

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 Fotos do CoastSnap**

Ramon Seugling

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 fotos do CoastSnap

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: Ramon Seugling

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

Florianópolis
2023

RESUMO

Os casos de afogamento possuem uma grande parcela das causas de óbitos do planeta, ocorrendo muitas vezes por falta de cuidado ou de conscientização com o perigo que são as águas. As correntes de retorno são um dos principais motivos desses incidentes, onde se forma uma correnteza que parte da areia em direção mar adentro, ou seja, um fluxo contrário ao das ondas, levando os banhistas para longe da praia. Um dos principais problemas da presença dessas correntes, é a sua identificação. Na maioria das vezes, essa identificação se torna difícil para qualquer pessoa, e geralmente somente pessoas capacitadas na área como salva-vidas conseguem identificar as correntes de retorno, o que pode dificultar o banhista ter esta informação. Uma solução poderá ser uma detecção automática dessas correntes de retornos em aplicativos móveis. Já existem algumas pesquisas relacionadas ao desenvolvimento de modelos de *Deep Learning* para a detecção de correntes de retorno, mas utilizam fotos de câmeras instaladas nas praias. Assim, o objetivo geral deste trabalho é o desenvolvimento de um modelo de *Deep Learning* que por meio de fotos tiradas do costão da praia com um celular utilizando o suporte CoastSnap, identifica as correntes de retorno e informa o usuário sobre o perigo existente ao banhar-se nestes locais. Espera-se que este trabalho ajude na conscientização maior sobre o assunto e diminua o risco iminente que essas correntes trazem.

Palavras-chave: Inteligência artificial, *Deep Learning*, detecção de objetos, correntes de retorno, YOLO.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1: Vista aérea de corrente de retorno na Praia Brava em Itajaí, Santa Catarina (Mocellin, 2005) | 10 |
| Figura 2: Representação de IA, ML, NN e DL por bonecas russas (Kavlakoglu, 2020) | 14 |
| Figura 3: Detecção de objetos e respectivos <i>bounding boxes</i> (Redmon <i>et al.</i> , 2016) | 15 |
| Figura 4: Esquema do IOU (Rosebrock, 2016) | 16 |
| Figura 5: Rede neural convolucional e suas diferentes camadas (Vargas; Paes; Vasconcelos, 2016) | 18 |
| Figura 6. Processo de detecção de objetos com <i>grid</i> do YOLO (Redmon <i>et al.</i> , 2016) | 19 |
| Figura 7. Processo de detecção de objetos SxS <i>Grid</i> (Lan <i>et al.</i> , 2018) | 19 |
| Figura 8. Diferentes modelos do YOLOv5 (YOLOv5, 2022) | 20 |
| Figura 9: Comparação de desempenho entre diferentes versões do YOLO (Ultralytics, 2023) | 21 |
| Figura 10. Arquitetura do modelo de detecção YOLOv5 (Ultralytics, 2020) | 22 |
| Figura 11: Representação de uma corrente de retorno (Maia; Pereira; Lessa, 2014) | 23 |
| Figura 12: A e B esquema e foto das <i>flash rips</i> . C e D esquema e foto das <i>shear instability rips</i> (Castelle <i>et al.</i> , 2016). | 24 |
| Figura 13: A e B esquema e foto das <i>channel rip currents</i> . C e D esquema e foto das <i>focused rips</i> (no esquema apresentando uma anomalia batimétrica com maior profundidade)(Castelle <i>et al.</i> , 2016). | 25 |
| Figura 14: A e B esquema e foto de <i>shadow rip current</i> . C e D esquema e foto da <i>deflection rip</i> (Castelle <i>et al.</i> , (2016)). | 26 |
| Figura 15: Suporte do CoastSnap para coleta de imagem em <i>Stockton Beach</i> , Austrália (NSW, 2021) | 27 |
| Figura 16: Suporte do CoastSnap Santa Catarina localizado na Praia do Moçambique | 28 |
| Figura 17: Suporte do CoastSnap Santa Catarina localizado na Praia do Santinho | 28 |
| Figura 18: Quantidade de artigos relevantes ao assunto publicados nos últimos 6 anos | 32 |
| Figura 19: Quantidade de imagens no conjunto de dados por pesquisa | 34 |
| Figura 20: Quantidade de imagens no conjunto de dados por pesquisa após limpeza de <i>outlier</i> | 35 |
| Figura 21. Exemplo de imagem de entrada do modelo utilizando suporte do CoastSnap | 41 |
| Figura 22. Exemplo de imagem classificada pelo modelo | 41 |

Figura 23: Exemplos de imagens do conjunto. As imagens A, B foram fotografadas na praia do Moçambique. As imagens C e D, fotografadas na praia do Santinho. Todas contém correntes de retorno indicadas por *bounding boxes*

44

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1: Fotos do suporte CoastSnap em praias de Florianópolis | 28 |
| Tabela 2: Termos de busca utilizados no protocolo de revisão | 30 |
| Tabela 3: <i>String</i> de busca para cada fonte | 30 |
| Tabela 4: Número de artigos identificados por repositório e por fase de seleção | 31 |
| Tabela 5: Pesquisas que utilizam <i>Deep Learning</i> para detecção de correntes de retorno | 32 |
| Tabela 6: Informações sobre os dados encontrados nas pesquisas | 33 |
| Tabela 7: Informações sobre o treinamento dos trabalhos encontrados | 35 |
| Tabela 8: Desempenhos relatados | 37 |
| Tabela 9: História de usuário | 41 |
| Tabela 10: Objetivos do modelo de <i>Deep Learning</i> | 42 |
| Tabela 11: <i>Status</i> de preparação do conjunto de imagens | 43 |
| Tabela 12: Técnicas de <i>data augmentation</i> | 45 |
| Tabela 13: Características do conjunto de dados de teste da praia do Moçambique | 55 |
| Tabela 14: Características do conjunto de dados de teste da praia do Santinho | 58 |
| Tabela 15: Características do conjunto de dados de teste da praia do Moçambique + praia do Santinho | 61 |
| Tabela 16: Resultado dos treinamentos dos diferentes conjuntos de dados e modelos | 64 |
| Tabela 17: Resultado dos testes com diferentes conjuntos de dados e modelos | 66 |

LISTA DE ABREVIATURAS E SIGLAS

IA - Inteligência Artificial

CNN - *Convolutional Neural Networks*

DL - *Deep Learning*

ML - *Machine Learning*

YOLO - *You Only Look Once*

IOU - *Intersection Over Union*

R-CNN - *Region Based Convolutional Neural Network*

SUMÁRIO

| | |
|--|-----------|
| 1. INTRODUÇÃO..... | 9 |
| 1.1 CONTEXTUALIZAÇÃO..... | 9 |
| 1.2 OBJETIVOS..... | 11 |
| 1.3 METODOLOGIA..... | 11 |
| 1.4 ESTRUTURA DO DOCUMENTO..... | 13 |
| 2. FUNDAMENTAÇÃO TEÓRICA..... | 14 |
| 2.1 MACHINE LEARNING E DEEP LEARNING..... | 14 |
| 2.2 CORRENTES DE RETORNO..... | 22 |
| 3. ESTADO DA ARTE..... | 29 |
| 3.1 DEFINIÇÃO DO PROTOCOLO DE REVISÃO..... | 29 |
| 3.2 EXECUÇÃO DA BUSCA..... | 31 |
| 3.3 RESULTADOS DA BUSCA..... | 31 |
| 3.3.1 QUAIS PESQUISAS EXISTEM EM TERMOS DE DETECÇÃO DE CORRENTES DE RETORNO?..... | 31 |
| 3.3.2 QUAIS AS CARACTERÍSTICAS EM TERMOS DO CONJUNTO DE DADOS?..... | 32 |
| 3.3.3 COMO OS MODELOS FORAM TREINADOS?..... | 35 |
| 3.3.4 QUAIS OS DESEMPENHOS RELATADOS?..... | 37 |
| 3.4 DISCUSSÃO..... | 37 |
| 4. DESENVOLVIMENTO DO MODELO DE DETECÇÃO DE CORRENTES DE RETORNO..... | 40 |
| 4.1 REQUISITOS..... | 42 |
| 4.2 PREPARAÇÃO DO CONJUNTO DE IMAGENS..... | 43 |
| 4.3 TREINAMENTO..... | 47 |
| 4.3.1 TREINAMENTO COM O CONJUNTO DE IMAGENS DA PRAIA DO MOÇAMBIQUE..... | 48 |
| 4.3.1.1 TREINAMENTO COM YOLOv5n..... | 48 |
| 4.3.1.2 TREINAMENTO COM YOLOv8s..... | 49 |
| 4.3.2 TREINAMENTO COM O CONJUNTO DE IMAGENS DA PRAIA DO SANTINHO..... | 51 |
| 4.3.2.1 TREINAMENTO COM YOLOv5s..... | 51 |
| 4.3.2.2 TREINAMENTO COM YOLOv8s..... | 52 |
| 4.3.3 TREINAMENTO COM O CONJUNTO DE IMAGENS DA PRAIA DO MOÇAMBIQUE + PRAIA DO SANTINHO..... | 53 |
| 4.3.3.1 TREINAMENTO COM YOLOv5s..... | 53 |
| 4.3.3.2 TREINAMENTO COM YOLOv8s..... | 54 |
| 4.4 TESTE DE DESEMPENHO..... | 55 |
| 4.4.1 TESTE DE DESEMPENHO COM O CONJUNTO DE IMAGENS DA PRAIA DO MOÇAMBIQUE..... | 55 |
| 4.4.1.1 PREPARAÇÃO DO TESTE..... | 55 |

| | |
|---|-----------|
| 4.4.1.2 RESULTADO DO TESTE COM YOLOv5n..... | 56 |
| 4.4.1.3 RESULTADO DO TESTE COM YOLOv8s..... | 57 |
| 4.4.2 TESTE DE DESEMPENHO COM O CONJUNTO DE IMAGENS DA PRAIA DO SANTINHO..... | 58 |
| 4.4.2.1 PREPARAÇÃO DO TESTE..... | 58 |
| 4.4.2.2 RESULTADO DO TESTE COM YOLOv5s..... | 59 |
| 4.4.2.3 RESULTADO DO TESTE COM YOLOv8s..... | 60 |
| 4.4.3 TESTE DE DESEMPENHO COM O CONJUNTO DE IMAGENS DA PRAIA DO MOÇAMBIQUE + PRAIA DO SANTINHO..... | 61 |
| 4.4.3.1 PREPARAÇÃO DO TESTE..... | 61 |
| 4.4.3.2 RESULTADO DO TESTE COM YOLOv5s..... | 62 |
| 4.4.3.3 RESULTADO DO TESTE COM YOLOv8s..... | 63 |
| 4.5 DISCUSSÃO..... | 64 |
| 5. CONCLUSÃO..... | 67 |
| REFERÊNCIAS..... | 70 |

1. INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Atualmente, o afogamento é uma das maiores causas de morte de pessoas ao redor do mundo (OMS, 2019). Somente em 2019, 236 mil pessoas perderam suas vidas por este tipo de asfixia. Com uma porcentagem alta perante o total de mortes globais, o afogamento vêm ganhando cada vez mais destaque, ocorrendo 90% dos casos em países de baixa e média renda. Sendo assim, iniciou-se por parte da Organização Mundial de Saúde (OMS), uma luta de conscientização para prevenir afogamentos e consequentemente reduzir o número de mortes.

No Brasil, por se tratar de um país continental com uma costa com mais de 8 mil quilômetros de extensão, e por possuir uma das maiores áreas banháveis do mundo durante o ano inteiro, o país possui um dos maiores números de incidentes e óbitos por afogamento do planeta (SOBRASA, 2021). Segundo a Sociedade Brasileira de Salvamento Aquático (SOBRASA) mais de 100 mil incidentes não fatais e mais de 5 mil óbitos ocorreram no Brasil em 2019 (SOBRASA, 2021). É um número alto que pode ser diminuído com conscientização das pessoas em relação às maiores causas.

Uma das causas, muito desconhecida pela população, são as correntes de retorno e centenas de pessoas se afogam e dezenas de milhares são resgatadas dessas correntes todos os anos (Castelle *et al.*, 2016). O estado de Santa Catarina, por possuir um litoral repleto de praias turísticas e ser o destino de banhistas todos os anos, possui diversos incidentes com afogamento. Segundo o Corpo de Bombeiros Militar (2023), 90% desses casos acontecem em correntes de retorno.

Em termos oceanográficos, correntes de retorno são fluxos de água com velocidade alta, que fluem preferencialmente perpendicular à praia em direção mar adentro, ou seja, fluxo contrário ao das ondas. A partir destas ondas que vão em direção à praia, carregadas de energia, massa e impulso, elas tendem a voltar ao mar, formando os canais de retorno (Figura 1). As correntes de retorno podem variar de acordo com a localização e tipo de arrebentação da praia, mudando de profundidade, força, tamanho e lugar. Sendo assim, torna-se um grande perigo para banhistas que podem ser levados para águas profundas em pouco tempo (Dalrymple *et al.*, 2011).



Figura 1: Vista aérea de corrente de retorno na Praia Brava em Itajaí, Santa Catarina (Mocellin, 2005);

CR = Corrente de retorno

As correntes de retorno são muitas vezes identificadas por meio de suas características como a coloração mais escura do mar que indica maior profundidade e a não formação de ondas e espuma em uma zona de arrebatção (Dalrymple *et al.*, 2011). Ainda que a visualização dessas correntes possa ser relativamente compreensível, muitas vezes não são identificadas com facilidade. Na maioria dos casos, essa função é regida por profissionais do assunto e salva-vidas que atuam no local. Consequentemente, a maioria dos banhistas acaba não tendo ciência do que aquela região se trata e acaba correndo o risco de incidentes ao entrar em uma corrente de retorno.

Tendo em vista que existe o problema na identificação dessas correntes, uma possível solução pode ser a utilização de um aplicativo móvel utilizando *Deep Learning* para identificar estas correntes utilizando fotos do costão da praia, que por possuir uma visão mais ampla da água, identificaria as correntes presentes no mar. A identificação dessas correntes nas imagens pode ser realizada com *Deep Learning*, detectando na foto a presença dessas correntes e mostrando ao usuário sua posição e o avisa sobre o perigo. Já existem algumas propostas de detecção de correntes de retorno usando *Deep Learning*, como o trabalho de Ishikawa *et al.* (2021), que utiliza vídeos de câmeras fixadas a uma altura elevada, obtendo uma visão mais panorâmica da água. Porém ainda não existe uma solução utilizando fotos tiradas do costão da praia.

Nesse contexto, existe no mundo um monitoramento comunitário de praias chamado CoastSnap (Harley; Kinsela, 2022). Assim, para coletar imagens das praias por meio de *crowdsourcing*, o projeto disponibiliza suportes localizados em praias para posicionar a câmera do celular para fotografar, e, posteriormente, compartilhar fotos da praia nas redes sociais. Na Ilha de Santa Catarina, em parceria com a UFSC, foram instaladas estações nas praias para coleta destas imagens. O foco dessas estações é monitorar as praias, o comportamento dos bancos arenosos e as correntes de retorno.

Sendo assim, o presente trabalho busca criar um modelo de detecção de correntes, a partir de fotos tiradas de um celular do costão de praias na Ilha de Santa Catarina usando o suporte CoastSnap.

1.2 OBJETIVOS

OBJETIVO GERAL

O objetivo geral deste trabalho é desenvolver um modelo de detecção de correntes de retorno do mar a partir de fotos do mar tiradas com a câmera de celular do costão da praia, visando obter uma área mais panorâmica via o CoastSnap. São adotadas técnicas de *Deep Learning* para automatizar a detecção da posição dos correntes.

OBJETIVOS ESPECÍFICOS

- O1. Analisar a fundamentação teórica sobre correntes de retorno e *Deep Learning*, especificamente detecção de objetos e do projeto CoastSnap.
- O2. Analisar o estado da arte em relação a detecção de correntes de retorno com *Deep Learning*.
- O3. Desenvolver e testar modelos 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 e do projeto CoastSnap

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 do reconhecimento de correntes de retorno. Esta etapa é dividida nas seguintes atividades:

A2.1 – Definição do protocolo de 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* (Polyzotis *et al.*, 2017) treinando e comparando o desempenho de vários modelos. Esta etapa é dividida nas seguintes atividades:

A3.1 – Análise de requisitos

A3.2 – Coleta de dados

A3.3 – Preparação de conjunto de dados no Roboflow

A3.4 – Treinamento de modelos de *Deep Learning*

A3.5 - Avaliação do desempenho de modelos de *Deep Learning*

A3.6 - Predição/Inferência (teste com novas imagens)

1.4 ESTRUTURA DO DOCUMENTO

O segundo capítulo contém a fundamentação teórica, onde são abordados os assuntos relevantes, tais como Inteligência Artificial, *Machine Learning*, *Deep Learning* e detecção de objetos. Também é abordado correntes de retorno. O capítulo 3 visa analisar o estado atual da arte, sendo realizado um levantamento de diversas pesquisas, seguindo um protocolo de busca estabelecido, que contribui para o presente estudo. No quarto capítulo, é apresentado o desenvolvimento de modelos de *Deep Learning* de detecção de correntes de retorno a partir de imagens fotografadas em suportes do CoastSnap. São apresentados também os resultados obtidos com o treinamento e validação do modelo. Por fim, no capítulo 5 é apresentado a conclusão.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 MACHINE LEARNING E DEEP LEARNING

A Inteligência Artificial (IA) é uma área da ciência da computação, que estuda o desenvolvimento da automação do comportamento inteligente (Luger, 2004). A IA engloba diversos subcampos de estudo, como *Machine Learning*, *Neural Networks* e *Deep Learning* (Kavlakoglu, 2020) (Figura 2).

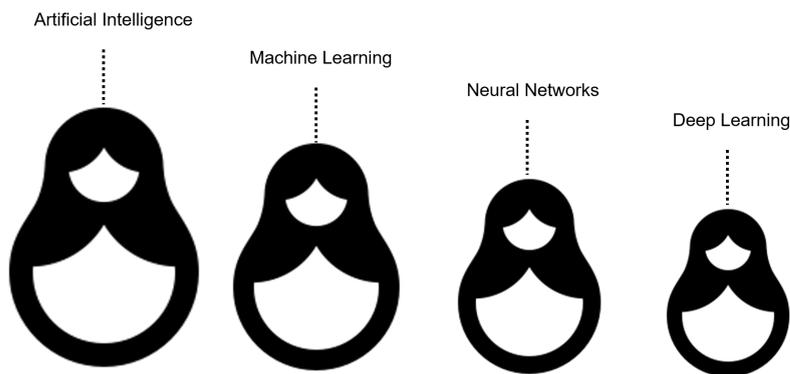


Figura 2: Representação de IA, ML, NN e DL por bonecas russas (Kavlakoglu, 2020).

O *Machine Learning* (ML) é um subcampo da inteligência artificial que permite que os computadores aprendam a partir de dados, sem que sejam explicitamente programados para fazer isto (Alpaydin, 2010).

A extração de informações a partir de imagens, utilizando a visão computacional, pode ser realizada por meio de algoritmos de aprendizado que estão dentro do campo de *Deep Learning* (Lecun; Bengio; Hinton, 2015). Um dos principais conceitos que envolvem esses algoritmos são as redes neurais artificiais (Poletaev; Pervunin; Tokarev, 2016). Entre os algoritmos de aprendizagem, um dos principais tipos é a aprendizagem supervisionada. Na aprendizagem supervisionada, o modelo recebe padrões explicitamente, ou seja, dados rotulados, para então criar uma função que irá reconhecer esses mesmos padrões em outros dados (Russel; Norvig, 2013).

Aprendizado profundo ou *Deep Learning*, é um subcampo do ML que busca a abstração de informações complexas, por meio de profundas camadas de processamento. Atualmente o *Deep Learning* é amplamente utilizado no campo da visão computacional, inclusive para detecção de objetos. A detecção de objetos obteve notoriedade nos últimos anos, devido ao grande número de possibilidades de aplicações do mundo que podem ser criadas utilizando-a (Zou *et al.*, 2019). Ela tem se mostrado

definidos os parâmetros incluindo, p.ex., o número de épocas e métricas para avaliação de desempenho.

Avaliação. Para avaliar o desempenho que o modelo possui para detectar os objetos, utilizam-se métricas. No caso de detecção de objetos, geralmente utiliza-se a que é baseada na *Intersection Over Union* (IOU), uma métrica que se baseia no Jaccard Index. Por meio desta métrica, avalia-se a sobreposição de duas *bounding boxes*, a que possui a verdadeira informação rotulada e a estimada pelo modelo treinado (Zou *et al.*, 2019). Na maioria das vezes é esperado um valor de 0.5 IOU, ou seja, 50% de acerto, para cada predição que é realizada no treinamento do modelo. Também é possível utilizar outra medida mais rigorosa comparado ao IOU de 0.5, que é o IOU de 0.75. A diferença entre os dois é que a IOU de 0.75 exige uma sobreposição ainda maior entre as *bounding boxes*, tornando-a uma medida mais restritiva, porém mais assertiva (Bochkovskiy; Wang; Liao, 2020).

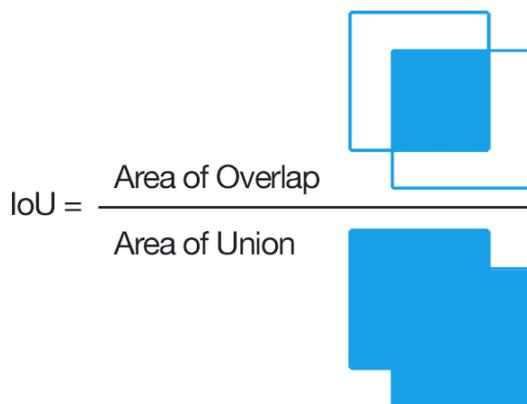


Figura 4: Esquema do IOU (Rosebrock, 2016)

Entretanto, a métrica para avaliação mais utilizada nos últimos anos é o *Average Precision* (AP) (Liu *et al.*, 2020). O AP é definido como a média da precisão da detecção em diferentes *recalls*. O *recall* na detecção de objetos refere a proporção de objetos verdadeiros que são corretamente identificados pelo modelo sobre o número total de objetos verdadeiros para uma determinada classe de interesse. Ou seja, um *recall* alto indica que o modelo está detectando os objetos de forma efetiva (Zou *et al.*, 2019). Para comparar o desempenho em todas as categorias de objetos, utiliza-se o *mean Average Precision* (mAP), que geralmente é utilizado como métrica final de desempenho (Zou *et al.*, 2019). O mAP possui uma variação que é o mAP em 0.5, que utiliza a mesma fórmula de avaliação que o mAP tradicional, porém busca avaliar a precisão da detecção de objetos em uma única taxa de IOU de 0,5 (Wang, 2019). Isso significa que apenas as detecções de objetos que possuem uma sobreposição de 50% ou mais com os objetos

de referência são consideradas corretas. O mAP50 é útil quando se deseja avaliar a precisão em um nível de sobreposição moderado. Existe também o mAP90, que considera uma taxa de IOU de 0.9. Nesse caso, apenas as detecções de objetos com uma sobreposição de 90% ou mais com os objetos de referência são consideradas corretas. O mAP90 é útil quando o objetivo é avaliar a precisão em um nível de sobreposição mais rigoroso, onde apenas as detecções muito precisas são consideradas corretas.

Predição. Na etapa de predição, são utilizadas imagens novas no modelo, para detectar os objetos nessas imagens novas.

Implantação. Por fim, o modelo pode ser exportado para ser implantado em um sistema web ou aplicativo móvel.

TIPOS DE REDES NEURAIS

Existem diversos tipos de redes neurais para resolver os problemas que estão relacionados à detecção de objetos e uma das mais populares é a *Convolutional Neural Networks* (CNN) (Padilla; Netto; Silva, 2020). A CNN foi inspirada no processo biológico de dados visuais e vem sendo amplamente utilizada no reconhecimento, detecção e classificação de imagens. Ela consiste em diferentes camadas, em que cada uma delas possui uma função diferente. Essa divisão permite reconhecer padrões por meio da convolução das imagens. A camada de convolução consiste em um conjunto de neurônios, que são responsáveis por aplicar filtros em determinadas regiões da imagem de entrada. Pode-se imaginar que cada neurônio está conectado em um grupo de *pixels* da camada anterior, e que estas conexões possuem um peso. Logo, a combinação dessas conexões que cada neurônio realizou, retornam uma saída para a camada seguinte, permitindo detectar características na imagem (Vargas; Paes; Vasconcelos, 2016).

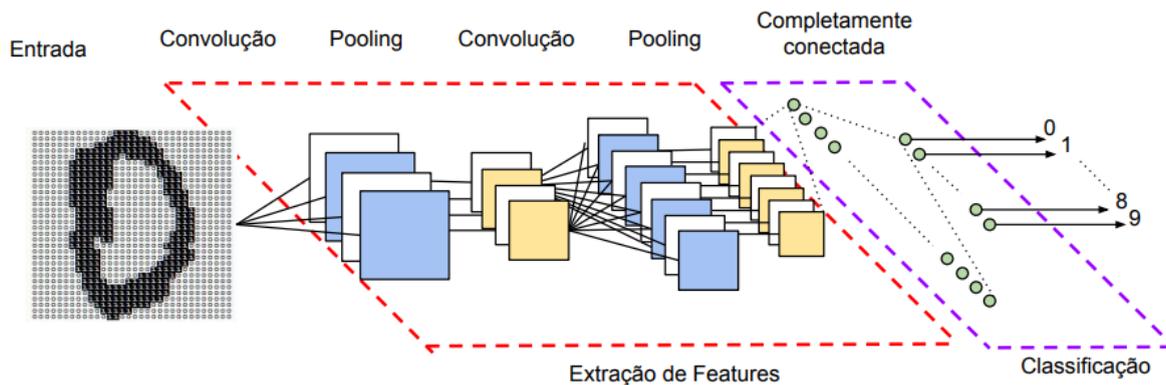


Figura 5: Rede neural convolucional e suas diferentes camadas (Vargas; Paes; Vasconcelos, 2016).

No passar do tempo, surgiram novos algoritmos para aprimorar o desempenho das CNN's e outras redes que são utilizadas na visão computacional. Um deles é o *Region Based Convolutional Neural Network (R-CNN)*, que realiza uma busca na imagem, dividindo-a em possíveis categorias independentes que serão utilizadas como possíveis categorias de detecção. Na sequência, é utilizado a rede neural convolucional para computar essas categorias e extrair as características identificadas para realizar a classificação correta (Girshick *et al.*, 2014). Entretanto, o R-CNN possui algumas desvantagens como a divisão das etapas de teste e o grande número de sub imagens que é gerado (aproximadamente 2000), acarretando em um grande tempo de espera (von Wangenheim, 2022).

Visando resolver esses problemas de lentidão e aumentar o desempenho, foram criados outros tipos de redes como o Fast R-CNN (Girshick, 2015) e o Faster R-CNN (Girshick, 2015), que buscam ser mais ágil nas etapas de treinamento e teste, consumindo menos recursos do computador e também aumentando a acurácia da detecção (Girshick, 2015).

Outro tipo de rede que é utilizada para a detecção de objetos são as redes neurais convolucionais de disparo único. Uma das mais utilizadas hoje é o YOLO (*You Only Look Once*) (Jiang *et al.*, 2022). O YOLO funciona de uma maneira diferente das redes vistas anteriormente, precisando olhar para imagem apenas uma vez. Utilizando uma imagem de entrada, ele divide-a em um *grid* de $S \times S$ células (Figura 6).

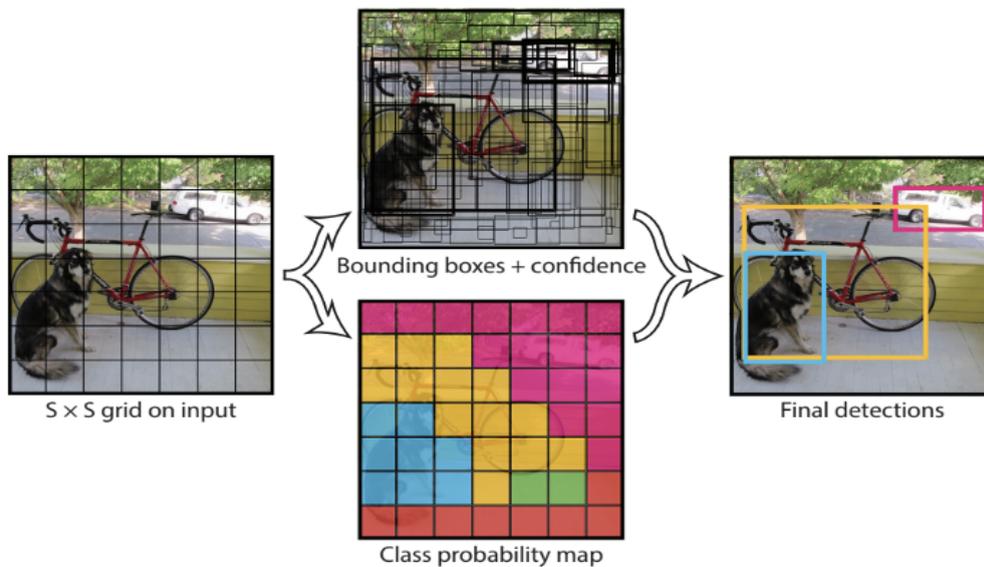


Figura 6: Processo de detecção de objetos com *grid* do YOLO (Redmon *et al.*, 2016)

A partir de cada uma dessas células do *grid*, é gerado uma predição de *bounding boxes* e probabilidades de possíveis classes. Essa predição possui 5 atributos: x , y , w , h e a confiança. Os valores de x e y representam o deslocamento do centro do *bounding box* em relação aos limites da célula do *grid*. Os valores w e h representam as dimensões do *bounding box* e a confiança representa a precisão do *bounding box* (Lan *et al.*, 2018).

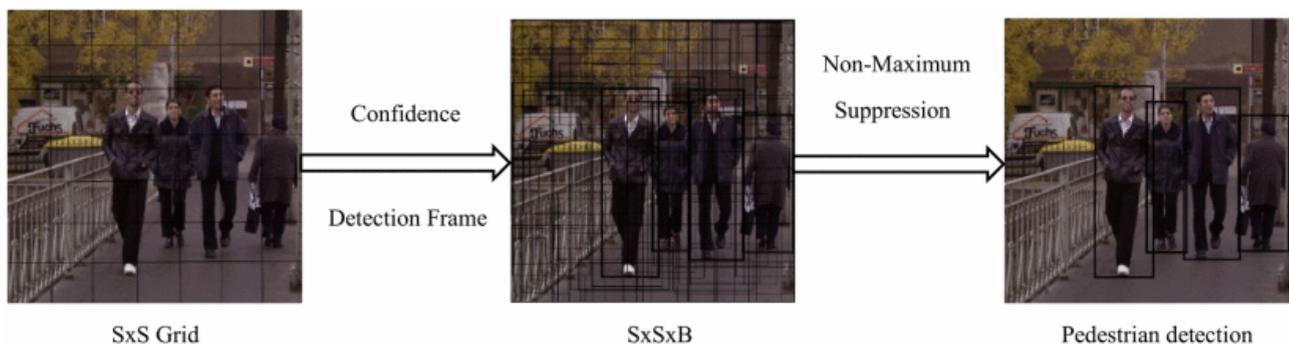


Figura 7: Processo de detecção de objetos *SxS Grid* (Lan *et al.*, 2018)

Assim como as CNN's, o YOLO também evoluiu com o passar do tempo. Com novas versões que foram lançadas, o YOLOv2, alcançou-se uma maior precisão e velocidade na detecção de objetos, e também uma melhora na detecção de objetos menores (Redmon; Farhadi, 2017). Logo após o lançamento do YOLOv2 em 2018, foi lançado o YOLOv3 que também incrementou a velocidade e precisão na detecção de objetos (Redmon; Farhadi, 2018). O YOLOv4, uma versão posterior ao YOLOv3, trouxe

melhorias de desempenho se comparado a outros detectores de objetos. Esta versão comparada à anterior, aumentou em 10% o AP (*Average Precision*) e 12% o FPS (*Frames Per Second*) (Bochkovskiy *et al.*, 2020). Esta versão possibilitou que qualquer pessoa utilizando uma GPU comum, alcançasse bons resultados na detecção de objetos.

Outra versão do YOLO que trouxe mudanças significativas é o YOLOv5 (2022). Como todas as versões citadas anteriormente tiveram aumento de velocidade e acurácia na detecção de objetos, o YOLOv5 também obteve essas mudanças. Entretanto, um grande diferencial é a utilização do PyTorch, que simplifica a exportação do modelo em formatos ONNX e CoreML, que facilita a integração com dispositivos móveis (YOLOv5, 2022). Esta nova versão do YOLO que se tornou muito popular, possui cinco diferentes tipos de modelo (Figura 8), possibilitando a criação de modelos mais simples até modelos mais complexos.

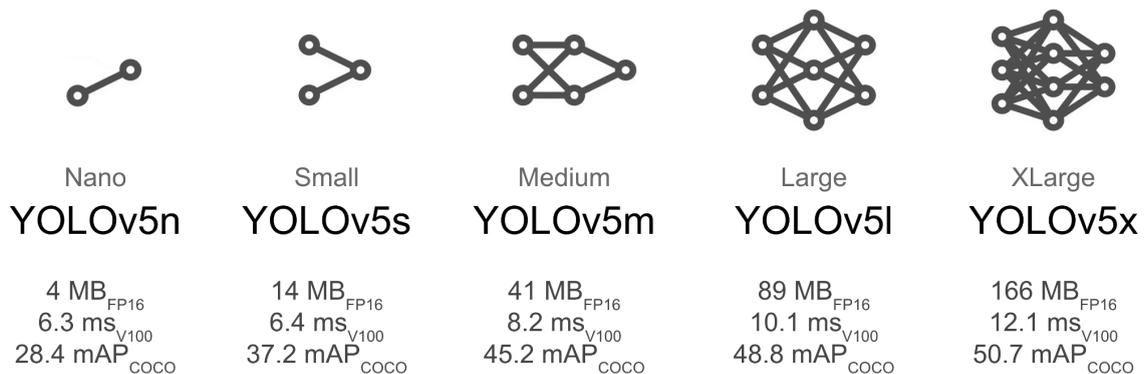


Figura 8: Diferentes modelos do YOLOv5 (Ultralytics, 2021)

Entre estes modelos, a versão que mais se adequa a dispositivos móveis é a versão YOLOv5s devido ao motivo dela ser mais leve e menor comparado às outras versões (Ultralytics, 2021). Esta versão utiliza blocos convolucionais mais leves, o que permite um processamento mais rápido e eficiente em dispositivos móveis (Wang; He, 2021).

A versão 6 do YOLO também apresentou um desempenho melhor que as versões anteriores, alcançando um nível de *Average Precision* e acurácia superior ao YOLOv5 (Li *et al.*, 2022). A versão 7 do YOLO também evoluiu no aumento de desempenho, obtendo uma maior velocidade e acurácia na detecção de objetos (Wang *et al.*, 2022).

Por fim, a versão YOLOv8 trouxe melhorias de desempenho comparado às versões anteriores do YOLO, possuindo uma maior velocidade e acurácia na detecção de objetos. Ele também possui diferentes funcionalidades no campo de *visão*

computacional, como detecção, segmentação, estimativa de pose, rastreamento e classificação (Ultralytics, 2023).

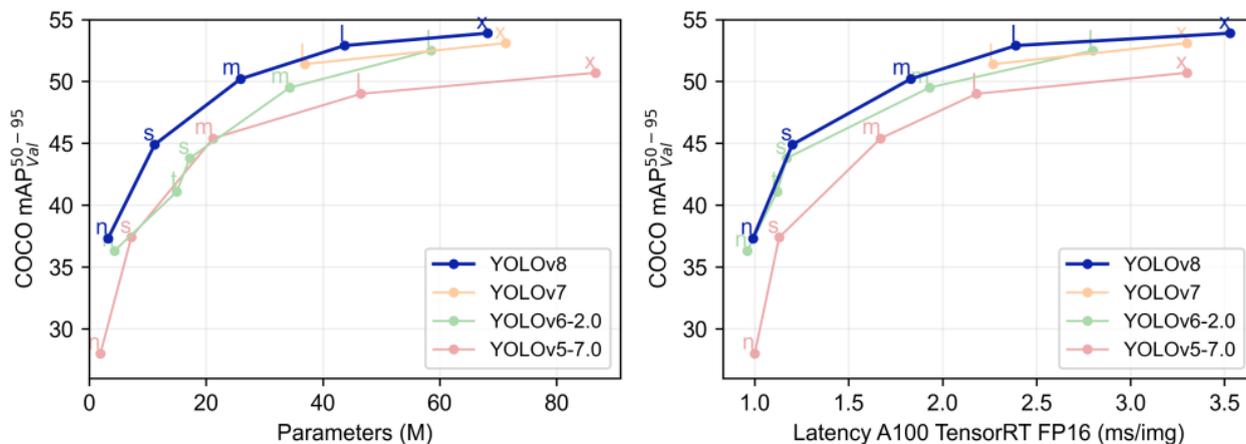


Figura 9: Comparação de desempenho entre diferentes versões do YOLO (ULTRALYTICS, 2023)

A arquitetura do YOLO é constituída de alguns elementos fundamentais como *backbone*, *head* e *neck* (Bochkovskiy *et al.*, 2020):

- O **backbone** é uma rede neural convolucional que é responsável por extrair as características da imagem e gerar uma representação intermediária. Geralmente ele é pré-treinado com um grande conjunto de dados de imagens para extrair recursos genéricos e, em seguida, é ajustado em um conjunto menor de dados para tarefas específicas.
- O **neck** é um conjunto de camadas convolucionais responsável por conectar o *backbone* ao *head*. Ele é responsável por diminuir a dimensão da representação intermediária gerada pelo *backbone*, mantendo as informações relevantes para a detecção de objetos.
- O **head** é a parte responsável por gerar as *bounding boxes* e as probabilidades de classe de cada objeto detectado. Ele é composto por camadas que são totalmente conectadas entre si, que realizam a conversão da representação intermediária gerada pelo *neck*. O *head* é a parte final da arquitetura do YOLO.

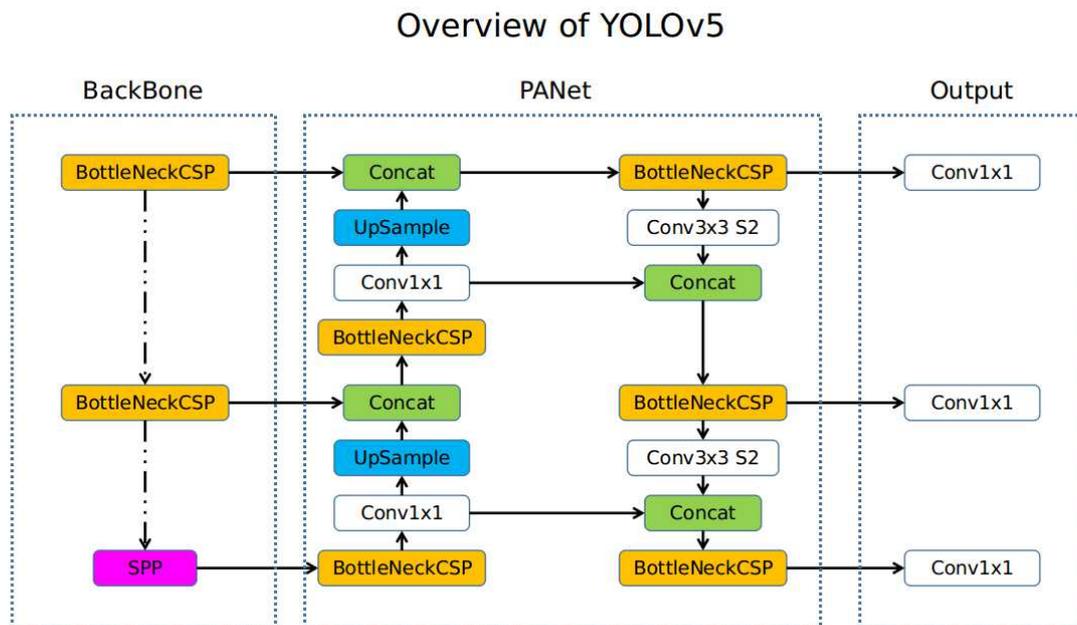


Figura 10: Arquitetura do modelo de detecção YOLOv5 (Ultralytics, 2020)

2.2 CORRENTES DE RETORNO

Correntes de retorno são fluxos de água que se formam na costa e seguem em direção ao mar, através da zona de surfe, num fluxo contrário a direção das ondas, sendo estreitas, concentradas e com tamanhos variados (Castelle *et al.*, 2016). Todos os anos, as correntes de retorno são responsáveis por centenas de acidentes de afogamento e dezenas de milhares de incidentes envolvendo banhistas em praias ao redor do mundo (Castelle *et al.*, 2016).

Essas correntes podem ocorrer em diferentes tipos de praias, sob diferentes condições de ondas e maré. Elas surgem a partir de ondas que, ao chegar à praia carregando massa e energia, retornam ao mar formando uma resposta hidrodinâmica através das áreas de zona de surfe (Dalrymple *et al.*, 2011). As correntes de retorno são compostas por duas áreas hidrodinâmicas: a zona de arrebentação, que é a região onde ocorre a quebra das ondas e a parte externa à arrebentação, conhecida como antepraia. O comportamento destas correntes de retorno muitas vezes é camuflado pela arrebentação das ondas na zona de surfe (Dalrymple *et al.*, 2011), dificultando assim sua identificação. Uma das maneiras de identificar estas correntes quando estão presentes

na zona de surfe é por meio de sua coloração. Por estarem situadas em um canal mais profundo, adotam uma cor mais escura comparada ao mar em sua volta. Elas também podem interromper a quebra das ondas (Dalrymple *et al.*, 2011). Conforme a Figura 11, as correntes de retorno compõem-se com a chegada das ondas na zona de surfe, que após sua arrebentação, geram um fluxo mais fraco e amplo comparado a corrente de retorno, mantendo as correntes alimentadoras. Como estas correntes alimentadoras são constantes, acaba-se criando um canal na região nomeada como pescoço. Por fim, esta corrente retorna a águas mais profundas e tende a se dissipar na região conhecida e representada como cabeça (Maia; Pereira; Lessa, 2014).

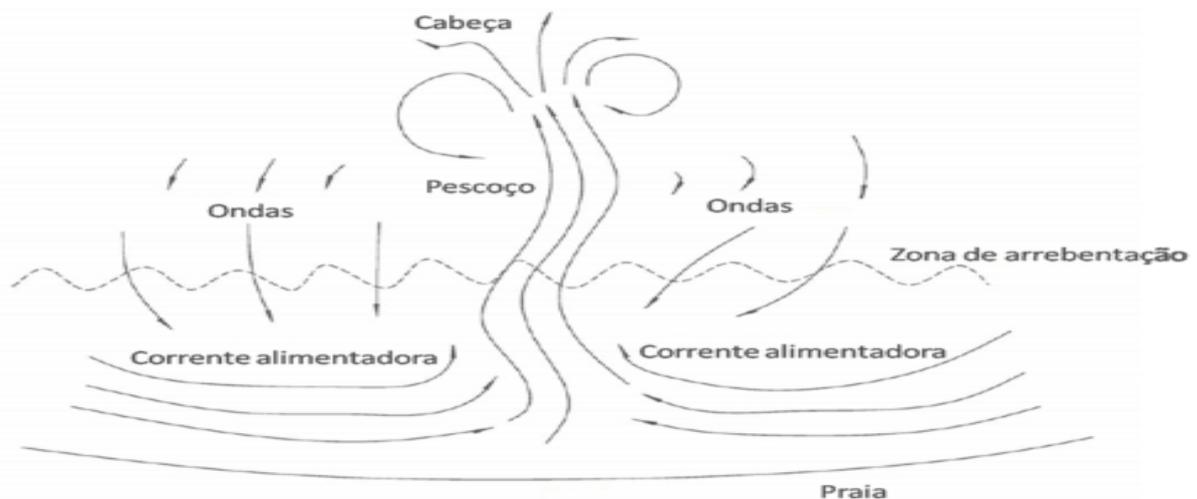


Figura 11: Representação de uma corrente de retorno (Maia; Pereira; Lessa, 2014)

As correntes de retorno podem ocorrer em diferentes tipos de praia, onde diversas características influenciam na formação delas. Segundo Castelle *et al.* (2016), as principais características são a configuração do fundo marinho costeiro e/ou presença de obstáculos (estruturas de engenharia ou rochosas, bancos de areia, entre outros) e a forma de como a energia das ondas se comporta. Conforme a classificação de Jackson (2020), existem diferentes tipos de correntes de retorno:

Correntes de retorno controladas hidrodinamicamente (Figura 12): são correntes que apresentam uma maior dificuldade para serem identificadas e conseqüentemente um maior perigo aos banhistas devido ao fato de se formarem rapidamente e aleatoriamente. Este tipo de corrente geralmente está presente em praias morfologicamente uniformes, ou que apresentam bancos de areia planos. Estudos sugerem que elas podem ser geradas como uma resposta a redemoinhos causados pela quebra das ondas na zona de surfe.

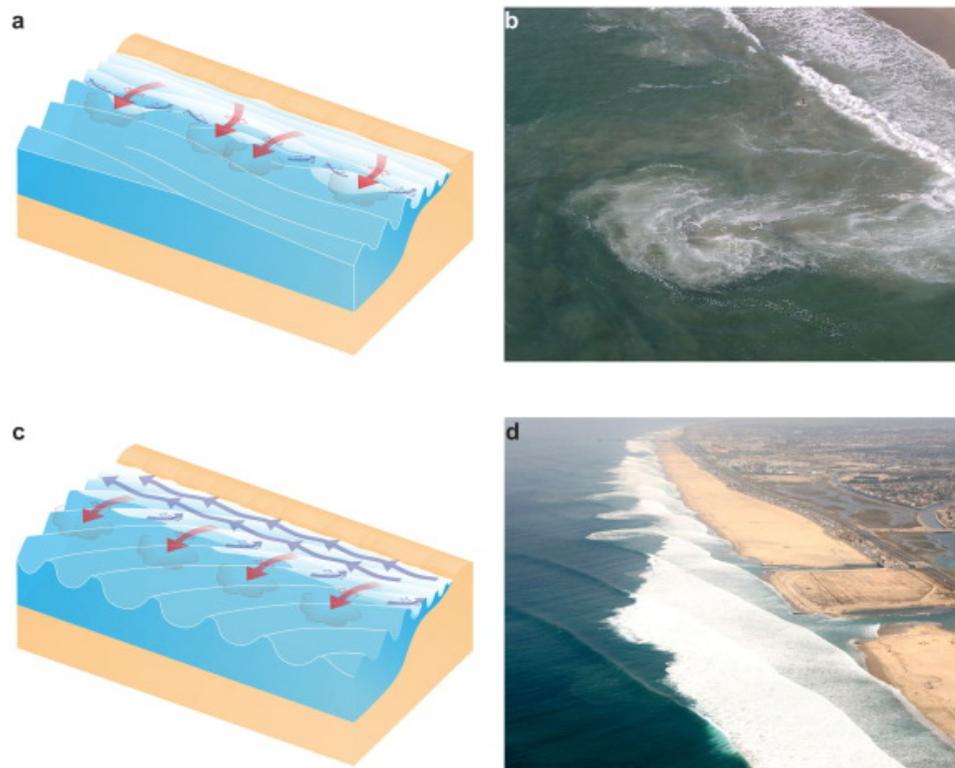


Figura 12: A e B esquema e foto das *flash rips*. C e D esquema e foto das *shear instability rips* (Castelle *et al.*, 2016).

Correntes de retorno controladas pela batimetria (Figura 13): são correntes que possuem uma maior estabilidade em relação a espaço e tempo, tendo sua localização ao longo da costa associada a características morfológicas da zona de arrebentação. Este tipo de corrente é influenciado pelas ondas que se propagam perpendicularmente em direção a costa e por padrões de quebra de onda. Por serem estacionárias, podem permanecer na mesma região por períodos como dias, semanas e até meses.



Figura 13: 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) (Castelle *et al.*, 2016).

Correntes de retorno controladas por barreiras (Figura 14): são correntes que tem suas características controladas por estruturas topográficas fixas rígidas, sendo elas antropogênicas ou naturais, como promontórios, píeres e afloramentos rochosos. Elas ocorrem em adjacência a estas estruturas e, por conta da estacionalidade das estruturas topográficas, estas também assumem a estacionalidade e ocorrem em pontos fixos.

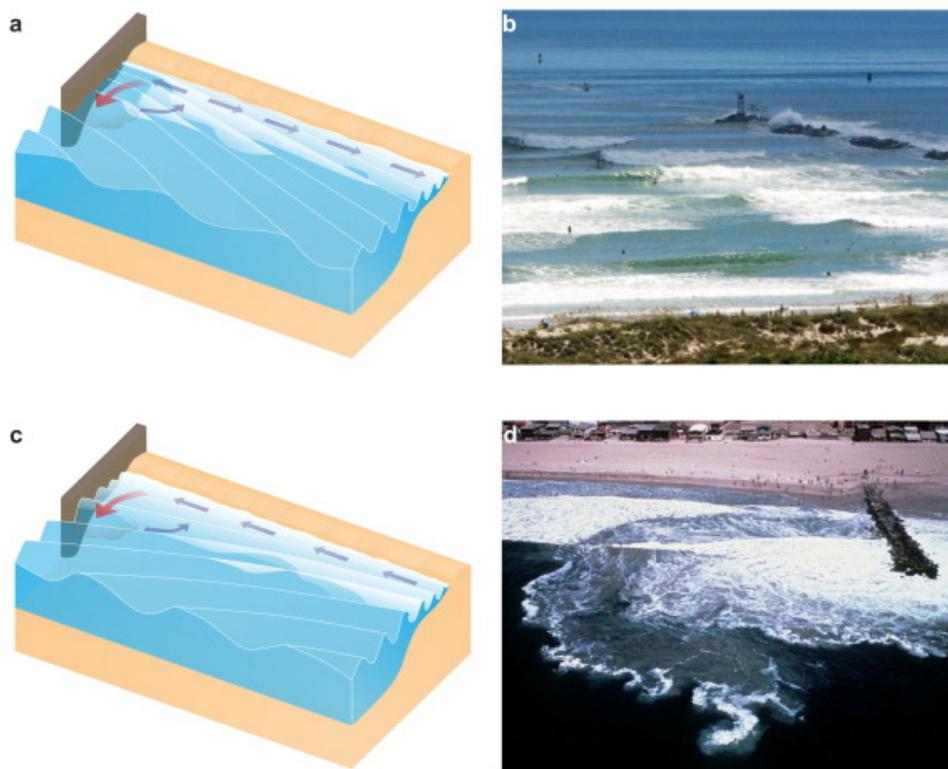


Figura 14: A e B esquema e foto de *shadow rip current*. C e D esquema e foto da *deflection rip*. (Castelle et al., 2016).

Estes tipos de correntes de retorno possuem características cabíveis de serem analisadas nas praias localizadas na cidade de Florianópolis, no estado de Santa Catarina, como a Praia do Santinho e a Praia do Moçambique.

Um dos principais problemas relacionados às correntes de retorno é a dificuldade para identificá-las. Alguns estudos mostram que mesmo pessoas que conhecem sobre as correntes de retorno e o risco que elas trazem, não conseguem visualizá-las com facilidade. Uma pesquisa realizada pela *Surf Life Saving Australia* (SLSA, 2019) mostrou que apenas 27% dos nadadores experientes australianos se consideram aptos a identificar uma corrente de retorno com acurácia.

Correntes de retorno são difíceis de identificar devido aos diferentes tipos que podem ocorrer, assumindo diferentes formas hidrodinâmicas. Por exemplo, as correntes de retorno que se formam no meio de bancos de areia geralmente assumem uma coloração mais escura e aparentam uma água mais mansa sem quebra de ondas (Castelle et al., 2016). Devido ao fato de as correntes apresentarem visualmente uma zona de mar calmo, elas acabam representando um risco para os banhistas.

A presença da comunidade em pesquisa e gestão da área costeira tem sofrido mudanças nos últimos anos, mudando os modos tradicionais de consulta como oficinas e reuniões públicas para uma participação mais efetiva no desenvolvimento de conhecimento e tomada de decisão. Tudo isso tem sido impulsionado pelo avanço da ciência cidadã, que ensina e capacita comunidades locais colocando-as nas etapas de coleta, processamento e, em alguns casos, análise de dados (Wehn *et al.*, 2021).

As iniciativas de ciência cidadã para o monitoramento costeiro tem como objetivo conscientizar as comunidades costeiras sobre as interações entre os processos marinhos (como ondas, marés e tempestades), as formas terrestres costeiras (como praias, dunas e casas) e as estruturas construídas (como portos, muralhas do mar e casas). Estas iniciativas em conjunto com essa conscientização são essenciais para as comunidades entenderem os acontecimentos recorrentes das áreas costeiras (Harley; Kinsela, 2022).

Um programa de monitoramento costeiro inovador é o CoastSnap *Community Beach Monitoring* (Coastsnap, 2023), que utiliza a tecnologia dos celulares dos cidadãos para coleta remota de imagens. Este programa utiliza a abordagem de coleta de fotos envolvendo cidadãos cientistas sem precisar de muito compromisso ou treinamento. Esta coleta de imagens é feita em pontos estratégicos do CoastSnap ao longo de regiões costeiras, onde são instalados suportes para os cidadãos posicionarem seus *smartphones*, capturam fotos da praia e compartilham em um banco de dados (Harley; Kinsela, 2022).



Figura 15: Suporte do CoastSnap para coleta de imagem em Stockton Beach, Austrália (NSW, 2021)

O projeto originalmente foi criado na universidade de *New South Wales* em Sidney na Austrália e atualmente está sendo aplicado também pelo Laboratório de Oceanografia Costeira do curso de Oceanografia da Universidade Federal de Santa Catarina (UFSC). O projeto possui suportes de monitoramento de praias do CoastSnap localizados na cidade de Florianópolis em Santa Catarina. As praias na Ilha que possuem os suportes são Praia dos Açores, Praia do Santinho, Praia do Moçambique e Praia do Morro das Pedras. A comunidade acadêmica realiza a coleta das fotos por meio da ciência cidadã, solicitando que as pessoas que frequentam estas praias postem as fotos nas redes sociais utilizando a *hashtag* CoastSnapSC (#CoastSnapSC) (UFSC, 2019).

Tabela 1: Fotos do suporte *CoastSnap* em praias de Florianópolis

| | |
|--|---|
|  |  |
| <p>Figura 16: Suporte do CoastSnap localizado na Praia do Moçambique</p> | <p>Figura 17: Suporte do CoastSnap localizado na Praia do Santinho</p> |

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.* (2015). Este mapeamento foi feito em colaboração com outro TCC (Noguerol, 2023) também focado na detecção de correntes de retorno a partir de imagens.

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 públicos nos últimos 10 anos. 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.

Cr terios de qualidade. Somente foram considerados artigos ou materiais que forneciam informa es pertinentes para a extra o de respostas  s perguntas de an lise. Artigos que cont m apenas um resumo de uma proposta, ou para os quais informa es mais detalhadas n o foram encontradas, foram exclu dos.

Fontes dos dados. Foram abrangidos materiais e artigos publicados que est o dispon veis no ACM *Digital Portal*, IEEE e Scopus, que s o importantes bibliotecas digitais acess veis por meio do Portal Capes. Al m disso, foi conduzida uma pesquisa no *Google Scholar*, devido ao fato desse mecanismo indexar um amplo conjunto de dados provenientes de diversas fontes (Piasecki; Waligora; Dranseika, 2018).

Defini o da *string* de busca. A *string* de busca foi composta de conceitos relacionados   quest o de pesquisa, incluindo sin nimos.

Tabela 2: Termos de busca utilizados no protocolo de revis o

| Termo | Sin nimo |
|-----------------|---|
| "Rip current" | - |
| "Deep Learning" | "Machine Learning", "Object detection", "Artificial Intelligence", YOLO |

A partir disso foi gerado o *string* de busca gen rico:

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

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

Tabela 3: *String* de busca para cada fonte

| Fonte | <i>String</i> 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 |
|----------------|--|

3.2 EXECUÇÃO DA BUSCA

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

Tabela 4: Número de artigos identificados por repositório e por fase de seleção

| 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 |

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; Ellis, 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?

Não foram encontradas muitas pesquisas sobre detecção de correntes de retorno usando *Deep Learning* dentro dos critérios de busca estabelecidos (Tabela 5).

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

| Referência | Título do artigo |
|---------------------------------|---|
| (de Silva <i>et al.</i> , 2021) | Automated Rip Current Detection with Region based Convolutional Neural Networks |
| (Ishikawa <i>et al.</i> , 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 <i>et al.</i> , 2022) | Interpretable Deep Learning Applied to Rip Current Detection and Localization |
| (Rashid <i>et al.</i> , 2022) | Reducing rip current drowning: An improved residual based lightweight deep architecture for rip detection |
| (Rashid <i>et al.</i> , 2021) | RipDet: A Fast and Lightweight Deep Neural Network for Rip Currents Detection |
| (Zhu <i>et al.</i> , 2022) | YOLO-Rip: A modified lightweight network for Rip currents detection |

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).



Figura 18: Quantidade de artigos relevantes ao assunto publicados nos últimos 6 anos

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.

Tabela 6: Informações sobre os dados encontrados nas pesquisas

| 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) | (1086 x 916) até (234 x 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 <i>et al.</i> , 2021) | Imagens em tons de cinza com contornos de correntes de retorno | Treinamento: 4126 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 <i>et al.</i> , 2022) | Não informado | 4.608 imagens (4.126 para treinamento e 482 para teste) | (1001 × 301) pixels | -Translação aleatória -Rotação aleatória -Escala aleatória -Cisalhamento aleatório -Espelhamento horizontal |
| (Zhu <i>et al.</i> , 2022) | Imagens aéreas | 1.740 (sendo 700 sem correntes de retorno) 23 vídeos para treinamento | (4000 × 2250) até (480 × 360) pixels. | Não informado |

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 capturadas a partir dos costões da praia, utilizando dispositivos móveis como *smartphones* e suportes do CoastSnap.

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 *et al.* (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).

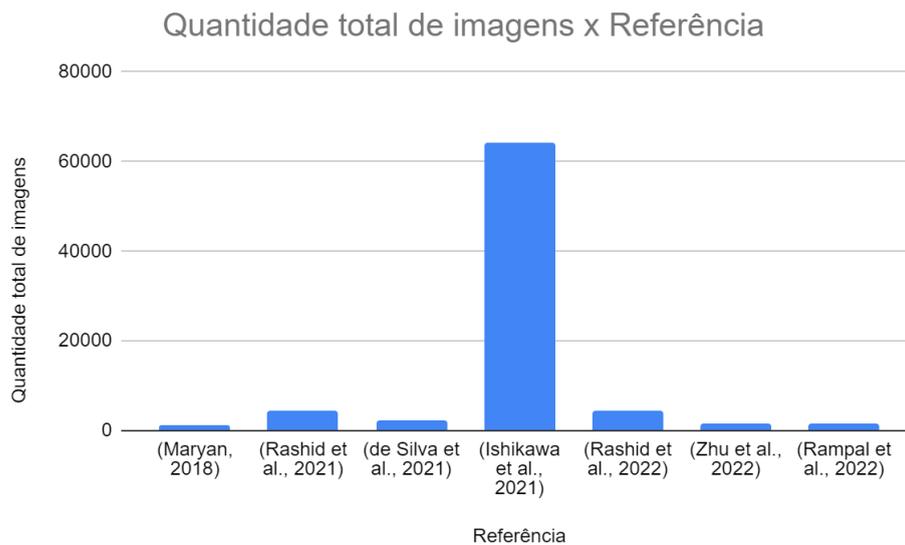


Figura 19: Quantidade de imagens no conjunto de dados por pesquisa

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

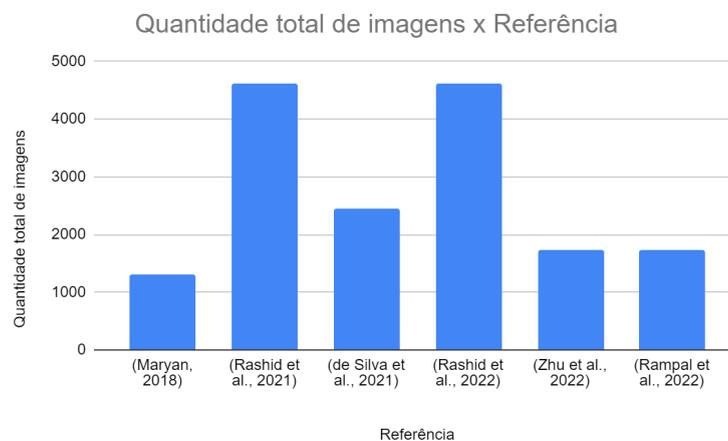


Figura 20: Quantidade de imagens no conjunto de dados por pesquisa após limpeza de *outlier*

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.

3.3.3 COMO OS MODELOS FORAM TREINADOS?

No que se refere aos detalhes sobre o treinamento dos modelos, incluindo o número de épocas utilizadas e outras métricas pertinentes, os dados estão disponíveis na Tabela 7.

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

| Referência | Modelo de DL | Parâmetros | | | |
|---------------------------------|--|----------------------|---|-----------|--|
| | | Taxa de aprendizagem | Epochs | Optimizer | IoU Threshold |
| (de Silva <i>et al.</i> , 2021) | F-RCNN, F-RCNN+Frame Aggregation | NI | 60 | NI | 0,3 |
| (Ishikawa <i>et al.</i> , 2021) | Tiny Yolo V3 | NI | NI | NI | NI |
| (Maryan, 2018) | Max Distance from Average, SVM, CNN, Viola-Jones, Meta Learner | NI | NI | NI | NI |
| (Rashid <i>et al.</i> , 2021) | RipDet (Tiny Yolo V3 modificado) | 1e-4/1e-6 | Warmup: 2 Validation:100 | Adam | - |
| (Rampal <i>et al.</i> , 2022) | Classificação 3-layer CNN com Max Pooling, Batch normalization and Dropout Regularization Mobile Net - 28-layer CNN, Residual Blocks, Max Pooling, Batch Normalization and Dropout Regularization. Localização Grad-CAM | NI | NI | NI | NI |
| (Rashid <i>et al.</i> , 2022) | RipDet (Tiny Yolo V3 modificado) | NI | • Épocas de treinamento: 100. • Épocas após as quais o modelo foi avaliado durante o treinamento: 5. | Adam | • IoU threshold during testing: 0,45. • IoU threshold during training: 0,5. |

| | | | | | |
|----------------------------|--|------|-----|----|-----|
| | | | | | |
| (Zhu <i>et al.</i> , 2022) | YOLOv5s (modificado utilizando um joint dilatation convolution no neck da arquitetura e SimAM como mecanismo de atenção) | 0,01 | 300 | NI | 0,5 |

Observando as informações sobre os treinamentos dos artigos, percebemos que a maioria 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.

3.3.4 QUAIS OS DESEMPENHOS RELATADOS?

Na Tabela 8 estão apresentados os resultados relacionados ao desempenho, incluindo métricas como mAP e acurácia.

Tabela 8: Desempenhos relatados

| Referência | mAP | Acurácia |
|---------------------------------|--------|--|
| (Rashid <i>et al.</i> , 2021) | 98,131 | NI |
| (de Silva <i>et al.</i> , 2021) | NI | F-RCNN: 0,884 F-RCNN+FA: 0,984 |
| (Ishikawa <i>et al.</i> , 2021) | NI | Tiny Yolo: 88% para correntes de retorno, 61% sem correntes de retorno |
| (Zhu <i>et al.</i> , 2022) | 92,15% | NI |
| (Rampal <i>et al.</i> , 2022) | NI | 0.89 |

| Referência | mAP | Acurácia |
|---------------------------------|--------|--|
| (Rashid <i>et al.</i> , 2021) | 98,131 | NI |
| (de Silva <i>et al.</i> , 2021) | NI | F-RCNN: 0,884 F-RCNN+FA: 0,984 |
| (Ishikawa <i>et al.</i> , 2021) | NI | Tiny Yolo: 88% para correntes de retorno, 61% sem correntes de retorno |
| (Maryan, 2018) | NI | CNN: 50% SVM: <85% |
| (Rashid <i>et al.</i> , 2022) | 98,55% | NI |

Nos trabalhos analisados foram observadas 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

Como resultado do mapeamento da literatura observa-se que existem trabalhos de pesquisa recentes que buscam realizar a detecção de correntes de retorno utilizando *Deep Learning*.

Entretanto, grande parte destas pesquisas utilizam imagens aéreas ou imagens obtidas por meio de câmeras estáticas localizadas na região da praia, o que foge do escopo do presente trabalho, que visa utilizar fotos tiradas no costão da praia para possibilitar o próprio cidadão a identificar as correntes de retorno.

Outro aspecto relevante é que não foram encontrados trabalhos relacionados à detecção de correntes de retorno utilizando *Deep Learning* com fotos tiradas com o suporte do CoastSnap e nem pesquisas no Brasil. Isso pode ser um problema tendo em vista que o Brasil possui uma costa com mais de 8 mil quilômetros de extensão e diversas praias.

A maioria dos trabalhos encontrados também não implementaram o modelo de detecção em um aplicativo móvel para contribuir com a sociedade, que é a mais afetada com os acidentes relacionados a correntes de retorno. Como atualmente a detecção dessas correntes é muito desafiadora e difícil para pessoas comuns, a implementação em um aplicativo móvel seria interessante e é um dos objetivos deste trabalho.

Nesse contexto, a análise do panorama atual revela a ausência de um modelo de detecção de correntes de retorno específico para o litoral de Santa Catarina, que possa ser facilmente utilizado por cidadãos por meio de um aplicativo móvel. Além disso, é importante que esse modelo apresente uma alta precisão para os objetivos deste projeto.

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. Mapeamentos sistemáticos podem sofrer do viés comum de que os resultados positivos têm maior probabilidade de serem publicados do que os negativos. No entanto, foi considerado que os resultados dos artigos, sejam positivos ou negativos, têm apenas uma pequena influência sobre esse mapeamento sistemático, uma vez que se busca caracterizar as unidades instrucionais, em vez de analisar seus impactos sobre a aprendizagem.

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 não apenas os principais conceitos, mas também sinônimos. Isso gera um possível problema em ocultar artigos em bases de dados que foram recortadas em 200 resultados pelo grande volume de artigos encontrados, embora a possibilidade de ocorrência de tal fato seja menor do que a de omitir resultados sem usar sinônimos. Foram também realizadas buscas em várias fontes para minimizar esses riscos.

Seleção e extração de dados de estudos. Ameaças para estudar seleção e extração de dados foram mitigadas por meio do fornecimento de uma definição detalhada dos

critérios de inclusão, exclusão e de qualidade. Foi definido e documentado um protocolo para a seleção do estudo e a execução do mapeamento foi revisada pelo colega e pela orientadora do presente trabalho.

4. DESENVOLVIMENTO DO MODELO DE DETECÇÃO DE CORRENTES DE RETORNO

Este trabalho foca no problema de que as correntes de retorno são um fenômeno hidrodinâmico comum em praia, sendo a principal razão de afogamentos em praias. A principal maneira de reduzir essas situações de afogamento é por meio da implementação de medidas preventivas por parte dos salva-vidas durante a temporada de verão, seja marcando a posição das áreas perigosas ou alertando os frequentadores da praia sobre os perigos. Entretanto, nem sempre existem salva-vidas designados para todas as praias, ou então o número deles é insuficiente para cobrir toda a extensão do litoral. Portanto, um aplicativo com inteligência artificial voltado para a detecção de correntezas perigosas auxiliaria os banhistas a reduzirem os riscos de afogamento.

Considere o seguinte caso de uso:

Um grupo jovem de amigos, vindos de uma cidade interiorana distante do litoral, decide explorar as praias de Florianópolis fora da temporada de verão. Ao dirigirem-se à praia do Santinho, notam a ausência de sinalização indicativa. Sem saber se o local seguro para nadar, recorrem a um aplicativo móvel que é capaz de detectar perigos como correntes de retorno a partir de fotos do costão da praia. Para isso, eles avançam em direção ao costão, onde acabam encontrando um suporte do CoastSnap. Este suporte auxilia eles a posicionar o celular para capturar as imagens e obter em tempo real informações precisas sobre as condições das águas.



Figura 21. Exemplo de imagem de entrada do modelo utilizando suporte do CoastSnap

Utilizando o suporte do CoastSnap, eles tiram uma foto da praia com a câmera do celular (Figura 21). Usando esta foto como entrada do modelo de *Deep Learning*, ele detecta onde há corrente de retorno nesta praia. Como resultado é apresentado a imagem com os *bounding boxes* marcando a posição dos correntes de retorno (Figura 22).



Figura 22. Exemplo de imagem classificada pelo modelo

Assim, o grupo de amigos conseguem ter uma noção onde nesta praia tem correntes de retorno e assim escolher um local para banho mais apropriado e seguro.

4.1 REQUISITOS

O presente trabalho visa desenvolver um modelo de detecção de correntes de retorno a partir de fotos do mar tiradas com a câmera do celular em suportes do CoastSnap localizados nos costões de praias de Florianópolis.

São empregadas estratégias de *Deep Learning* com o intuito de automatizar o processo de detecção, por meio da análise e comparação de diversos modelos YOLO, seguindo as melhores práticas da área, inclusive considerando as versões mais atualizadas.

Tabela 9: História de usuário

| | |
|---------------------|--|
| História de usuário | COMO banhista EU QUERO identificar locais de ocorrência de correntes de retorno PARA prevenir acidentes relacionados a afogamentos no mar. |
| Funcionalidade(s) | Detectar uma corrente de retorno a partir de uma imagem fotografada de um suporte CoastSnap. |

Tabela 10: Objetivos do modelo de *Deep Learning*

| | |
|--|--|
| Tarefa | Detectar a presença ou não de uma corrente de retorno em imagens capturadas em um aplicativo Android |
| 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 tiradas nos suportes oferecidos pelo CoastSnap |
| 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 |

4.2 PREPARAÇÃO DO CONJUNTO DE IMAGENS

Para o presente trabalho está sendo coletado um conjunto de imagens tiradas pelo autor no suporte do CoastSnap presente em praias na cidade de Florianópolis e em parceria com o projeto CoastSnap. São coletadas imagens nas praias Costa do Moçambique e Santinho. O conjunto de imagens é armazenado e disponibilizado no Roboflow (<https://universe.roboflow.com/>).

A rotulação das correntes de retornos foi realizada por um aluno do curso de Oceanografia da Universidade Federal de Santa Catarina (UFSC) que também é salva-vidas civil e revisado por professor do curso de Oceanografia da Universidade Federal de Santa Catarina (UFSC).

Tabela 11: Preparação do conjunto de imagens

| Conjunto de imagens | | | | |
|-----------------------|-------|--------------|--------------|---|
| Praia | Total | Com corrente | Sem corrente | Link do conjunto de imagens |
| Santinho | 1.003 | 857 | 146 | https://app.roboflow.com/cne-ufsc/rip-current---coastsnap---praia-santinho/deploy/24 |
| Moçambique | 133 | 128 | 5 | https://app.roboflow.com/cne-ufsc/rip-current---coastsnap---praia-mocambique/deploy/52 |
| Moçambique + Santinho | 1.136 | 985 | 151 | https://app.roboflow.com/cne-ufsc/rip-current-coastsnap-mocambique-santinho/deploy/3 |

Os conjuntos de imagens estão disponíveis no Roboflow conforme indicado na Tabela 11. As imagens presentes na Figura 23 apresentam alguns exemplos de imagens do conjunto.

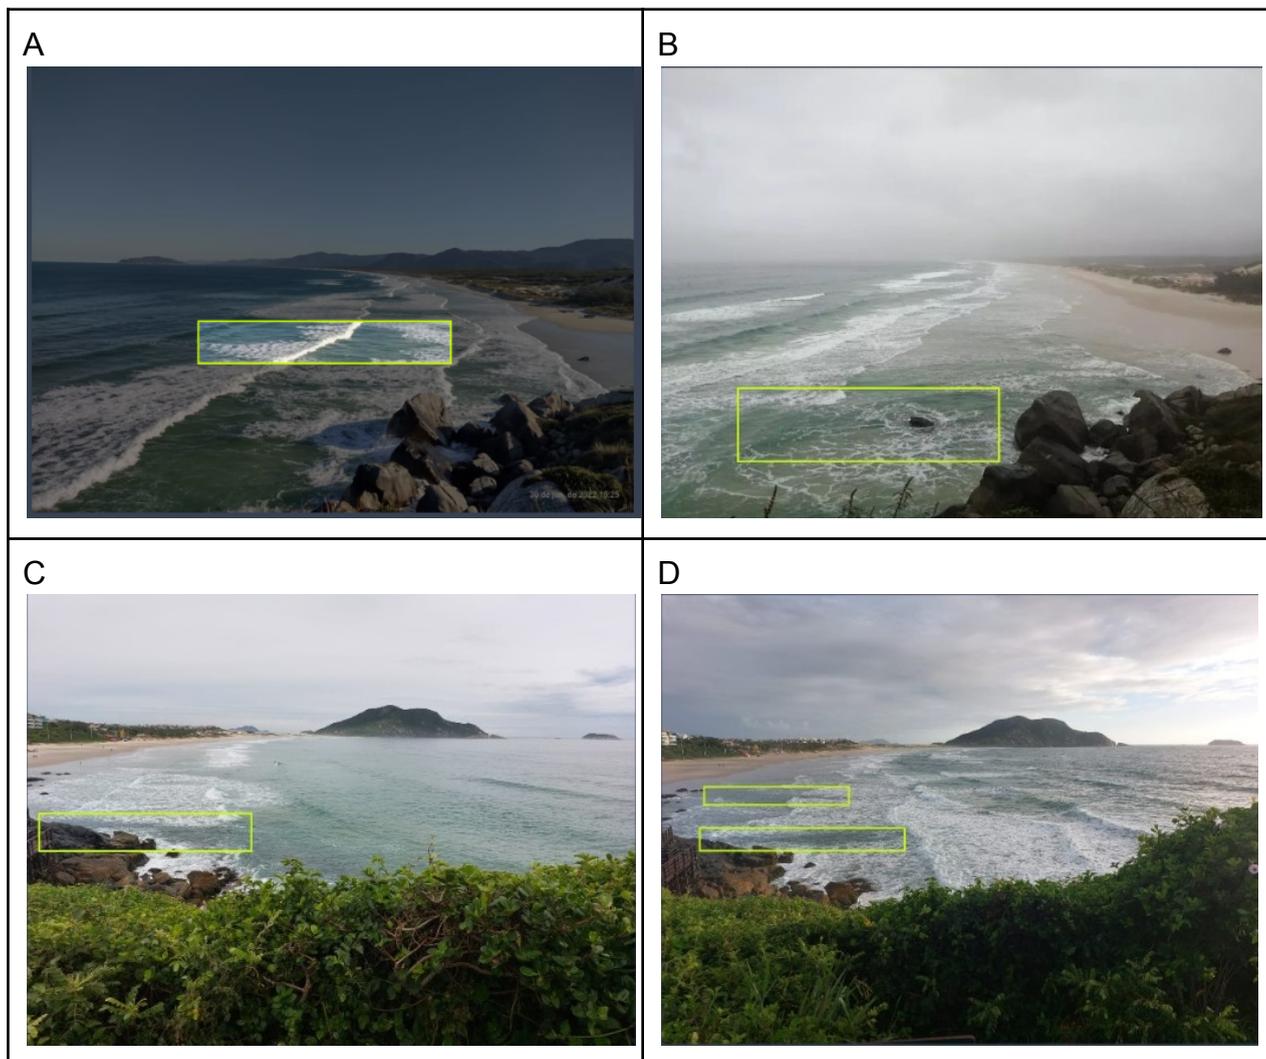


Figura 23: Exemplos de imagens do conjunto. As imagens A, B foram fotografadas na praia do Moçambique. A imagem C e D, fotografadas na praia do Santinho. Todas contém correntes de retorno indicadas por *bounding boxes*

Com o objetivo de aumentar e diversificar o conjunto de dados, são utilizadas técnicas de *data augmentation* no Roboflow. Isso inclui técnicas que serão aplicadas estão relacionadas ao posicionamento das imagens, como rotação e deformação (alteração da perspectiva). Além disso, serão aplicadas técnicas que afetam o aspecto visual das imagens, como alteração de tom, saturação, brilho, desfoque e adição de ruído.

Tabela 12: Técnicas de *data augmentation*

| Técnica | Exemplo |
|--------------------------------|--|
| Rotação de 15 graus - 15 graus |  |
| Shear 15 graus |  |
| Matiz 25 graus |  |
| Saturação 25% |  |

Brilho 25%



-25%



25%

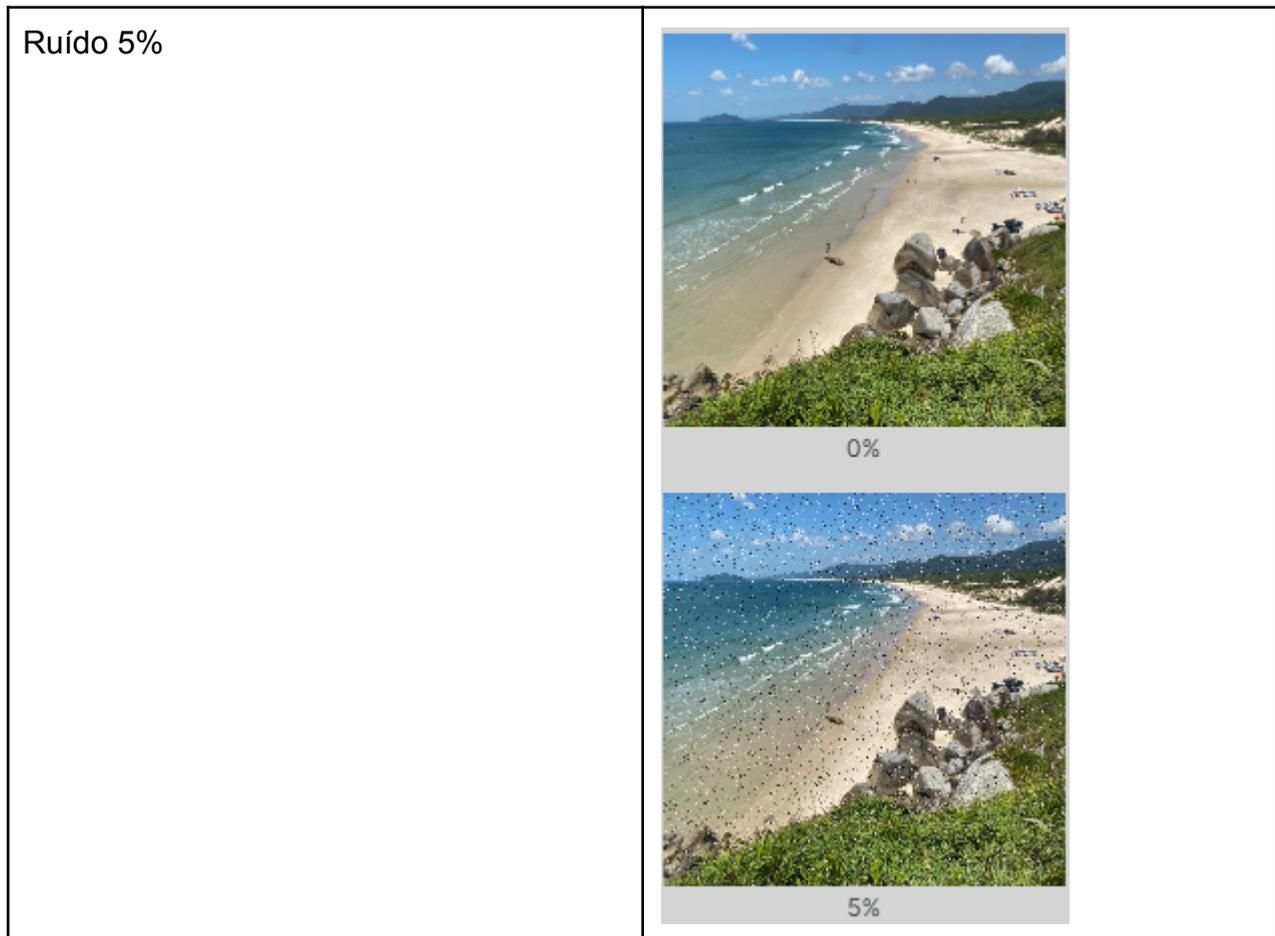
Blur 1.25px



0px



1.25px



Para o presente trabalho, visa-se realizar a divisão do conjunto de imagens da seguinte maneira:

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

4.3 TREINAMENTO

Na etapa de treinamento, são utilizados os modelos de YOLOv5n, YOLOv5s e YOLOv8s. Essas redes neurais foram selecionadas por serem atualmente entre os mais avançados entre os modelos YOLO indicados para esse tipo de pesquisa, o que permite obter um desempenho aprimorado. As versões de cada YOLO foram escolhidas levando em consideração a intenção da implantação dos modelos treinados em um aplicativo

móvel, e conseqüentemente focando em modelos menores. Cada um dos modelos foi criado e aprimorado usando o software *Jupyter Notebook* executado no Google Colab.

Para o desenvolvimento do modelo foram realizados vários experimentos com cada um dos modelos selecionados usando diferentes conjuntos de imagens, incluindo imagens da praia do Moçambique, da praia do Santinho e a união dos dois conjuntos. Nos experimentos foram também testadas várias combinações de parâmetros de treinamento, como o tamanho do lote, tamanho da imagem e quantidade de épocas. Também foi utilizado o parâmetro “*early stopping*” como valores 50 e 100, que finaliza o treinamento caso não melhore o desempenho em 50 e 100 épocas, evitando tempo de processamento.

Nas próximas seções são apresentados os experimentos para cada modelo que apresentaram os melhores resultados de desempenho durante o treinamento/validação. Para analisar o desempenho foi avaliado os valores de mAP50, precisão, *recall* e métricas relacionadas ao *loss* durante as épocas para verificar a ocorrência de *overfitting*.

4.3.1 TREINAMENTO COM O CONJUNTO DE IMAGENS DA PRAIA DO MOÇAMBIQUE

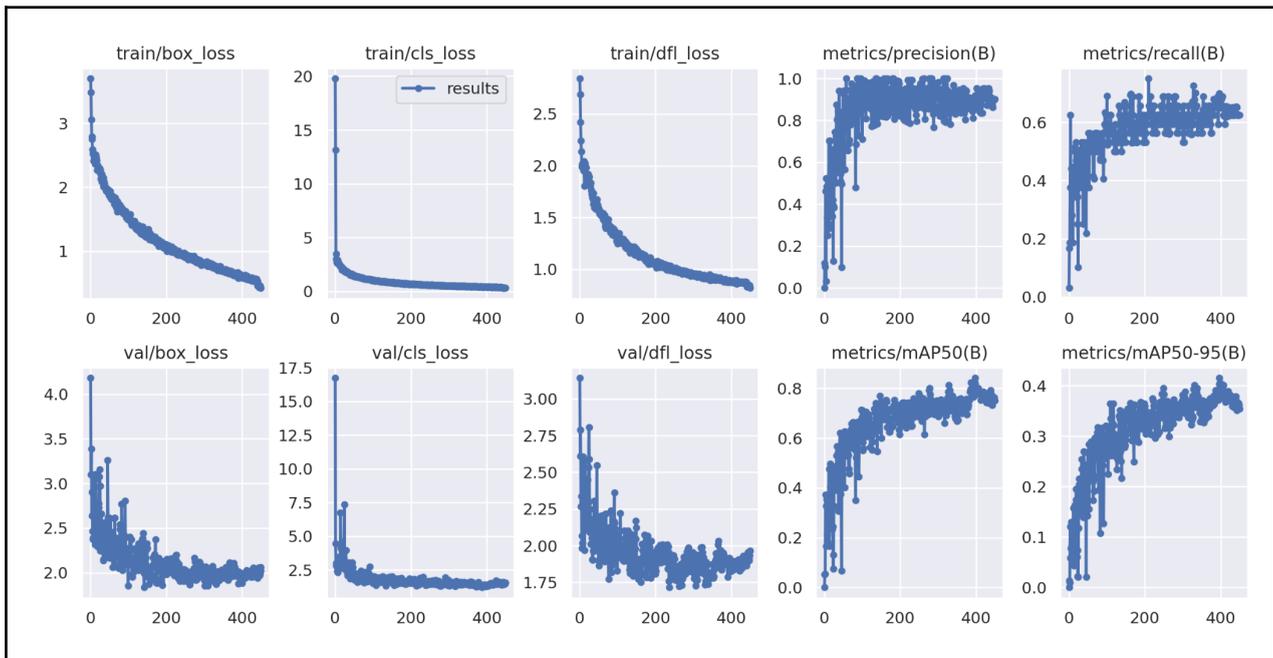
4.3.1.1 TREINAMENTO COM YOLOv5n

| Conjunto de dados | |
|--------------------------------|---|
| Praia do Moçambique | Total de 133 imagens (128 com correntes de retorno / 5 sem correntes de retorno) |
| Treinamento | |
| Modelo | YOLOv5n |
| Quantidade de épocas | 300 |
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| mAP50 | 66% |
| Precisão | 97% |

| | |
|----------------------------------|--|
| <i>Recall</i> | 53% |
| <i>F1-score</i> | 72% |
| Resultados do treinamento | |
| | |
| Interpretação | O treinamento atual apresenta resultados inferiores aos valores de trabalhos relacionados e, especialmente, em relação ao mAP50 necessário para que o modelo seja considerado aceitável. |

4.3.1.2 TREINAMENTO COM YOLOv8s

| | |
|--------------------------------|---|
| Conjunto de dados | |
| Praia do Moçambique | Total de 133 imagens (128 com correntes de retorno / 5 sem correntes de retorno) |
| Treinamento | |
| Modelo | YOLOv8s |
| Quantidade de Épocas | 450 |
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| mAP50 | 84% |
| Precisão | 91% |
| <i>Recall</i> | 69% |
| <i>F1-score</i> | 79% |
| Resultados do treinamento | |



Interpretação

Observa-se que o treinamento atual apresenta resultados superiores aos valores obtidos no treinamento anterior utilizando o YOLOv5, mostrando uma maior eficácia do YOLOv8 na etapa de treinamento em comparação ao YOLOv5. Também atingiu uma maior proximidade com o desempenho esperado. Ao comparar as métricas de *loss* como *box_loss*, *cls_loss* e *df_l_loss* entre treinamento e validação, percebe-se um leve aumento, indicando um possível *overfitting*.

4.3.2 TREINAMENTO COM O CONJUNTO DE IMAGENS DA PRAIA DO SANTINHO

4.3.2.1 TREINAMENTO COM YOLOv5s

| Conjunto de dados | |
|--|---|
| Praia do Santinho | Total de 1.003 imagens (857 com correntes de retorno / 146 sem correntes de retorno) |
| Treinamento | |
| Modelo | YOLOv5s |
| Quantidade de épocas | 450 |
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| <i>mAP50</i> | 69% |
| Precisão | 77% |
| <i>Recall</i> | 63% |
| F1-score | 69% |
| Resultados do treinamento | |
| <p>The figure displays ten plots arranged in two rows and five columns, showing training and validation results over 200 epochs. The top row shows training metrics: train/box_loss (decreasing from ~0.09 to ~0.03), train/obj_loss (decreasing from ~0.03 to ~0.01), train/cls_loss (constant at 0.00), metrics/precision (increasing from ~0.4 to ~0.75), and metrics/recall (increasing from ~0.1 to ~0.6). The bottom row shows validation metrics: val/box_loss (decreasing from ~0.11 to ~0.05), val/obj_loss (decreasing from ~0.016 to ~0.008), val/cls_loss (constant at 0.00), metrics/mAP_0.5 (increasing from ~0.3 to ~0.65), and metrics/mAP_0.5:0.95 (increasing from ~0.05 to ~0.25). Each plot includes a blue line for 'results' and an orange dashed line for 'smooth'.</p> | |
| Interpretação | O treinamento atual apresenta resultados inferiores aos valores de trabalhos relacionados e, especialmente, em relação ao mAP50 necessário para que o modelo seja considerado aceitável. Ao comparar o box_loss e obj_loss de treinamento e validação, percebe-se o aumento na etapa de validação que indica o <i>overfitting</i> . |

4.3.2.2 TREINAMENTO COM YOLOv8s

| Conjunto de dados | |
|---------------------------|---|
| Praia do Santinho | Total de 1.003 imagens (857 com correntes de retorno / 146 sem correntes de retorno) |
| Treinamento | |
| Modelo | YOLOv8s |
| Quantidade de épocas | 450 |
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| <i>mAP50</i> | 71% |
| Precisão | 74% |
| <i>Recall</i> | 65% |
| F1-score | 69% |
| Resultados do treinamento | |
| | |
| Interpretação | O treinamento atual apresenta resultados superiores aos valores do treinamento utilizando o modelo YOLOv5. Entretanto, o mAP50 está abaixo do necessário para que o modelo seja aceito. |

4.3.3 TREINAMENTO COM O CONJUNTO DE IMAGENS DA PRAIA DO MOÇAMBIQUE + PRAIA DO SANTINHO

4.3.3.1 TREINAMENTO COM YOLOv5s

| Conjunto de dados | |
|---|---|
| Praia do Moçambique + Praia do Santinho | Total de 1.136 imagens (985 com correntes de retorno / 151 sem correntes de retorno) |
| Treinamento | |
| Modelo | YOLOv5s |
| Quantidade de épocas | 450 |
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| <i>mAP50</i> | 70% |
| Precisão | 73% |
| <i>Recall</i> | 63% |
| F1-score | 67% |
| Resultados do treinamento | |
| | |
| Interpretação | O treinamento atual apresenta resultados inferiores aos valores de trabalhos relacionados e, especialmente, em relação ao mAP50 necessário para que o modelo seja considerado aceitável. Mesmo que o conjunto de imagens tenha aumentado, o modelo não obteve um desempenho superior. Houve um aumento também do obj_loss na etapa de validação, indicando <i>overfitting</i> . |

4.3.3.2 TREINAMENTO COM YOLOv8s

| Conjunto de dados | |
|---|--|
| Praia do Moçambique + Praia do Santinho | Total de 1.136 imagens (985 com correntes de retorno / 151 sem correntes de retorno) |
| Treinamento | |
| Modelo | YOLOv8s |
| Quantidade de épocas | 450 |
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| <i>mAP50</i> | 69% |
| Precisão | 78% |
| <i>Recall</i> | 63% |
| F1-score | 69% |
| Resultados do treinamento | |
| | |
| Interpretação | <p>O treinamento atual apresenta resultados inferiores aos valores de trabalhos relacionados e, especialmente, em relação ao <i>mAP50</i> necessário para que o modelo seja considerado aceitável. Mesmo que o conjunto de imagens tenha aumentado, o modelo não obteve um desempenho superior. Ao comparar as métricas de loss como <i>box_loss</i>, <i>cls_loss</i> e <i>dfl_loss</i> entre as etapas de treinamento e validação, percebe-se um crescimento que representa <i>overfitting</i> do modelo.</p> |

4.4 TESTE DE DESEMPENHO

De acordo com as diretrizes estabelecidas na norma ISO/IEC 4213 (2022), foram realizados testes utilizando os modelos previamente treinados, com o objetivo de detectar correntes de retorno em imagens que não foram incluídas no estágio de treinamento ou validação.

4.4.1 TESTE DE DESEMPENHO COM O CONJUNTO DE IMAGENS DA PRAIA DO MOÇAMBIQUE

4.4.1.1 PREPARAÇÃO DO TESTE

O conjunto de teste é composto por um total de 14 imagens, com as características de qualidade de dados conforme descrito na Tabela 13.

Tabela 13: Características do conjunto de dados de teste da praia do Moçambique

| Característica | Especificação |
|---|--|
| Número total de imagens no conjunto de testes | 14 imagens |
| Distribuição do conjunto de testes | Total de 14 imagens (14 com correntes de retorno / 0 sem correntes de retorno) |
| Uso das imagens | Essas imagens não foram usadas durante o treinamento do modelo. As imagens foram coletadas pelo projeto CoastSnapSC em conjunto com o autor do presente trabalho. |
| Fonte | Essas imagens não foram usadas durante o treinamento do modelo. As imagens foram coletadas pelo projeto <i>CoastSnapSC</i> em conjunto com o autor do presente trabalho. |
| 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/ aumento de dados | Auto-orientação e redimensionamento para 640x640 |
| 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 do Moçambique na cidade de Florianópolis/SC |
| | As imagens correspondem às imagens a serem coletadas pelo público-alvo conforme definido no caso de uso. |
| Robustez do conjunto de testes | As imagens foram coletadas a partir do suporte do CoastSnap, sem variar muito o plano de fundo, ângulos, iluminação, etc. |
| Confidencialidade do conjunto de teste | Não aplicável |

Métricas. Para avaliar o desempenho dos modelos, foram utilizadas as seguintes métricas:

- mAP50 para avaliar o desempenho geral;
- Precisão e *recall* para apoiar a compreensão de como o modelo lida com falsos

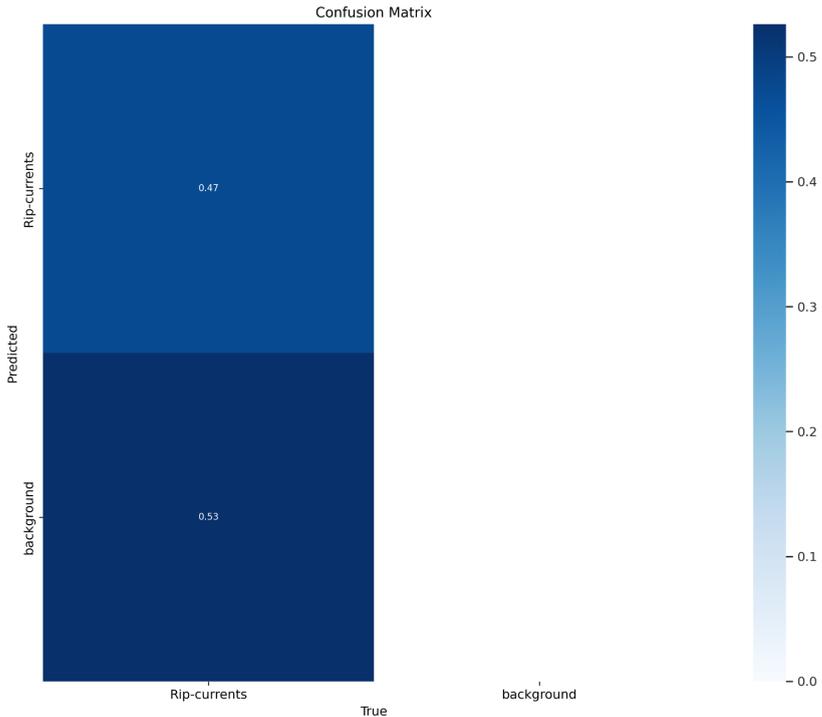
positivos e falsos negativos;

- Pontuação F1 que é a média harmônica entre a precisão e o *recall*.

Ambiente de execução. O teste foi executado usando Jupyter Notebooks no Google Colab.

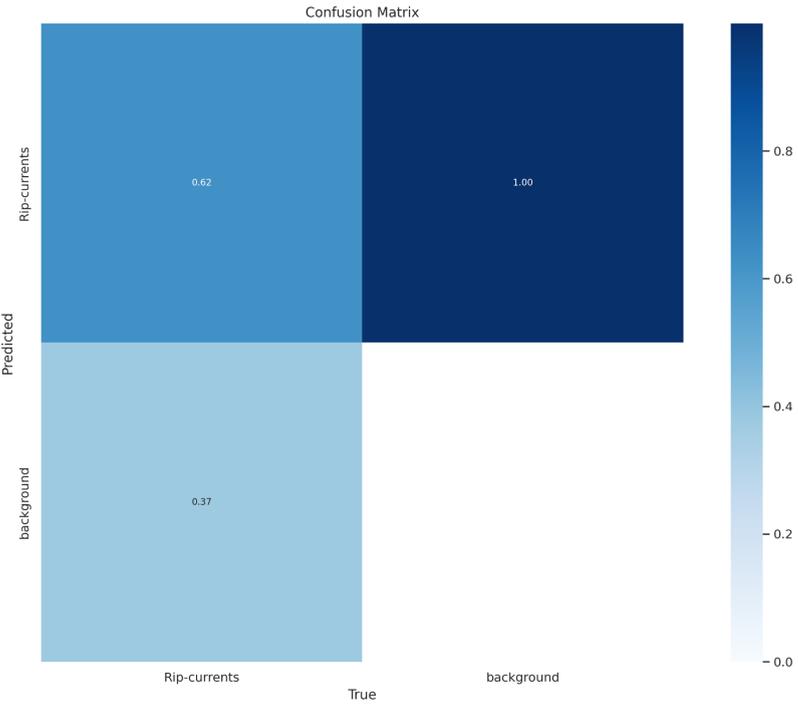
4.4.1.2 RESULTADO DO TESTE COM YOLOv5n

| | |
|--------------------------------|-----|
| Testes | |
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| <i>mAP50</i> | 70% |
| <i>Precision</i> | 90% |
| <i>Recall</i> | 47% |
| F1-score | 62% |

| 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>0.47</td> <td></td> </tr> <tr> <th>background</th> <td></td> <td>0.53</td> </tr> </tbody> </table> | Predicted \ True | Rip-currents | background | Rip-currents | 0.47 | | background | | 0.53 |
|--------------------|---|------------------|--------------|------------|--------------|------|--|------------|--|------|
| Predicted \ True | Rip-currents | background | | | | | | | | |
| Rip-currents | 0.47 | | | | | | | | | |
| background | | 0.53 | | | | | | | | |
| Interpretação | <p>Nota-se que o treinamento atual apresenta resultados melhores que os relatados no treinamento deste modelo, com um de aumento 4% do <i>mAP</i>. O valor ainda é inferior aos valores mencionados na revisão do estado da arte e para a meta estabelecida no presente trabalho.</p> | | | | | | | | | |

4.4.1.3 RESULTADO DO TESTE COM YOLOv8s

| Testes | |
|--------------------------------|-----|
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| mAP50 | 62% |
| <i>Precision</i> | 78% |
| <i>Recall</i> | 57% |
| F1-score | 64% |

| <p>Matriz de confusão</p> |  <p>Confusion Matrix</p> <table border="1" data-bbox="630 179 1428 884"> <thead> <tr> <th>Predicted \ True</th> <th>Rip-currents</th> <th>background</th> </tr> </thead> <tbody> <tr> <th>Rip-currents</th> <td>0.62</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.37</td> <td>0.00</td> </tr> </tbody> </table> | Predicted \ True | Rip-currents | background | Rip-currents | 0.62 | 1.00 | background | 0.37 | 0.00 |
|---------------------------|--|------------------|--------------|------------|--------------|------|------|------------|------|------|
| Predicted \ True | Rip-currents | background | | | | | | | | |
| Rip-currents | 0.62 | 1.00 | | | | | | | | |
| background | 0.37 | 0.00 | | | | | | | | |
| <p>Interpretação</p> | <p>Observa-se que o teste diminuiu muito o desempenho do modelo se comparado ao desempenho do treinamento/validação. Isso mostra uma dificuldade em detectar correntes de retorno em imagens nunca vistas pelo modelo. Uma das razões pode ter sido o tamanho relativamente pequeno deste conjunto de imagens, impedindo que o modelo de fato aprende generalizar a detecção de correntes de retorno.</p> | | | | | | | | | |

4.4.2 TESTE DE DESEMPENHO COM O CONJUNTO DE IMAGENS DA PRAIA DO SANTINHO

4.4.2.1 PREPARAÇÃO DO TESTE

O conjunto de teste é composto por um total de 102 imagens, com as características de qualidade de dados conforme descrito na Tabela 14.

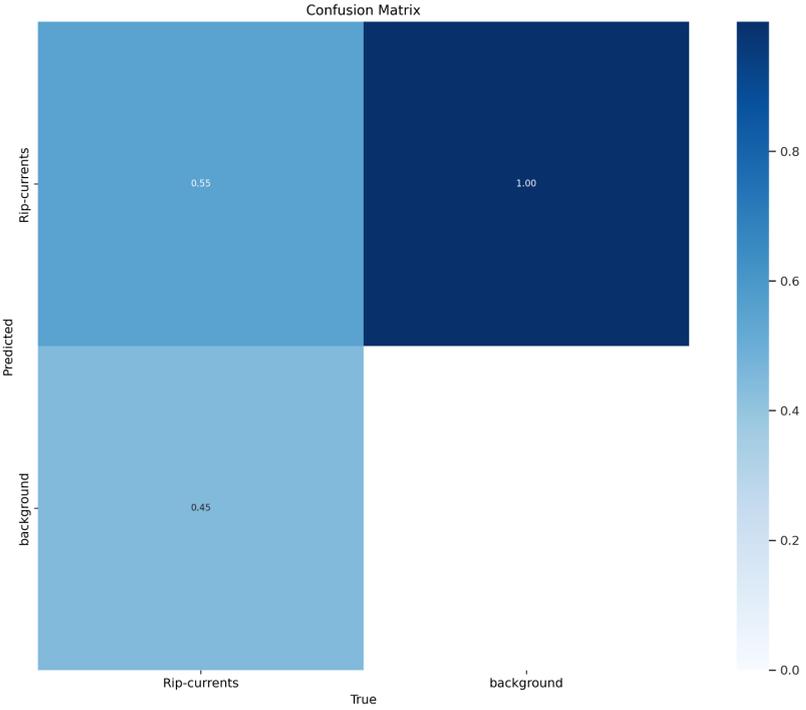
Tabela 14: Características do conjunto de dados de teste da praia do Santinho

| Característica | Especificação |
|--|---|
| Número total de imagens no conjunto de testes | 102 imagens |
| Distribuição do conjunto de testes | Total de 102 imagens (84 com correntes de retorno / 18 sem correntes de retorno) |
| Uso das imagens | Essas imagens não foram usadas durante o treinamento do modelo. As imagens foram coletadas pelo projeto CoastSnapSC em conjunto com o autor do presente trabalho. |
| Fonte | Essas imagens não foram usadas durante o treinamento do |

| | |
|---|---|
| | modelo. As imagens foram coletadas pelo projeto CoastSnapSC em conjunto com o autor do presente trabalho. |
| 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/ aumento de dados | Auto-orientação e redimensionamento para 640x640 |
| 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. |
| Robustez do conjunto de testes | As imagens foram coletadas a partir do suporte do CoastSnap, sem variar muito o plano de fundo, ângulos, iluminação, etc. |
| Confidencialidade do conjunto de teste | Não se aplica |

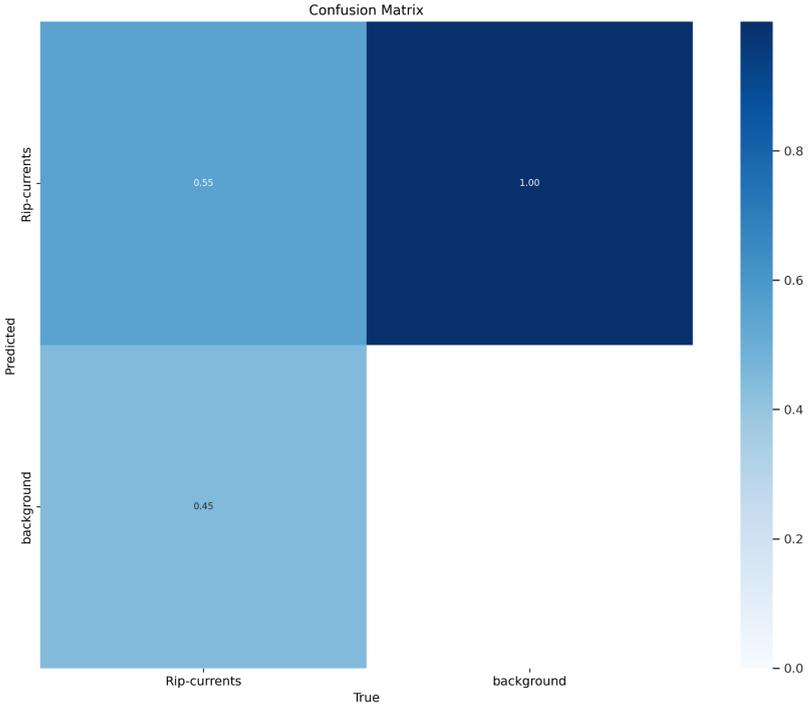
4.4.2.2 RESULTADO DO TESTE COM YOLOv5s

| | |
|--------------------------------|-----|
| Testes | |
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| <i>mAP50</i> | 59% |
| Precisão | 71% |
| <i>Recall</i> | 50% |
| F1-score | 59% |

| 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>0.55</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.45</td> <td>0.00</td> </tr> </tbody> </table> | Predicted \ True | Rip-currents | background | Rip-currents | 0.55 | 1.00 | background | 0.45 | 0.00 |
|--------------------|---|------------------|--------------|------------|--------------|------|------|------------|------|------|
| Predicted \ True | Rip-currents | background | | | | | | | | |
| Rip-currents | 0.55 | 1.00 | | | | | | | | |
| background | 0.45 | 0.00 | | | | | | | | |
| Interpretação | <p>Nota-se que o treinamento atual apresenta resultados inferiores ao comparar com os resultados do 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> | | | | | | | | | |

4.4.2.3 RESULTADO DO TESTE COM YOLOv8s

| Testes | |
|--------------------------------|-----|
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| <i>mAP50</i> | 61% |
| <i>Precision</i> | 67% |
| <i>Recall</i> | 56% |
| <i>F1-score</i> | 59% |

| 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>0.55</td> <td>0.45</td> </tr> <tr> <th>background</th> <td>1.00</td> <td>0.00</td> </tr> </tbody> </table> | Predicted \ True | Rip-currents | background | Rip-currents | 0.55 | 0.45 | background | 1.00 | 0.00 |
|--------------------|---|------------------|--------------|------------|--------------|------|------|------------|------|------|
| Predicted \ True | Rip-currents | background | | | | | | | | |
| Rip-currents | 0.55 | 0.45 | | | | | | | | |
| background | 1.00 | 0.00 | | | | | | | | |
| Interpretação | <p>Nota-se que o treinamento atual apresenta resultados inferiores ao comparar com os resultados do 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> | | | | | | | | | |

4.4.3 TESTE DE DESEMPENHO COM O CONJUNTO DE IMAGENS DA PRAIA DO MOÇAMBIQUE + PRAIA DO SANTINHO

4.4.3.1 PREPARAÇÃO DO TESTE

O conjunto de teste é composto por um total de 116 imagens, com as características de qualidade de dados conforme descrito na Tabela 15.

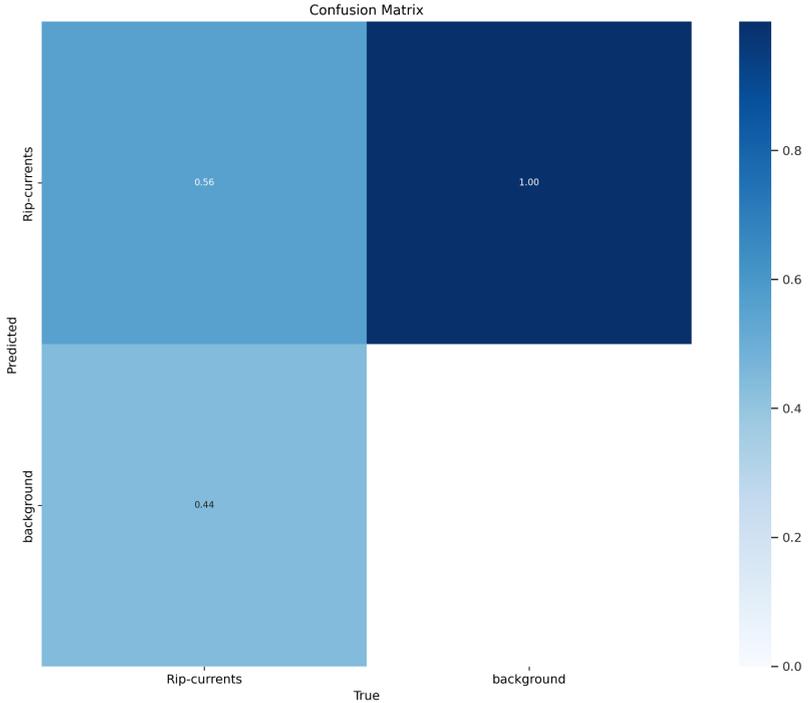
Tabela 15: Características do conjunto de dados de teste da praia do Moçambique + praia do Santinho

| Característica | Especificação |
|--|---|
| Número total de imagens no conjunto de testes | 116 imagens |
| Distribuição do conjunto de testes | Total de 116 imagens (98 com correntes de retorno / 18 sem correntes de retorno) |
| Uso das imagens | Essas imagens não foram usadas durante o treinamento do modelo. As imagens foram coletadas pelo projeto CoastSnapSC |

| | |
|---|---|
| | em conjunto com o autor do presente trabalho. |
| Fonte | Essas imagens não foram usadas durante o treinamento do modelo. As imagens foram coletadas pelo projeto CoastSnapSC em conjunto com o autor do presente trabalho. |
| 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/ augmentation de dados | Auto-orientação e redimensionamento para 640x640 |
| 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 do Moçambique e 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. |
| Robustez do conjunto de testes | As imagens foram coletadas a partir do suporte do CoastSnap, sem variar muito o plano de fundo, ângulos, iluminação, etc. |
| Confidencialidade do conjunto de teste | Não se aplica |

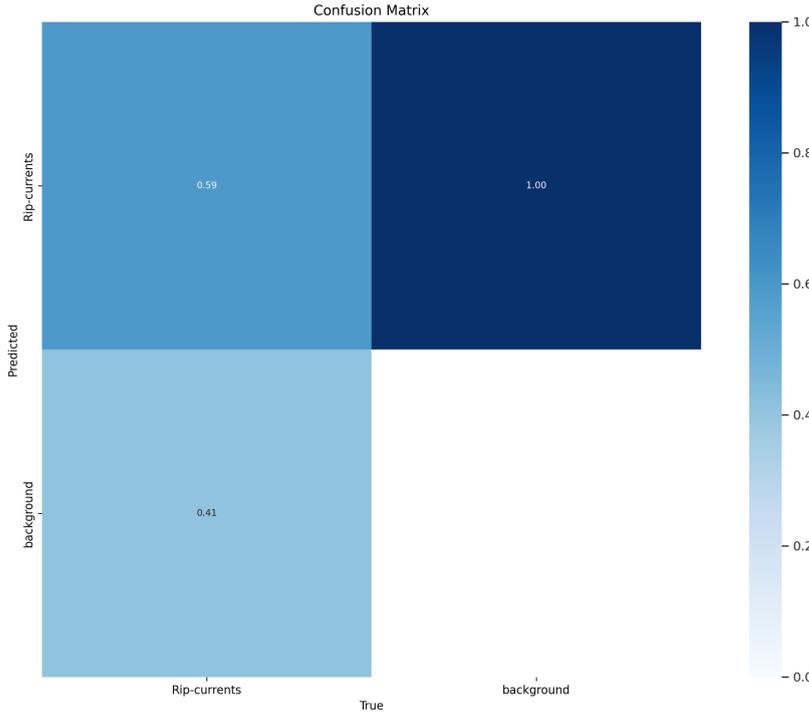
4.4.3.2 RESULTADO DO TESTE COM YOLOv5s

| | |
|--------------------------------|-----|
| Testes | |
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| <i>mAP50</i> | 60% |
| Precisão | 72% |
| <i>Recall</i> | 50% |
| F1-score | 60% |

| 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>0.56</td> <td>0.44</td> </tr> <tr> <th>background</th> <td>1.00</td> <td>1.00</td> </tr> </tbody> </table> | Predicted \ True | Rip-currents | background | Rip-currents | 0.56 | 0.44 | background | 1.00 | 1.00 |
|--------------------|---|------------------|--------------|------------|--------------|------|------|------------|------|------|
| Predicted \ True | Rip-currents | background | | | | | | | | |
| Rip-currents | 0.56 | 0.44 | | | | | | | | |
| background | 1.00 | 1.00 | | | | | | | | |
| Interpretação | <p>Nota-se que o treinamento atual apresenta resultados inferiores ao comparar com os resultados do 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> | | | | | | | | | |

4.4.3.3 RESULTADO DO TESTE COM YOLOv8s

| Testes | |
|--------------------------------|-----|
| Tamanho do lote | 32 |
| Tamanho da imagem | 800 |
| Avaliação de desempenho | |
| mAP50 | 54% |
| <i>Precision</i> | 74% |
| <i>Recall</i> | 49% |
| F1-score | 58% |

| 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>0.59</td> <td>1.00</td> </tr> <tr> <th>background</th> <td>0.41</td> <td></td> </tr> </tbody> </table> | Predicted \ True | Rip-currents | background | Rip-currents | 0.59 | 1.00 | background | 0.41 | |
|--------------------|---|------------------|--------------|------------|--------------|------|------|------------|------|--|
| Predicted \ True | Rip-currents | background | | | | | | | | |
| Rip-currents | 0.59 | 1.00 | | | | | | | | |
| background | 0.41 | | | | | | | | | |
| Interpretação | <p>Observa-se que o teste diminuiu muito o desempenho do modelo se comparado ao desempenho do treinamento/validação. Isso mostra uma dificuldade em detectar correntes de retorno em imagens nunca vistas pelo modelo.</p> | | | | | | | | | |

4.5 DISCUSSÃO

Os resultados provenientes do treinamento/validação dos modelos estão resumidos na Tabela 16. Esta tabela oferece uma visão abrangente da eficiência dos modelos em várias métricas de avaliação, tais como mAP, precisão, *recall* e F1-score, destacando em negrito os maiores valores de cada métrica por praia.

Tabela 16: Resultado dos treinamentos com diferentes conjuntos de dados e modelos

| Resultados da validação do desempenho | | mAP | Precisão | <i>Recall</i> | F1-score |
|---------------------------------------|---------|------------|------------|---------------|------------|
| Praia do Moçambique | YOLOv5n | 66% | 97% | 53% | 72% |
| | YOLOv8s | 84% | 91% | 69% | 79% |
| Praia do Santinho | YOLOv5s | 69% | 77% | 63% | 69% |
| | YOLOv8s | 71% | 74% | 65% | 69% |

| | | | | | |
|--|----------------|------------|------------|------------|------------|
| Praia do Moçambique + Praia do Santinho | YOLOv5s | 69% | 73% | 63% | 67% |
| | YOLOv8s | 69% | 78% | 63% | 69% |

A maioria dos modelos apresentados na Tabela 15 demonstraram resultados abaixo do esperado. Somente o YOLOv8s obteve um desempenho próximo ao esperado com o conjunto de imagens da praia de Moçambique. Isso se deve ao fato de que o conjunto de imagens de Moçambique oferecia uma perspectiva elevada do suporte do CoastSnap, facilitando a observação das correntes. Além disso, as correntes de retorno na praia de Moçambique são mais evidentes, tornando a detecção mais fácil. No entanto, um dos problemas que afetou o desempenho foi a escassez de imagens disponíveis. A praia de Moçambique possui uma trilha de difícil acesso, o que complicou a coleta de imagens em diferentes momentos.

Por outro lado, a praia do Santinho é mais acessível para a coleta de imagens, mas o suporte do CoastSnap não estava localizado em um ponto elevado do costão. Isso resultou em imagens com uma perspectiva mais plana, o que por sua vez dificultou a visualização das correntes. A praia também não possui correntes de retorno tão evidentes próximas ao costão onde está localizado o suporte do CoastSnap.

Cabe ressaltar que os modelos foram treinados e otimizados levando em consideração as demandas e restrições dos dispositivos móveis, incluindo suas limitações de recursos e capacidade de processamento.

A Tabela 17 exhibe resultados dos testes realizados com os modelos utilizando imagens novas. Para o conjunto de imagens da praia do Moçambique, foram utilizadas 14 imagens, para a praia do Santinho foram utilizadas 102 imagens e para a união dos dois conjuntos 116 imagens, destacando em negrito os maiores resultados de cada métrica por praia.

Tabela 17: Resultado dos testes com diferentes conjuntos de dados e modelos

| Resultados da validação do desempenho | | mAP | Precisão | Recall | F1-score |
|---|---------|-----|----------|--------|----------|
| Praia do Moçambique | YOLOv5n | 70% | 90% | 47% | 62% |
| | YOLOv8s | 62% | 78% | 57% | 64% |
| Praia do Santinho | YOLOv5s | 59% | 71% | 50% | 59% |
| | YOLOv8s | 61% | 67% | 56% | 59% |
| Praia do Moçambique + Praia do Santinho | YOLOv5s | 60% | 72% | 50% | 60% |
| | YOLOv8s | 54% | 74% | 49% | 58% |

Diferente dos resultados do treinamento/validação, os testes com a versão YOLO5s mostraram um desempenho superior na tarefa de detecção de correntes de retorno em imagens previamente não vistas em comparação com o modelo na versão YOLO8s. Isso indica que mesmo com o desempenho mais baixo, em geral consegue aprender a generalizar de forma melhor. No entanto, os resultados obtidos ainda não alcançaram as expectativas conforme especificadas nos requisitos de acordo com os riscos no presente caso de uso.

Ao comparar nossos resultados com trabalhos correlatos, como o estudo de Zhu et al. (2022), que utiliza imagens aéreas, fica evidente que imagens com uma visão mais ampla do mar podem facilitar a detecção das correntes. Assim pode-se inferir que a escolha do tipo de imagem e sua qualidade podem ter um impacto significativo na capacidade de detecção de correntes.

Ameaças à validade. Existem ameaças à validade que devem ser consideradas em relação aos resultados obtidos. No que se refere ao viés de seleção, foi buscada a criação de uma amostra diversificada e representativa de imagens, abrangendo diferentes cenários e condições. No entanto, é importante reconhecer que o conjunto de dados utilizado pode não ser completamente 74 abrangente, o que pode limitar a generalização dos resultados para todos os contextos possíveis. Além disso, embora um tamanho de amostra 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, onde foram aplicadas técnicas padronizadas a todos os modelos comparados para evitar distorções. Além disso, foram adotados parâmetros de treinamento consistentes para garantir uma comparação justa entre os modelos. Por fim, é importante mencionar o viés das métricas de avaliação, onde várias métricas padrão foram utilizadas 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, pode-se obter uma compreensão mais abrangente e realista dos resultados alcançados.

5. CONCLUSÃO

Para embasar o estudo, foi realizado uma análise teórica das correntes de retorno e da aplicação do deep learning (O1) e também feito um levantamento do estado da arte na detecção de correntes de retorno por meio do *deep learning* (O2). Essas etapas forneceram as bases necessárias para o desenvolvimento da pesquisa. Em relação ao terceiro objetivo (OE3), foi elaborado modelos de detecção de correntes de retorno utilizando *deep learning*, com base em um conjunto de imagens especialmente coletado e preparado para este estudo. Embora os resultados obtidos no treinamento e validação dos modelos não tenham atingido os requisitos especificados, registramos um desempenho máximo de 84% de mAP durante o treinamento com YOLOv8s e 70% de mAP nos testes com YOLOv5s. Estes resultados destacam a necessidade de otimizar os modelos e seus parâmetros para alcançar níveis aceitáveis considerando os riscos envolvidos no caso de uso previsto na detecção de correntes.

Os resultados deste estudo, embora não tenham alcançado uma acurácia de 98% na detecção de correntes de retorno, demonstram a viabilidade do desenvolvimento de modelos capazes de realizar essa detecção. Tais modelos têm o potencial de auxiliar os banhistas na identificação de perigos iminentes. É importante ressaltar que este trabalho se concentrou no uso de redes neurais mais leves, visando à futura implementação em

um aplicativo móvel e à captura de imagens diretamente pela câmera do celular, sem a necessidade de zoom físico ou digital.

Essa abordagem promissora pode beneficiar significativamente a população, tornando mais acessível a disponibilidade de um detector eficaz e fornecendo uma ferramenta valiosa tanto para banhistas como para turistas.

Há oportunidades promissoras para futuras pesquisas neste campo. A eficácia do modelo pode ser aprimorada por meio do aumento da quantidade de dados de treinamento e pela otimização das técnicas de pré-processamento. Além disso, a implementação prática dos modelos em um aplicativo é um passo crucial para a sua disseminação e uso generalizado. Isso possibilitará um acesso rápido e fácil a essa ferramenta de detecção de correntes de retorno para banhistas, equipes de resgate nas praias e até mesmo para a população em geral, contribuindo para um monitoramento mais eficaz, conscientização sobre o perigo que estas correntes trazem e a prevenção de possíveis acidentes.

Dado que os resultados obtidos no presente estudo não atingiram o limiar mínimo de mAP, é apresentado a seguir algumas sugestões para aprimorar futuros trabalhos. Primeiramente, considerar a possibilidade de incorporar imagens já coletadas pelo CoastSnap em diversas praias ao redor do mundo, uma vez que as restrições de acesso a algumas praias resultaram em uma coleta de dados relativamente limitada. Dada a natureza colaborativa do CoastSnap e seu propósito de contribuir para a ciência, a exploração de parcerias entre universidades e laboratórios pode viabilizar um intercâmbio valioso de dados.

Outra consideração crucial é a evolução do YOLO para detecção de objetos. A realização de testes mais abrangentes com a versão mais recente do YOLO, o YOLO-NAS, pode potencialmente otimizar a detecção de correntes de retorno.

Adicionalmente, há a possibilidade de explorar o uso de vídeos em vez de imagens. Durante a pesquisa, observou-se que alguns estudos correlatos empregaram vídeos para realizar a detecção de correntes. A divisão desses vídeos em frames poderia proporcionar um aumento significativo na quantidade de imagens disponíveis,

potencialmente contribuindo para um aprimoramento no desempenho dos modelos desenvolvidos.

REFERÊNCIAS

- ALPAYDIN, E. Introduction to Machine Learning. Cambridge, MA: MIT press, 2010. 472 p. ISBN 978-0-262-01243-0
- AMERSHI, S. et al. Software Engineering for Machine Learning: A Case Study. In: 2019 IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice (ICSE-SEIP). IEEE, 2019.
- BOCHKOVSKY, V. et al. YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv preprint arXiv:2004.10934, 2020. Disponível em: <https://arxiv.org/abs/2004.10934>. Acesso em: 08 abr. 2023.
- CASTELLE, B. et al. Rip current types, circulation and hazard. *Earth-Science Reviews*, [S.l.], v. 163, n. 1, p. 1-21, dez. 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0012825216303117>. Acesso em: 4 jul. 2022.
- CBM. Dicas de prevenção - Praia, 2023. Disponível em: <https://www.cbm.sc.gov.br/index.php/dicas-de-prevencao/praias?highlight=WyJjb3JyZW50ZSIsImRlIiwicmV0b3JubyIsImNvcnJlbnRlIGRlIiwiaY29ycmVudGUgZGUgcmV0b3JubyIsImRlIHJldG9ybm8iXQ==>
- CoastSnap. Disponível em: <https://www.coastsnap.com>
- CORDEIRO, A. M. et al. Revisão sistemática: uma revisão narrativa. *Revista do Colégio Brasileiro de Cirurgias*, v. 36, n. 6, p. 428-431, dez. 2007.
- DALRYMPLE, R. et al. Rip Currents. *Annual Review of Fluid Mechanics*, [S.l.], v. 43, n. 1, p. 551-581, 2011.
- GIRSHICK, R. et al. Rich feature hierarchies for accurate object detection and semantic segmentation. In: Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, Columbus, EUA, 2014. p. 580-587.
- GIRSHICK, R. Fast R-CNN. 2015.
- HARLEY, M. D.; KINSELA, M. A. CoastSnap: A global citizen science program to monitor changing coastlines. *Continental Shelf Research*, v. 245, 2022.
- IBM. Machine Learning, 2020. Disponível em: <https://www.ibm.com/br-pt/cloud/learn/machine-learning>
- IBM Cloud Blog. Disponível em: <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-net-works>. Acesso em: 3 de outubro de 2022
- ISHIKAWA, T. et al. Proposal and verification of rip current detection using AI. In: Coastal Dynamics Conference. Coastal Dynamics 2021 Conference, 2021.
- JACKSON, D. W.T.; SHORT, A. D. (Eds.). Sandy Beach Morphodynamics. 2020. Capítulo 11 - Rip currents, p. 255-276.
- JIANG, P. et al. A Review of Yolo Algorithm Developments. *Procedia Computer Science*, v. 199, p. 1066-1073, 2022.

- LAN, W. et al. Pedestrian Detection Based on YOLO Network Model. In: Proc. of the IEEE International Conference on Mechatronics and Automation. IEEE, 2018.
- LECUN, Y; BENGIO, Y; HINTON, G. Deep Learning. Nature, v. 521, p. 436-444, 2015.
- LI, C. et al. YOLOv6: A Single-Stage Object Detection Framework for Industrial Applications. Computer Vision and Pattern Recognition, 2022.
- 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.
- LUGER, G. F. Inteligência Artificial: estruturas e estratégias para a solução de problemas complexos. 4. ed. Porto Alegre: Artmed Editora, 2004.
- MAIA, J.; PEREIRA, P; LESSA, R. Variação espaço-temporal das correntes de retorno em municípios da região metropolitana do Recife. Quaternary and Environmental Geosciences, v. 5, n. 2, 2014.
- MARYAN, C. et al. Machine learning applications in detecting rip channels from images. Applied Soft Computing, v. 78, p. 84-93, 2019.
- MCGILL, S. P., & ELLIS, J. T. (2022). Rip current and channel detection using surfcams and optical flow. Shore & Beach, 90(1), 50-58.
- Mocellin, O. Determinação do nível de risco público ao banho de mar das praias arenosas do litoral Centro Norte de Santa Catarina. Tese (Mestrado em Ciência e Tecnologia Ambiental) – Centro de Ciências Tecnológicas da Terra e do Mar, Universidade do Vale do Itajaí. Itajaí, p. 28. 2006.
- MULLER, B. Z. Desenvolvimento de uma Extensão do App Inventor para Implantar Modelos de Machine Learning para Detecção de Objetos em Aplicativos em andamento. Trabalho de Conclusão de Curso. (Graduação em Sistemas de Informação) – Universidade Federal de Santa Catarina.)
- NSW. Disponível em:
<https://www.environment.nsw.gov.au/research-and-publications/your-research/citizen-science/get-involved/coastsnap>. Acesso em: 09 de abril de 2023
- OMS. Afogamentos continuam sendo uma das principais causas de mortes acidentais. 2021. Disponível em: <https://news.un.org/pt/story/2021/07/1757642>
- PADILLA, R. et al. A Survey on Performance Metrics for Object-Detection Algorithms. In: Proc. of the International Conference on Systems, Signals and Image Processing IEEE, 2020.
- PETERSEN, K.; VAKKALANKA, S.; KUZNIARZ, L. Guidelines for conducting systematic mapping studies in software engineering: An update. Information and Software Technology, v. 64, p. 1-18, 2015.
- PETERSEN, K. et al. Systematic Mapping Studies in Software Engineering. In: Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering, Bari, Italy, p. 68-77, 2008.
- PIASECKI, J., WALIGORA, M., DRANSEIKA, V. Google Search as an Additional Source in Systematic Reviews. Science And Engineering Ethics, v. 24, p. 809- 810, 2018.

POLETAEV, E.; PERVUNIN, K. S.; TOKAREV, M. P. Artificial neural network for bubbles pattern recognition on the images. Journal of Physics: Conference Series, vol.754. 2016.

POLYZOTIS, N. et al. Data Management Challenges in Production Machine Learning. Proceedings of the ACM International Conference on Management of Data, Chicago, IL, USA, 2017.

PRESSMAN, R. Engenharia de software: Uma abordagem profissional. 8 ed. Porto Alegre: Bookman, 2016.

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

RASHID, S. H. et al. RipDet: A Fast and Lightweight Deep Neural Network for Rip Currents Detection. In: 2021 International Joint Conference on Neural Networks, Computer Vision and Pattern Recognition, 2021.

RASHID, A. H. et al. Reducing rip current drowning: An improved residual based lightweight deep architecture for rip detection. ISA Transactions, v. 132, 2023.

REDMON, J; FARHADI, A. Yolov3: An incremental improvement. arXiv arXiv:1804.02767, 2018.

REDMON, J; FARHADI, A. YOLO9000: Better, Faster, Stronger. In: Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2017.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You Only Look Once: Unified, Real-Time Object Detection. In: Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE,. 2016.

REN, S. et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 39, 2017.

RUSSEL, S; NORVIG, P. Inteligência artificial. 3. ed. Rio de Janeiro: Elsevier Editora Ltda., 2013.

ROSEBROCK, Adrian. Intersection over Union (IoU) for Object Detection. PyImageSearch. Disponível em: <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>. Acesso em: 3 de outubro de 2022.

SILVA, A. et al. Automated rip current detection with region based convolutional neural networks. Coastal Engineering, v. 166, p. 103859, 2021.

SLSA. National Coastal Safety Report, 2019. Disponível em: <https://issuu.com/surflifesavingaustralia/docs/ncsr2019>

SOBRASA. Afogamentos, Boletim Brasil, 8, 2021. Disponível em: https://www.sobrasa.org/new_sobrasa/arquivos/baixar/AFOGAMENTOS_Boletim_Brasil_2021.pd

UFSC. Monitoramento costeiro comunitário da UFSC solicita participação de usuários, 2019. Disponível em:

<https://noticias.ufsc.br/2019/03/monitoramento-costeiro-comunitario-da-ufsc-solicita-participacao-de-usuarios/>

ULTRALYTICS. "Tips for Best Training Results". GitHub, Ultralytics, 2021. Disponível em: <https://github.com/ultralytics/yolov5/wiki/Tips-for-Best-Training-Results>. Acesso em: 08 de abril de 2023.

ULTRALYTICS. Ultralytics. Disponível em: <https://github.com/ultralytics/ultralytics>, 2023. Acesso em: 8 de abril de 2023.

ULTRALYTICS. YOLOv5 - Issue #280. Disponível em: <https://github.com/ultralytics/yolov5/issues/280>. Acesso em: 20 jun. 2023.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um Estudo sobre Redes Neurais Convolucionais e sua Aplicação em Detecção de Pedestres. In: Proc. of the Conference on graphics, patterns and images, São José dos Campos, SP, Brazil, 2016.

VON WANGENHEIM, C. G.; VON WANGENHEIM, A. Overview on a human-centric interactive ML process for teaching ML in K-12. Technical Report, GQS/INCOD/INE/UFSC, Florianópolis, 2020. Disponível em: <http://www.gqs.ufsc.br/files/2020/02/GQSTemplate-RelatorioTecnico-HumanCentricProcess-v10.pdf>. Acesso em: 18 de outubro de 2022.

VON WANGENHEIM, A. Deep Learning: Detecção de Objetos em Imagens. Material didático, 2023. Disponível em: <https://lapix.ufsc.br/ensino/visao/visao-computacionaldeep-learning/deteccao-de-objetos-em-imagens/#Fast-R-CNN> [Fast Region-based Convolutional Networks for object detection](https://lapix.ufsc.br/ensino/visao/visao-computacionaldeep-learning/deteccao-de-objetos-em-imagens/#Fast-Region-based-Convolutional-Networks-for-object-detection)

WANG, X. et al. Evaluating Object Detection Models with Mean Average Precision at Different IoU Thresholds. In: Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops . IEEE, 2019.

WANG, D; HE, D. Channel pruned YOLO V5s-based Deep Learning approach for rapid and accurate apple fruitlet detection before fruit thinning. Biosystems Engineering, v. 210, 2021.

WANG, C; BOCHKOVSKIY, A; LIAO, H. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In: Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops . IEEE, 2023.

WEHN, U., GHARESIFARD, M., CECCARONI, L. et al. Impact assessment of citizen science: state of the art and guiding principles for a consolidated approach. Sustainability Science 16, 1683–1699, 2021.

ZHU, D. et al. YOLO-Rip: A modified lightweight network for Rip currents detection. AI and Remote Sensing in Ocean Sciences, 2022.

ZOU, Z. et al. Object Detection in 20 Years: A Survey. Proceedings of the IEEE, v. 111, n. 3, p. 257-276, 2023.

APÊNDICE A - ARTIGO NO FORMATO SBC

Desenvolvimento de um Modelo de Detecção de Correntes de Retorno usando *Deep Learning* com Fotos do CoastSnap

Ramon Seugling

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

ramon.seugling@grad.ufsc.br

Abstract. *Drowning, a major global health concern, claimed 236,000 lives in 2019, with 90% of incidents in low- to middle-income countries. In Brazil, with over 100,000 non-fatal incidents and 5,000 deaths in 2019, rip currents contribute significantly, particularly in tourist destinations like Santa Catarina. This study proposes a YOLO-based (You Only Look Once) Deep Learning model to detect rip currents in coastal photos, taken from the CoastSnap project. The YOLO model enhances the identification of these perilous currents, offering a promising tool for public awareness and mitigating drowning incidents in regions prone to rip current-related accidents.*

Resumo. *Afogamento, uma preocupação global de saúde pública, resultou em 236.000 óbitos em 2019, com 90% dos incidentes ocorrendo em países de baixa e média renda. No Brasil, com mais de 100.000 incidentes não fatais e 5.000 mortes em 2019, as correntes de retorno contribuem significativamente, especialmente em destinos turísticos como Santa Catarina. Este estudo propõe um modelo de Aprendizado Profundo baseado como YOLO (You Only Look Once) para detectar correntes de retorno em fotos costeiras, obtidas no projeto CoastSnap. O modelo YOLO aprimora a identificação dessas correntes perigosas, apresentando uma ferramenta promissora para conscientização pública e redução de incidentes de afogamento em regiões propensas a acidentes relacionados a correntes de retorno.*

1. Introdução

Atualmente, o afogamento é uma das maiores causas de morte de pessoas ao redor do mundo [OMS, 2019]. Somente em 2019, 236 mil pessoas perderam suas vidas por este tipo de asfixia. Com uma porcentagem alta perante o total de mortes globais, o afogamento vêm ganhando cada vez mais destaque, ocorrendo 90% dos

casos em países de baixa e média renda. Sendo assim, iniciou-se por parte da Organização Mundial de Saúde (OMS), uma luta de conscientização para prevenir afogamentos e conseqüentemente reduzir o número de mortes.

No Brasil, por se tratar de um país continental com uma costa com mais de 8 mil quilômetros de extensão, e por possuir uma das maiores áreas banháveis do mundo durante o ano inteiro, o país possui um dos maiores números de incidentes e óbitos por afogamento do planeta [SOBRASA, 2021]. Segundo a Sociedade Brasileira de Salvamento Aquático (SOBRASA) mais de 100 mil incidentes não fatais e mais de 5 mil óbitos ocorreram no Brasil em 2019 [SOBRASA, 2021]. É um número alto que pode ser diminuído com conscientização das pessoas em relação às maiores causas.

Uma das causas, muito desconhecida pela população, são as correntes de retorno e centenas de pessoas se afogam e dezenas de milhares são resgatadas dessas correntes todos os anos [Castelle *et al.*, 2016]. O estado de Santa Catarina, por possuir um litoral repleto de praias turísticas e ser o destino de banhistas todos os anos, possui diversos incidentes com afogamento. Segundo o Corpo de Bombeiros Militar (2023), 90% desses casos acontecem em correntes de retorno.

Em termos oceanográficos, correntes de retorno são fluxos de água com velocidade alta, que fluem preferencialmente perpendicular à praia em direção mar adentro, ou seja, fluxo contrário ao das ondas. A partir destas ondas que vão em direção à praia, carregadas de energia, massa e impulso, elas tendem a voltar ao mar, formando os canais de retorno. As correntes de retorno podem variar de acordo com a localização e tipo de arrebentação da praia, mudando de profundidade, força, tamanho e lugar. Sendo assim, torna-se um grande perigo para banhistas que podem ser levados para águas profundas em pouco tempo [Dalrymple *et al.*, 2011].

As correntes de retorno são muitas vezes identificadas por meio de suas características como a coloração mais escura do mar que indica maior profundidade e a não formação de ondas e espuma em uma zona de arrebentação [Dalrymple *et al.*, 2011]. Ainda que a visualização dessas correntes possa ser relativamente compreensível, muitas vezes não são identificadas com facilidade. Na maioria dos casos, essa função é regida por profissionais do assunto e salva-vidas que atuam no local. Conseqüentemente, a maioria dos banhistas acaba não tendo ciência do que aquela região se trata e acaba correndo o risco de incidentes ao entrar em uma corrente de retorno.

Tendo em vista que existe o problema na identificação dessas correntes, uma possível solução pode ser a utilização de um aplicativo móvel utilizando *Deep Learning*

para identificar estas correntes utilizando fotos do costão da praia, que por possuir uma visão mais ampla da água, identificaria as correntes presentes no mar. A identificação dessas correntes nas imagens pode ser realizada com *Deep Learning*, detectando na foto a presença dessas correntes e mostrando ao usuário sua posição e o avisa sobre o perigo. Já existem algumas propostas de detecção de correntes de retorno usando *Deep Learning*, como o trabalho de Ishikawa *et al.* (2021), que utiliza vídeos de câmeras fixadas a uma altura elevada, obtendo uma visão mais panorâmica da água. Porém ainda não existe uma solução utilizando fotos tiradas do costão da praia.

Nesse contexto, existe no mundo um monitoramento comunitário de praias chamado CoastSnap [Harley; Kinsela, 2022]. Assim, para coletar imagens das praias por meio de *crowdsourcing*, o projeto disponibiliza suportes localizados em praias para posicionar a câmera do celular para fotografar, e, posteriormente, compartilhar fotos da praia nas redes sociais. Na Ilha de Santa Catarina, em parceria com a UFSC, foram instaladas estações nas praias para coleta destas imagens. O foco dessas estações é monitorar as praias, o comportamento dos bancos arenosos e as correntes de retorno. Sendo assim, o presente trabalho busca criar um modelo de detecção de correntes, a partir de fotos tiradas de um celular do costão de praias na Ilha de Santa Catarina usando o suporte CoastSnap.

2. Trabalhos correlatos

Como resultado do mapeamento da literatura observou-se que existem trabalhos de pesquisa recentes que buscam realizar a detecção de correntes de retorno utilizando *Deep Learning*. Entretanto, grande parte destas pesquisas utilizam imagens aéreas ou imagens obtidas por meio de câmeras estáticas localizadas na região da praia, o que foge do escopo do presente trabalho, que visa utilizar fotos tiradas no costão da praia para possibilitar o próprio cidadão a identificar as correntes de retorno.

Outro aspecto relevante é que não foram encontrados trabalhos relacionados à detecção de correntes de retorno utilizando *deep learning* no estado de Santa Catarina e nem no Brasil. Isso pode ser um problema tendo em vista que o Brasil possui uma costa com mais de 8 mil quilômetros de extensão e diversas praias.

A maioria dos trabalhos encontrados também não implementaram o modelo de detecção em um aplicativo móvel para contribuir com a sociedade, que é a mais afetada com os acidentes relacionados a correntes de retorno.

Nesse contexto, a análise do panorama atual revela a ausência de um modelo de detecção de correntes de retorno específico para o litoral de Santa Catarina, que possa ser facilmente utilizado por cidadãos. Além disso, é importante que esse modelo apresente uma alta precisão para os objetivos deste projeto.

3. Solução

3.1 Requisitos

O objetivo é desenvolver um modelo de detecção de correntes de retorno que seja portátil a um aplicativo móvel para auxiliar os usuários na identificação de correntes de retorno a partir de fotos do costão utilizando suportes do CoastSnap. O modelo utilizará *deep learning* e aprenderá com base em um conjunto de imagens rotuladas por um salva-vidas civil. A medida de desempenho desejada é um mean Average Precision (mAP) de 98%. O erro na detecção de correntes de retorno pode gerar consequências para a vida das pessoas, por isso é necessário um desempenho tão efetivo.

3.2 Preparação de dados

Para o presente trabalho foi coletado um conjunto de imagens tiradas pelo autor no suporte do CoastSnap presente em praias na cidade de Florianópolis e em parceria com o projeto CoastSnap. Foram coletadas 1.136 imagens das praias do Moçambique e da praia do Santinho. O conjunto de imagens foi armazenado e disponibilizado no Roboflow (<https://universe.roboflow.com/>).

A rotulação das correntes de retornos foi realizada por um aluno do curso de Oceanografia da Universidade Federal de Santa Catarina (UFSC) que também é salva-vidas civil e revisado por professor do curso de Oceanografia da Universidade Federal de Santa Catarina (UFSC).

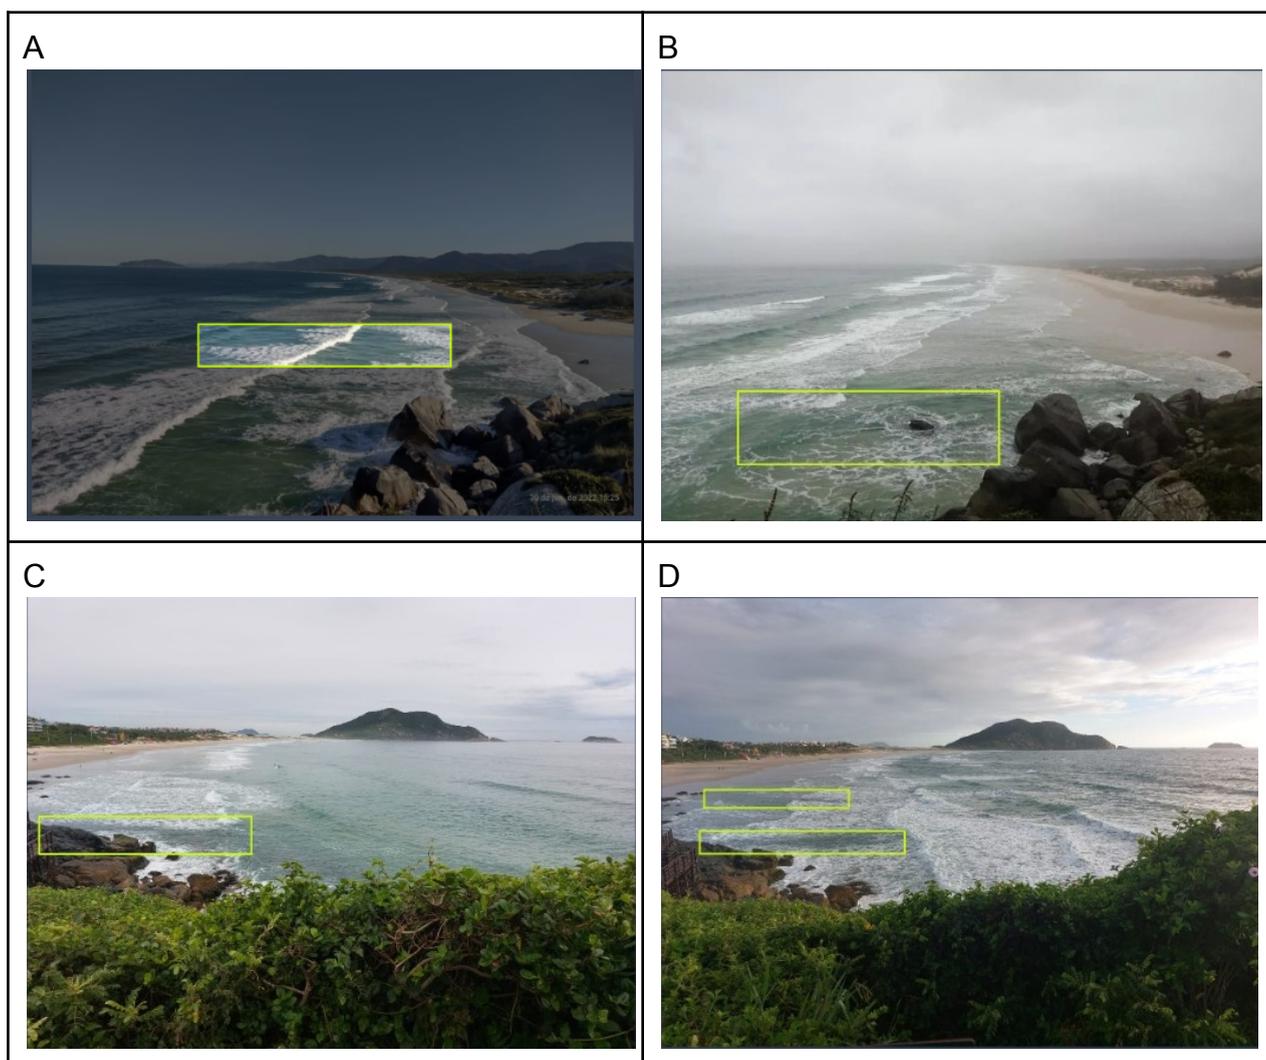


Figura 1: Exemplos de imagens do conjunto. As imagens A, B foram fotografadas na praia do Moçambique. A imagem C e D, fotografadas na praia do Santinho. Todas contém correntes de retorno indicadas por *bounding boxes*

Com o objetivo de aumentar e diversificar o conjunto de dados, são utilizadas técnicas de *data augmentation* no Roboflow. Isso inclui técnicas que serão aplicadas estão relacionadas ao posicionamento das imagens, como rotação e deformação (alteração da perspectiva). Além disso, serão aplicadas técnicas que afetam o aspecto visual das imagens, como alteração de tom, saturação, brilho, desfoque e adição de ruído.

A divisão do conjunto de imagens ocorreu da seguinte maneira: 70% para treinamento, 20% para validação e 10% para teste.

3.3 Treinamento

Foram realizados treinamentos com o modelo de rede neural YOLO (*You Only Look Once*) com portabilidade para dispositivos móveis incluindo as versões 5 (tamanho *small*) e 8 (tamanho *small*). Os conjuntos de imagens utilizados foram: conjunto da praia do Moçambique, conjunto da praia do Santinho e junção de ambos conjuntos. Os modelos foram treinados no ambiente *Jupyter Notebook* na plataforma Google Colab.

Os resultados encontrados são apresentados na Tabela 1.

Tabela 1: Resultado dos treinamentos com diferentes conjuntos de dados e modelos

| Resultados da validação do desempenho | | mAP | Precisão | Recall | F1-score |
|---|---------|------------|------------|------------|------------|
| Praia do Moçambique | YOLOv5n | 66% | 97% | 53% | 72% |
| | YOLOv8s | 84% | 91% | 69% | 79% |
| Praia do Santinho | YOLOv5s | 69% | 77% | 63% | 69% |
| | YOLOv8s | 71% | 74% | 65% | 69% |
| Praia do Moçambique + Praia do Santinho | YOLOv5s | 69% | 73% | 63% | 67% |
| | YOLOv8s | 69% | 78% | 63% | 69% |

A maioria dos modelos apresentados na Tabela 1 demonstraram resultados abaixo do esperado. Somente o YOLOv8s obteve um desempenho próximo ao esperado com o conjunto de imagens da praia de Moçambique. Isso se deve ao fato de que o conjunto de imagens de Moçambique oferecia uma perspectiva elevada do suporte do CoastSnap, facilitando a observação das correntes. Além disso, as correntes de retorno na praia de Moçambique são mais evidentes, tornando a detecção mais fácil.

3.4 Testes de desempenho

De acordo com as diretrizes estabelecidas na norma ISO/IEC 4213 (2022), foram realizados testes utilizando os modelos previamente treinados, com o objetivo de detectar correntes de retorno em imagens que não foram incluídas no estágio de

treinamento ou validação. O conjunto de testes da praia do Moçambique é constituído por 14 imagens, o da praia do Santinho de 102 imagens e o da junção dos conjuntos é de 116 imagens.

Tabela 2: Resultado dos testes com diferentes conjuntos de dados e modelos

| Resultados da validação do desempenho | | mAP | Precisão | Recall | F1-score |
|---|---------|------------|------------|------------|------------|
| Praia do Moçambique | YOLOv5n | 70% | 90% | 47% | 62% |
| | YOLOv8s | 62% | 78% | 57% | 64% |
| Praia do Santinho | YOLOv5s | 59% | 71% | 50% | 59% |
| | YOLOv8s | 61% | 67% | 56% | 59% |
| Praia do Moçambique + Praia do Santinho | YOLOv5s | 60% | 72% | 50% | 60% |
| | YOLOv8s | 54% | 74% | 49% | 58% |

Diferente dos resultados do treinamento/validação, os testes com a versão YOLO5s mostraram um desempenho superior na tarefa de detecção de correntes de retorno em imagens previamente não vistas em comparação com o modelo na versão YOLO8s. Isso indica que mesmo com o desempenho mais baixo, em geral consegue aprender a generalizar de forma melhor. No entanto, os resultados obtidos ainda não alcançaram as expectativas conforme especificadas nos requisitos de acordo com os riscos no presente caso de uso.

Ao comparar nossos resultados com trabalhos correlatos, como o estudo de Zhu et al. (2022), que utiliza imagens aéreas, fica evidente que imagens com uma visão mais ampla do mar podem facilitar a detecção das correntes. Assim pode-se inferir que a escolha do tipo de imagem e sua qualidade podem ter um impacto significativo na capacidade de detecção de correntes.

4. Conclusão

Neste estudo foram elaborados modelos de detecção de correntes de retorno utilizando *deep learning*, com base em um conjunto de imagens especialmente coletadas. Embora os resultados de treinamento e validação não tenham atingido os requisitos, registrou-se um desempenho máximo de 84% de mAP no treinamento com YOLOv8s e 70% nos testes com YOLOv5s. Apesar de não alcançar uma acurácia de 98%, o estudo demonstrou a viabilidade do desenvolvimento de modelos para detecção de correntes, com potencial para auxiliar banhistas na identificação de perigos. O foco foi em redes neurais mais leves para implementação em um aplicativo móvel, tornando a detecção mais acessível. O estudo destaca oportunidades futuras, incluindo o aprimoramento da eficácia do modelo com mais dados de treinamento e otimização do pré-processamento, além da implementação prática em um aplicativo para ampla utilização. Isso contribuiria para um monitoramento mais eficaz, conscientização sobre perigos e prevenção de acidentes relacionados a correntes de retorno.

Referências

OMS. Afogamentos continuam sendo uma das principais causas de mortes acidentais. 2021. Disponível em: <https://news.un.org/pt/story/2021/07/1757642>

SOBRASA. Afogamentos, Boletim Brasil, 8, 2021. Disponível em: https://www.sobrasa.org/new_sobrasa/arquivos/baixar/AFOGAMENTOS_Boletim_Brasil_2021.pd

CASTELLE, B. *et al.* *Rip current types, circulation and hazard. Earth-Science Reviews*, [S.l.], v. 163, n. 1, p. 1-21, dez. 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0012825216303117> Acesso em: 11 dez. 2023.

CBM. Dicas de prevenção - Praia, 2023. Disponível em: <https://www.cbm.sc.gov.br/index.php/dicas-de-prevencao/praias?highlight=WyJjb3JyZW50ZSIsImRlliwicmV0b3JubyIsImNvcnJlbnRllGRlliwY29ycmVudGUgZGUgcmV0b3JubyIsImRllHJldG9ybm8iXQ==>

CoastSnap. Disponível em: <https://www.coastsnap.com>

DALRYMPLE, R. *et al.* *Rip Currents. Annual Review of Fluid Mechanics*, [S.l.], v. 43, n. 1, p. 551-581, 2011.

HARLEY, M. D.; KINSELA, M. A. CoastSnap: A global citizen science program to monitor changing coastlines. *Continental Shelf Research*, v. 245, 2022.

ZHU, D. *et al.* YOLO-Rip: A modified lightweight network for Rip currents detection. *AI and Remote Sensing in Ocean Sciences*, 2022.