	w	$\overline{L}_h$	A	P_x	P_y
...	...	m	m	m	m^2	m	m
1	Not a barchan	308	221	199	62924	1024	1800
2	Barchan	193	134	10	23621	1788	956
3	Barchan	159	134	32	19836	1734	626
4	Barchan	201	181	53	37064	921	1128
5	Barchan	153	140	42	21517	459	2615
6	Barchan	183	157	48	28602	233	1472
7	Barchan	189	181	47	34929	808	454
8	Barchan	207	169	29	32432	870	716
9	Barchan	230	175	33	36250	635	3202
10	Barchan	183	135	39	22882	1946	3536
11	Barchan	189	157	36	27465	1304	2678
12	Barchan	153	117	27	17540	1941	3177
13	Barchan	165	129	39	20424	1943	2550
14	Not a barchan	278	181	24	42301	1849	1587
15	Barchan	207	181	47	35475	731	205
16	Barchan	183	215	68	41711	516	2899
17	Barchan	159	87	9	13008	1718	329
18	Barchan	207	157	45	31802	1101	3402
19	Barchan	254	181	68	45779	292	2162
20	Barchan	129	104	15	12483	724	3565
21	Barchan	111	65	1	6712	2011	2907
22	Barchan	105	65	1	5639	1916	2977
23	Barchan	225	87	2	15367	1832	1265
24	Not a barchan	255	151	20	30993	1509	3548
25	Barchan	171	152	33	24570	276	3429
26	Barchan	135	117	21	15170	1311	3571
27	Not a barchan	473	89	16	35518	249	2658
28	Barchan	200	163	51	33117	1116	2790
29	Barchan	183	87	12	15303	1209	2026
30	Barchan	183	135	38	25290	1390	3008
31	Barchan	207	175	80	27080	1051	2087

5 CONCLUSÕES E TRABALHOS FUTUROS

5.1 Conclusões

O desenvolvimento e aplicação da rede YOLOv8 para a detecção automática de dunas barcanas revelou-se altamente eficaz ao longo deste estudo. Os resultados obtidos tanto em imagens experimentais quanto em imagens de satélite demonstram a capacidade da YOLOv8 treinada de identificar, classificar, segmentar, rastrear e contornar adequadamente ambas as classes ("*Barchan*" e "*Not a barchan*"), fornecendo uma ferramenta robusta para análise morfológica. Além disso, observou-se que a precisão estimada nos resultados atingiu valores de 90% em casos de dunas isoladas, enquanto, a interação de dunas apresentou valores de 70%. Além disso, destacou-se a versatilidade da CNN treinada, uma vez que consegue detectar e contornar dunas com diversas características, como cores, tamanhos e interações, independentemente dos diferentes cenários onde as barcanas estão inseridas. Essa adaptabilidade da rede sugere uma aplicabilidade ampla em diferentes cenários e contextos, fortalecendo a utilidade da YOLOv8 para análises em diversos ecossistemas. No entanto, é importante notar que, embora os resultados sejam promissores, o treinamento da YOLOv8 não conseguiu convergir no caso do satélite, indicando possíveis desafios relacionados ao número de imagens disponíveis. Essa limitação sugere oportunidades para futuros trabalhos, incluindo treinamentos adicionais com conjuntos de dados mais extensos e diversificados.

A eficiência do método desenvolvido não se restringiu apenas à detecção, mas também, à obtenção de parâmetros morfológicos cruciais para a compreensão da dinâmica das interações de dunas. Esses parâmetros incluíram o comprimento (L), largura (W), comprimento médio dos chifres ($\overline{L_h}$), área (A) e as coordenadas dos centroides (P_x e P_y), proporcionando uma base completa para a análise morfológica das dunas ao longo do tempo. Desse modo, esses resultados tiveram concordância com os resultados mostrados por (Assis; Franklin, 2020), mostrando que o delineamento dos contornos teve sucesso.

Em síntese, este trabalho destaca a eficácia da detecção automática de dunas barcanas com a rede YOLOv8, oferecendo informações valiosas para a detecção, classificação, delineamento e compreensão das interações entre as dunas. A capacidade da rede em adaptar-se a diferentes condições e a obtenção precisa de parâmetros morfológicos posicionam este estudo como uma ferramenta poderosa para estudos nos diferentes cenários (aquáticos, terrestres e

marcianos), contribuindo significativamente para a pesquisa em geomorfologia e dinâmica das dunas barcanas.

5.2 Trabalhos futuros

Para trabalhos futuros, um treinamento que contenha maior número de imagens de dunas barcanas nos cenários terrestres e marcianos poderia ser desenvolvida, proporcionaria uma melhor detecção das dunas que estão colidindo. Estas imagens poderiam conter diferentes paisagens naturais, entornos e cores.

Além disso, seria interessante explorar outras técnicas de aprendizado profundo (*deep learning*) que permitam antecipar o comportamento das interações das barcanas (destacadas por Assis e Franklin (2020) na seção 2.2.2) em determinados instantes de tempo. Nesse contexto, poderia ser considerada o desenvolvimento de uma rede capaz de prever sequências de imagens para prever o tipo de interação que provavelmente ocorrerá no futuro. Essa abordagem tem o potencial de ampliar significativamente nosso entendimento das dunas e adquirir informações passadas e futuras das dunas barcanas nos diferentes ecossistemas (aquático, terrestre e marciano).

REFERÊNCIAS

- Aboah, A.; Wang, B.; Bagci, U.; Adu-Gyamfi, Y. Real-time Multi-Class Helmet Violation Detection Using Few-Shot Data Sampling Technique and YOLOv8. **IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops**, v. 2023-June, p. 5350–5358, 2023.
- Akhtar, S.; Hanif, M.; Malih, H. Automatic Urine Sediment Detection and Classification Based on YoloV8. In: **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**. [S.l.: s.n.], 2023. v. 14112 LNCS, p. 269–279. ISBN 9783031371288. ISSN 16113349.
- Alvarez, C. A.; Cúñez, F. D.; Franklin, E. M. Growth of barchan dunes of bidispersed granular mixtures. **Physics of Fluids**, v. 33, n. 5, 2021.
- Alvarez, C. A.; Franklin, E. M. Birth of a subaqueous barchan dune. **Physical Review E**, v. 96, n. 6, p. 062906, 2017.
- Alvarez, C. A.; Franklin, E. M. Role of Transverse Displacements in the Formation of Subaqueous Barchan Dunes. **Physical Review Letters**, v. 121, n. 16, p. 164503, 2018.
- Andreotti, B.; Claudin, P.; Douady, S. Selection of dune shapes and velocities part 1: Dynamics of sand, wind and barchans. **European Physical Journal B**, v. 28, n. 3, p. 321–339, 2002.
- Andresen, S. L. John McCarthy: Father of AI. **IEEE Intelligent Systems**, v. 17, n. 5, p. 84–85, 2002.
- Assis, W. R.; Franklin, E. d. M. A comprehensive picture for binary interactions of subaqueous barchans. **Geophysical Research Letters**, v. 47, n. 18, p. e2020GL089464, 2020.
- Assis, W. R.; Franklin, E. d. M. Morphodynamics of barchan-barchan interactions investigated at the grain scale. **Journal of Geophysical Research: Earth Surface**, v. 126, n. 8, p. e2021JF006237, 2021.
- Azzaoui, M.; Adnani, M.; El Belrhiti, H.; Chaouki, I.; Masmoudi, C. Detection of barchan dunes in high resolution satellite images. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 41, p. 153–160, 2016.
- Bagnold, R. The physics of blown sand and desert dunes: New york. **William Morrow & Company**, 1941.
- Bourke, M. C. Barchan dune asymmetry: Observations from Mars and Earth. **Icarus**, v. 205, n. 1, p. 183–197, 2010.
- Bristow, N.; Blois, G.; Best, J.; Christensen, K. Turbulent flow structure associated with collision between laterally offset, fixed-bed barchan dunes. **Journal of Geophysical Research: Earth Surface**, v. 123, n. 9, p. 2157–2188, 2018.
- Browne, M.; Ghidary, S. S.; Mayer, N. M. Convolutional neural networks for image processing with applications in mobile robotics. **Studies in Computational Intelligence**, v. 83, p. 327–349, 2008.

- Carrera, D.; Bandeira, L.; Santana, R.; Lozano, J. A. Detection of sand dunes on Mars using a regular vine-based classification approach. **Knowledge-Based Systems**, v. 163, p. 858–874, 2019.
- Charru, F.; Franklin, E. M. Subaqueous barchan dunes in turbulent shear flow. Part 1: Dune motion. **Journal of Fluid Mechanics**, v. 694, n. 1978, p. 131–154, 2012.
- Charru, F.; Franklin, E. M. Subaqueous barchan dunes in turbulent shear flow. Part 2: Fluid flow. **Journal of Fluid Mechanics**, v. 694, n. ii, p. 131–154, 2012.
- Cunez, E.; Franklin, E. **CNN training of experimental images for "Detection and tracking of barchan dunes using Artificial Intelligence"**. 2023. Mendeley Data, V1.
- Cunez, E.; Franklin, E. **CNN training of satellite images for "Detection and tracking barchan dunes using Artificial Intelligence"**. 2023. Mendeley Data, V1.
- Cunez, E.; Franklin, E. **Experimental dataset on "Detection and tracking of barchan dunes using Artificial Intelligence"**. 2023. Mendeley Data, V1.
- Cúñez, E. A.; Franklin, E. M. Detection and tracking of barchan dunes using artificial intelligence. *Scientific Reports*, under review.
- Dhillon, A.; Verma, G. K. Convolutional neural network: a review of models, methodologies and applications to object detection. **Progress in Artificial Intelligence**, v. 9, n. 2, p. 85–112, 2020.
- Endo, N.; Taniguchi, K.; Katsuki, A. Observation of the whole proces of interaction between barchans by flume experiments. **Geophysical Research Letters**, v. 31, n. 12, p. 2–4, 2004.
- Ertel, W. **Introduction to Artificial Intelligence**. [S.l.]: Springer US, 2019. v. 2. 323 p. ISBN 9780857292988.
- Gunning, D.; Stefik, M.; Choi, J.; Miller, T.; Stumpf, S.; Yang, G. Z. XAI-Explainable artificial intelligence. **Science Robotics**, v. 4, n. 37, p. 4–6, 2019.
- Haddawy, P.; Nghi Do, T.; Nghe, N. T. **Intelligent Systems and Data Science**. Part 1. Can Tho, Vietnam: Springer US, 2023. 322 p. ISBN 9789819976485.
- Haynes, C. V. Bagnold's barchan: A 57-Yr Record of dune movement in the eastern Sahara and implications for dune origin and paleoclimate since Neolithic times. **Quaternary Research**, v. 32, n. 2, p. 153–167, 1989.
- Herrmann, H. J.; Sauermann, G. Shape of dunes. **Physica A: Statistical Mechanics and its Applications**, v. 283, n. 1, p. 24–30, 2000.
- Hersen, P. On the crescentic shape of barchan dunes. **European Physical Journal B**, v. 37, n. 4, p. 507–514, 2004.
- Hersen, P. Flow effects on the morphology and dynamics of aeolian and subaqueous barchan dunes. **Journal of Geophysical Research: Earth Surface**, v. 110, n. 4, p. 1–10, 2005.
- Hersen, P.; Douady, S.; Andreotti, B. Relevant length scale of barchan dunes. **Physical Review Letters**, v. 89, n. 26, p. 264301, 2002.

- Hugenholtz, C. H.; Barchyn, T. E. Real barchan dune collisions and ejections. **Geophysical Research Letters**, v. 39, n. 2, 2012.
- Iliadis, L.; Papalepnidas, A.; Plamen, A.; Jayne, C. **Artificial Neural Networks and Machine Learning – ICANN 2023**. [S.l.]: Springer, 2023. 559 p. ISBN 9783031417306.
- Jiang, X.; Hou, Y.; Zhang, D.; Feng, X. **Deep learning in face recognition across variations in pose and illumination**. [S.l.: s.n.], 2019. 59–90 p. ISBN 9789811051524.
- Khan, A.; Sohail, A.; Zahoor, U.; Qureshi, A. S. **A survey of the recent architectures of deep convolutional neural networks**. Springer Netherlands, 2020. v. 53. 5455–5516 p. ISSN 15737462. ISBN 0123456789.
- Khan, S.; Rahmani, H.; Shah, S. A. A.; Bennamoun, M. A Guide to Convolutional Neural Networks for Computer Vision. **Synthesis Lectures on Computer Vision**, v. 8, n. 1, p. 1–207, 2018.
- Khan, Z.; Shen, Y.; Liu, H.; Zeng, X. Improved YOLOv8 deep learning instance segmentation algorithm with dilated convolution: Real time precise segmentation of orchard canopies in natural environment. v. 6, n. 6, p. 81–91, 2019.
- Lee, P.; Thomas, P. C. Longitudinal dunes on Mars: relation to current wind regimes. **Journal of Geophysical Research**, v. 100, n. E3, p. 5381–5395, 1995.
- McKee, E. D. **A study of global sand seas**. [S.l.]: US Government Printing Office, 1979. v. 1052.
- Merwe, B. van der; Pillay, N.; Coetzee, S. An application of cnn to classify barchan dunes into asymmetry classes. **Aeolian Research**, v. 56, p. 100801, 2022.
- Moosavi, V.; Moradi, H.; Shamsi, S. R. F.; Shirmohammadi, B. Assessment of the planimetric morphology of barchan dunes. **Catena**, v. 120, p. 12–19, 2014.
- Norris, R. M. Barchan dunes of imperial valley, california. **The Journal of Geology**, v. 74, n. 3, p. 292–306, 1966.
- Pye, K.; Tsoar, H. **Aeolian sand and sand dunes**. [S.l.]: Springer Science & Business Media, 2008.
- Redmon, J.; Farhadi, A. Yolov3: An incremental improvement. **arXiv preprint arXiv:1804.02767**, 2018.
- Rodríguez-García, J. D.; Moreno-León, J.; Román-González, M.; Robles, G. Introducing Artificial Intelligence Fundamentals with LearningML: Artificial Intelligence made easy. **ACM International Conference Proceeding Series**, p. 18–20, 2020.
- Rosebrock, A. Practical Phyton and OpenCV. p. 150, 2014.
- Rosebrock, A. Aprendizaje Profundo para Visión Computacional con Python : Práctica. **Pyimagesearch**, p. 330, 2017.
- Rouhiainen, L. Inteligencia artificial 101 cosas que debes saber hoy sobre nuestro futuro. **Alenta editorial**, p. 22, 2018.

- Rubanenko, L.; Pérez-López, S.; Schull, J.; Lapôtre, M. G. Automatic detection and segmentation of barchan dunes on mars and earth using a convolutional neural network. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 9364–9371, 2021.
- Sauermann, G.; Rognon, P.; Poliakov, A.; Herrmann, H. J. The shape of the barchan dunes of Southern Morocco. **Geomorphology**, v. 36, n. 1-2, p. 47–62, 2000.
- Schwämmle, V.; Herrmann, H. J. Solitary wave behaviour of sand dunes. **Nature**, v. 426, n. 6967, p. 619–620, 2003.
- Soylu, E.; Soylu, T. A performance comparison of YOLOv8 models for traffic sign detection in the Robotaxi-full scale autonomous vehicle competition. **Multimedia Tools and Applications**, n. 0123456789, 2023.
- Suarez, G. B. G. O. D. **Learning image processing with OpenCV**. [S.l.: s.n.], 2013.
- Terven, J.; Cordova-Esparza, D. A Comprehensive Review of YOLO: From YOLOv1 and Beyond. p. 1–34, 2023.
- Tsoar, H. 17 Types of Aeolian Sand Dunes. p. 403–429, 2001.
- Tsoar, H.; Greeley, R.; Peterfreund, A. R. Mars: The north polar sand sea and related wind patterns. **Journal of Geophysical Research: Solid Earth**, v. 84, n. B14, p. 8167–8180, 1979.
- Wenzel, J. Transporte de grãos sobre uma duna do tipo barcana. 2018.
- Wong, A.; Famuori, M.; Shafiee, M. J.; Li, F.; Chwyl, B.; Chung, J. Yolo nano: A highly compact you only look once convolutional neural network for object detection. In: IEEE. **2019 Fifth Workshop on Energy Efficient Machine Learning and Cognitive Computing-NeurIPS Edition (EMC2-NIPS)**. [S.l.], 2019. p. 22–25.
- Xiao, B.; Nguyen, M.; Yan, W. Q. Fruit ripeness identification using YOLOv8 model. **Multimedia Tools and Applications**, n. August, 2023.
- Yue, X.; Qi, K.; Na, X.; Zhang, Y.; Liu, Y.; Liu, C. Improved YOLOv8-Seg Network for Instance Segmentation of Healthy and Diseased Tomato Plants in the Growth Stage. **Agriculture (Switzerland)**, v. 13, n. 8, 2023.
- Zhang, J.; Wan, G.; Jiang, M.; Lu, G.; Tao, X.; Huang, Z. Small object detection in UAV image based on improved YOLOv5. **Systems Science and Control Engineering**, v. 11, n. 1, 2023.
- Zhang, Z.; Dong, Z.; Hu, G.; Parteli, E. J. Migration and morphology of asymmetric barchans in the central hexi corridor of northwest china. **Geosciences**, v. 8, n. 6, p. 204, 2018.