

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE INFORMÁTICA E ESTATÍSTICA

**Desenvolvimento de um Modelo de Detecção de Correntes de Retorno
usando *Deep Learning* com base em Fotos a partir da Praia**

Caio Nogueira Motta

Florianópolis
2023

Universidade Federal de Santa Catarina
Departamento de Informática e Estatística

Desenvolvimento de um Modelo de Detecção de Correntes de Retorno
usando *Deep Learning com Base em Fotos a Partir da Praia*

Trabalho de Conclusão de Curso de Graduação em Sistemas de Informação, do Departamento de Informática e Estatística, do Centro Tecnológico da Universidade Federal de Santa Catarina, requisito parcial à obtenção do título de Bacharel em Sistemas de Informação.

Autor: Caio Nogueiro Motta

Orientadora: Prof.^a Dr.^a rer. nat. Christiane Gresse von Wangenheim, PMP

Florianópolis
2023

RESUMO

Afogamentos relacionados a correntes de retorno é uma das maiores razões de mortes de banhistas no mar. Embora existam características físicas visíveis da praia, a identificação dessas correntes de retorno pode ser uma tarefa complicada, sendo necessário conhecimento prévio de um profissional salva-vidas ou especialista da área. Neste contexto, um modelo que identifique as correntes de retorno a partir de fotos tiradas da praia poderá auxiliar na hora de decidir qual é o melhor local para se banhar com segurança. Já existem propostas de classificação de correntes de retorno em imagens usando *deep learning*, porém esses tipicamente usam imagens capturadas por *webcams* instaladas em pontos com campo de visão mais altos que aquele do banhista. Assim, o objetivo geral deste trabalho é desenvolver um modelo de detecção de correntes de retorno a partir de fotos de frente para o mar. Para tal, são adotadas técnicas de *deep learning* para automatizar a detecção a partir de fotos do mar capturadas com a câmera de celular de forma frontal. Espera-se que este trabalho ajude na conscientização maior sobre o assunto e diminua o risco iminente que essas correntes trazem.

Palavras-chave: Correntes de retorno, praia, *deep learning*, detecção de objetos

LISTA DE FIGURAS

Figura 1 - Esquema das correntes de retorno. Fonte (Ribeiro, 2014).	10
Figura 2. Diagrama de do sistema de correntes de retorno. Baseado em Castelle et al. (2016)	14
Figura 3 - A e B esquema e foto das flash rips. C e D esquema e foto das shear instability rips. Fonte: Castelle et al. (2016)	15
Figura 4 - A e B esquema e foto das channel rip currents. C e D esquema e foto das focused rips (no esquema apresentando uma anomalia batimétrica com maior profundidade). Fonte: Castelle et al. (2016).	16
Figura 4 - A e B esquema e foto de shadow rip current. C e D esquema e foto da deflection rip. Fonte: Castelle et al. (2016).	17
Figura 5 - As imagem A e B são da Praia do santinho, a seta na imagem B indica a corrente de retorno. As imagens B e C são da Praia do Moçambique, a seta na imagem D indica a corrente de retorno.	20
Figura 6 - Exemplo de um nodo.. Fonte: ZOU et al. (2008)	21
Figura 7 - Exemplo de topologia de uma rede neural. Fonte: ZOU et al. (2008)	21
Figura 8 - Exemplos de Bounding Box indicando uma corrente de retorno	22
Figura 9 - Esquema do IoU. Fonte: Rosebrock (2016).	24
Figura 11 - Esquema das convoluções nas redes neurais convolucionais. Fonte: Ponti e Costa (2017)	25
Figura 12 - Esquema das R-CNN. Fonte: Zhao, 2019	26
Figura 13 - Esquema de funcionamento do YOLO. Fonte: Redmon et al. (2016).	26
Figura 14 - Divisão da imagem em uma matriz, identificação das bounding boxes e nível de confiança e detecção fina. Fonte: Redmon et al. (2016).	27
Figura 15 - Arquitetura YOLO. Fonte: Redmon et al. (2016).	27
Figura 16 - Modelos de YOLOv5. Fonte: Ultralytics (2021).	28
Figura 17 - Comparação de desempenho entre diferentes versões do YOLO. Fonte: Ultralytics (2021).	29
Figura 18 - Quantidade de artigos relevantes ao assunto publicados nos últimos 6 anos. Fonte: Autor, 2023	33
Figura 19 - Quantidade de imagens no conjunto de dados por pesquisa Fonte: Autor, 2023	35
Figura 20 - Quantidade de imagens no conjunto de dados por pesquisa após limpeza de outlier. Fonte: Autor, 2023	35
Figura 21 - Exemplo de imagem fotografada por um banhista.	40
Figura 22 - Exemplo de imagem classificada pelo aplicativo	41
Figura 23 - Exemplos de imagens do conjunto. As imagens A, B e C possuem correntes de retorno indicadas por bounding boxes. A imagem D não possui corrente de retorno.	44

LISTA DE TABELAS

Tabela 1 - Caracterização das praias no foco da presente pesquisa. Fontes: Tipos de correntes baseado em Castelle et al. (2016), estado praias (KLEIN et al., 2016) e observações do próprio autor para caracterização do entorno.	19
Tabela 2: Termos de busca utilizados no protocolo de revisão	31
Tabela 3 - String de busca para cada fonte.	31
Tabela 4 - Número de artigos identificados por repositório e por fase de seleção.	32
Tabela 5. Pesquisas que utilizam Deep Learning para detecção de correntes de retorno	32
Tabela 6: Informações sobre os dados encontrados nas pesquisas	34
Tabela 7: Informações sobre o treinamento dos trabalhos encontrados (NI - Não informado)	36
Tabela 8 - Desempenhos relatados	37
Tabela 9 - História do usuário	41
Tabela 10 - Objetivos do modelo de DL	42
Tabela 11 - Conjunto de imagens rotulados	43
Tabela 12 - Técnicas de data augmentation adotadas	47
Tabela 13 - Resumo de informações do treinamento Praia da Armação sem data augmentation	50
Tabela 14 - Resumo de informações do treinamento Praia da Armação com data augmentation	51
Tabela 15 - Resumo de informações do treinamento Praia da Armação sem data augmentation	52
Tabela 16 - Resumo de informações do treinamento Praia da Armação com data augmentation	54
Tabela 17 - Resumo de informações do treinamento Praia do Santinho sem data augmentation	55
Tabela 18 - Resumo de informações do treinamento Praia do Santinho com data augmentation	56
Tabela 19 - Resumo de informações do treinamento Praia do Santinho sem data augmentation	57
Tabela 20 - Resumo de informações do treinamento Praia do Santinho com data augmentation	59
Tabela 21 - Resumo de informações do treinamento Praia do Santinho sem data augmentation	60
Tabela 22 - Resumo de informações do treinamento Praia do Santinho com data augmentation	61
Tabela 23 - Resumo de informações do treinamento Praia do Santinho sem data augmentation	62
Tabela 24 - Resumo de informações do treinamento Praia do Santinho com data augmentation	63
Tabela 25 - Características do conjunto de dados de teste da Praia da Armação	65
Tabela 26 - Resultados do teste para o conjunto de dados da Praia da Armação sem data augmentation utilizando YOLOv5s	66
Tabela 27 - Resultados do teste para o conjunto de dados da Praia da Armação com data augmentation utilizando YOLOv5s	67

Tabela 28 - Resultados do teste para o conjunto de dados da Praia da Armação sem data augmentation utilizando YOLOv8s	67
Tabela 29 - Resultados do teste para o conjunto de dados da Praia da Armação com data augmentation utilizando YOLOv8s	68
Tabela 30 - Características do conjunto de dados de teste da Praia do Santinho	69
Tabela 31 - Resultados do teste para o conjunto de dados da Praia do Santinho sem data augmentation utilizando YOLOv5s	70
Tabela 32 - Resultados do teste para o conjunto de dados da Praia do Santinho com data augmentation utilizando YOLOv5	71
Tabela 33 - Resultados do teste para o conjunto de dados da Praia do Santinho sem data augmentation utilizando YOLOv8	72
Tabela 34 - Resultados do teste para o conjunto de dados da Praia do Santinho com data augmentation utilizando YOLOv8s	73
Tabela 35 - Características do conjunto de dados de teste da Praia do Santinho + Armação	74
Tabela 36 - Resultados do teste para o conjunto de dados da Praia do Santinho + Armação sem data augmentation utilizando YOLOv5	75
Tabela 37 - Resultados do teste para o conjunto de dados da Praia do Santinho + Armação com data augmentation utilizando YOLOv5s	76
Tabela 38 - Resultados do teste para o conjunto de dados da Praia do Santinho + Armação sem data augmentation utilizando YOLOv8s	77
Tabela 39 - Resultados do teste para o conjunto de dados da Praia do Santinho + Armação com data augmentation utilizando YOLOv8s	78
Tabela 40 - Resultados da validação e testes realizados	79

LISTA DE ABREVIATURAS E SIGLAS

CNN - *Convolutional Neural Networks*

DL - *Deep Learning*

IA - *Inteligência Artificial*

IOU - *Intersection Over Union*

ML - *Machine Learning*

R-CNN - *Region Based Convolutional Neural Network*

YOLO - *You Only Look Once*

SUMÁRIO

1. INTRODUÇÃO	9
1.1 Contextualização	9
1.2. OBJETIVOS	11
1.2.1 Objetivo geral	11
1.2.2 Objetivos Específicos	11
1.3 METODOLOGIA	12
2. FUNDAMENTAÇÃO TEÓRICA	13
2.1 CORRENTES DE RETORNO	13
2.2 CARACTERIZAÇÃO DAS PRAIAS	17
2.2 DETECÇÃO DE OBJETOS COM O DEEP LEARNING	20
2.2.1 Deep learning	20
2.3 PROCESSO DE DETECÇÃO DE OBJETOS	22
2.3.1 Modelos de detecção de objetos	25
3 ESTADO DA ARTE	29
3.1 DEFINIÇÃO DO PROTOCOLO DE REVISÃO	30
3.2 EXECUÇÃO DA BUSCA	31
3.3 RESULTADOS DA BUSCA	32
3.3.1 Quais pesquisas existem em termos de detecção de correntes de retorno?	32
3.3.2 Quais as características em termos do conjunto de dados?	33
3.3.4 Como os modelos foram treinados?	36
3.3.5 Quais os desempenhos relatados?	37
3.4 DISCUSSÃO	37
4 DESENVOLVIMENTO DO MODELO DE DETECÇÃO DE CORRENTES DE RETORNO	39
4.1 REQUISITOS	39
4.2 PREPARAÇÃO DOS CONJUNTOS DE IMAGENS	42
4.3 TREINAMENTO	48
4.3.1 - Treinamento com imagens da Praia da Armação	49
4.3.1.1 - Modelos YOLOv5s	49
4.3.1.2 - Modelos YOLOv8s	51
4.3.2 - Treinamento Praia do Santinho	54
4.3.2.1 - Modelos YOLOv5s	54
4.3.2.2 - Modelos YOLOv8s	56
4.3.3 - Treinamento Praia da Armação + Praia do Santinho	59
4.3.3.1 - Modelos YOLOv5s	59
4.3.3.2 - Modelos YOLOv8s	61
4.4 TESTE DE DESEMPENHO	63
4.4.1 Teste de desempenho para os modelos com imagens da Praia da Armação	64
4.4.1.1 Características dos dados	64
4.4.1.2 Resultados YOLOv5s	65
4.4.1.2 Resultados YOLOv8s	67
4.4.2 Teste de desempenho para os modelos da Praia do Santinho	68
4.4.2.1 Características dos dados	68
4.4.2.2 Resultados YOLOv5	69

4.4.2.3 Resultados YOLOv8s	71
4.4.3 Teste de desempenho para os modelos com imagens da Praia do Santinho + Praia da Armação	73
4.4.3.1 Características dos dados	73
4.4.3.2 Resultados YOLOv5s	74
4.4.3.3 Resultados YOLOv8s	76
4.5 DISCUSSÃO	78
5 CONCLUSÃO	82
REFERÊNCIAS	83

1. INTRODUÇÃO

1.1 Contextualização

Todos os anos milhares de pessoas ao redor do planeta morrem por afogamento, sendo uma das principais causas de mortes não intencionais (OMS, 2014). Segundo o *Global Burden of Disease* de 2019, 237 mil pessoas morreram por afogamento no planeta. No mesmo ano, no Brasil morreram 5,6 mil pessoas (SOBRASA, 2021).

Devido ao seu tamanho, o Brasil possui uma vasta rede hidrográfica e extensa costa, contendo assim, uma grande quantidade de localidades com acesso às águas naturais. De acordo com o Boletim de 2021 da Sociedade Brasileira de Salvamento Aquático (SOBRASA), 90% dos afogamentos ocorreram em águas naturais, sendo que 15% desses afogamentos ocorreram nas praias brasileiras.

Especificamente o estado de Santa Catarina possui aproximadamente 430 km de costa que pertencem a 36 municípios, que por sua vez contém aproximadamente 38% da população do estado (KLEIN et al., 2016). Nesta costa estão presentes um variado tipo de ambientes como praias, ilhas, enseadas, baías, mangues, áreas alagáveis, estuários e lagoas. Essa variedade, juntamente com o clima ameno, faz com que a região seja utilizada para uma variedade de usos que incluem, entre outras atividades, a recreação, banho, surfe e turismo de forma geral, aumentando significativamente o uso durante a estação do verão. A costa de Santa Catarina é formada por 246 praias arenosas que ocupam 60% do seu litoral. Deste total de praias, 31% são de alta energia, 46,5% são de praias de energia intermediária com presença de correntes de retorno e apenas 20% são de baixa energia e menos perigosas para o banho (KLEIN et al., 2016). Assim, essa condição das praias de Santa Catarina, juntamente com a prática do turismo, proporciona um elevado potencial de risco de afogamento. Conforme o Corpo de Bombeiros de Santa Catarina (2021), 90% dos afogamentos ocorridos em águas salgadas têm alguma relação com correntes de retorno.

As correntes de retorno, por sua vez, são fluxos de água rápidos e estreitos que se iniciam perto da costa e se estendem através da zona de surf em direção ao mar (BRANDER e SHORT, 2000; DALRYMPLE et al., 2011). Esses fluxos variam de tamanho, largura, profundidade e intensidade de acordo com o tipo de praia e são formados pelo retorno da água que chegou até a praia empurrada pelas ondas (Figura 1). Assim que as ondas arrebentam, a água é empurrada acima do nível

médio do mar, forçando um retorno dessa água através da força da gravidade (BERRIBILLI et al., 2007; DALRYMPLE et al., 2011).




Figura 1 - Esquema das correntes de retorno. Fonte (Ribeiro, 2014).

As correntes de retorno podem frequentemente serem identificadas na zona de surf em áreas de coloração mais escura associadas a canais mais profundos e em locais onde as ondas não arrebentam, localizadas entre áreas mais rasas onde as ondas arrebentam constantemente (DALRYMPLE et al., 2011).

Ainda que as correntes de retorno possam ter características físicas visíveis, tais quais as citadas acima, identificá-las geralmente não é uma tarefa fácil. Em geral, essa capacidade é restrita à estudiosos da área e profissionais como salva-vidas, com o devido treinamento. Assim, esta dificuldade gera aos banhistas potencial risco, pois o critério de escolha do local de banho pode não levar em consideração as características visuais de correntes de retorno.

Uma possível solução para este problema pode ser o uso de um aplicativo móvel que auxilie a identificação de correntes de retorno por meio de fotos frontais da localidade de banho desejada, permitindo a identificação, sobretudo, quando não houver a possibilidade de identificação e orientação por um profissional salva-vidas. Utilizando um modelo de *Deep Learning* o aplicativo realiza a classificação da imagem, indicando ao banhista onde potencialmente tem uma corrente de retorno e, dessa forma, o banhista pode tomar uma decisão mais assertiva sobre qual local escolher, sem a necessidade de ter um conhecimento prévio acerca do assunto.

Já existem propostas de identificação de correntes de retorno utilizando modelos de *machine learning* e classificação de imagens, como proposto por Ishikawa et al. (2021) que utiliza o modelo de detecção de objetos TinyYoloV3 para identificar correntes de retorno em imagens de *webcam*. Zhu et al. (2022), utilizaram o modelo YoloV5s com a mesma finalidade, porém em imagens aéreas. Por sua vez, Rashid et al. (2021) criou um modelo baseado em Tiny YoloV3 chamado RipDet em imagens em tons de cinza com contornos de correntes de retorno. No entanto, nenhum deles utiliza imagens na visão do banhista.

Assim, o objetivo do presente trabalho consiste na criação de um modelo de detecção de correntes de retorno a partir de fotos frontais de celular capturadas a partir da praia (visão do banhista). Visa-se no futuro implantar o modelo em um aplicativo móvel usando o App Inventor.

Espera-se com os resultados desta pesquisa contribuir com a segurança de banhistas, criando também um exemplo de caso no contexto da iniciativa Computação na Escola/INCoD/INE/UFSC para demonstrar o desenvolvimento de aplicativos inteligentes voltados a metas de desenvolvimento sustentável.

1.2. OBJETIVOS

1.2.1 Objetivo geral

O objetivo geral deste trabalho é desenvolver um modelo de detecção de correntes de retorno. Para tal, são adotadas técnicas de *deep learning* para automatizar a detecção a partir de fotos do mar capturadas com a câmera de celular de forma frontal ao mar.

1.2.2 Objetivos Específicos

O1. Analisar a fundamentação teórica sobre correntes de retorno e *deep learning*, principalmente detecção de objetos.

O2. Analisar o estado da arte em relação a detecção de correntes de retorno com *deep learning*.

O3. Desenvolver e testar um modelo utilizando *deep learning* para a detecção de correntes de retorno.

1.3 METODOLOGIA

A metodologia de pesquisa utilizada neste trabalho é dividida nas seguintes etapas.

Etapa 1 – Fundamentação teórica

Estudando, analisando e sintetizando os conceitos principais e a teoria referente aos temas a serem abordados neste trabalho é apresentado a fundamentação teórica utilizando a metodologia de revisão narrativa (CORDEIRO et al., 2007). Nesta etapa são realizadas as seguintes atividades:

A1.1 – Análise teórica sobre correntes de retorno

A1.2 – Análise teórica sobre *deep learning*

Etapa 2 – Estado da arte

Nesta etapa é realizado um mapeamento sistemático da literatura seguindo o processo proposto por Petersen et al. (2015) para identificar e analisar modelos de análise automatizado da originalidade de design de interfaces de usuário de apps atualmente sendo utilizados. Esta etapa é dividida nas seguintes atividades:

A2.1 – Definição do protocolo da revisão

A2.2 – Execução da busca e seleção de artigos relevantes

A2.3 – Extração e análise de informações relevantes

Etapa 3 – Desenvolvimento do modelo de *deep learning*

Nesta etapa é desenvolvido um modelo para detecção de correntes de retorno, seguindo um processo de desenvolvimento de redes neurais/deep learning (KIERSKI, 2017; POLYZOIS et al., 2017). Esta etapa é dividida nas seguintes atividades:

A3.1 – Análise de requisitos

A3.2 – Coleta de dados

A3.3 – Preparação de conjunto de dados utilizando o Roboflow¹.

A3.4 – Treinamento da rede neural e avaliação do desempenho

A3.5 – Predição/Inferência (teste com novas imagens)

¹ Acesso em: <https://universe.roboflow.com/>

2. FUNDAMENTAÇÃO TEÓRICA

2.1 CORRENTES DE RETORNO

As correntes de retorno são fenômenos hidrodinâmicos de alta complexidade que apresentam grande perigo para a segurança de banhistas no mar. Além do desconhecimento geral do público sobre a existência das correntes de retorno e seu comportamento, a sua identificação nem sempre é uma tarefa fácil.

As correntes de retorno são fluxos de água rápidos e estreitos que se iniciam perto da costa e se estendem através da zona de surfe² em direção às áreas profundas (BRANDER e SHORT, 2000; DALRYMPLE et al., 2011). Essas correntes são associadas à circulação de água entre a zona de surfe e áreas profundas onde a água trazida pelas ondas gera ao longo do litoral locais por onde ela retorna. Essas correntes rápidas se estendem em direção ao mar e aos poucos vão desacelerando, onde novamente essas águas estarão disponíveis para serem levadas pelas ondas em direção à costa (BRANDER et al., 2016).

As correntes de retorno são sistemas complexos que podem apresentar características físicas diversas como ocorrer em canais profundos ou fluir contra estruturas físicas (artificiais ou naturais). Podem ser duradouras ou transitórias, ocorrer dentro da zona de surf ou extrapolar-lá. Além disso, podem variar de acordo com o ângulo de incidência das ondas na praia. Isso significa que diferentes tipos de correntes de retorno podem existir e, inclusive, ocorrer em uma mesma praia. Existem algumas tentativas de classificação dos tipos de correntes de retorno, porém nenhuma foi adotada de forma universal na literatura. Isto representa um potencial risco para a educação e conscientização sobre as correntes e seu comportamento (CASTELLE et al., 2016).

Uma forma de classificação apresentada por Castelle et al. (2016) foi realizada levando em consideração os aspectos formadores de uma corrente de retorno. Em sua análise estas ocorrem devido a interação da energia e formação das ondas costeiras, da morfologia do assoalho marinho e/ou presença de obstáculos (afloramentos rochosos, promontórios, estruturas edificadas e etc). Essa interação é influenciada pelas diferentes profundidades causadas pelas marés (Figura 2).

² Arrebentação.

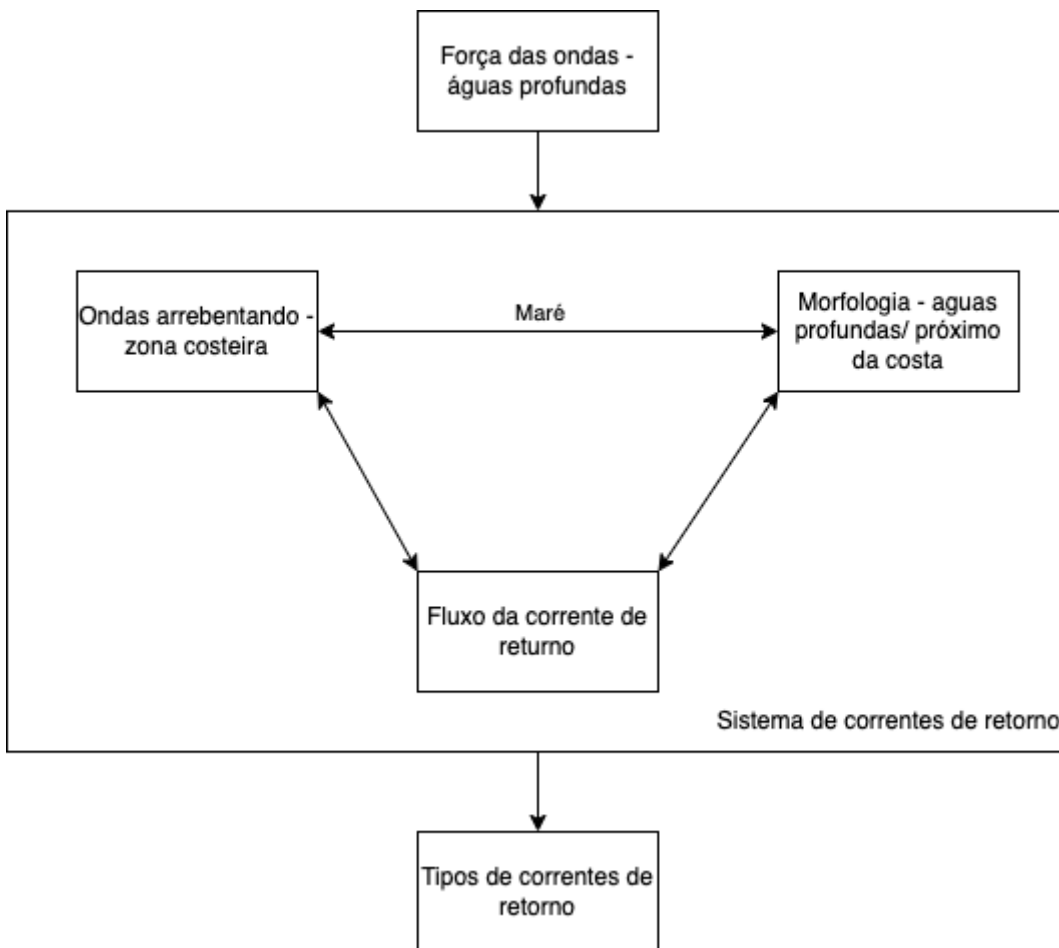


Figura 2. Diagrama de do sistema de correntes de retorno. Baseado em Castelle et al. (2016)

Esses tipos de correntes são divididos em três grupos principais:

- Correntes de retorno controladas hidrodinamicamente³ (Figura 3): que são definidas apenas por forças hidrodinâmicas, são temporárias e mudam de lugar, conseqüentemente são muito imprevisíveis. Podem ser causadas por redemoinhos gerados pela quebra das ondas na zona de surf, neste caso denominadas de *flash rips*. Ou podem ser geradas pela incidência oblíqua de ondas em praias de mar aberto, denominadas como *shear instability rips*.

³ *Hydrodynamically-controlled rip currents*




Figura 3 - A e B esquema e foto das *flash rips*. C e D esquema e foto das *shear instability rips*. Fonte: Castelle et al. (2016)

- Correntes de retorno controladas pela batimetria⁴: onde a morfologia do assoalho marinho é o principal fator gerador. Neste grupo existem dois tipos de correntes: *channel rip currents* onde devido a variabilidade morfológica na zona de surf faz com que surjam canais entre bancos de areia por percorrem e as *focused rips* causadas por anomalias batimétricas geradas por feições geológicas. Esse grupo de correntes costuma durar mais tempo sob uma determinada condição de marés ou ondulações.

⁴ Bathymetrically-controlled rips




Figura 4 - A e B esquema e foto das *channel rip currents*. C e D esquema e foto das *focused rips* (no esquema apresentando uma anomalia batimétrica com maior profundidade). Fonte: Castelle et al. (2016).

- Correntes de retorno controladas por barreiras: são correntes de retorno geradas em praias com presença de estruturas rígidas como afloramentos rochosos, promontórios e construções. Existem dois tipos de correntes nessa categoria, as *shadow rips* e as *deflection rips*. A diferença entre essas é basicamente dada pela forma como as ondas incidem sobre a praia (Figura 4).




Figura 4 - A e B esquema e foto de *shadow rip current*. C e D esquema e foto da *deflection rip*. Fonte: Castelle et al. (2016).

Entre todos os tipos de corrente de retorno citadas, as *channel rips* são as mais comuns e bem documentadas. Essas correntes apresentam a características físicas que geralmente são associadas às correntes de forma mais evidente (áreas de coloração mais escura associadas a canais mais profundos e ondas que não quebram localizadas entre áreas mais rasas onde as ondas quebram constantemente).

Porém, existem alguns tipos de corrente de retorno que nem sempre apresentam essas características, muitas vezes apenas poderão ser perceptíveis com perturbações na linha de quebra das ondas, ou como um comportamento agitado das águas diferente do seu entorno.

2.2 CARACTERIZAÇÃO DAS PRAIAS

As praias escolhidas no escopo do presente trabalho estão localizadas no leste da ilha de Santa Catarina. São praias que estão em mar aberto, o que lhes confere maior energia, dessa forma, sendo mais perceptível a presença de correntes de

retorno. São elas: a Praia do Santinho, a Praia do Moçambique, a Praia Mole e a Praia da Armação. Todas essas praias estão em núcleos urbanos do município de Florianópolis e têm grande fluxo de turistas durante a temporada de verão. Essas praias possuem presença de barreiras como costões que podem gerar correntes de retorno associadas a elas.

As praias podem ser classificadas a partir das suas características morfodinâmicas (CALLIARI et al., 2003). Existem dois estados extremos de praias:

- Dissipativo: Possuem baixo gradiente topográfico, as ondas arrebentam longe da face da praia e diminuem a altura progressivamente à medida que dissipam sua energia.
- Refletivo: possui alto gradiente topográfico, o que reduz o tamanho da zona de surfe. Geralmente são praias estreitas e com ondas de alta energia próximas à areia da praia.

E existem quatro estados intermediários de praias com mais ou menos características dos tipos extremos: banco e calha longitudinal, banco e praia de cúspides, bancos transversais e terraço de baixa-mar. Nas praias intermediárias costumam estar presentes as *channel rips* (CASTELLE et al., 2016).

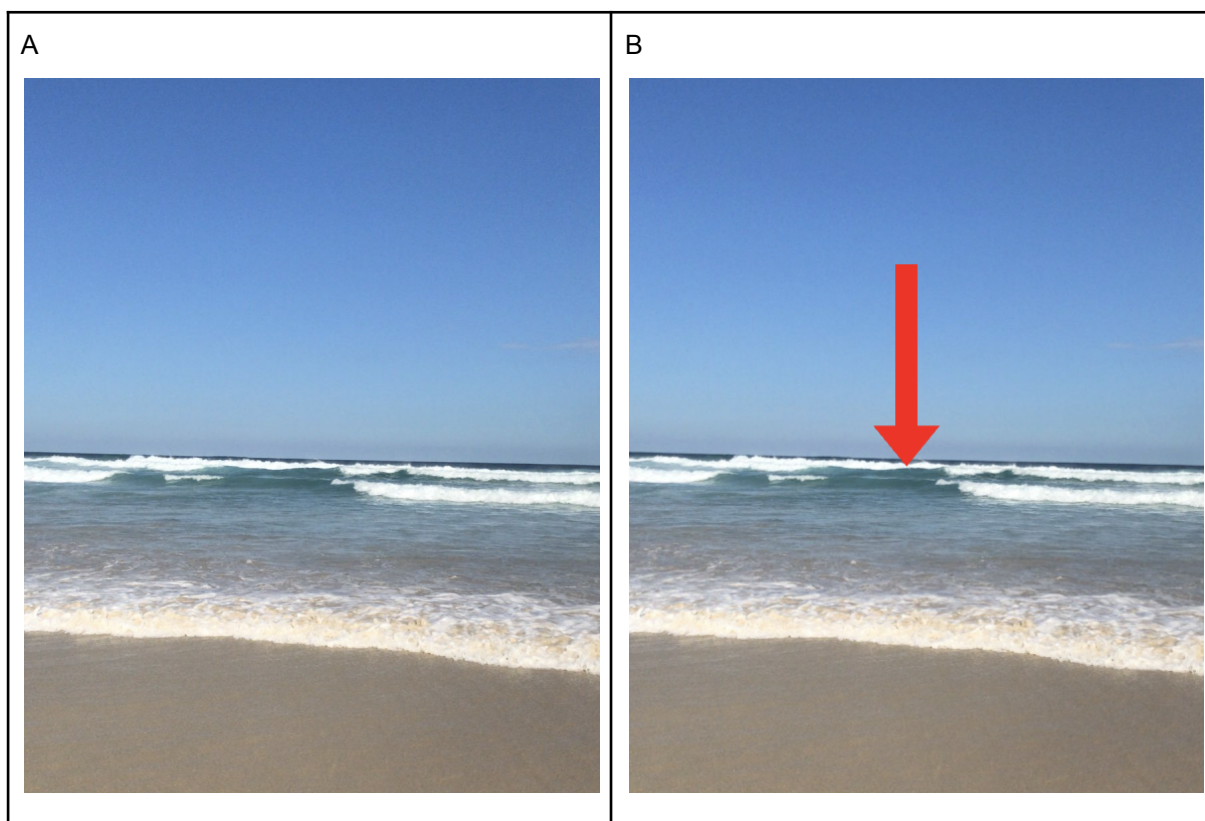
Considerando as praias selecionadas, todas podem ser classificadas como intermediárias, predominando o estado de bancos transversais (KLEIN et al, 2016), onde a praia apresenta bancos dispostos transversalmente intercalados com fortes correntes de retorno. Na praia da Armação também ocorre o estado de banco e calha longitudinal na porção mais ao sul, onde as ondas dissipam a energia no banco e se reformam na cava mais profunda. Segue na Tabela 1 um resumo das características das praias estudadas.

Praia	Características do entorno	Estado praial	Presença de barreiras	Tipos de correntes de retorno
Praia da Armação	Praia no perímetro urbano com uso turístico	Bancos transversais e banco e calha longitudinal	Costão na porção norte e ponta das campanhas ao sul	<i>Channel rip</i> , <i>Shadow rip</i> ou <i>Deflection rip</i>
Praia Mole	Praia no perímetro urbano com uso turístico	Bancos transversais	Costão nas porções norte e sul	<i>Channel rip</i> , <i>Shadow rip</i> ou <i>Deflection rip</i>
Praia do Moçambique	Praia com uso turístico cercado	Bancos transversais e	Costão na porção norte	<i>Channel rip</i> , <i>Shadow rip</i> ou

	pelo Parque Estadual do Rio Vermelho com presença de dunas	banco e praia rítmicos ou de cúspides		<i>Deflection rip</i>
Praia do Santinho	Praia no perímetro urbano com uso turístico, presença de dunas na porção norte	Bancos transversais	Costão nas porções norte e sul	<i>Channel rip, Shadow rip ou Deflection rip</i>

Tabela 1 - Caracterização das praias no foco da presente pesquisa. Fontes: Tipos de correntes baseado em Castelle et al. (2016), estado praias (KLEIN et al., 2016) e observações do próprio autor para caracterização do entorno.

As Figuras 5 apresentam imagens com correntes de retorno captadas na Praia do Santinho e Praia do Moçambique.






Figura 5 - As imagens A e B são da Praia do santinho, a seta na imagem B indica a corrente de retorno. As imagens C e D são da Praia do Moçambique, a seta na imagem D indica a corrente de retorno.

Essas imagens demonstram a complexidade de identificar correntes de retorno a partir da praia, pode-se perceber que na imagem da Praia do Moçambique é um pouco mais difícil de se perceber a presença da corrente de retorno.

2.2 DETECÇÃO DE OBJETOS COM O DEEP LEARNING

2.2.1 Deep learning

A Inteligência Artificial é uma área da Ciência da Computação que busca o desenvolvimento de programas de computador que podem perceber, raciocinar e se adaptar ao contexto em que estão inseridos (ALZUBAIDI et al., 2021). Dentro do escopo da inteligência artificial, existe o *Machine Learning (ML)*. ML pode ser entendido como um ramo desta área do conhecimento em que desenvolve-se algoritmos que executam tarefas e à medida que essas tarefas são executadas, o seu desempenho vai sendo aperfeiçoado. Assim, o computador "aprendeu" a executar melhor a tarefa designada (RAY, 2019; ALZUBAIDI et al. 2021). Esse aprendizado é feito a partir dos dados que são consumidos pelo algoritmo, métricas que quantificam o erro por meio da distância entre o desempenho obtida e o ideal e mecanismos de *feedback* que usam esse erro mensurado para gerar um melhor desempenho na próxima execução (JOSHI, 2020).

As redes neurais são estruturas baseadas no funcionamento do cérebro humano, que é composto por um grande número de neurônios interconectados. Assim, analogamente ao cérebro humano, uma rede neural contém nodos, que tal qual um

neurônio, se conecta a outros nodos. Cada nodo recebe múltiplos inputs através de conexões, cada uma com o seu peso. Na Figura 6, os valores x são os inputs, w são os pesos, f é a função de ativação e y o output. Quando a soma ponderada dos *inputs* ultrapassa um valor limite de cada nodo, este é ativado e passa o *output* para os próximos nodos conectados (ZOU et al., 2008).




Figura 6 - Exemplo de um nodo.. Fonte: ZOU et al. (2008)

As redes neurais tem uma topologia (Figura 7). Ela varia de acordo com o número de nodos em cada camada, o número de camadas e tipos de camadas, bem como as vias de conexão entre os nodos (ZOU et al., 2008).




Figura 7 - Exemplo de topologia de uma rede neural. Fonte: ZOU et al. (2008)

Geralmente, as redes possuem uma camada de *input* (por onde entram os dados), uma camada de *hidden layer* (camada em que os dados são processados) e uma camada de *outputs* (camada de saída dos resultados processados).

Com a evolução da capacidade de processamento e dos modelos de redes neurais, surgiu o *deep learning*, um conjunto de métodos em que são utilizadas redes neurais profundas. Esses métodos permitem que uma máquina receba os dados brutos e descubra automaticamente as representações necessárias para a classificação e/ou detecção. Cada camada da rede neural é responsável por transformar a

representação, desde o nível mais bruto na entrada de dados até um nível mais alto de abstração (ALZUBAIDI et al., 2021; LECUN et al., 2015).

Tanto no *machine learning* quanto no *deep learning*, a forma de aprendizado mais comum é a supervisionada (LECUN et al., 2015). Na aprendizagem supervisionada um conjunto de dados rotulados é utilizado para treinar a rede. Assim, o resultado obtido pela rede pode ser comparado com os resultados desejados, de modo a ser possível computar o erro obtido pela rede. Com essa informação os parâmetros de peso de cada nodo da rede são ajustados de modo a obter um novo conjunto de resultados e erros. Esse ciclo de ajuste da rede se repete até se obter um valor muito próximo do resultado da rede ao esperado (LECUN et al., 2015).

2.3 PROCESSO DE DETECÇÃO DE OBJETOS

Deep learning é aplicado a diversas tarefas, entre elas as de detecção de objetos em imagens. A detecção de objetos busca determinar onde objetos estão localizados na imagem e a qual classe cada objeto pertence (JIAO et al., 2019; ZHAO et al., 2019). A detecção de objeto pode ser utilizada para identificar uma instância específica de um objeto ou a instância genérica de alguma categoria já predefinida, por exemplo, cachorro, gato, carro, etc. (LIU et al., 2020). A detecção de objetos utiliza as chamadas *bounding boxes* para demonstrar o objeto detectado na imagem (Figura 8).



Figura 8 - Exemplos de *Bounding Box* indicando uma corrente de retorno

O desenvolvimento de um modelo de detecção de objetos segue um processo definido (AMERSHI et al., 2019) (GRESSE VON WANGENHEIM e VON WANGENHEIM, 2021).

Primeiramente é feita a análise de requisitos. Nesta etapa, é definido o objetivo do modelo de *Deep Learning*, a caracterização dos entradas e saídas esperadas, especificando o problema.

Em seguida vem a preparação dos conjuntos de imagens. No caso da detecção de objetos é necessário realizar a coleta de imagens com boa resolução, que não estejam desfocadas, conter os objetos a serem detectadas em diferentes perspectivas e muitas imagens para cada categoria. Na abordagem supervisionada de detecção de objetos é necessário fazer a rotulação de imagens. Para isso é necessário demarcar *bounding boxes* ao redor dos objetos que devem ser detectadas e identificá-los como pertencentes às categorias.

É importante ressaltar que o conjunto de imagens é dividido em três conjuntos: o de treinamento, o de validação e o de teste.

O conjunto de imagens de treinamento e validação preparados e rotulados é usado para o treinamento do modelo. Existem diversos modelos para detecção de objetos, entre eles Fast-RNN, YOLO, etc. O treinamento pode ser parametrizado em termos da quantidade de camadas na *hidden layer*, o tamanho do lote de imagens usado a cada iteração, a taxa de aprendizado (que define o quanto os pesos são alterados a cada iteração) e o número de épocas (o número de iterações realizadas no treinamento).

Após o treinamento é feita a avaliação de desempenho do modelo utilizando o conjunto de validação. Para isso é necessário considerar alguns conceitos. Primeiramente para medir a acurácia de localização do objeto detectado é utilizado o *intersection over union* (IoU), que avalia o quanto a proximidade do objeto detectado pelo modelo e a posição correta na imagem.




Figura 9 - Esquema do IoU. Fonte: Rosebrock (2016).

A partir do resultado do IoU, é determinado a incidência de falsos negativos (FN), falsos positivos (FP), verdadeiros negativos (VN), verdadeiros positivos (VP) para os objetos detectados, assim é possível estabelecer a precisão e o *recall*. A precisão é a medição da porcentagem de predições corretas, enquanto o *recall* é a capacidade de um modelo de encontrar todos os casos relevantes dentro de um conjunto de dados (AMORIM, 2020). A precisão é calculada pela fórmula:

$$\text{Precisão} = \text{VP} / (\text{VP} + \text{FP})$$

Já o *recall* é calculado por meio da fórmula:

$$\text{Recall} = \text{VP} / (\text{VP} + \text{FN})$$

Para calcular a *average precision* (AP) é feita uma interpolação utilizando os valores de *recall* e precisão utilizando da fórmula, sendo R os valores de *recall* e P o valor de precisão:

$$AP = (R_n - R_{n+1}) * P$$

A partir do AP é possível calcular o *mean average precision* (mAP), que é o somatório de AP dividido pelo número de classes.

$$mAP = \frac{1}{N} \sum_{k=1}^{k=n} AP_k$$

O limiar de IoU aceito para definir um VP influenciará o mAP e conseqüentemente na avaliação do modelo, dessa forma é dado o nome mAP50 para aqueles que utilizam um IoU de 50%, mAP90 para um IoU de 90%. Um mAP90 poderá ter um

valor menor em virtude de devido ao limiar de IoU, enquanto um mAP50 poderá ter uma valor maior devido ao limiar de aceitação.

Uma vez treinado na etapa de predição utiliza-se o conjunto de testes para testar o modelo com imagens não utilizadas durante o treinamento/validação. Como resultado, o modelo identifica uma *bounding box* ao redor do objeto mostrando o percentual de nível de confiança de pertencimento do objeto a uma determinada categoria.

Ao final, o modelo treinado pode ser exportado em formato nativo ou ONNX para possibilitar a implantação em sistemas *web* ou aplicativos móveis.

2.3.1 Modelos de detecção de objetos

As redes neurais convolucionais são os modelos comumente utilizados para processamento de imagens (PONTI e COSTA, 2017). Esse tipo de rede é composto por camadas convolucionais, em que cada nodo é um filtro aplicado em uma imagem de entrada, dessa forma, ao invés de se processar pixel a pixel na rede, é processado um conjunto de pixels vizinhos⁵ de acordo com o tamanho do filtro (Figura 11). Assim, devido aos pesos estabelecidos nos filtros é possível extrair características da imagem (PONTI e COSTA, 2017)

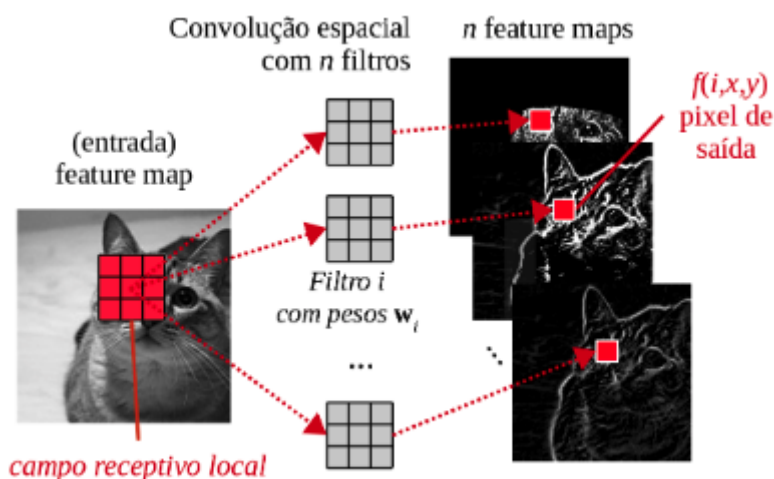


Figura 11 - Esquema das convoluções nas redes neurais convolucionais. Fonte: Ponti e Costa (2017)

⁵ Denominado campo receptivo local.

As redes neurais convolucionais apresentam melhor desempenho para a detecção de objetos e com o tempo surgiram outras propostas de redes neurais convolucionais. Um exemplo são as *Region Based Convolutional Neural Network* (R-CNN) que propõe um primeiramente pré-processamento realizando uma busca grosseira por regiões de interesse numa imagem e depois é feito o processamento em uma rede neural convolucional para computar da região que por fim são classificadas (ZHAO, 2019).

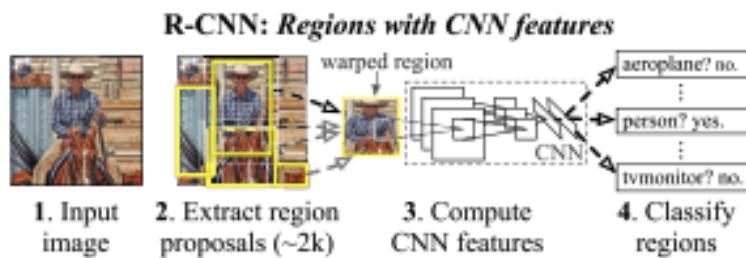


Figura 12 - Esquema das R-CNN. Fonte: Zhao, 2019

As R-CNN tem alto consumo computacional, em virtude disso foram propostas evoluções como a *Fast R-CNN* e o *Faster R-CNN*.

Neste contexto surgiu o YOLO (*You Only Look Once*), um *framework* que simplifica a *pipeline* de detecção de objetos, tornando-o extremamente rápido e possibilitando a detecção em tempo real. Diferentemente de outros algoritmos como R-CNN, essa técnica utiliza apenas uma avaliação da imagem na rede neural (REDMON et al., 2016).




Figura 13 - Esquema de funcionamento do YOLO. Fonte: Redmon et al. (2016).

A imagem de entrada é redimensionada para 448x448, e a imagem passa por uma rede convolucional e em seguida é feita uma *non-max suppression* que descarta

bounding boxes com baixa probabilidade de conter um objeto, retornando apenas as com maior probabilidade (REDMON et al., 2016).

O sistema divide a imagem em uma matriz SXS (Figura 14), caso o centro de um objeto esteja em uma célula da matriz, a mesma será responsável por detectá-lo. Cada célula delimita *bounding boxes* e um valor de confiança de que esta contém um objeto (REDMON et al., 2016).

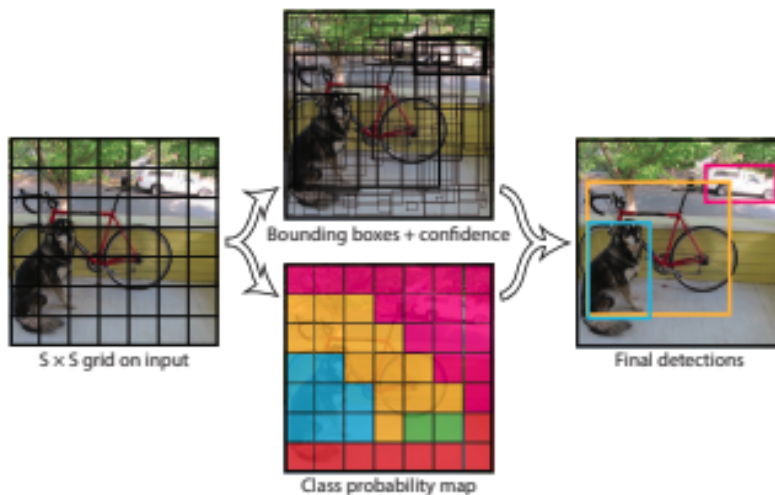



Figura 14 - Divisão da imagem em uma matriz, identificação das *bounding boxes* e nível de confiança e detecção fina. Fonte: Redmon et al. (2016).

A arquitetura original do YOLO foi inspirada no modelo de classificação de imagem GoogleNET e possui 24 camadas convolucionais que extraem os dados da imagem e 2 camadas totalmente conectadas que realizam a predição das probabilidades e coordenadas dos objetos (Figura 15).



O YOLO evoluiu ao longo dos anos, em 2016 foi lançado o YOLO v2 que apresentou uma melhoria em termos de velocidade e precisão. Utilizando o conjunto de dados PASCAL VOC2007 o YOLOv2 apresentou um AP de 78,6%, enquanto a versão anterior apresentou um AP de 63,4% (TERVEN e CORDOVA-ESPARZA, 2023). Em 2018 foi lançado o YOLOv3, que apresentava uma arquitetura maior, mas que ainda mantinha a velocidade e melhorava a precisão (REDMON e FARHADI, 2018). A partir dessa versão a arquitetura passou a ser descrita em três partes (TERVEN e CORDOVA-ESPARZA, 2023):

- *Backbone*: rede convolucional pré-treinada em grande conjunto de dados. É responsável por extrair as características úteis da imagem. Captura características como bordas e texturas a partir das camadas iniciais e partes do objeto e informações semânticas a partir das camadas mais profundas.
- *Neck*: componente intermediário que agrega e refina as características extraídas pelo backbone. O *neck* pode incluir mais camadas de convolucionais ou outros mecanismos para melhorar a representação das características.
- *Head*: parte responsável por realizar as previsões gerando as bounding-boxes. Consiste em uma ou mais camadas que classificam e localizam os objetos. No fim, um pós-processamento dos objetos classificados filtra-os para remover classificações sobrepostas.

O YOLOv4 foi lançado em 2020 e apresenta um AP 10% maior que o YOLOv3. Além disso, a arquitetura dessa versão possibilitou a realização do treinamento e a operação da detecção de objetos em GPUs convencionais, possibilitando assim um preço mais acessível e o seu uso em massa (BOCHKOVSKIY et al., 2020).

Ainda em 2020 foi lançado o YOLOv5, a principal diferença para a YOLOv4 é que foi desenvolvido utilizando PyTorch. Além disso, foram disponibilizadas algumas versões que podem ser utilizadas em diferentes contextos, inclusive dispositivos móveis (Figura 16). O YOLOv5 permite exportar o modelo para o formato ONNX,

possibilitando a integração com dispositivos móveis.

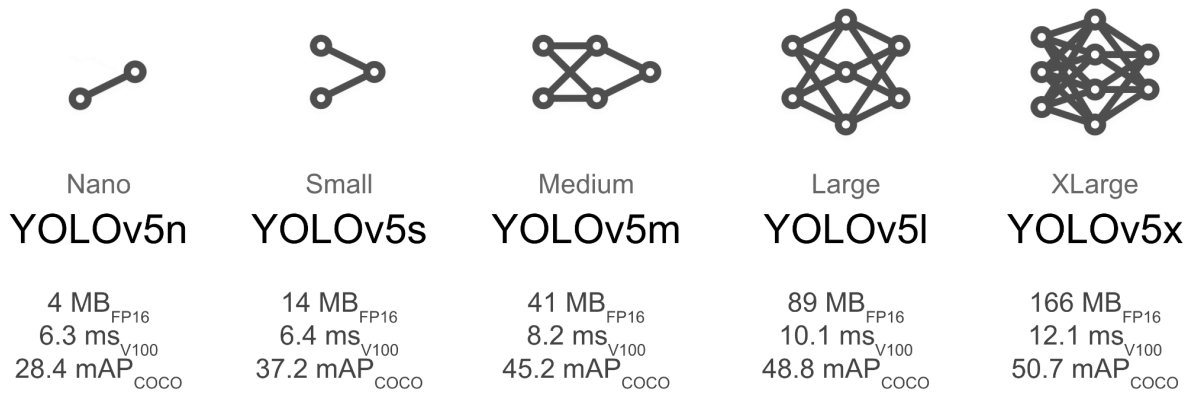


Figura 16 - Modelos de YOLOv5. Fonte: Ultralytics (2021).

As versões YOLOv5l e YOLOv5x tem mais parâmetros e geralmente obtêm resultados melhores, contudo são mais lentas, por este motivo são recomendadas para a implantação em nuvem. Enquanto as versões YOLOv5s e o YOLOv5m são menores e demandam menos capacidade de processamento, sendo recomendadas para implantação em dispositivos móveis (ULTRALYTICS, 2021).

As versões YOLOv6 e YOLOv7 foram lançadas em 2022 e apresentam uma melhora no desempenho em relação a outras versões, obtendo valores de AP maiores (TERVEN e CORDOVA-ESPARZA, 2023).

O YOLOv8 foi lançado em 2023, apresenta maior rapidez e utiliza menos parâmetros que o YOLOv7, conforme apresentado na Figura 17.




Figura 17 - Comparação de desempenho entre diferentes versões do YOLO. Fonte: Ultralytics (2021).

3 ESTADO DA ARTE

Para levantar o estado da arte sobre quais pesquisas existem para automaticamente detectar correntes de retorno em imagens utilizando *Deep Learning*, foi conduzido um mapeamento sistemático seguindo os procedimentos propostos por Petersen et al. (2008). Este mapeamento foi feito em colaboração com outro TCC (SEUGLING, 2023) também focado na detecção de correntes de retorno a partir de imagens do projeto CoastSnap.

3.1 DEFINIÇÃO DO PROTOCOLO DE REVISÃO

O objetivo desta revisão é responder às seguintes questões: quais pesquisas existem para detectar automaticamente correntes de retorno a partir de imagens adotando *Deep Learning*? Com base no objetivo desta revisão, a pergunta de pesquisa é refinada nas seguintes questões de análise:

AQ1. Quais pesquisas existem em termos de detecção de correntes de retorno?

AQ2. Quais as características em termos do conjunto de dados?

AQ3. Como os modelos foram treinados?

AQ4. Quais os desempenhos relatados?

Critérios de inclusão/exclusão. Foram consideradas somente pesquisas voltadas para a detecção de correntes de retorno. Foram excluídos artigos não coniventes a detecção de objetos, p.ex., somente a classificação de imagens. Foram considerados somente trabalhos publicados nos últimos 10 anos em inglês e português. Foram incluídas somente pesquisas que analisem imagens. Pesquisas exclusivamente baseadas em vídeos foram excluídas. Foram consideradas imagens de qualquer tipo, incluindo imagens aéreas ou *webcams*.

Critérios de qualidade. Somente foram considerados artigos ou materiais que forneciam informações pertinentes para a extração de respostas às perguntas de análise. Artigos

que contêm apenas um resumo de uma proposta, ou para os quais informações mais detalhadas não foram encontradas, foram excluídos.

Fontes dos dados. Foram abrangidos materiais e artigos publicados que estão disponíveis no ACM Digital Portal, IEEE e Scopus, que são importantes bibliotecas digitais acessíveis por meio do Portal Capes. Além disso, foi conduzida uma pesquisa no Google Scholar, devido ao fato desse mecanismo indexar um amplo conjunto de dados provenientes de diversas fontes (HADDAWAY et al., 2015).

Definição da *string* de busca. A *string* de busca foi composta de conceitos relacionados à questão de pesquisa, incluindo sinônimos.

Termo	Sinônimo
"Rip current"	-
"Deep learning"	"Machine Learning", "Object detection", "Artificial Intelligence", YOLO

Tabela 2: Termos de busca utilizados no protocolo de revisão

A partir disso foi gerado o *string* de busca genérico:

"Rip current" AND ("Deep learning" OR "Machine Learning" OR "Object detection" OR "Artificial Intelligence" OR YOLO)

A *string* de busca genérica foi adaptada para cada fonte de dados apresentada na Tabela 3.

Fonte	String de busca
ACM	[Abstract: "rip current"] AND [[Abstract: object detection] OR [Abstract: deep learning] OR [Abstract: machine learning] OR [Abstract: artificial intelligence] OR [Abstract: ai] OR [Abstract: yolo]] AND [E-Publication Date: (01/01/2018 TO 12/31/2022)]
IEEE	((("Abstract": "rip current") AND ("Abstract": "machine learning" OR "Abstract": "deep learning" OR "Abstract": "artificial intelligence" OR "Abstract": "neural network" OR YOLO OR AI)))
SCOPUS	(TITLE-ABS-KEY ("Rip current") AND TITLE-ABS-KEY ("Deep learning" OR "Machine Learning" OR "Object detection" OR "Artificial Intelligence" OR yolo))
Google Scholar	Rip current "Deep learning" OR "Machine Learning" OR "Object detection" OR "Artificial Intelligence" OR YOLO OR AI

Tabela 3 - *String* de busca para cada fonte.

3.2 EXECUÇÃO DA BUSCA

A pesquisa foi realizada em maio de 2023 pelo autor em conjunto com Seugling (2023) e revisada pela orientadora (Tabela 4).

Fonte	No. de resultados da busca	No. de resultados analisados	No. de resultados potencialmente relevantes	No. de resultados relevante
ACM	1	1	1	0
IEEE	3	3	2	1
Google Scholar	327	200	13	7
SCOPUS	11	11	5	4
Total (sem duplicados)				7

Tabela 4 - Número de artigos identificados por repositório e por fase de seleção.

Na primeira fase de análise, os títulos e resumos dos resultados da busca foram analisados, resultando em 21 artefatos potencialmente relevantes. No segundo estágio, os materiais foram lidos por inteiro, para assegurar sua relevância com respeito aos critérios de inclusão/exclusão. Foram excluídos artigos como, p.ex. (McGill et al., 2022) na qual utiliza apenas visão computacional e não *Deep Learning*. Sendo assim, apenas 7 dos 21 artefatos potenciais foram considerados relevantes (Tabela 4).

3.3 RESULTADOS DA BUSCA

Com base nas perguntas de análise, foram identificadas e extraídas as informações pertinentes dos artefatos encontrados.

3.3.1 Quais pesquisas existem em termos de detecção de correntes de retorno?

Referência	Título do artigo
(de Silva et al., 2021)	Automated Rip Current Detection with Region based Convolutional Neural Networks
(Ishikawa et al., 2021)	Proposal and verification of rip current detection using AI
(Maryan, 2018)	Detecting Rip Currents from Images/Machine learning applications in detecting rip channels from images
(Rampal et al., 2022)	Interpretable Deep Learning Applied to Rip Current Detection and Localization
(Rashid et al., 2022)	Reducing rip current drowning: An improved residual based lightweight deep architecture for rip detection
(Rashid et al., 2021)	RipDet: A Fast and Lightweight Deep Neural Network for Rip Currents Detection
(Zhu et al., 2022)	YOLO-Rip: A modified lightweight network for Rip currents detection

Tabela 5. Pesquisas que utilizam *Deep Learning* para detecção de correntes de retorno

Não foram encontradas muitas pesquisas sobre detecção de correntes de retorno usando *Deep Learning* dentro dos critérios de busca estabelecidos (Figura 18). Durante o período em que foi realizada a busca, verifica-se que a primeira pesquisa foi publicada em 2018 e depois acontece um intervalo sem publicação de dois anos. Em 2021 volta a ter trabalhos relevantes, sendo 2021 e 2022 os anos com mais artigos publicados, o que mostra um crescimento de pesquisas envolvendo o assunto.




Figura 18 - Quantidade de artigos relevantes ao assunto publicados nos últimos 6 anos. Fonte: Autor, 2023

3.3.2 Quais as características em termos do conjunto de dados?

Após a seleção dos trabalhos, foi conduzida uma pesquisa e os resultados obtidos foram organizados na Tabela 6, que contém uma visão geral das informações coletadas.

Referência	Tipo de imagens/vídeos	Quantidade de imagens no conjunto de dados	Resolução	Técnicas de <i>data augmentation</i> utilizadas
(de Silva et al., 2021)	Imagens aéreas do Google Earth, 23 vídeos	Treinamento: 2.440 imagens (sendo 700 sem correntes de retorno) Teste: 18.042 frames dos vídeos (sendo 8.989 sem correntes de retorno)	Treinamento: (1086 x 916) até (234 x 234) Redimensionada para (300 x 300) Teste: 1289x720 até 108x920	Rotação de imagens 90° no sentido horário e anti horário.
(Ishikawa et al., 2021)	Imagens de webcams na praia (ângulo oblíquo)	Treinamento: 64.127	Não informado	Não informado
(Maryan, 2018)	Imagens ortorretificadas (<i>collection of backlogged imagery</i>)	514 correntes de retorno e 800 sem correntes de retorno	24 x 24	Não informado
(Rampal et al., 2022)	Imagens aéreas do Google Earth	1.740 (sendo 700 sem correntes de retorno)	(1.086 × 916) até (234 × 234)	Normalização de histograma da imagem, perturbação de canal e embaralhamento de canais. Geração sintética de névoa, chuva, brilho do sol, rotação e zoom aleatório
(Rashid et al., 2021)	Imagens em tons de cinza com contornos de correntes de retorno	Treinamento: 4.126 Teste: 483	(1001 x 301)	<i>Random Translation</i> : (-0.3, 0.3) <i>Horizontal flip</i> : probabilidade 1 <i>Random Shear</i> : (0.1) <i>Random scaling</i> : (-0.3, 0.3) <i>Random rotation</i> : (1, 360) <i>Random Object Replacement</i> , <i>Random Object Cutout</i>
(Rashid et al., 2022)	Não informado	4.608 imagens (4.126 para treinamento e 482 para teste)	(1001 × 301) pixels	-Tradução aleatória -Rotação aleatória -Escala aleatória -Cisalhamento aleatório -Espelhamento horizontal
(Zhu et al., 2022)	Imagens aéreas	1.740 (sendo 700 sem correntes de retorno) 23 vídeos para treinamento	(4000 × 2250) até (480 × 360) pixels.	Não informado

Tabela 6: Informações sobre os dados encontrados nas pesquisas

Analisando as pesquisas encontradas, observa-se que foram utilizadas câmeras *webcams*, imagens aéreas do Google Earth e *frames* de vídeos, como a pesquisa apresentada por de Silva et al. (2021) (Tabela 6). Observa-se também que não foi

encontrado nenhuma pesquisa usando imagens frontais capturadas a partir da praia, capturadas por dispositivos móveis como *smartphones*.

Em geral, os trabalhos utilizam mais de mil imagens, chegando a 4.000 imagens. Porém, existe uma exceção, a pesquisa de Ishikawa et al. (2021) usando mais de 60 mil imagens. Segundo o Ishikawa (2021), foram instaladas 3 câmeras nas praias durante 4 meses capturando imagens em uma taxa contínua de 3 por segundo. Por meio de técnicas de *data augmentation*, eles alcançaram esta quantidade grande de imagens (Figura 19).

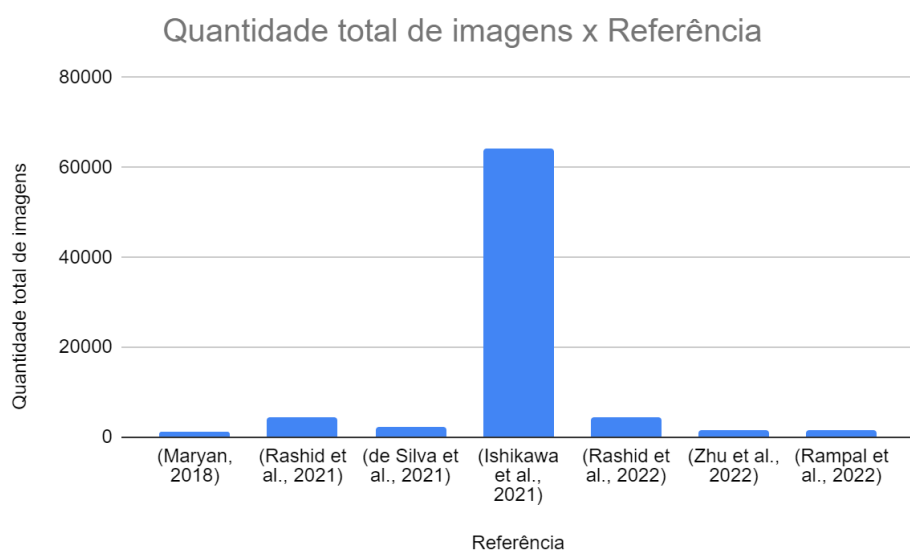


Figura 19 - Quantidade de imagens no conjunto de dados por pesquisa Fonte: Autor, 2023

Para detalhar a análise foi feito um gráfico removendo o *outlier* conforme apresentado na Figura 20.

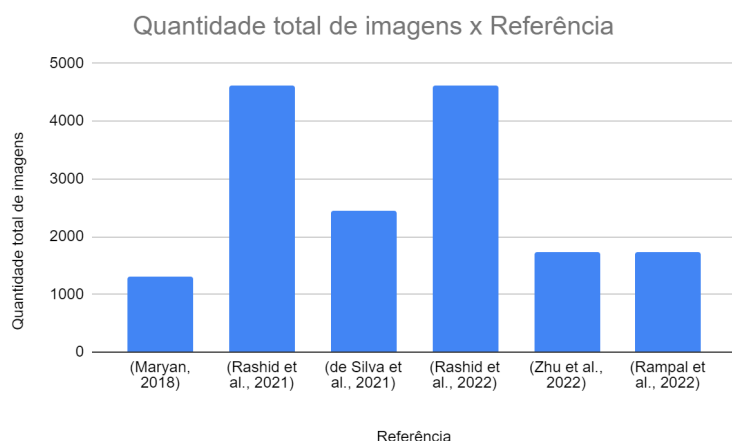


Figura 20 - Quantidade de imagens no conjunto de dados por pesquisa após limpeza de *outlier*. Fonte: Autor, 2023

Percebe-se que os trabalhos que realizaram *data augmentation* utilizaram técnicas para alterar o posicionamento da imagem como rotação, zoom, *shear*, espelhamento. No trabalho de Rampal et al. (2022), também são utilizadas técnicas para adição de ruídos como névoa, brilho do sol e chuva.

3.3.4 Como os modelos foram treinados?

A Tabela 7 mostra as informações sobre o treinamento.

Referência	Modelo de DL	Parâmetros		
		Taxa de aprendizagem	Epochs	Optimizer
(de Silva et al., 2021)	F-RCNN, F-RCNN+Frame Aggregation	NI	60	NI
(Ishikawa et al., 2021)	Tiny Yolo V3	NI	NI	NI
(Maryan, 2018)	Max Distance from Average, SVM, CNN, Viola-Jones, Meta Learner	NI	NI	NI
(Rampal et al., 2022)	Classificação: 3-layer CNN com MaxPooling, Batch normalization and Dropout Regularization Mobile Net - 28-layer CNN, Residual Blocks, Max Pooling, Batch Normalization and Dropout Regularization. Localização: Grad-CAM	Não informado	Não informado	NI
(Rashid et al., 2021)	RipDet (Tiny Yolo V3 modificado)	1e-4/1e-6	Warmup: 2	Adam

			Validation:100	
(Rashid et al., 2022)	RipDet (Tiny Yolo V3 modificado)	Não informado	<ul style="list-style-type: none"> • Épocas de treinamento: 100. • Épocas após as quais o modelo foi avaliado durante o treinamento: 5. 	Adam
(Zhu et al., 2022)	YOLOv5s (modificado utilizando um joint dilatation convolution no neck da arquitetura e SimAM como mecanismo de atenção)	0.01	300	Não informado

Tabela 7: Informações sobre o treinamento dos trabalhos encontrados (NI - Não informado)

Observando as informações sobre os treinamentos dos artigos, percebe-se que a maioria dos trabalhos utiliza modelos YOLO ou modelos baseados nele. O modelo YOLO mais utilizado foi o Tiny YOLOv3, apenas o trabalho de Zhu et al. (2022) utilizou o YOLOv5s. Os trabalhos que não utilizaram YOLO utilizaram outras redes neurais convolucionais. No caso de Maryan (2018) também se utilizou outras técnicas de *machine learning* como *Support Machine Vector* e *Viola-Jones*. Já o trabalho de Rampal et al. (2022) utiliza dois modelos diferentes de redes neurais convolucionais para a classificação de imagens e o Grad-CAM para interpretar quais regiões da imagem foram mais relevantes para classificação da imagem, sendo possível localizar a corrente de retorno.

3.3.5 Quais os desempenhos relatados?

Os desempenhos relatados nos trabalhos revisados estão na Tabela 8.

Referência	mAP	Acurácia	IoU Threshold
(de Silva et al., 2021)		F-RCNN: 0,884, F-RCNN+FA: 0,984	0.3
(Ishikawa et al., 2021)		Tiny Yolo: 88% para correntes de retorno, 61% sem correntes de retorno	NI
(Maryan, 2018)		CNN: 50%, SVM: <85%	NI
(Rampal et al., 2022)		0.89	NI
(Rashid et al., 2021)	98.131%		NI
(Rashid et al., 2022)	98.55%		<ul style="list-style-type: none"> • IoU threshold durante o teste: 0.45. • <i>IoU threshold</i> durante treinamento : 0.5.
(Zhu et al., 2022)	92.15%		0.5

Tabela 8 - Desempenhos relatados

Nos trabalhos relevantes foram utilizadas duas métricas de análise de desempenho: a acurácia que mede a proporção de amostras classificadas corretamente em relação ao total e o mAP. Em termos de acurácia destaca-se a pesquisa de Silva et al. (2021) relatando uma acurácia de 0.984. Já considerando o mAP50 o trabalho que relatou o melhor desempenho foi o de Rashid et al. (2022) com 98.55%. Por serem diferentes formas de avaliar desempenho, não é possível comparar os trabalhos em termos de desempenho do modelo.

3.4 DISCUSSÃO

A revisão sistemática da literatura demonstra que existem pesquisas recentes sobre detecção de correntes utilizando *deep learning*. No entanto, essas pesquisas utilizam conjunto de dados com imagens aéreas ou *webcams* em pontos estáticos da praia que possuem um campo de visão mais amplo possibilitando uma melhor identificação das correntes de retorno. Esse aspecto difere do presente trabalho que pretende utilizar fotos frontais a partir da praia coletadas com *smartphones*. Não foi encontrado nenhum trabalho usando imagens frontais até este momento.

Com relação aos modelos utilizados nos trabalhos, percebe-se a predominância das redes neurais convolucionais e especificamente do YOLO para a detecção de objetos. Que conforme os resultados de avaliação de desempenho relatados conseguem nos respectivos contextos obter bons desempenhos. Os modelos baseados em Tiny YOLOv3 de Rashid et al (2021) e Rashid et al (2022) obtiveram mAP de 98.131% e 98.55% respectivamente. Já o modelo de Zhu et al (2022) que utilizou YOLOv5s obteve mAP de 92.15%.

Não foi observado a implantação de modelos treinados em aplicativos móveis. Desta forma, o desenvolvimento de modelos utilizando fotos frontais da praia possibilita a implantação futura em um app mobile, tornando possível sua disponibilidade a um público maior.

Não foram identificadas pesquisas brasileiras sobre detecção de correntes de retorno utilizando detecção de objetos, o que evidencia uma lacuna de conhecimento que precisa ser mais explorada, já que o Brasil possui uma costa extensa e é bastante comum a ocorrência das correntes de retorno.

Ameaças a validade. Como em qualquer mapeamento sistemático, existem algumas ameaças à validade dos resultados. As ameaças potenciais foram identificadas e estratégias de mitigação para minimizar os impactos foram aplicadas:

- Viés de publicação: Pesquisas com resultados positivos têm maior probabilidade de publicação. No entanto, foi considerado que os resultados dos artigos, sejam positivos ou negativos, têm apenas uma pequena influência sobre esse mapeamento sistemático.
- Identificação de estudos: Outro risco é a omissão de estudos relevantes. A fim de mitigar esse risco, a string de busca foi construída para ser o mais abrangente possível, considerando também os sinônimos. Também foram realizadas buscas em diferentes bases e Google Scholar para reduzir o risco de omissão.
- Seleção e extração de dados de estudos: Ameaças para estudar seleção e extração de dados foram mitigadas por meio de um protocolo para a seleção de artigos relevantes. A execução da seleção e extração foi também revisado e

discutido com o colega de TCC (Seugling, 2023) e a orientadora do presente trabalho.

4 DESENVOLVIMENTO DO MODELO DE DETECÇÃO DE CORRENTES DE RETORNO

As correntes de retorno são um fenômeno hidrodinâmico comum em praias, sendo a principal razão de afogamentos nelas. A forma principal de diminuir esses afogamentos é por meio da prevenção feita por salva vidas durante a temporada de verão, seja demarcando sua localização ou alertando banhistas sobre o risco na praia. Contudo, nem sempre há salva vidas alocados nas praias ou há salva vidas suficientes para cobrir toda a extensão da praia. Assim, um aplicativo com AI para detecção das correntes de retorno ajudaria banhistas a diminuir o risco de afogamento. No seu ponto de vista, um banhista precisa saber onde na praia tem correntes de retorno, porque quer diminuir o risco de afogamento no mar.

4.1 REQUISITOS

Conforme indicado pelo levantamento do estado da arte, o presente estudo adota *deep learning* para automatizar a detecção utilizando e comparando vários modelos YOLO incluindo modelos YOLO mais recentes prevendo a futura implantação do modelo treinado em um aplicativo móvel usando o App Inventor. Considera o seguinte cenário de uso:

Uma família de turistas provenientes de uma cidade sem costa, chega no município de Florianópolis para aproveitar as férias fora da temporada de verão. A família vai à praia do Santinho, porém a mesma não está com a devida guarnição e sinalização de perigos. Para decidir em que ponto da praia a família vai se banhar utiliza um aplicativo de celular em que ao apontar a câmera e captura uma foto do mar a sua frente (Figura 21).



Figura 21 - Exemplo de imagem fotografada por um banhista.

Utilizando a foto como entrada o aplicativo usa o modelo de DL para detectar as correntes de retorno na foto e apresenta como resultado a informação se há ou não correntes e caso sim, apresenta a sua presença na foto com *bounding box* (Figura 22).



Figura 22 - Exemplo de imagem classificada pelo aplicativo

Desta forma, usuários com baixo conhecimento sobre o tema são auxiliados na detecção das correntes de retorno e com essa informação minimizam os riscos de afogamento. Considerando esse cenário, visa-se desenvolver um aplicativo inteligente para detecção de correntes de retorno em imagens frontais de mar (paisagem) de uma câmera de celular Android.

História de usuário	COMO banhista EU QUERO descobrir onde tem correntes de retorno PARA diminuir o risco de afogamento no mar.
Funcionalidade(s)	Detectar uma corrente de retorno a partir de uma imagem frontal fotografada a partir da praia

Tabela 9 - História do usuário

Desta forma, visa-se o desenvolvimento de um modelo de detecção de objetos que pode ser futuramente implantado no aplicativo móvel de acordo com as características especificadas na Tabela 9.

Objetivo do modelo de DL	
Tarefa	Detectar a presença ou não de uma corrente de retorno em imagens capturadas em um dispositivo móvel
Tipo da tarefa	Detecção de objetos
Categorias	Corrente de retorno/Sem corrente de retorno
Contexto de uso	O modelo é utilizado por um banhista para identificar pontos sem correntes de retorno na praia para se banhar a partir de imagens frontais
Riscos e requisitos de desempenho	
Risco	Risco alto A não detecção de uma corrente de retorno na praia pode colocar o banhista em risco que pode ter consequências fatais
Desempenho esperado	O modelo será otimizado para precisão pois precisa-se reduzir o risco de não detectar uma corrente de retorno
	Espera se atingir no mínimo um mAP50= 0.98

Tabela 10 - Objetivos do modelo de DL

4.2 PREPARAÇÃO DOS CONJUNTOS DE IMAGENS

Pela inexistência de conjunto de imagens deste tipo, foi coletado um conjunto de imagens frontais a partir da praia. As imagens foram todas coletadas em Florianópolis, mais

especificamente nas praias da Armação, Mole, Santinho e Moçambique. O conjunto de dados é armazenado no Roboflow.

A anotação das imagens foi feita por um aluno de graduação do curso de oceanografia e salva-vidas civil sob a revisão de professor do curso de oceanografia da UFSC. Durante a anotação são indicados a presença de correntes de retornos nas imagens utilizando *bounding boxes*, também são marcadas as imagens que não possuem correntes de retorno.

Conjunto de dados				
Praia	Total	Com corrente	Sem corrente	Link do conjunto de imagens rotulados no Roboflow
Santinho	875	347	528	https://app.roboflow.com/cne-ufsc/rip-current---frontal---praia-santinho/overview
Armação	1.194	606	588	https://app.roboflow.com/cne-ufsc/rip-current---frontal---praia-armacao/overview
Moçambique	1.187	47	1140	https://app.roboflow.com/cne-ufsc/rip-current---frontal---praia-mocambique/overview
Mole	1.364	51	1313	https://app.roboflow.com/cne-ufsc/rip-current-frontal-praia-mole/overview

Tabela 11 - Conjunto de imagens rotulados

O tamanho do conjunto de dados coletados não difere tanto em relação aos trabalhos correlatos no estado da arte. Apenas os artigos de Ishikawa et al (2021) e de Silva et al (2021) possuem um conjunto de dados maior que o coletado.

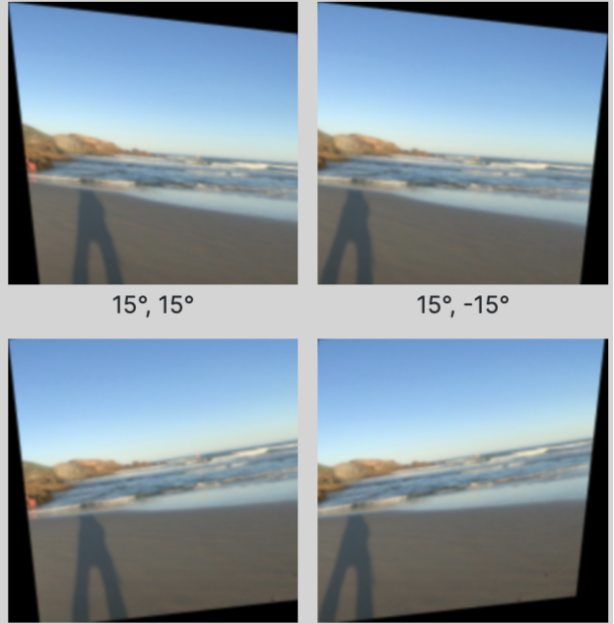
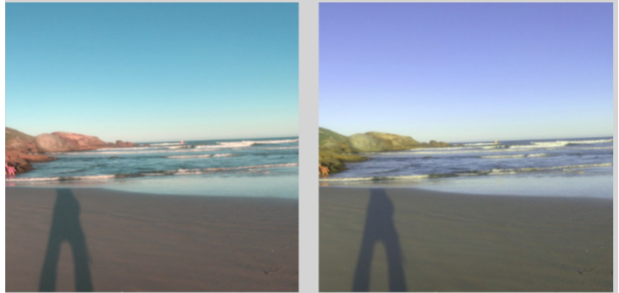
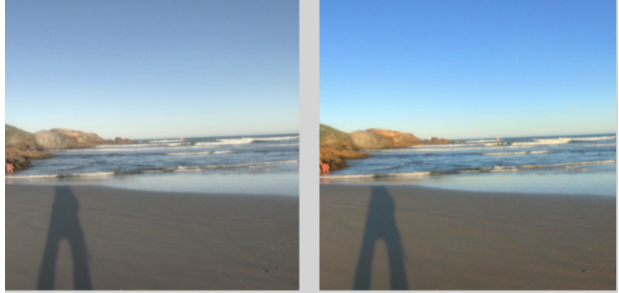
A Figura 23 apresenta alguns exemplos de imagens do conjunto.



Figura 23 - Exemplos de imagens do conjunto. As imagens A, B e C possuem correntes de retorno indicadas por *bounding boxes*. A imagem D não possui corrente de retorno.

Usou-se técnicas de *data augmentation* para aumentar o conjunto de dados e gerar maior variabilidade. Entre as técnicas propostas são utilizadas as relativas ao posicionamento da imagem: rotação, *shear* (alterando a perspectiva da imagem). Também serão utilizadas técnicas relativas ao aspecto das imagens: alteração de matiz, saturação e brilho, borramento e adição de ruído. Esse processo foi realizado no Roboflow (Tabela 12).

Técnica	Exemplo
---------	---------

<p>Rotação de 15 graus - 15 graus</p>	 <p style="text-align: center;">-15° 15°</p>
<p>Shear 15 graus</p>	 <p style="text-align: center;">15°, 15° 15°, -15°</p> <p style="text-align: center;">-15°, 15° -15°, -15°</p>
<p>Matiz 20 graus</p>	 <p style="text-align: center;">-20° 20°</p>
<p>Saturação 25%</p>	 <p style="text-align: center;">-25% 25%</p>

Brilho 25%



Blur 1px

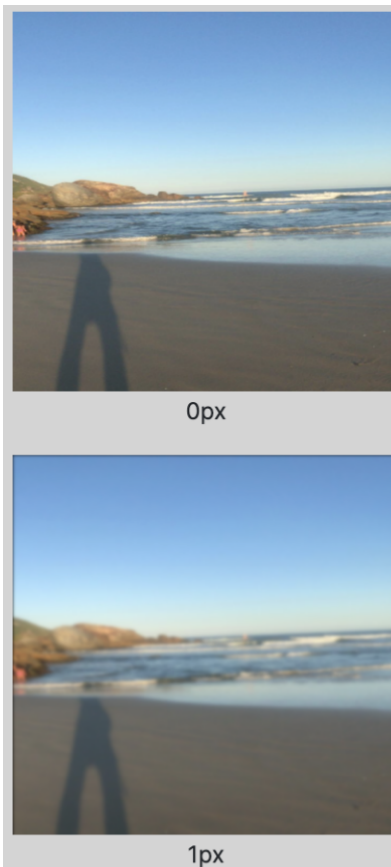




Tabela 12 - Técnicas de *data augmentation* adotadas

As técnicas de *data augmentation* foram aplicadas de forma aleatória, ou seja, uma imagem selecionada não recebia efeitos do *data augmentation* e duas cópias delas recebiam aleatoriamente algum dos efeitos citados.

Os conjuntos de imagens foram dividido da seguinte maneira:

- 70% para treinamento
- 20% para validação
- 10% para teste

O balanceamento destes conjuntos segue a proporção de classes presentes no conjunto de imagens.

O conjunto de treinamento foi utilizado durante o processo de treinamento para generalizar os padrões e características das correntes de retorno. A cada época de treinamento o conjunto de validação é utilizado para avaliar a generalização do modelo

utilizando dados não vistos no treinamento. Já o conjunto de testes foi utilizado para avaliar o desempenho final do modelo após treinamento e validação.

4.3 TREINAMENTO

O treinamento foi realizado utilizando modelos YOLOv5s e YOLOv8s. A escolha das redes neurais foi feita com base nos resultados do estado da arte, observando a importância que os modelos do YOLO para este tipo de pesquisa, possibilitando melhores resultados em termos de desempenho. Porém, diferente dos trabalhos identificados no estado da arte, foi considerado também a versão mais recente do YOLO. Além disso, foram escolhidas redes pequenas (as versões "s") para possibilitar a implantação dos modelos treinados em aplicativo móvel futuramente.

Por conta do balanceamento entre as classes "sem corrente de retorno" e "com corrente retorno", foram selecionados apenas os conjuntos de imagens da Praia do Santinho e da Praia da Armação para o treinamento. Dessa forma, para cada praia foram feitos quatro experimentos de treinamento:

- Modelo YOLOv5s sem data augmentation
- Modelo YOLOv5s com data augmentation
- Modelo YOLOv8s sem data augmentation
- Modelo YOLOv8s com data augmentation

A partir de *notebooks* fornecidos pelo Roboflow em sua documentação foram feitos os *notebooks* utilizados para o treinamento dos modelos⁶⁷. Por fim, os dois conjuntos de dados das praias foram unidos em único conjunto com o intuito de aumentar a variabilidade no teste. Os mesmos quatro treinamentos foram realizados para este conjunto unificado. Nas próximas seções são relatados os resultados obtidos nos treinamentos.

⁶ *Notebook* para treinamento do modelo YOLOv5s. Disponível em: https://colab.research.google.com/drive/1OPEs5EDyFk5ECCtFsX1gptna_baJyfEN?usp=sharing

⁷ *Notebook* para treinamento do modelo YOLOv8s. Disponível em: <https://colab.research.google.com/drive/1fA1V0jFWUajVcd1R4W5oTUA4sOaV4wpc?usp=sharing>

Durante o treinamento foi utilizado o conjunto de treinamento para que o modelo generalizasse as características das classes e o conjunto de validação para avaliar seu desempenho.

Foi utilizado o parâmetro de "*early stopping*" para que o modelo finalize o processamento caso não melhore seu desempenho nas últimas 50 épocas, reduzindo o tempo de processamento desnecessário.

A avaliação dos treinamentos/validação levou em consideração a evolução e resultados finais das métricas de *mAP50*, precisão e *recall*. Além disso foi feita uma análise do comportamento dessas métricas e métricas relativas a *loss* ao longo das épocas. Esta avaliação ao longo das épocas possibilita a identificação de *overfitting* do modelo.

4.3.1 - Treinamento com imagens da Praia da Armação

4.3.1.1 - Modelos YOLOv5s

Conjunto de dados (sem <i>data augmentation</i>)	
Conjunto original	Total de 1.194 imagens 606 imagens com correntes/ 588 sem correntes
Treinamento	834 imagens
Validação	238 imagens
Teste	121 imagens
Treinamento YOLOv5	
Modelo	YOLOv5s
Quantidade de Épocas	300
Tamanho do lote	32
Avaliação de desempenho	
<i>mAP50</i>	0.359
Precisão	0.46
<i>Recall</i>	0.353
<i>F1-score</i>	0.399
Resultados do treinamento	

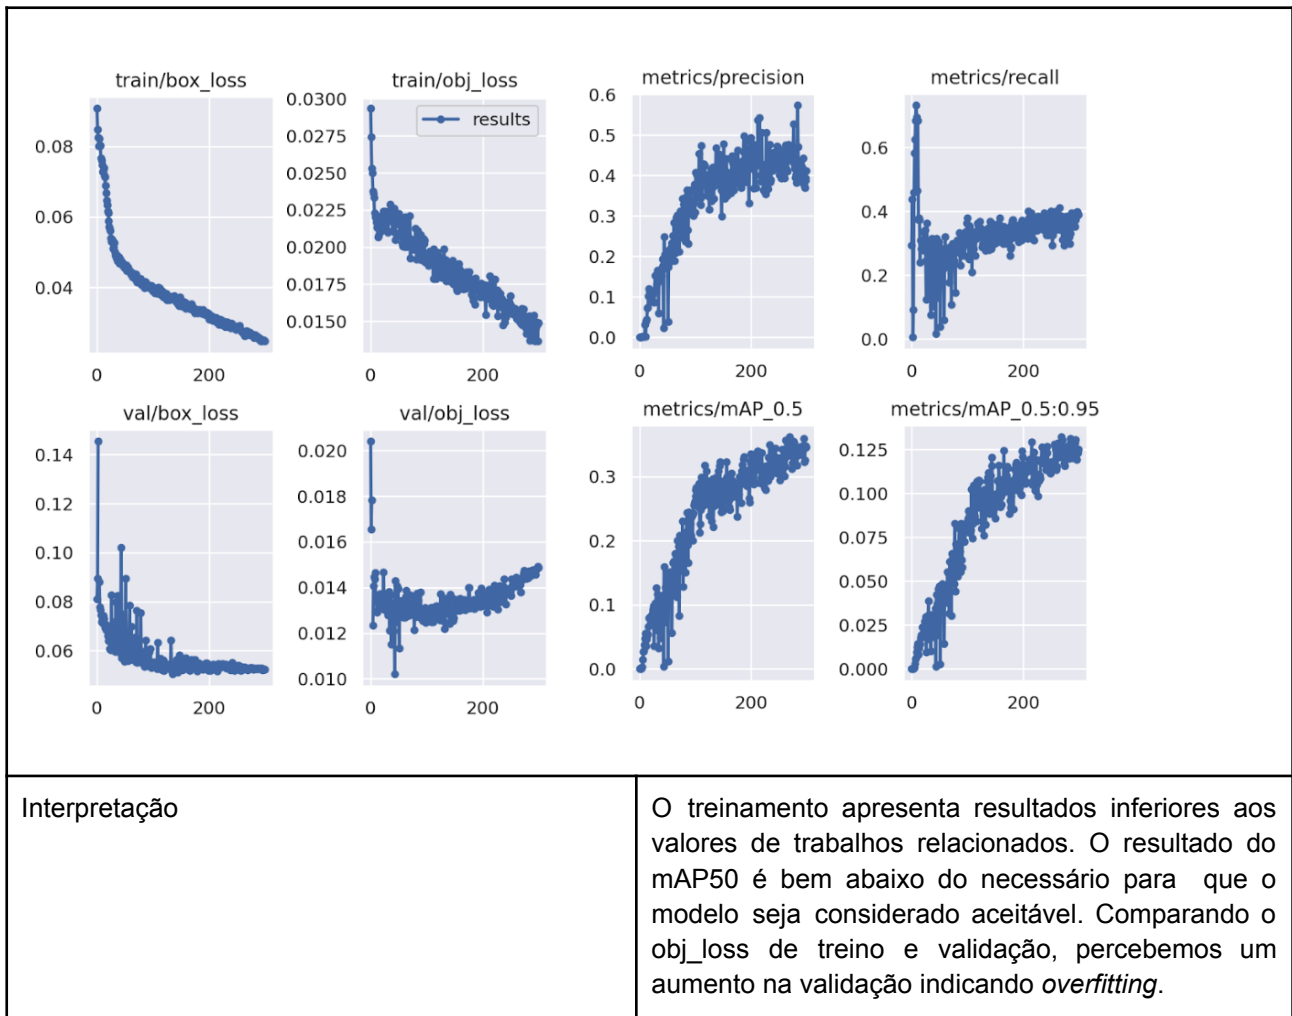


Tabela 13 - Resumo de informações do treinamento Praia da Armação sem *data augmentation*

Conjunto de dados (com <i>data augmentation</i>)	
Conjunto original	Total de 1.194 imagens 606 imagens com correntes/ 588 sem correntes
Treinamento	2.502 imagens
Validação	238 imagens
Teste	121 imagens
Treinamento YOLOv5	
Modelo	YOLOv5s
Quantidade de Épocas	300
Tamanho do lote	32
Avaliação de desempenho	
<i>mAP</i> 50	0.329

Precisão	0.396
Recall	0.379
F1-score	0.387
Resultados do treinamento	
Interpretação	<p>O treinamento apresenta resultados inferiores aos valores de trabalhos relacionados. O resultado do mAP50 é bem abaixo do necessário para que o modelo seja considerado aceitável. Além disso, o <i>data augmentation</i> parece não ter efeito positivo no treinamento. Comparando o obj_loss de treino e validação, percebemos um aumento na validação indicando <i>overfitting</i>.</p>

Tabela 14 - Resumo de informações do treinamento Praia da Armação com *data augmentation*

4.3.1.2 - Modelos YOLOv8s

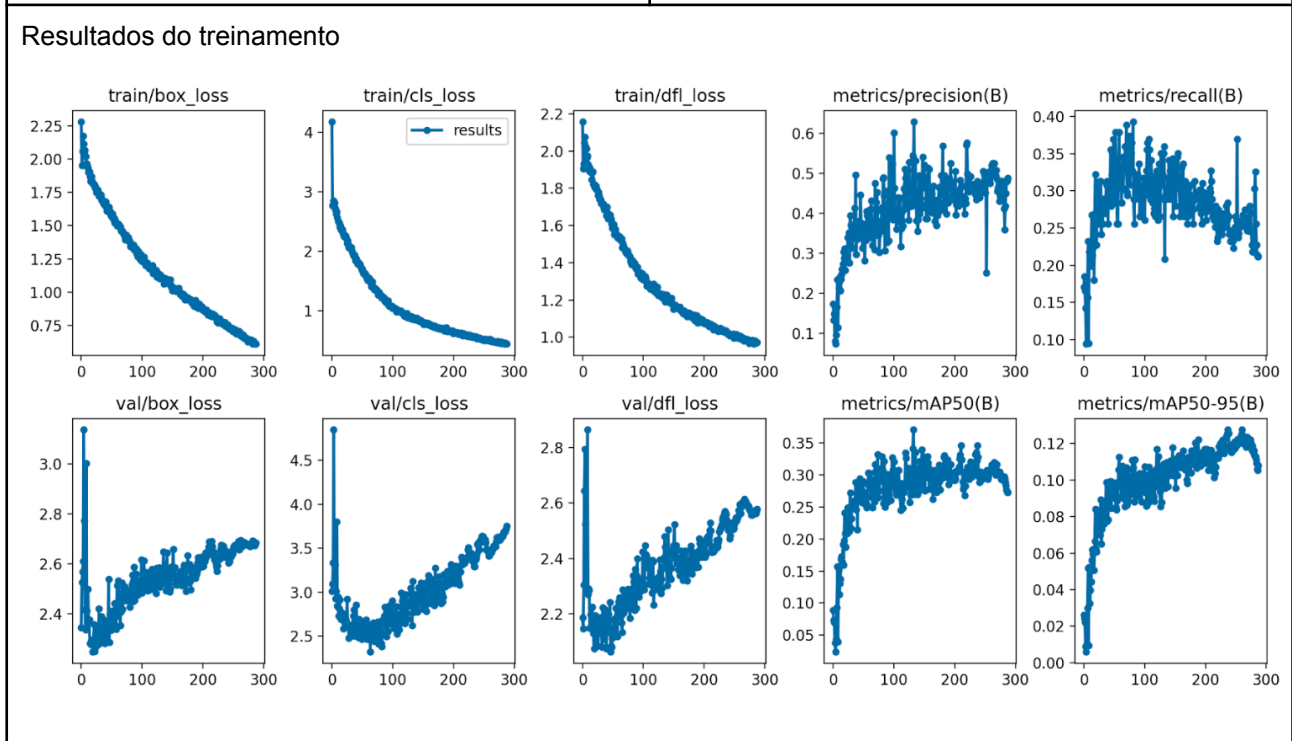
Conjunto de dados (sem <i>data augmentation</i>)	
Conjunto original	Total de 1.194 imagens 606 imagens com correntes/ 588 sem correntes
Treinamento	834 imagens
Validação	238 imagens
Teste	121 imagens
Treinamento YOLOv8	
Modelo	YOLOv8s
Quantidade de Épocas	Definidas: 300, realizadas: 199

Tamanho do lote	16
Avaliação de desempenho	
<i>mAP50</i>	0.318
Precisão	0.451
<i>Recall</i>	0.342
<i>F1-score</i>	0.389
Resultados do treinamento	
Interpretação	<p>O treinamento apresenta resultados inferiores aos valores de trabalhos relacionados. O resultado do mAP50 é bem abaixo do necessário para que o modelo seja considerado aceitável. Além disso, não apresenta melhora em relação aos treinamentos dos modelos YOLOv5s. Comparando o box_loss, cls_loss e df_l_loss percebemos um aumento na validação indicando <i>overfitting</i>. Além disso, o modelo só realizou 199 épocas em virtude pois não apresentou melhora de desempenho nas últimas 50 épocas.</p>

Tabela 15 - Resumo de informações do treinamento Praia da Armação sem *data augmentation*

Conjunto de dados (com <i>data augmentation</i>)	
Conjunto original	Total de 1.194 imagens 606 imagens com correntes/ 588 sem correntes
Treinamento	2502 imagens
Validação	238 imagens

Teste	121 imagens
Treinamento YOLOv8	
Modelo	YOLOv8s
Quantidade de Épocas	300
Tamanho do lote	16
Avaliação de desempenho	
<i>mAP50</i>	0.346
Precisão	0.480
<i>Recall</i>	0.284
<i>F1-score</i>	0,357



Interpretação	<p>O treinamento apresenta resultados inferiores aos valores de trabalhos relacionados. O resultado do mAP50 é bem abaixo do necessário para que o modelo seja considerado aceitável. Além disso, não apresenta melhora em relação aos treinamentos dos modelos YOLOv5s. Apresentou leve melhora em relação ao treinamento sem <i>data augmentation</i>. Comparando o <i>box_loss</i>, <i>cls_loss</i> e <i>df_l_loss</i> percebemos um aumento na validação indicando <i>overfitting</i>.</p>
---------------	--

Tabela 16 - Resumo de informações do treinamento Praia da Armação com *data augmentation*

4.3.2 - Treinamento Praia do Santinho

4.3.2.1 - Modelos YOLOv5s

Conjunto de dados (sem <i>data augmentation</i>)	
Conjunto original	Total de 875 imagens 347 imagens com correntes/ 528 sem correntes
Treinamento	609 imagens
Validação	177 imagens
Teste	89 imagens
Treinamento YOLOv5	
Modelo	YOLOv5s
Quantidade de Épocas	300
Tamanho do lote	32
Avaliação de desempenho	
<i>mAP</i> 50	0.347
Precisão	0.407
<i>Recall</i>	0.402
<i>F1-score</i>	0.404
Resultados do treinamento	

Interpretação	O treinamento apresenta resultados inferiores aos valores de trabalhos relacionados. O resultado do mAP50 é bem abaixo do necessário para que o modelo seja considerado aceitável.
---------------	--

Tabela 17 - Resumo de informações do treinamento Praia do Santinho sem *data augmentation*

Conjunto de dados (com <i>data augmentation</i>)	
Conjunto original	Total de 875 imagens 347 imagens com correntes/ 528 sem correntes
Treinamento	1.827 imagens
Validação	177 imagens
Teste	89 imagens
Treinamento YOLOv5	
Modelo	YOLOv5s
Quantidade de Épocas	300
Tamanho do lote	32
Avaliação de desempenho	
<i>mAP50</i>	0.405
Precisão	0.385
<i>Recall</i>	0.390
<i>F1-score</i>	0.387
Resultados do treinamento	

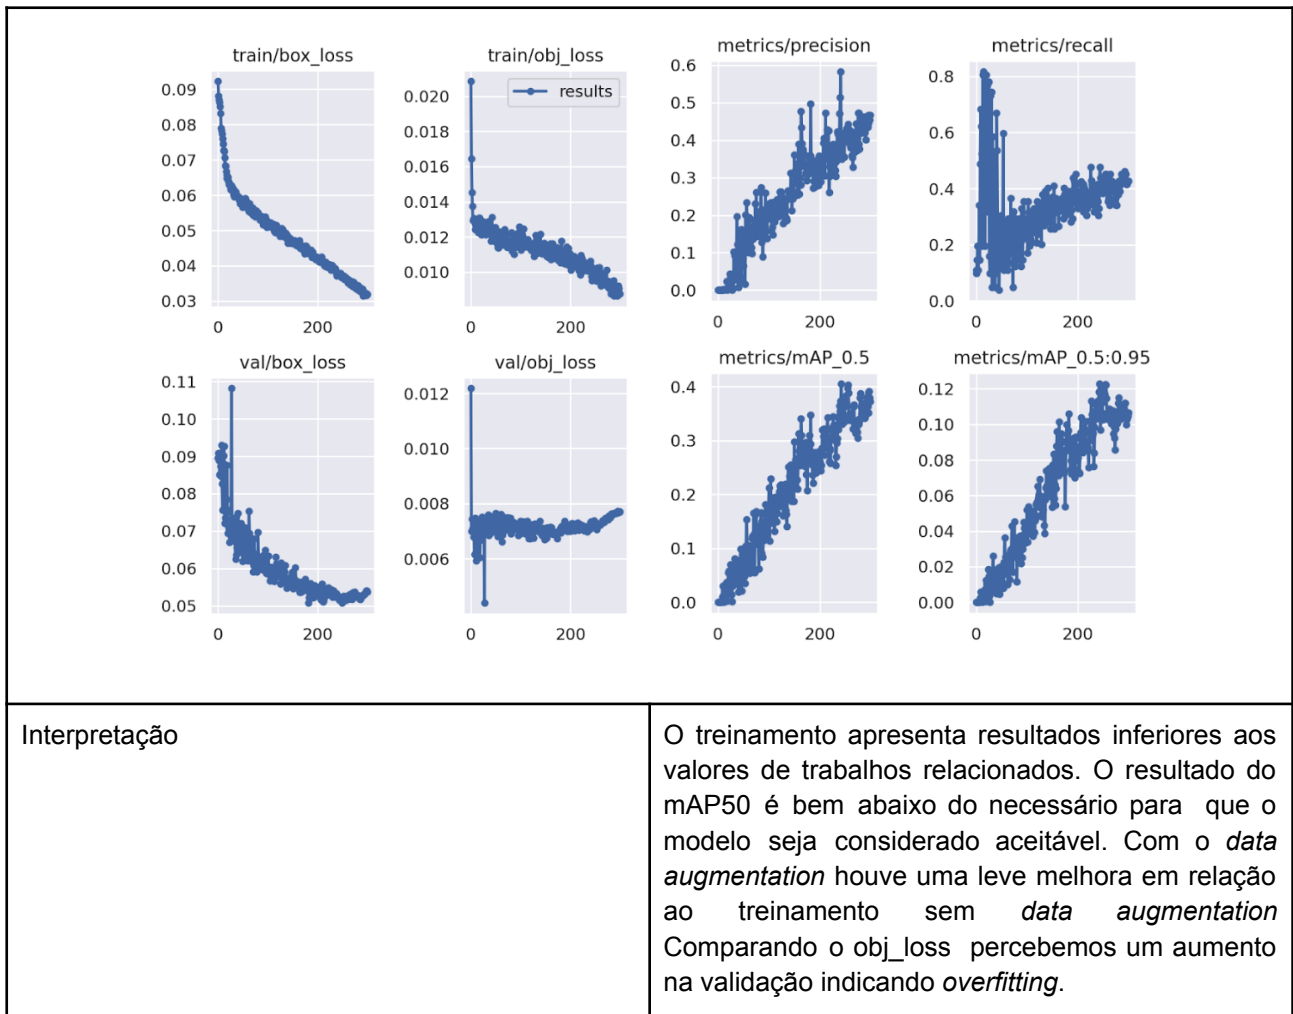


Tabela 18 - Resumo de informações do treinamento Praia do Santinho com *data augmentation*

4.3.2.2 - Modelos YOLOv8s

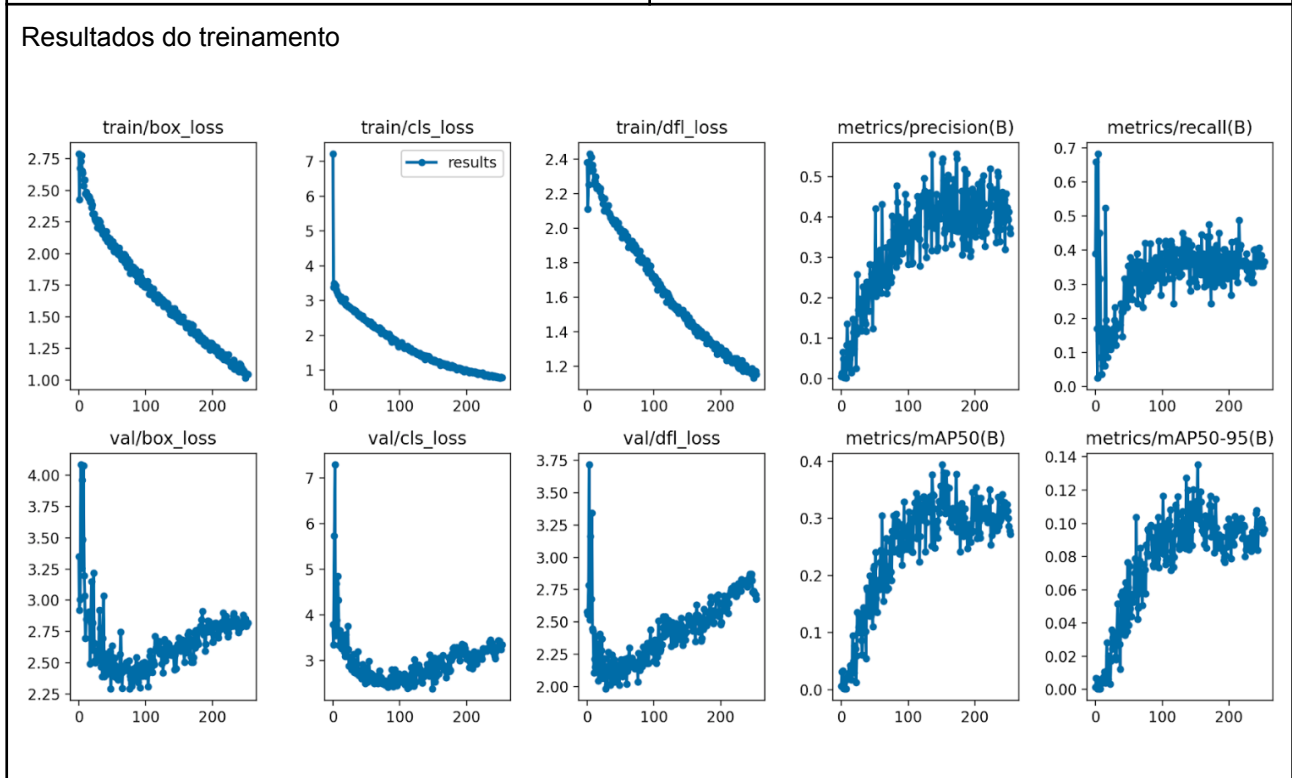
Conjunto de dados (sem <i>data augmentation</i>)	
Conjunto original	Total de 875 imagens 347 imagens com correntes/ 528 sem correntes
Treinamento	609 imagens
Validação	177 imagens
Teste	89 imagens
Treinamento YOLOv8	
Modelo	YOLOv8s
Quantidade de Épocas	300
Tamanho do lote	16
Avaliação de desempenho	

<i>mAP50</i>	0.407
Precisão	0.428
<i>Recall</i>	0.488
<i>F1-score</i>	0.456
Resultados do treinamento	
Interpretação	<p>O treinamento apresenta resultados inferiores aos valores de trabalhos relacionados. O resultado do mAP50 é bem abaixo do necessário para que o modelo seja considerado aceitável. Este treinamento apresentou uma leve melhora em relação aos treinamentos com YOLOv5s. Comparando o box_loss, dfl_loss percebemos um aumento na validação indicando <i>overfitting</i>.</p>

Tabela 19 - Resumo de informações do treinamento Praia do Santinho sem *data augmentation*

Conjunto de dados (com <i>data augmentation</i>)	
Conjunto original	Total de 875 imagens 347 imagens com correntes/ 528 sem correntes
Treinamento	1.827 imagens
Validação	177 imagens
Teste	89 imagens
Treinamento YOLOv8	

Modelo	YOLOv8s
Quantidade de Épocas	300
Tamanho do lote	16
Avaliação de desempenho	
<i>mAP50</i>	0.381
Precisão	0.489
<i>Recall</i>	0.385
<i>F1-score</i>	0.431



Interpretação	<p>O treinamento apresenta resultados inferiores aos valores de trabalhos relacionados. O resultado do mAP50 é bem abaixo do necessário para que o modelo seja considerado aceitável. Além disso, não apresenta melhora em relação aos treinamentos dos modelos YOLOv5s. O mAP50 piorou em relação ao treinamento sem <i>data augmentation</i>. Comparando o box_loss, cls_loss e df_l_loss percebemos um aumento na validação indicando <i>overfitting</i>.</p>
---------------	--

Tabela 20 - Resumo de informações do treinamento Praia do Santinho com *data augmentation*

4.3.3 - Treinamento Praia da Armação + Praia do Santinho

4.3.3.1 - Modelos YOLOv5s

Conjunto de dados (sem <i>data augmentation</i>)	
Conjunto original	Total de 2.069 imagens 1.153 imagens com correntes/ 1.116 sem correntes
Treinamento	1.450 imagens
Validação	404 imagens
Teste	215 imagens
Treinamento YOLOv5	
Modelo	YOLOv5s
Quantidade de Épocas	300
Tamanho do lote	32
Avaliação de desempenho	
<i>mAP</i> 50	0.409
Precisão	0.384
<i>Recall</i>	0.503
<i>F1-score</i>	0.436
Resultados do treinamento	

Interpretação	O treinamento apresenta resultados inferiores aos valores de trabalhos relacionados. O resultado do mAP50 é bem abaixo do necessário para que o modelo seja considerado aceitável. Apresenta melhora em relação aos treinamentos dos conjuntos de dados individualizados das praias. Comparando o box_loss e obj_loss percebe-se uma leve aumento na validação indicando possível <i>overfitting</i>
---------------	--

Tabela 21 - Resumo de informações do treinamento Praia do Santinho sem *data augmentation*

Conjunto de dados (com <i>data augmentation</i>)	
Conjunto original	Total de 2.069 imagens 1.153 imagens com correntes/ 1.116 sem correntes
Treinamento	4.350 imagens
Validação	404 imagens
Teste	215 imagens
Treinamento YOLOv5	
Modelo	YOLOv5s
Quantidade de Épocas	300
Tamanho do lote	32
Avaliação de desempenho	
<i>mAP50</i>	0.351
Precisão	0.402
<i>Recall</i>	0.43
<i>F1-score</i>	0.416
Resultados do treinamento	

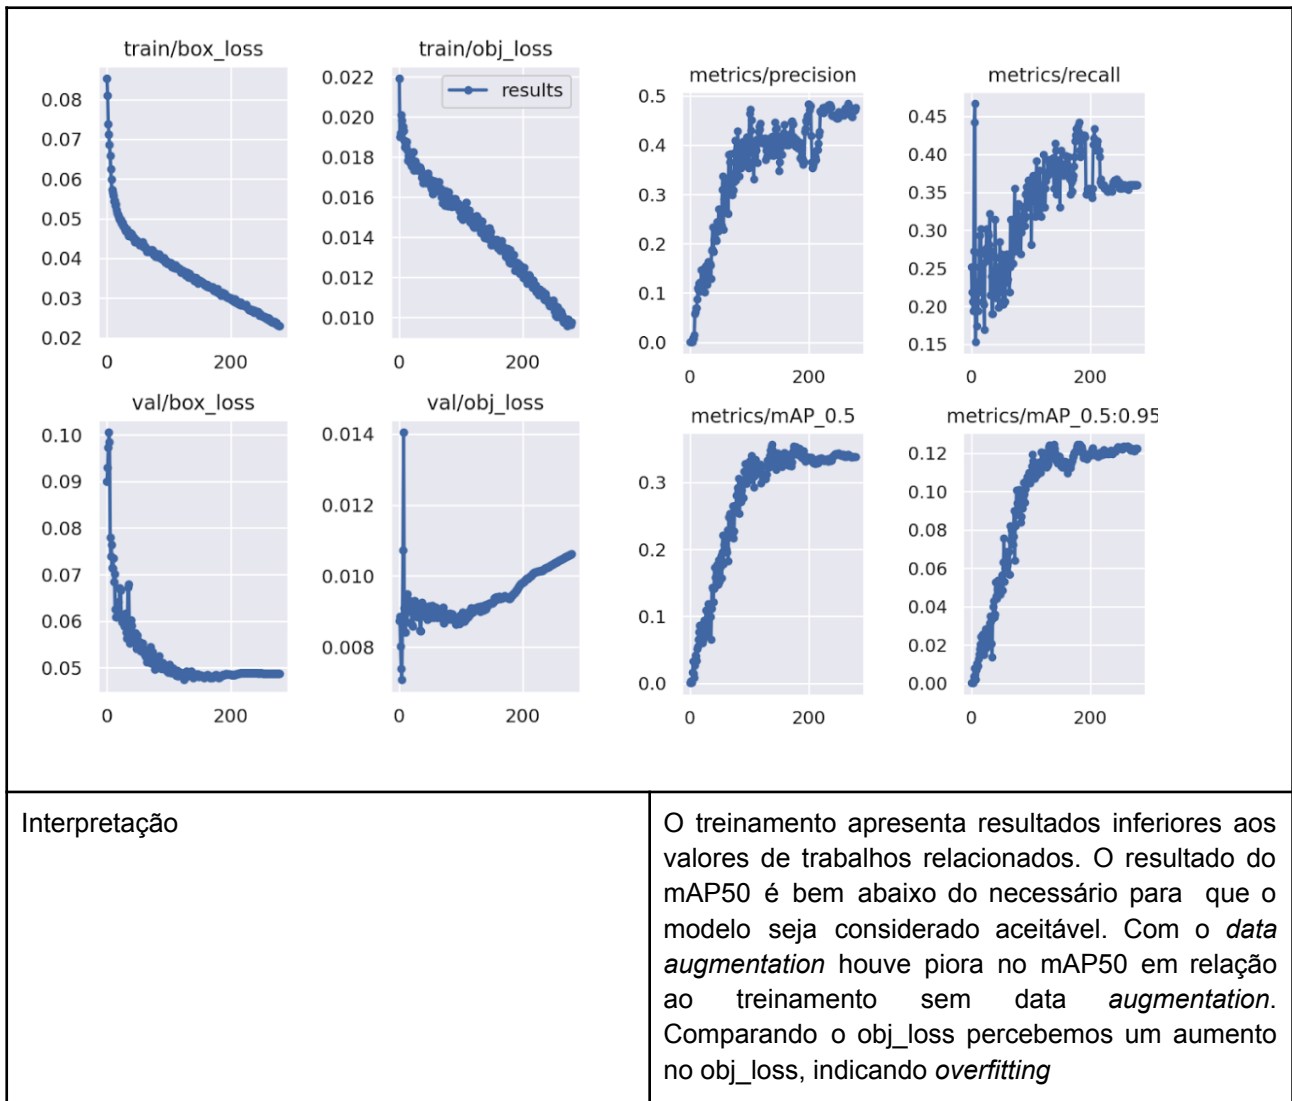
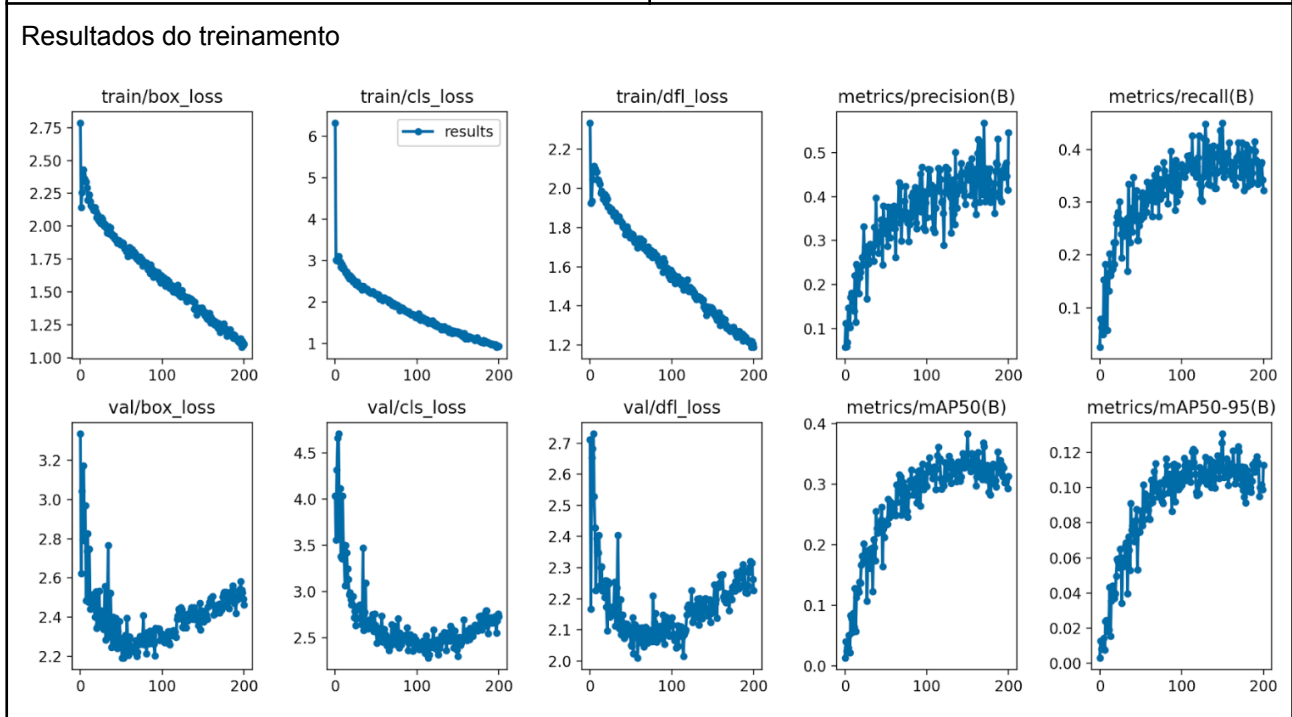


Tabela 22 - Resumo de informações do treinamento Praia do Santinho com *data augmentation*

4.3.3.2 - Modelos YOLOv8s

Conjunto de dados (sem <i>data augmentation</i>)	
Conjunto original	Total de 2.069 imagens 1.153 imagens com correntes/ 1.116 sem correntes
Treinamento	1.450 imagens
Validação	404 imagens
Teste	215 imagens
Treinamento YOLOv8	
Modelo	YOLOv8s
Quantidade de Épocas	Definidas: 300 Realizadas: 201
Tamanho do lote	32
Avaliação de desempenho	

<i>mAP50</i>	0.381
Precisão	0.462
<i>Recall</i>	0.450
<i>F1-score</i>	0.456



Interpretação	O treinamento apresenta resultados inferiores aos valores de trabalhos relacionados. O resultado do mAP50 é bem abaixo do necessário para que o modelo seja considerado aceitável. Este treinamento não apresentou melhora em relação aos treinamentos com YOLOv5s. Comparando o box_loss, cls_loss e dfl_loss percebemos um aumento na validação indicando <i>overfitting</i> . Por não melhorar seu desempenho nas últimas 50 épocas, o modelo só realizou 201 épocas.
---------------	--

Tabela 23 - Resumo de informações do treinamento Praia do Santinho sem *data augmentation*

Conjunto de dados (com <i>data augmentation</i>)	
Conjunto original	Total de 2.069 imagens 1.153 imagens com correntes/ 1116 sem correntes
Treinamento	4.350 imagens
Validação	404 imagens
Teste	215 imagens
Treinamento YOLOv8	

Modelo	YOLOv8s
Quantidade de Épocas	Definidas: 300 Realizadas: 128
Tamanho do lote	32
Avaliação de desempenho	
<i>mAP50</i>	0.329
Precisão	0.426
<i>Recall</i>	0.372
<i>F1-score</i>	0.397
Resultados do treinamento	
Interpretação	<p>O treinamento apresenta resultados inferiores aos valores de trabalhos relacionados. O resultado do mAP50 é bem abaixo do necessário para que o modelo seja considerado aceitável. Além disso, não apresenta melhora em relação aos treinamentos dos modelos YOLOv5s. O mAP50 piorou em relação ao treinamento sem <i>data augmentation</i>. Comparando o <i>box_loss</i>, <i>cls_loss</i> e <i>df_l_loss</i> percebemos um aumento na validação indicando <i>overfitting</i>. Por não melhorar seu desempenho nas últimas 50 épocas, o modelo só realizou 128 épocas.</p>

Tabela 24 - Resumo de informações do treinamento Praia do Santinho com *data augmentation*

4.4 TESTE DE DESEMPENHO

De acordo com a norma ISO/IEC 4213 (2022), foram feitos testes com os modelos treinados. Os testes conduzidos foram feitos utilizando imagens não incluídas nos subconjuntos de treinamento e validação. Os testes foram realizados usando o Google Colab.

Os testes utilizaram os parâmetros da época de melhor resultado no treinamento. Ao fim do teste as métricas de mAP50, precisão, *Recall* e *F1-score* foram avaliadas, bem como a matriz de confusão.

4.4.1 Teste de desempenho para os modelos com imagens da Praia da Armação

4.4.1.1 Características dos dados

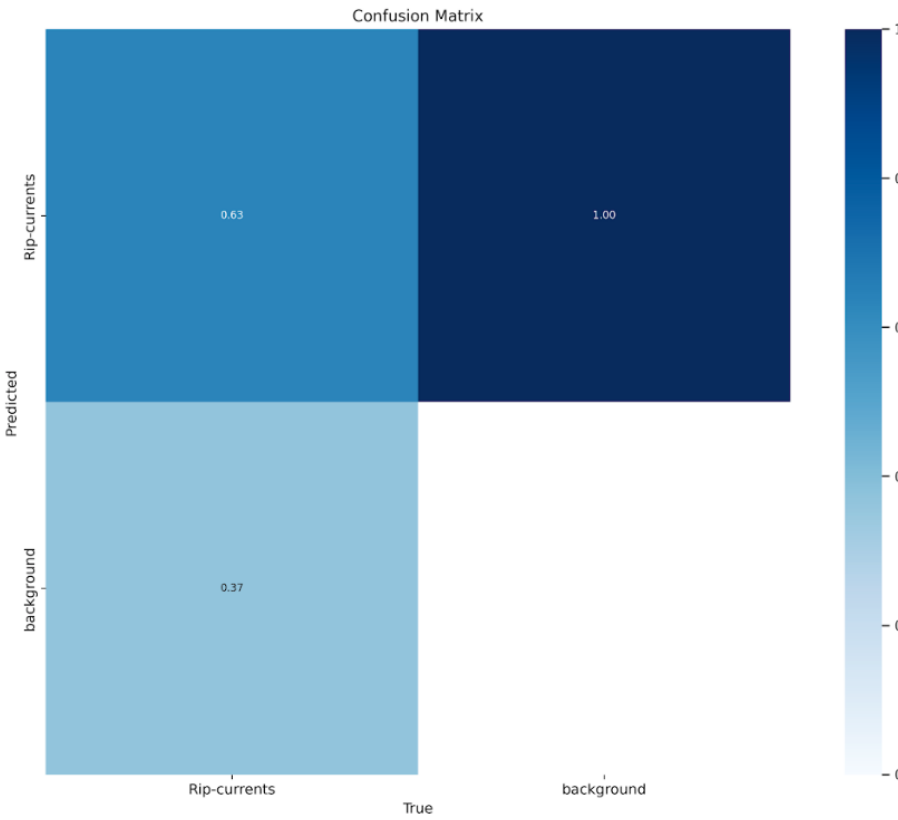
A Tabela 25 mostra as características e especificações dos dados utilizados nos testes.

Característica	Especificação
Número total de imagens no conjunto de testes	121 imagens
Uso das imagens	Imagens de uso exclusivo para teste
Fonte	Imagens coletadas pelo autor.
Verdade fundamental	As imagens foram rotuladas por um aluno do curso de Oceanografia da Universidade Federal de Santa Catarina (UFSC) que também é salva-vidas civil.
Pré-processamento/ <i>data augmentation</i>	Teste sem <i>data augmentation</i>
	Auto-orientação e redimensionamento para 640x640
	Teste com <i>data augmentation</i>
	<i>Rotation</i> : Between -15° and +15° <i>Shear</i> : ±15° Horizontal, ±15° Vertical <i>Hue</i> : Between -20° and +20° <i>Saturation</i> : Between -25% and +25% <i>Brightness</i> : Between -25% and +25% <i>Blur</i> : Up to 1px <i>Noise</i> : Up to 2% of pixels
Precisão do conjunto de teste	A precisão dos rótulos das imagens é de 100%.
Completeness do conjunto de teste	As imagens no conjunto de dados cobrem todas as classes de interesse com uma variedade de exemplos.
Exclusividade do conjunto de teste	Não há duplicatas de imagens no conjunto de testes.
Autenticidade do conjunto de teste	As imagens foram coletadas localmente tirando

	fotos do mar na praia da Armação na cidade de Florianópolis/SC
	As imagens correspondem às imagens a serem coletadas pelo público-alvo conforme definido no caso de uso.
Confidencialidade do conjunto de teste	Não aplicável

Tabela 25 - Características do conjunto de dados de teste da Praia da Armação

4.4.1.2 Resultados YOLOv5s

Teste sem <i>data augmentation</i>										
Tamanho do lote	32									
Tamanho da imagem	640									
Avaliação de desempenho										
<i>mAP</i> 50	0.572									
<i>Precision</i>	0.572									
<i>Recall</i>	0.598									
<i>F1-score</i>	0.585									
Matriz de confusão	 <p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.63</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.37</td> <td>0.63</td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.63	1.00	background	0.37	0.63
Predicted \ True	Rip-currents	background								
Rip-currents	0.63	1.00								
background	0.37	0.63								

Interpretação	Nota-se que o treinamento atual apresenta mAP50 melhor que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.
---------------	--

Tabela 26 - Resultados do teste para o conjunto de dados da Praia da Armação sem *data augmentation* utilizando YOLOv5s

Teste com <i>data augmentation</i>										
Tamanho do lote	32									
Tamanho da imagem	640									
Avaliação de desempenho										
<i>mAP50</i>	0.595									
<i>Precision</i>	0.541									
<i>Recall</i>	0.671									
<i>F1-score</i>	0.599									
Matriz de confusão	<p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.41</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.59</td> <td></td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.41	1.00	background	0.59	
Predicted \ True	Rip-currents	background								
Rip-currents	0.41	1.00								
background	0.59									
Interpretação	Nota-se que o treinamento atual apresenta mAP50 melhor que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.									

Tabela 27 - Resultados do teste para o conjunto de dados da Praia da Armação com *data augmentation* utilizando YOLOv5s

4.4.1.2 Resultados YOLOv8s

Teste sem <i>data augmentation</i>										
Tamanho do lote	32									
Tamanho da imagem	640									
Avaliação de desempenho										
<i>mAP50</i>	0.479									
<i>Precision</i>	0.634									
<i>Recall</i>	0.423									
<i>F1-score</i>	0.507									
Matriz de confusão	<p>The figure is a confusion matrix titled "Confusion Matrix". The y-axis is labeled "Predicted" and has two categories: "Rip-currents" and "background". The x-axis is labeled "True" and has two categories: "Rip-currents" and "background". The matrix is represented by a heatmap with the following values:</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.50</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.50</td> <td>0.00</td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.50	1.00	background	0.50	0.00
Predicted \ True	Rip-currents	background								
Rip-currents	0.50	1.00								
background	0.50	0.00								
Interpretação	<p>Nota-se que o treinamento atual apresenta <i>mAP50</i> melhor que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>									

Tabela 28 - Resultados do teste para o conjunto de dados da Praia da Armação sem *data augmentation* utilizando YOLOv8s

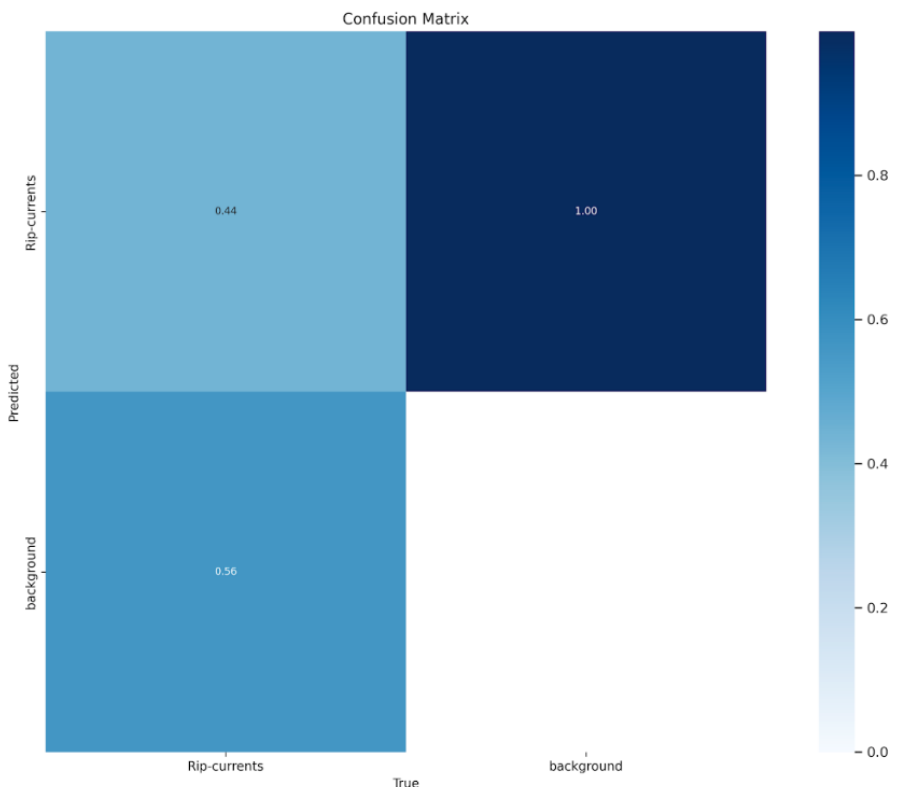
Teste com <i>data augmentation</i>										
Tamanho do lote	32									
Tamanho da imagem	640									
Avaliação de desempenho										
<i>mAP50</i>	0.519									
<i>Precision</i>	0.700									
<i>Recall</i>	0.463									
<i>F1-score</i>	0.557									
Matriz de confusão	 <p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.44</td> <td>0.56</td> </tr> <tr> <th>background</th> <td>0.00</td> <td>1.00</td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.44	0.56	background	0.00	1.00
Predicted \ True	Rip-currents	background								
Rip-currents	0.44	0.56								
background	0.00	1.00								
Interpretação	<p>Nota-se que o treinamento atual apresenta <i>mAP50</i> melhor que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>									

Tabela 29 - Resultados do teste para o conjunto de dados da Praia da Armação com *data augmentation* utilizando YOLOv8s

4.4.2 Teste de desempenho para os modelos da Praia do Santinho

4.4.2.1 Características dos dados

A Tabela 30 mostra as características e especificações dos dados utilizados nos testes.

Característica	Especificação
Número total de imagens no conjunto de testes	89 imagens
Uso das imagens	Imagens de uso exclusivo para teste
Fonte	Imagens coletadas pelo autor.
Verdade fundamental	As imagens foram rotuladas por um aluno do curso de Oceanografia da Universidade Federal de Santa Catarina (UFSC) que também é salva-vidas civil.
Pré-processamento/ data augmentation	Teste sem data augmentation
	Auto-orientação e redimensionamento para 640x640
	Teste com data augmentation
	<i>Rotation:</i> Between -15° and +15° <i>Shear:</i> ±15° Horizontal, ±15° Vertical <i>Hue:</i> Between -20° and +20° <i>Saturation:</i> Between -25% and +25% <i>Brightness:</i> Between -25% and +25% <i>Blur:</i> Up to 1px <i>Noise:</i> Up to 2% of pixels
Precisão do conjunto de teste	A precisão dos rótulos das imagens é de 100%.
Completude do conjunto de teste	As imagens no conjunto de dados cobrem todas as classes de interesse com uma variedade de exemplos.
Exclusividade do conjunto de teste	Não há duplicatas de imagens no conjunto de testes.
Autenticidade do conjunto de teste	As imagens foram coletadas localmente tirando fotos do mar na praia do Santinho na cidade de Florianópolis/SC
	As imagens correspondem às imagens a serem coletadas pelo público-alvo conforme definido no caso de uso.
Confidencialidade do conjunto de teste	Não aplicável

Tabela 30 - Características do conjunto de dados de teste da Praia do Santinho

4.4.2.2 Resultados YOLOv5

Teste sem data augmentation	
Tamanho do lote	32
Tamanho da imagem	640
Avaliação de desempenho	
<i>mAP</i> 50	0.302

<i>Precision</i>	0.336									
<i>Recall</i>	0.459									
<i>F1-score</i>	0.388									
Matriz de confusão	<p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.41</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.59</td> <td></td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.41	1.00	background	0.59	
Predicted \ True	Rip-currents	background								
Rip-currents	0.41	1.00								
background	0.59									
Interpretação	<p>Nota-se que o treinamento atual apresenta mAP50 pior que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>									

Tabela 31 - Resultados do teste para o conjunto de dados da Praia do Santinho sem *data augmentation* utilizando YOLOv5s

Teste com <i>data augmentation</i>	
Tamanho do lote	32
Tamanho da imagem	640
Avaliação de desempenho	
<i>mAP50</i>	0.342
<i>Precision</i>	0.512
<i>Recall</i>	0.324
<i>F1-score</i>	0.397

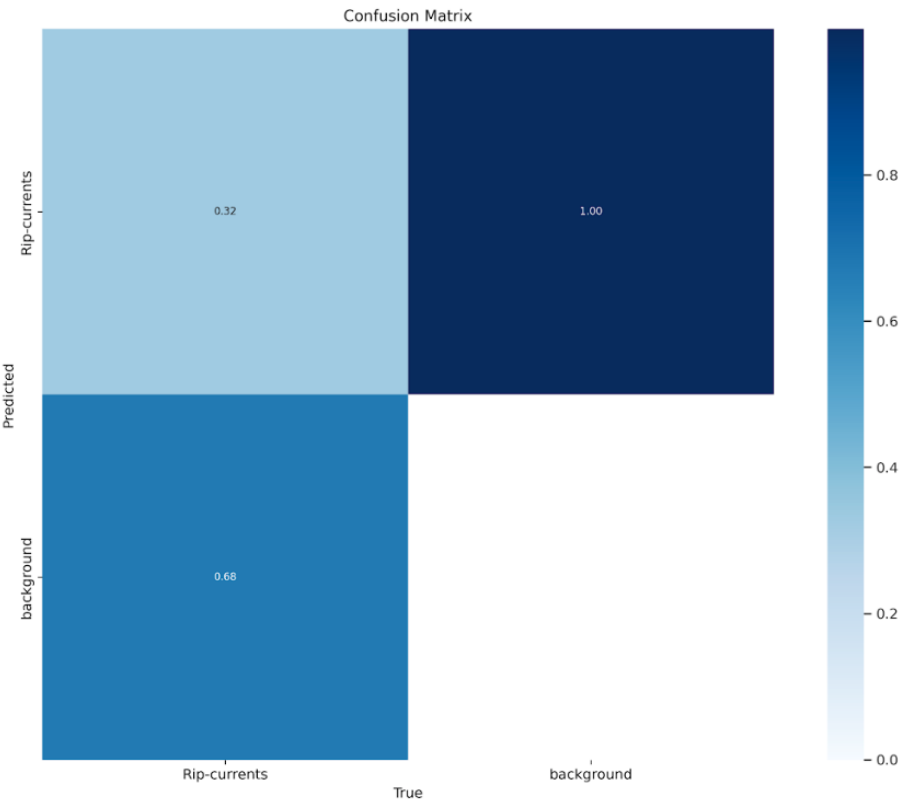
Matriz de confusão	 <p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.32</td> <td>0.00</td> </tr> <tr> <th>background</th> <td>0.00</td> <td>0.68</td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.32	0.00	background	0.00	0.68
Predicted \ True	Rip-currents	background								
Rip-currents	0.32	0.00								
background	0.00	0.68								
Interpretação	<p>Nota-se que o treinamento atual apresenta mAP50 pior que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>									

Tabela 32 - Resultados do teste para o conjunto de dados da Praia do Santinho com *data augmentation* utilizando YOLOv5

4.4.2.3 Resultados YOLOv8s

Teste sem <i>data augmentation</i>	
Tamanho do lote	32
Tamanho da imagem	640
Avaliação de desempenho	
<i>mAP50</i>	0.427
<i>Precision</i>	0.577
<i>Recall</i>	0.405
<i>F1-score</i>	0.476

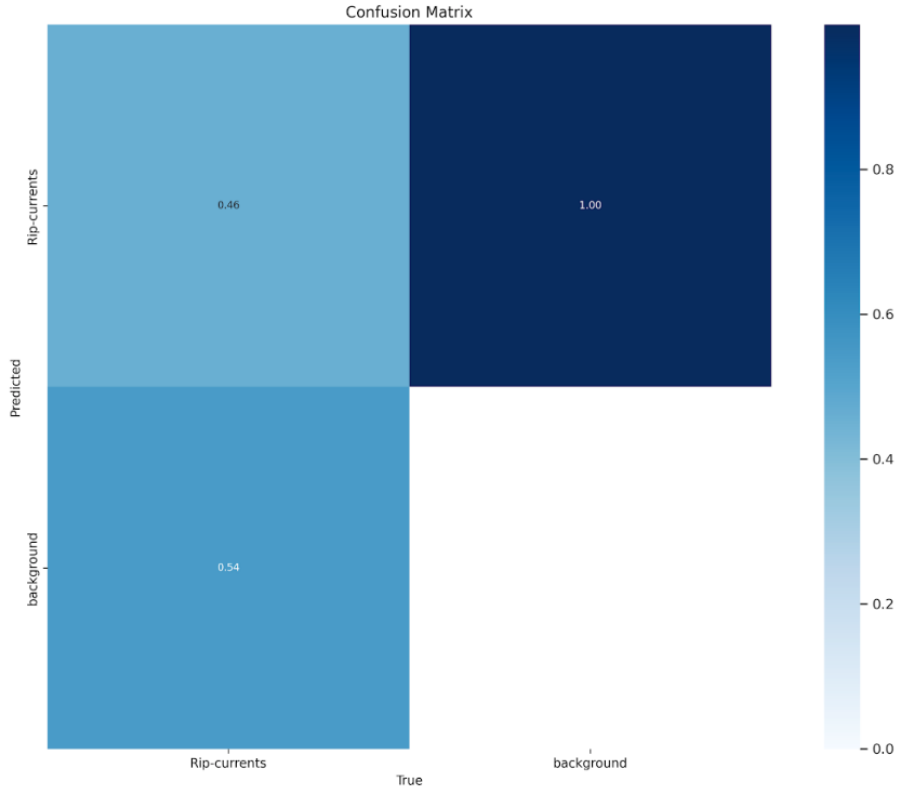
Matriz de confusão	 <p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.46</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.54</td> <td></td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.46	1.00	background	0.54	
Predicted \ True	Rip-currents	background								
Rip-currents	0.46	1.00								
background	0.54									
Interpretação	<p>Nota-se que o treinamento atual apresenta mAP50 pior que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>									

Tabela 33 - Resultados do teste para o conjunto de dados da Praia do Santinho sem *data augmentation* utilizando YOLOv8

Teste com <i>data augmentation</i>	
Tamanho do lote	32
Tamanho da imagem	640
Avaliação de desempenho	
<i>mAP50</i>	0.296
<i>Precision</i>	0.373
<i>Recall</i>	0.351
<i>F1-score</i>	0.362

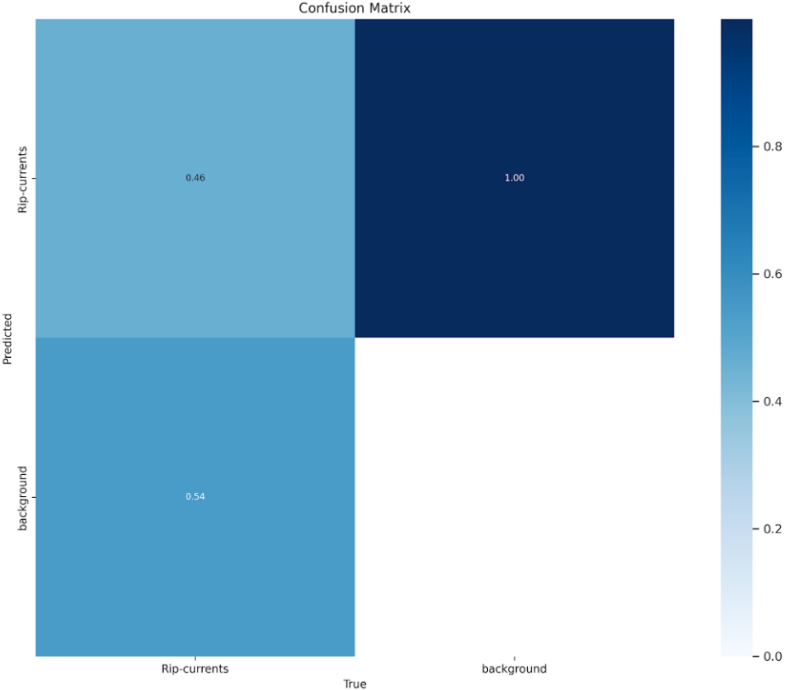
Matriz de confusão	 <p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.46</td> <td>0.54</td> </tr> <tr> <th>background</th> <td>1.00</td> <td>1.00</td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.46	0.54	background	1.00	1.00
Predicted \ True	Rip-currents	background								
Rip-currents	0.46	0.54								
background	1.00	1.00								
Interpretação	<p>Nota-se que o treinamento atual apresenta mAP50 pior que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>									

Tabela 34 - Resultados do teste para o conjunto de dados da Praia do Santinho com *data augmentation* utilizando YOLOv8s

4.4.3 Teste de desempenho para os modelos com imagens da Praia do Santinho + Praia da Armação

4.4.3.1 Características dos dados

A Tabela 34 mostra as características e especificações dos dados utilizados nos testes.

Característica	Especificação
Número total de imagens no conjunto de testes	215 imagens
Uso das imagens	Imagens de uso exclusivo para teste
Fonte	Imagens coletadas pelo autor.
Verdade fundamental	As imagens foram rotuladas por um aluno do curso de Oceanografia da Universidade Federal de Santa Catarina (UFSC) que também é salva-vidas civil.
Pré-processamento/ <i>data augmentation</i>	Teste sem <i>data augmentation</i>
	Auto-orientação e redimensionamento para 640x640

	<p>Teste com data augmentation</p> <p><i>Rotation:</i> Between -15° and +15° <i>Shear:</i> ±15° Horizontal, ±15° Vertical <i>Hue:</i> Between -20° and +20° <i>Saturation:</i> Between -25% and +25% <i>Brightness:</i> Between -25% and +25% <i>Blur:</i> Up to 1px <i>Noise:</i> Up to 2% of pixels</p>
Precisão do conjunto de teste	A precisão dos rótulos das imagens é de 100%.
Completude do conjunto de teste	As imagens no conjunto de dados cobrem todas as classes de interesse com uma variedade de exemplos.
Exclusividade do conjunto de teste	Não há duplicatas de imagens no conjunto de testes.
Autenticidade do conjunto de teste	<p>As imagens foram coletadas localmente tirando fotos do mar na praia do Santinho e praia da Armação na cidade de Florianópolis/SC</p> <p>As imagens correspondem às imagens a serem coletadas pelo público-alvo conforme definido no caso de uso.</p>
Confidencialidade do conjunto de teste	Não aplicável

Tabela 35 - Características do conjunto de dados de teste da Praia do Santinho + Armação

4.4.3.2 Resultados YOLOv5s

Teste sem data augmentation	
Tamanho do lote	32
Tamanho da imagem	640
Avaliação de desempenho	
<i>mAP50</i>	0.490
<i>Precision</i>	0.481
<i>Recall</i>	0.533
<i>F1-score</i>	0.506

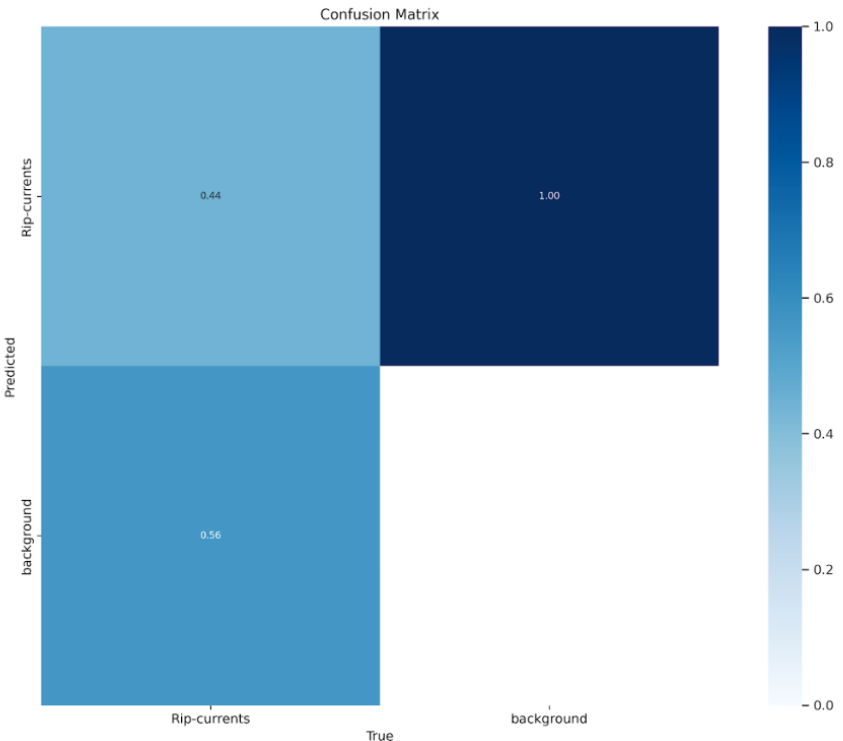
Matriz de confusão	 <p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.44</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.56</td> <td>0.00</td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.44	1.00	background	0.56	0.00
Predicted \ True	Rip-currents	background								
Rip-currents	0.44	1.00								
background	0.56	0.00								
Interpretação	<p>Nota-se que o treinamento atual apresenta mAP50 melhor que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>									

Tabela 36 - Resultados do teste para o conjunto de dados da Praia do Santinho + Armação sem *data augmentation* utilizando YOLOv5

Teste com <i>data augmentation</i>	
Tamanho do lote	32
Tamanho da imagem	640
Avaliação de desempenho	
<i>mAP50</i>	0.491
<i>Precision</i>	0.443
<i>Recall</i>	0.602
<i>F1-score</i>	0.510

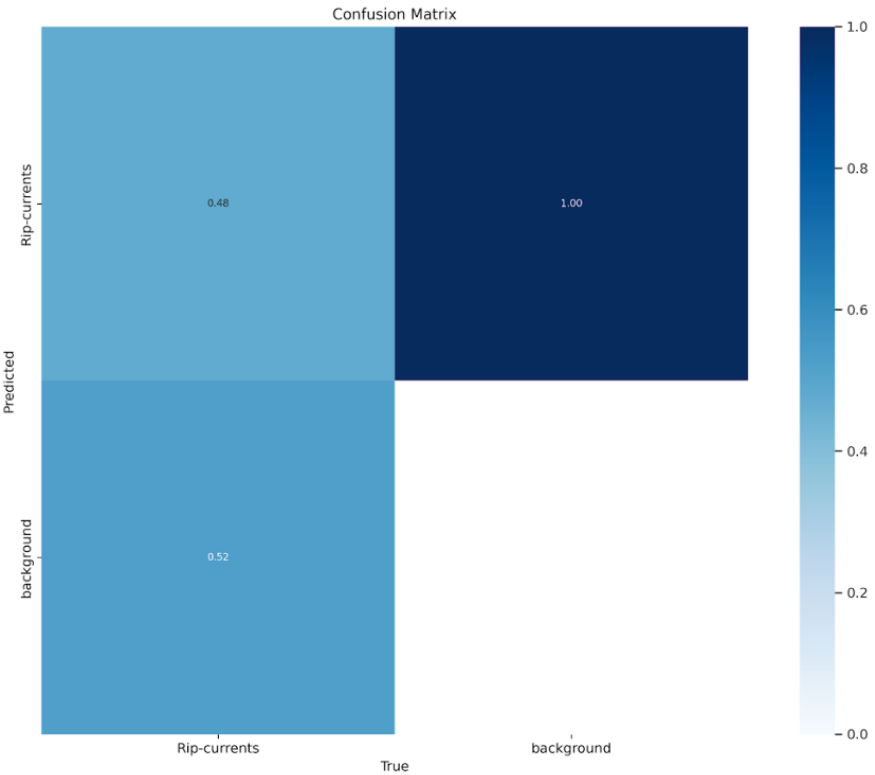
Matriz de confusão	 <p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.48</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.52</td> <td>0.00</td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.48	1.00	background	0.52	0.00
Predicted \ True	Rip-currents	background								
Rip-currents	0.48	1.00								
background	0.52	0.00								
Interpretação	<p>Nota-se que o treinamento atual apresenta mAP50 pior que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>									

Tabela 37 - Resultados do teste para o conjunto de dados da Praia do Santinho + Armação com *data augmentation* utilizando YOLOv5s

4.4.3.3 Resultados YOLOv8s

Teste sem <i>data augmentation</i>	
Tamanho do lote	32
Tamanho da imagem	640
Avaliação de desempenho	
<i>mAP50</i>	0.442
<i>Precision</i>	0.390
<i>Recall</i>	0.533
<i>F1-score</i>	0.450

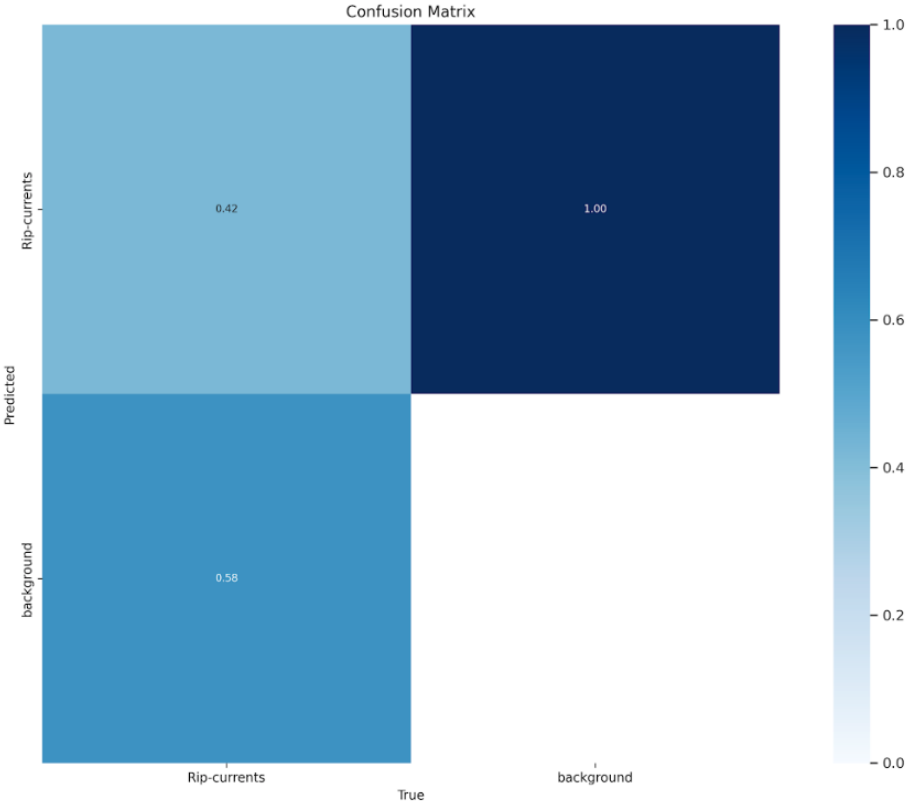
Matriz de confusão	 <p>Confusion Matrix</p> <table border="1"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.42</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.58</td> <td>0.00</td> </tr> </tbody> </table>	Predicted \ True	Rip-currents	background	Rip-currents	0.42	1.00	background	0.58	0.00
Predicted \ True	Rip-currents	background								
Rip-currents	0.42	1.00								
background	0.58	0.00								
Interpretação	<p>Nota-se que o treinamento atual apresenta mAP50 melhor que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>									

Tabela 38 - Resultados do teste para o conjunto de dados da Praia do Santinho + Armação sem *data augmentation* utilizando YOLOv8s

Teste com <i>data augmentation</i>	
Tamanho do lote	32
Tamanho da imagem	640
Avaliação de desempenho	
<i>mAP50</i>	0.451
<i>Precision</i>	0.600
<i>Recall</i>	0.451
<i>F1-score</i>	0.515

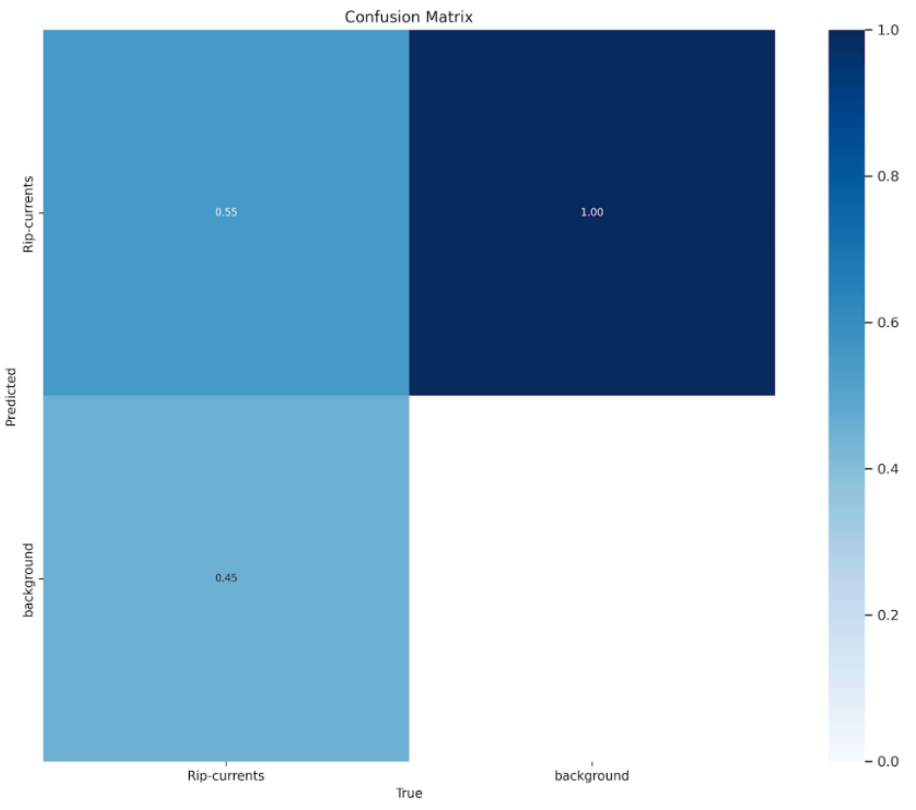
Matriz de confusão	 <p>Confusion Matrix</p> <p>True classes: Rip-currents, background</p> <p>Predicted classes: Rip-currents, background</p> <p>Values: (True Rip-currents, Predicted Rip-currents) = 0.55; (True Rip-currents, Predicted background) = 0.45; (True background, Predicted Rip-currents) = 1.00; (True background, Predicted background) = 0.00</p>
Interpretação	<p>Nota-se que o treinamento atual apresenta mAP50 pior que o observado no treinamento deste modelo. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p>

Tabela 39 - Resultados do teste para o conjunto de dados da Praia do Santinho + Armação com *data augmentation* utilizando YOLOv8s

4.5 DISCUSSÃO

Os resultados do treinamento/validação e testes dos modelos estão na Tabela 38 resumindo as métricas de mAP, precisão e *recall*.

		Resultados da validação dos treinamentos				Resultados dos testes			
		mAP	Precisão	Recall	F1-Score	mAP	Precisão	Recall	F1-Score
Praia da Armação	YOLOv5s	0.359	0.46	0.353	0.399	0.572	0.572	0.598	0.585
	YOLOv5s com <i>data augmentation</i>	0.329	0.396	0.379	0.387	0.595	0.541	0.671	0.599
	YOLOv8s	0.318	0.451	0.342	0.389	0.479	0.634	0.423	0.507
	YOLOv8s com <i>data augmentation</i>	0.346	0.480	0.284	0,357	0.519	0.700	0.463	0.557

	<i>augmentation</i>								
Praia do Santinho	YOLOv5s	0.347	0.407	0.402	0.404	0.302	0.336	0.459	0.388
	YOLOv5s com <i>data augmentation</i>	0.405	0.385	0.390	0.387	0.342	0.512	0.324	0.397
	YOLOv8s	0.407	0.428	0.488	0.456	0.427	0.577	0.405	0.476
	YOLOv8s com <i>data augmentation</i>	0.381	0.489	0.385	0.431	0.296	0.373	0.351	0.362
Praia do Santinho + Armação	YOLOv5s	0.409	0.384	0.503	0.436	0.490	0.481	0.533	0.506
	YOLOv5s com <i>data augmentation</i>	0.351	0.402	0.43	0.416	0.491	0.443	0.602	0.510
	YOLOv8s	0.381	0.462	0.450	0.456	0.442	0.390	0.533	0.450
	YOLOv8s com <i>data augmentation</i>	0.329	0.426	0.372	0.397	0.451	0.600	0.451	0.515

Tabela 40 - Resultados da validação e testes realizados

Todos os resultados obtidos durante a treino/validação referente ao mAP50 estão abaixo do desempenho esperado. Podemos observar também que as métricas de precisão, *recall* e *F1-score* também são baixas.

O treinamento com melhor desempenho foi do conjunto de imagens da Praia do Santinho + Armação sem *data augmentation* utilizado o YOLOv5s, e mesmo assim observamos que está bem abaixo do mAP esperado de 0.98. Além disso, observamos que o *data augmentation* não teve efeito para a melhora efetiva do desempenho dos treinamentos, em alguns casos o mAP melhorou e em outros piorou.

Além disso, analisando os gráficos referentes ao *loss* nos treinamentos, verificamos um aumento na validação com a decorrer das épocas, sendo forte indicativo de *overfitting* dos modelos treinados.

Observamos que nos resultados dos testes os modelos dos conjuntos Praia da Armação e Praia do Santinho + Armação melhoraram seu desempenho. Também foi percebido melhora no modelo YOLOv8s sem *data augmentation* do conjunto de dados da Praia do Santinho. Contudo, nota-se uma distância significativa para o mAP especificado em relação ao caso de uso, bem como um resultado abaixo em comparação ao dos trabalhos correlatos.

O melhor desempenho nos testes pode ter algumas explicações. Uma delas é que o conjunto de imagens de teste é menor (apenas 10% das imagens), assim é possível que ele tenha errado menos por ter menos chances de errar devido ao tamanho do conjunto. Consequentemente, isso levou a um melhor desempenho nas métricas de teste. Outra possível explicação é que embora a divisão do conjunto entre treinamento, validação e teste busque uma distribuição equalizada das classes, há a possibilidade de que as imagens do conjunto de teste tenham características diferentes das do conjunto de validação. Ocasionalmente, estas características do conjunto de teste podem ser melhor detectadas pelo modelo treinado. Observa-se que os conjuntos que apresentaram melhora nas métricas de teste contém imagens da Praia da Armação. Portanto, é possível que este conjunto de imagens favoreçam este tipo de resultado nos testes.

Observando a matriz de confusão nas tabelas com os resultados dos testes, percebe-se que todos os modelos treinados não conseguiram classificar corretamente imagens que não tem corrente de retorno. Todas elas foram classificadas erroneamente com algumas correntes de retorno, o que afetou a precisão do modelo. Portanto, percebe-se que os modelos treinados não foram capazes de distinguir o que é o que não é uma corrente de retorno.

Além disso, é baixa a detecção de verdadeiros positivos, ou seja, onde detectou corrente de retorno onde realmente havia corrente de retorno. Isto afeta as métricas de *recall* que no caso de uso proposto para o modelo é extremamente importante, pois é mais importante que o modelo detecte corretamente onde tem corrente de retorno do que onde não tem. Por fim, os valores de *F1-Score* (que considera a precisão e o *recall*) são baixos demonstrando a baixa qualidade do modelo na execução da tarefa de detecção de correntes de retorno.

O baixo desempenho nesses modelos pode ser explicado pela perspectiva em que as imagens são obtidas (imagens frontais, na perspectiva de um banhista). Por este motivo, pode ter pouco efeito uma comparação com os resultados dos trabalhos correlatos que de forma geral utilizavam imagens aéreas ou de um ponto de vista de maior altitude, como no trabalho de Ishikawa et al. (2021). Assuma-se que a visualização de uma perspectiva de maior altitude facilita a identificação das correntes de retorno, pois a sua identificação se dá pela diferenciação de aspectos visíveis no mar, assim, uma visão mais abrangente possibilita delimitar melhor as fronteiras do que é e o que não é uma corrente de retorno. Em uma imagem de visão frontal, a forma como uma determinada onda se dissipa ou o

momento em que ela foi fotografada afetam a interpretação sobre a existência ou não de uma corrente de retorno.

Ameaças à validade. Existem ameaças à validade que devem ser consideradas em relação aos resultados obtidos. No que se refere ao viés de seleção, buscou-se a criação de uma amostra diversificada e representativa de imagens, abrangendo diferentes cenários e condições. No entanto, é necessário reconhecer que o conjunto de imagens utilizado pode não ser completamente abrangente (sobretudo por se tratar de imagens de um ambiente dinâmico), o que pode limitar a generalização dos resultados para todos os contextos possíveis. Além disso, embora um tamanho de conjunto de imagens considerável tenha sido utilizado, é importante destacar que existem abordagens existentes na literatura que empregam conjuntos de dados maiores. Outra ameaça é o viés de pré-processamento dos dados, que foi minimizada aplicando técnicas padronizadas a todos os modelos comparados para evitar distorções. Além disso, foram adotados parâmetros de treinamento consistentes para assegurar uma comparação justa entre os modelos. Por fim, é importante mencionar que em relação ao viés das métricas de avaliação, foram utilizadas métricas padrão para avaliar diferentes aspectos do desempenho do modelo. No entanto, é necessário considerar as limitações inerentes a cada métrica e interpretar os resultados de forma crítica. Ao levar em conta essas ameaças à validade, os resultados apresentados devem ser interpretados com cuidado.

5 CONCLUSÃO

O objetivo deste TCC foi realizar experimentos para o desenvolvimento de um modelo para detecção de correntes de retorno a partir de imagens frontais do mar. Para a realização deste estudo, foi feita a análise teórica das correntes de retorno e da detecção de objetos utilizando *deep learning* (O1). Além disso, foi feito um levantamento do estado da arte na detecção de correntes de retorno por meio do *deep learning* (O2). Em seguida, foram treinados e testados modelos de detecção de correntes de retorno utilizando *deep learning* incluindo YOLO5s e YOLO8s utilizando conjuntos de dados preparados para este estudo (O3).

Os resultados demonstraram um desempenho bem abaixo do esperado (mAP 0.98), sendo o melhor o mAP50 obtido na validação do treinamento de 0.409 e nos testes de 0.595, ambos por modelos usando YOLOv5s. Desta forma, os resultados deste estudo, indicam a necessidade de melhoria no desenvolvimento de um modelo de detecção de correntes de retorno a partir de imagens frontais de praias para possibilitar o seu uso seguro a fim de alertar banhistas.

Verificou-se que o *data augmentation* não teve efeito de melhoria do desempenho do modelo treinado, inclusive em alguns treinamentos houve piora de desempenho em comparação ao uso sem *data augmentation*.

Assim como, em trabalhos futuros deve-se realizar novos experimentos com conjuntos de imagens maiores para tentar criar um modelo que possa generalizar melhor os aspectos das correntes de retorno. Outro aspecto importante, pode ser a realização de um *shuffle* no conjunto de dados antes do treinamento, desta forma previne-se que o modelo generalize ordens e padrões que não estão presentes em dados não utilizados no treinamento.

Além disso, pode ser interessante uma mudança de perspectiva, fazendo o uso de sequência de imagens (ou vídeos) para realizar o treinamento. Pois, uma imagem capturada pode não representar bem a existência ou não de uma corrente de retorno naquele momento, porém uma sequência de imagens pode dar um detalhamento maior sobre a situação daquele local, possibilitando melhor sua identificação.

REFERÊNCIAS

- AMERSHI, S. et al. Software Engineering for Machine Learning: A Case Study. In: Proc. of the IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice,. IEEE, 2019.
- ALZUBAIDI, L. et al. Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. Journal of Big Data, v. 8, n. 1, p. 1-74, 2021.
- AMORIM, J. G. A. Visão Computacional - Métricas: Mean Average Precision. LAPIX, [2020]. Disponível em: <https://lapix.ufsc.br/ensino/visao/visao-computacionaldeep-learning/visao-computacionalmetricasmean-average-precision/>. Acesso em: abr. 2023.
- BERRIBILLI, M. P. et al. Correntes de Retorno e os Riscos Associados ao Banho de Mar: Estudo de caso da Praia do Atalaia, Itajaí (SC). Revista Brasileira De Geomorfologia, v. 7, n. 2, 2007.
- BRANDER, R. W.; Short, A. D. Morphodynamics of a large-scale rip current system, Muriwai Beach, New Zealand. Marine Geology, v. 165, p. 27-39, 2000.
- BOCHKOVSKIY, A. et al. Yolov4: Optimal speed and accuracy of object detection. arXiv preprint arXiv:2004.10934, 2020.
- CALLIARI, L. J. et al. Morfodinâmica praias: uma breve revisão. Revista brasileira de oceanografia, v. 51, p. 63-78, 2003.
- CASTELLE, B. et al. Rip current types, circulation and hazard. Earth-Science Reviews, v. 163, p. 1-21, 2016.
- CDC. Drowning Facts. 2022. Disponível em: <https://www.cdc.gov/drowning/facts/index.html>. Acesso em: jul 2022.
- CORPO DE BOMBEIROS MILITAR - SC. Dicas de Prevenção - Praia. 2021. Disponível em: <https://www.cbm.sc.gov.br/index.php/dicas-de-prevencao/praias?highlight=WyJjb3JyZW50ZSIsImRliiwicmV0b3JubyIsImNvcnJlbnRlIGRliiwY29ycmVudGUgZGUuLCJjb3JyZW50ZSBkZSBvZXRvcml0>. Acesso em: jul 2022.
- DALRYMPLE, R. A. et al. Rip currents. Annual Review of Fluid Mechanics, v. 43, p. 551-581, 2011.
- DE SILVA, A. et al. Automated rip current detection with region based convolutional neural networks. Coastal Engineering, v. 166, p. 103859, 2021.
- GLOBAL BURDEN DISEASE. Drowning - Level 3 cause. 2019. Disponível em: <https://www.thelancet.com/pb-assets/Lancet/gbd/summaries/diseases/drowning.pdf>. Acesso em: jul 2022.
- ISHIKAWA, T. et al. Proposal and verification of rip current detection using AI. Coastal Dynamics - Conferência. 2021. Disponível em: <https://repository.tudelft.nl/islandora/object/uuid%3A8859f64c-2204-455d-a9a7-dfdacc4c2117>

- JIAO, L. et al. A survey of deep learning-based object detection. IEEE access, v. 7, p. 128837-128868, 2019.
- JOSHI, A. V. Machine learning and artificial intelligence. Springer: Cham, Switzerland, 2020.
- KIERSKI, M. Machine Learning development process - you've got it wrong. In: M. Kierski. [S.l.], 3 mar. 2017. Disponível em: <https://medium.com/sigmoidal/machinelearning-development-process-youve-got-it-wrong-396270e653f4>. Acesso em: mar 2023.
- KLEIN, A. et al. Santa Catarina Beach Systems. In: A. D. Short; A. H. da Fontoura Klein (Ed.). Brazilian beach systems. New York: Springer, 2016. 611 p.
- LECUN, Y. et al. Deep learning. Nature, v. 521, n. 7553, p. 436-444, 2015.
- LIU, L. et al. Deep learning for generic object detection: A survey. International journal of computer vision, v. 128, n. 2, p. 261-318, 2020.
- MARYAN, C. et al. Machine learning applications in detecting rip channels from images. Applied Soft Computing, v. 78, p. 84-93, 2019.
- MULLER, B. Z. Desenvolvimento de uma Extensão do App Inventor para Implantar Modelos de Machine Learning para Detecção de Objetos em Aplicativos, 2023. Em andamento. Trabalho de Conclusão de Curso. (Graduação em Sistemas de Informação) – Universidade Federal de Santa Catarina.
- OMS. Global report on drowning: preventing a leading killer. 2014. Disponível em: <https://www.who.int/publications/i/item/global-report-on-drowning-preventing-a-leading-killer>. Acesso em: jul 2022.
- PETERSEN, K. et al. Guidelines for conducting systematic mapping studies in software engineering: An update. Information and Software Technology, v. 64, p. 1-18, 2015.
- POLYZOTIS, N. et al. Data Management Challenges in Production Machine Learning. Proceedings of the ACM International Conference on Management of Data, Chicago, IL, USA, p. 1723 – 1726, 2017.
- PRESSMAN, R. Engenharia de software: Uma abordagem profissional. 8 ed. Porto Alegre: Bookman, 2016.
- PONTI, M. A.; COSTA, G. B. P. Como funciona o deep learning. In: V. Vieira et al. Tópicos em Gerenciamento de Dados e Informações: Minicursos do SBB. Tópicos, v. 2, p. 10, 2017.
- RAY, S. A quick review of machine learning algorithms. In: Proc. of the International conference on machine learning, big data, cloud and parallel computing. IEEE, 2019. p. 35-39.
- RIBEIRO, R. S. Caracterização morfodinâmica de praias do estado de Santa Catarina com vistas à avaliação de perigo ao banhista. 2014. 128 p. Dissertação (Mestrado) - Universidade Federal de Santa Catarina, Centro de Filosofia e Ciências Humanas, Programa de Pós-Graduação em Geografia, Florianópolis, 2014.

- RAMPAL, N. et al. Interpretable Deep Learning Applied to Rip Current Detection and Localization. *Remote Sensing*, v. 14, n. 23, p. 6048, 2022.
- RASHID, A. H. et al. Reducing rip current drowning: An improved residual based lightweight deep architecture for rip detection. *ISA transactions*, v. 132, p. 199-207, 2022.
- RASHID, A. H. et al. RipDet: A fast and lightweight deep neural network for rip currents detection. In: *Proc. of the International joint conference on neural networks*. IEEE, 2021. p. 1-6.
- REDMON, J.; FARHADI, A. Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018.
- ROSEBROCK, A. Intersection over Union (IoU) for object detection. *PyImageSearch*, 2016. Disponível em: <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>. Acesso em: abr 2023.
- ROBOFLOW. Roboflow. Disponível em: <https://roboflow.com/>. Acesso em: 11 jun. 2023.
- TERVEN, J.; CORDOVA-ESPARZA, D. A Comprehensive Review of YOLO: From YOLOv1 to YOLOv8 and Beyond. *arXiv preprint arXiv:2304.00501*, 2023.
- ULTRALYTICS. "Tips for Best Training Results". GitHub, Ultralytics, 2021. Disponível em: <https://github.com/ultralytics/yolov5/wiki/Tips-for-Best-Training-Results>. Acesso em: maio de 2023.
- ULTRALYTICS. Ultralytics. Disponível em: <https://github.com/ultralytics/ultralytics>, 2023. Acesso em: 16 de maio de 2023.
- VON WANGENHEIM, C. G.; VON WANGENHEIM, A. Overview on a human-centric interactive ML process for teaching ML in K-12. Disponível em: <http://www.gqs.ufsc.br/files/2020/02/GQSTemplate-RelatorioTecnico-HumanCentricProcess-v10.pdf>. Acesso em: jun 2023.
- ZHAO, Z. et al. Object detection with deep learning: A review. *IEEE transactions on neural networks and learning systems*, v. 30, n. 11, 2019, p. 3212-3232.
- ZHU, D. et al. YOLO-Rip: A modified lightweight network for Rip currents detection. *Frontiers in Marine Science*, v. 9, p. 930478, 2022.
- ZOU, J.; HAN, Y.; SO, S.-S. Overview of artificial neural networks. *Artificial Neural Networks*, p. 14-22, 2008.

APÊNDICE A - ARTIGO NO FORMATO SBC

Desenvolvimento de um Modelo de Detecção de Correntes de Retorno usando Deep Learning com base em Fotos a partir da Praia

Caio Nogueiro Motta

Departamento de Informática e Estatística, Universidade Federal de Santa Catarina, Florianópolis / SC, Brasil

caionogueiro@gmail.com

Abstract. *Thousands of people die from drowning annually. Among the main reasons for drowning are rip currents, a fast and narrow water flow that is difficult to identify. This study aims to train a model using Deep Learning to detect rip currents on beaches through cellphone photos, employing the YOLOv5s and YOLOv8s models. Despite efforts, the trained models showed performance below expectations, struggling to efficiently identify the currents. The frontal perspective of the images might limit the model's accuracy, contrasting with previous studies that utilized aerial images.*

Resumo. *Anualmente milhares de pessoas morrem afogadas. Entre os principais motivos de afogamento estão as correntes de retorno, um fluxo de água rápido e estreito de difícil identificação. Este estudo visa treinar um modelo usando Deep Learning para detectar correntes de retorno em praias através de fotos de celular, empregando os modelos YOLOv5s e YOLOv8s. Apesar dos esforços, os modelos treinados apresentaram desempenho abaixo do esperado, com dificuldade em identificar eficientemente as correntes. A perspectiva frontal das imagens pode limitar a precisão do modelo, contrastando com estudos anteriores que usaram imagens aéreas.*

1. Introdução

Todos os anos milhares de pessoas ao redor do planeta morrem por afogamento, sendo uma das principais causas de mortes não intencionais (OMS, 2014). Segundo o Global Burden of Disease de 2019, 237 mil pessoas morreram por afogamento no planeta. No mesmo ano, no Brasil morreram 5,6 mil pessoas (SOBRASA, 2021).

Devido ao seu tamanho, o Brasil possui uma vasta rede hidrográfica e extensa costa, contendo assim, uma grande quantidade de localidades com acesso às águas naturais. De acordo com o Boletim de 2021 da Sociedade Brasileira de Salvamento Aquático (SOBRASA), 90% dos afogamentos ocorreram em águas naturais, sendo que 15% desses afogamentos ocorreram nas praias brasileiras.

Especificamente o estado de Santa Catarina possui aproximadamente 430 km de costa que pertencem a 36 municípios, que por sua vez contém aproximadamente 38% da população do estado (KLEIN et al., 2016). Nesta costa estão presentes um variado tipo de ambientes como praias, ilhas, enseadas, baías, mangues, áreas alagáveis, estuários e lagoas. Essa variedade, juntamente com o clima ameno, faz com que a região seja utilizada para uma variedade de usos que incluem, entre outras atividades, a recreação, banho, surfe e turismo de forma geral, aumentando significativamente o uso durante a estação do verão. A costa de Santa Catarina é formada por 246 praias arenosas que ocupam 60% do seu litoral. Deste total de praias, 31% são de alta energia, 46,5% são de praias de energia intermediária com presença de correntes de retorno e apenas 20% são de baixa energia e menos perigosas para o banho (KLEIN et al., 2016). Assim, essa condição das praias de Santa Catarina, juntamente com a prática do turismo, proporciona um elevado potencial de risco de afogamento. Conforme o Corpo de Bombeiros de Santa Catarina (2021), 90% dos afogamentos ocorridos em águas salgadas têm alguma relação com correntes de retorno.

As correntes de retorno, por sua vez, são fluxos de água rápidos e estreitos que se iniciam perto da costa e se estendem através da zona de surf em direção ao mar (BRANDER e SHORT, 2000; DALRYMPLE et al., 2011). Esses fluxos variam de tamanho, largura, profundidade e intensidade

de acordo com o tipo de praia e são formados pelo retorno da água que chegou até a praia empurrada pelas ondas. Assim que as ondas arrebentam, a água é empurrada acima do nível médio do mar, forçando um retorno dessa água através da força da gravidade (BERRIBILLI et al., 2007; DALRYMPLE et al., 2011). As correntes de retorno podem frequentemente serem identificadas na zona de surf em áreas de coloração mais escura associadas a canais mais profundos e em locais onde as ondas não arrebentam, localizadas entre áreas mais rasas onde as ondas arrebentam constantemente (DALRYMPLE et al., 2011). Ainda que as correntes de retorno possam ter características físicas visíveis, tais quais as citadas acima, identificá-las geralmente não é uma tarefa fácil. Em geral, essa capacidade é restrita à estudiosos da área e profissionais como salva-vidas, com o devido treinamento. Assim, esta dificuldade gera aos banhistas potencial risco, pois o critério de escolha do local de banho pode não levar em consideração as características visuais de correntes de retorno.

Uma possível solução para este problema pode ser o uso de um aplicativo móvel que auxilie a identificação de correntes de retorno por meio de fotos frontais da localidade de banho desejada, permitindo a identificação, sobretudo, quando não houver a possibilidade de identificação e orientação por um profissional salva-vidas. Utilizando um modelo de *Deep Learning* o aplicativo realiza a classificação da imagem, indicando ao banhista onde potencialmente tem uma corrente de retorno e, dessa forma, o banhista pode tomar uma decisão mais assertiva sobre qual local escolher, sem a necessidade de ter um conhecimento prévio acerca do assunto.

Já existem propostas de identificação de correntes de retorno utilizando modelos de *machine learning* e classificação de imagens, como proposto por Ishikawa et al. (2021) que utiliza o modelo de detecção de objetos TinyYoloV3 para identificar correntes de retorno em imagens de webcam. Zhu et al. (2022), utilizaram o modelo YoloV5s com a mesma finalidade, porém em imagens aéreas. Por sua vez, Rashid et al. (2021) criou um modelo baseado em Tiny YoloV3 chamado RipDet em imagens em tons de cinza com contornos de correntes de retorno. No entanto, nenhum deles utiliza imagens na visão do banhista.

Assim, o objetivo do presente trabalho consiste na criação de um modelo de detecção de correntes de retorno a partir de fotos frontais de celular capturadas a partir da praia (visão do banhista) com mAP mínimo de 98%.

2. Trabalhos Correlatos

A revisão sistemática da literatura dos últimos 10 anos, demonstra que existem pesquisas recentes sobre detecção de correntes utilizando deep learning. No entanto, essas pesquisas utilizam conjunto de dados com imagens aéreas ou webcams em pontos estáticos da praia que possuem um campo de visão mais amplo possibilitando uma melhor identificação das correntes de retorno como em Ishikawa et al. (2021). Esse aspecto difere do presente trabalho que pretende utilizar fotos frontais a partir da praia coletadas com smartphones.

Com relação aos modelos utilizados nos trabalhos, percebe-se a predominância das redes neurais convolucionais e especificamente do YOLO para a detecção de objetos. Que conforme os resultados de avaliação de desempenho relatados conseguem nos respectivos contextos obter bons desempenhos. Os modelos baseados em Tiny YOLOv3 de Rashid et al (2021) e Rashid et al (2022) obtiveram mAP de 98.131% e 98.55% respectivamente. Já o modelo de Zhu et al (2022) que utilizou YOLOv5s obteve mAP de 92.15%.

Não foi encontrada implantação de modelos treinados em aplicativos móveis. Desta forma, o desenvolvimento de modelos utilizando fotos frontais da praia possibilita a implantação futura em um app mobile, tornando possível sua disponibilidade a um público maior. Não foram também identificadas pesquisas brasileiras sobre detecção de correntes de retorno utilizando detecção de objetos, o que evidencia uma lacuna de conhecimento que precisa ser mais explorada, já que o Brasil possui uma costa extensa e é bastante comum a ocorrência das correntes de retorno.

3. Solução

3.1 Requisitos

O objetivo é desenvolver um modelo que detecte a presença ou não de uma corrente de retorno em imagens frontais capturadas por um dispositivo móvel. O modelo utilizará deep learning e aprenderá com base em conjunto de imagens rotuladas de correntes de retorno e sem correntes de retorno. A medida de desempenho desejada é de mAP superior a 98%. O risco de classificação incorreta é alto, pois pode colocar a vida em risco de futuros usuários do modelo.

3.2 Preparação de dados

Pela inexistência de conjunto de imagens deste tipo, foi coletado um conjunto de imagens frontais a partir da praia. As imagens foram todas coletadas em Florianópolis por pesquisadores do Grupo de qualidade de software (GQS) da Universidade Federal de Santa Catarina. Dos conjuntos coletados foram utilizados neste trabalho as imagens da Praia do Santinho e da Praia da Armação.

A anotação das imagens foi feita por um aluno de graduação do curso de oceanografia e salva-vidas civil sob a revisão de professor do curso de oceanografia da UFSC. Durante a anotação são indicados a presença de correntes de retornos nas imagens utilizando *bounding boxes*, também são marcadas as imagens que não possuem correntes de retorno.

Conjunto de dados			
Praia	Total	Com corrente	Sem corrente
Santinho	875	347	528
Armação	1.194	606	588

Tabela 1 - Conjunto de imagens rotulados

Foi feito um outro conjunto somando os dois conjuntos de imagens mencionados para que fosse realizado treinamento.

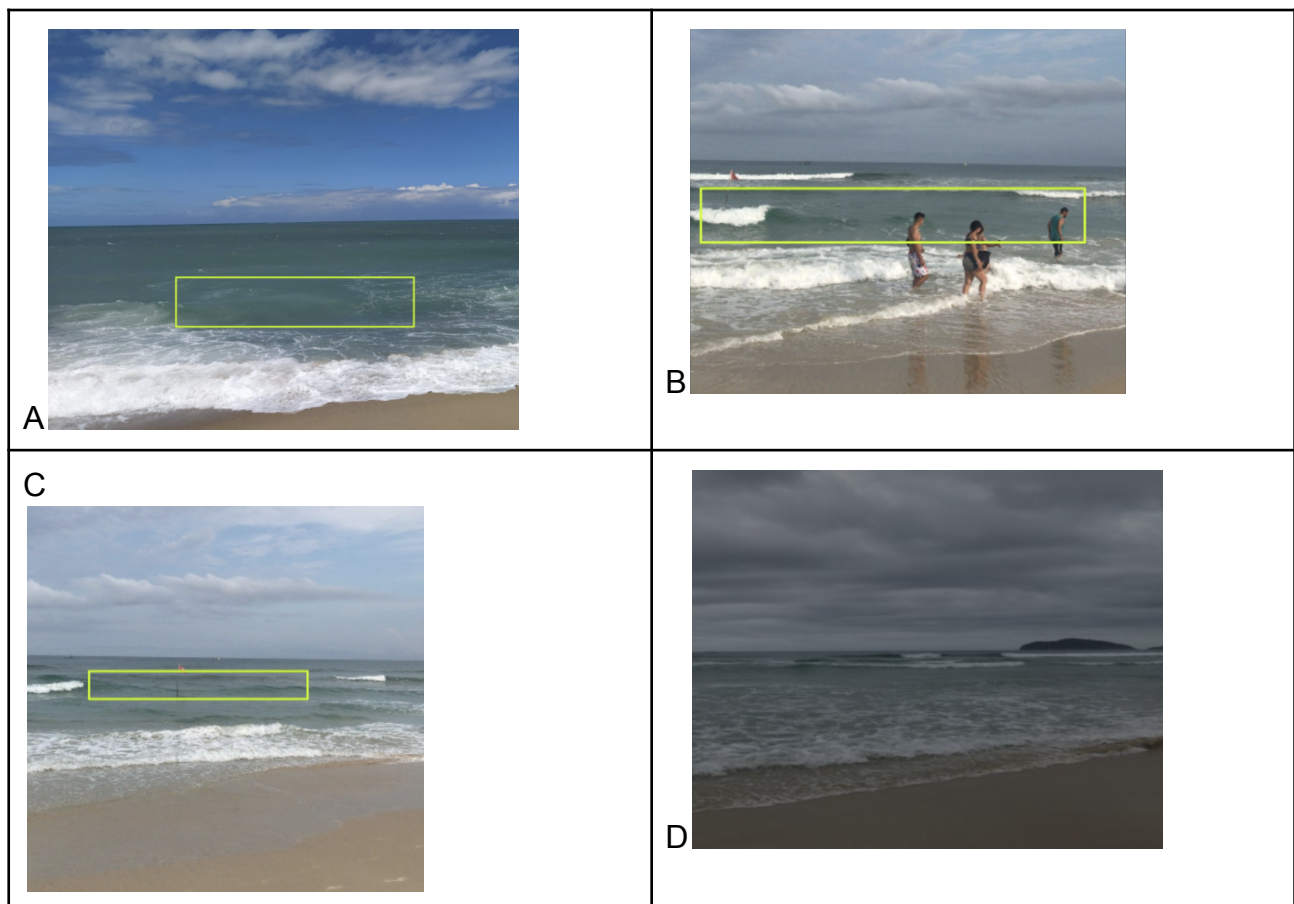


Tabela 2 - Exemplos de imagens do conjunto. As imagens A, B e C possuem correntes de retorno indicadas por *bounding boxes*. A imagem D não possui corrente de retorno.

Usou-se técnicas de *data augmentation* para aumentar o conjunto de dados e gerar maior variabilidade. Entre as técnicas propostas são utilizadas as relativas ao posicionamento da imagem: rotação, *shear* (alterando a perspectiva da imagem). Também serão utilizadas técnicas relativas ao aspecto das imagens: alteração de matiz, saturação e brilho, borramento e adição de ruído.

As técnicas de *data augmentation* foram aplicadas de forma aleatória, ou seja, uma imagem selecionada não recebia efeitos do *data augmentation* e duas cópias delas recebiam aleatoriamente algum dos efeitos citados.

Os conjuntos de imagens foram divididos em 70% para treinamento, 20% para validação e 10% para teste. O balanceamento destes conjuntos segue a proporção de classes presentes no conjunto de dados.

O conjunto de treinamento foi utilizado durante o processo de treinamento para generalizar os padrões e características das correntes de retorno. A cada época de treinamento o conjunto de validação é utilizado para avaliar a generalização do modelo utilizando dados não vistos no treinamento. Já o conjunto de testes foi utilizado para avaliar o desempenho final do modelo após treinamento e validação.

3.3 Treinamento

Foi realizado treinamento com redes neurais com portabilidade para dispositivos móveis como o YOLOv5s e o YOLOv8s. Para cada conjunto de imagem (Praia da Armação, Praia do Santinho e Praia da Armação + Santinho) foram feitos treinamentos com e sem *data augmentation* em cada um dos modelos. Os resultados estão na Tabela 2.

		Resultados da validação nos treinamentos			
		mAP	Precisão	Recall	F1-Score
Praia da Armação	YOLOv5s	0.359	0.46	0.353	0.399
	YOLOv5s com <i>data augmentation</i>	0.329	0.396	0.379	0.387
	YOLOv8s	0.318	0.451	0.342	0.389
	YOLOv8s com <i>data augmentation</i>	0.346	0.480	0.284	0,357
Praia do Santinho	YOLOv5s	0.347	0.407	0.402	0.404
	YOLOv5s com <i>data augmentation</i>	0.405	0.385	0.390	0.387
	YOLOv8s	0.407	0.428	0.488	0.456
	YOLOv8s com <i>data augmentation</i>	0.381	0.489	0.385	0.431
Praia do Santinho + Armação	YOLOv5s	0.409	0.384	0.503	0.436
	YOLOv5s com <i>data augmentation</i>	0.351	0.402	0.43	0.416

	YOLOv8s	0.381	0.462	0.450	0.456
	YOLOv8s com <i>data augmentation</i>	0.329	0.426	0.372	0.397

Tabela 2 - Resultado da validação dos treinamentos

Todos os resultados obtidos durante a treino/validação referente ao mAP50 estão abaixo do desempenho esperado. Podemos observar também que as métricas de precisão, *recall* e F1-score também são baixas. O treinamento com melhor desempenho foi do conjunto de imagens da Praia do Santinho + Armação sem *data augmentation* utilizado o YOLOv5s, e mesmo assim observamos que está bem abaixo do mAP esperado de 0.98. Além disso, observamos que o *data augmentation* não teve efeito para a melhora efetiva do desempenho dos treinamentos, em alguns casos o mAP melhorou e em outros piorou.

3.4 Testes de desempenho

Os conjuntos testados possuem uma distribuição proporcional entre as classes, contendo imagens com correntes de retorno e sem correntes de retorno. Estas imagens não foram utilizadas durante o treinamento e não possuem *data augmentation*. As imagens foram coletadas nas mesmas praias dos conjuntos de treinamento e validação. As métricas utilizadas para avaliar o desempenho foram o mAP, precisão, *recall* e *F1-score*.

		Resultados dos testes			
		mAP	Precisão	<i>Recall</i>	<i>F1-Score</i>
Praia da Armação	YOLOv5s	0.572	0.572	0.598	0.585
	YOLOv5s com <i>data augmentation</i>	0.595	0.541	0.671	0.599
	YOLOv8s	0.479	0.634	0.423	0.507
	YOLOv8s com <i>data augmentation</i>	0.519	0.700	0.463	0.557
Praia do Santinho	YOLOv5s	0.302	0.336	0.459	0.388
	YOLOv5s com <i>data augmentation</i>	0.342	0.512	0.324	0.397
	YOLOv8s	0.427	0.577	0.405	0.476
	YOLOv8s com <i>data augmentation</i>	0.296	0.373	0.351	0.362
Praia do Santinho + Armação	YOLOv5s	0.490	0.481	0.533	0.506
	YOLOv5s com <i>data augmentation</i>	0.491	0.443	0.602	0.510
	YOLOv8s	0.442	0.390	0.533	0.450
	YOLOv8s com <i>data augmentation</i>	0.451	0.600	0.451	0.515

Nota-se uma leve melhora de desempenho em relação ao treinamento/validação dos conjuntos Praia da Armação e Praia do Santinho + Armação melhoraram seu desempenho. Contudo, nota-se uma distância significativa para o mAP desejado em relação ao caso de uso, bem como um resultado abaixo em comparação ao dos trabalhos correlatos.

3.6 Discussão

Todos os resultados obtidos durante a treino/validação referente ao mAP estão abaixo do desempenho esperado. Podemos observar também que as métricas de precisão, *recall* e *F1-score* também são baixas.

O treinamento com melhor desempenho foi do conjunto de imagens da Praia do Santinho + Armação sem *data augmentation* utilizado o YOLOv5s, e mesmo assim observamos que está bem abaixo do mAP esperado de 0.98. Além disso, observamos que o *data augmentation* não teve efeito para a melhora efetiva do desempenho dos treinamentos, em alguns casos o mAP melhorou e em outros piorou.

Observamos que nos resultados dos testes os modelos dos conjuntos Praia da Armação e Praia do Santinho + Armação melhoraram seu desempenho. Também foi percebido melhora no modelo YOLOv8s sem *data augmentation* do conjunto de dados da Praia do Santinho. Há significativa distância entre o mAP dos resultados dos testes e mAP esperado.

O melhor desempenho nos testes em relação ao treinamento/validação pode ter algumas explicações. Uma delas é que o conjunto de imagens de teste é menor (apenas 10% das imagens), assim é possível que ele tenha errado menos por ter menos chances de errar devido ao tamanho do conjunto. Consequentemente, isso levou a um melhor desempenho nas métricas de teste. Outra possível explicação é que embora a divisão do conjunto entre treinamento, validação e teste busque uma distribuição equalizada das classes, há a possibilidade de que as imagens do conjunto de teste tenham características diferentes das do conjunto de validação. Ocasionalmente, estas características do conjunto de teste podem ser melhor detectadas pelo modelo treinado. Observa-se que os conjuntos que apresentaram melhora nas métricas de teste contém imagens da Praia da Armação. Portanto, é possível que este conjunto de imagens favoreçam este tipo de resultado nos testes.

Percebemos que todos os modelos treinados não conseguiram generalizar e identificar onde tem e não corrente de retorno. Percebemos que o *recall* é bastante afetado, pois há bastante ocorrência de falsos negativos, o que é bastante crítico para o objetivo do modelo. Por fim, os valores de *F1-Score* (que considera a precisão e o *recall*) são baixos demonstrando a baixa qualidade do modelo na execução da tarefa de detecção de correntes de retorno.

O baixo desempenho nesses modelos pode ser explicado pela perspectiva em que as imagens são obtidas (imagens frontais, na perspectiva de um banhista). Por este motivo, pode ter pouco efeito uma comparação com os resultados dos trabalhos correlatos que de forma geral utilizavam imagens aéreas ou de um ponto de vista de maior altitude.

Assuma-se que a visualização de uma perspectiva de maior altitude facilita a identificação das correntes de retorno, pois a sua identificação se dá pela diferenciação de aspectos visíveis no mar, assim, uma visão mais abrangente possibilita delimitar melhor as fronteiras do que é e o que não uma corrente de retorno. Em uma imagem de visão frontal, a forma como uma determinada onda se dissipa ou o momento em que ela foi fotografada afetam a interpretação sobre a existência ou não de uma corrente de retorno.

4. Conclusão

Neste estudo foram realizados experimentos para o desenvolvimento de um modelo para detecção de correntes de retorno a partir de imagens frontais do mar, com base em uma pesquisa teórica e o mapeamento do estado da arte.

OMS. Global report on drowning: preventing a leading killer. 2014. Disponível em: <https://www.who.int/publications/i/item/global-report-on-drowning-preventing-a-leading-killer>. Acesso em: jul 2022.

RAMPAL, N. et al. Interpretable Deep Learning Applied to Rip Current Detection and Localization. *Remote Sensing*, v. 14, n. 23, p. 6048, 2022.

RASHID, A. H. et al. Reducing rip current drowning: An improved residual based lightweight deep architecture for rip detection. *ISA transactions*, v. 132, p. 199-207, 2022.

RASHID, A. H. et al. RipDet: A fast and lightweight deep neural network for rip currents detection. En 2021 international joint conference on neural networks (IJCNN). IEEE, 2021. p. 1-6.

ZHU, D. et al. YOLO-Rip: A modified lightweight network for Rip currents detection. *Frontiers in Marine Science*, v. 9, p. 930478, 2022.