

NAUPLIUS: DESENVOLVENDO SOLUÇÕES PARA AQUICULTURA DE PRECISÃO

NAUPLIUS: DEVELOPING SOLUTIONS FOR PRECISION AQUACULTURE

José Cláudio Pereira da Silva *

Andressa Bezerra Ferreira**

Felipe Bastos Nunes ***

RESUMO

Na indústria de produção de camarão, a avaliação da quantidade de animais saudáveis em uma cultura é uma atividade chave. Atualmente, esse processo é realizado de forma manual em diversos laboratórios de nossa região e do Brasil. Uma amostra é retirada do tanque e as larvas são contabilizadas visualmente em uma placa de petri. Esse método é demorado, enfadonho e sujeito a erros. O estudo aqui realizado propõe um método que utiliza tecnologia de inteligência artificial para contar automaticamente a quantidade de camarões na fase larval (náuplios) em uma amostra e estimar a quantidade total contida em um tanque. Com essa solução, os produtores poderão economizar tempo e acompanhar a contagem de animais com maior frequência, além de obter resultados mais precisos.

Palavras-chave: Camarão. Reconhecimento de Objetos. Aquicultura. Redes neurais.

ABSTRACT

In the shrimp production industry, assessing the number of healthy animals in a culture is a key activity. Currently, this process is carried out manually in several laboratories in our region and in Brazil. A sample is taken from the tank and the larvae are visually counted in a petri dish. This method is time-consuming, tedious, and error-prone. The study presented here proposes a method that uses artificial intelligence technology to automatically count the number of shrimp in the larval stage (nauplii) in a sample and estimate the total quantity contained in a tank. With this solution, producers will be able to save time and monitor animal counts more frequently, in addition to obtaining more accurate results.

Keywords: Shrimp. Object Recognition. Aquaculture. Neural networks.

* Aluno do bacharelado em Ciências da Computação do IFCE campus Aracati.

** Professora do Bacharelado em Ciências da Computação do IFCE campus Aracati.

*** Professor do bacharelado em Ciências da Computação do IFCE campus Aracati.

1 INTRODUÇÃO

A produção de náuplios, estágios iniciais de desenvolvimento de organismos marinhos, como camarões, é uma etapa fundamental na aquicultura moderna, uma vez que esses organismos jovens representam a base de toda a cadeia produtiva. (COSTA et al., 2024; JUNIOR, 2021; VALENTI et al., 2020). Segundo as diretrizes estabelecidas pela Associação Brasileira de Aquicultura (ABRAq, 2019), os produtores devem garantir uma produção sustentável e de alta qualidade de náuplios, de modo a contribuir para o desenvolvimento da aquicultura no país. Portanto, a produção e contagem de náuplios são aspectos críticos e demandam atenção constante por parte dos produtores e pesquisadores.

Atualmente, o processo de contagem desses seres é realizado de forma manual nos mais diversos laboratórios do Brasil. Uma amostra é retirada do tanque e as larvas são contabilizadas visualmente em uma placa de petri. Esse método é demorado, enfadonho e sujeito a erros.

A automação da contagem de náuplios na aquicultura é um campo de pesquisa e desenvolvimento em constante evolução, com desafios técnicos e científicos que continuam a motivar a busca por soluções inovadoras. Estudos como o de (JATOBÁ et al., 2017) destacam a importância da automação para aumentar a eficiência e a produtividade na criação de camarões, incluindo a contagem de náuplios.

Considerando este cenário, a empresa Laboratórios Maris Pescados buscou a academia, por meio do Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE) Campus Aracati, para apoiar projetos inovadores que abordem esse contexto tecnológico e científico, transformando conhecimento em negócio e agregando valor ao seu processo produtivo.

Nesse contexto, surgiu a proposta de desenvolvimento do aplicativo Nauplius. O qual visa atender às expectativas do setor de aquicultura, fornecendo uma ferramenta tecnológica que transformará a maneira como a contagem de náuplios é realizada, substituindo a contagem manual por uma abordagem automatizada, com base em inteligência artificial.

Com base nesse contexto, o trabalho tem como principal objetivo a aplicação de técnicas avançadas de detecção de objetos em imagens para resolver o desafiador problema de contagem de náuplios na fase N3 em laboratórios de *Larvicultura*.

Uma vez que a solução aqui proposta faz uso de inteligência artificial (IA), considera-se relevante mencionar que o processamento de imagens na aquicultura tem ganhado destaque. Segundo (GOMES et al., 2019), a IA é uma ferramenta poderosa para identificar e contar náuplios em imagens, reduzindo a necessidade de intervenção humana. Essa abordagem promissora ressalta a importância da IA no contexto do Nauplius. Além disso, a implementação de soluções de automação na aquicultura pode ter impactos econômicos significativos. Pesquisadores como (LOPES; SANTOS, 2018) destacam como a automação pode melhorar a rentabilidade das operações de criação de camarões, reduzindo custos operacionais e aumentando a produtividade.

Mediante esse cenário, a automação na aquicultura pode contribuir para o desenvolvimento socioeconômico de regiões dependentes dessa indústria. O estudo de (ARAÚJO et al., 2020) ressalta como o fortalecimento da aquicultura pode criar empregos e aumentar a renda

local, beneficiando áreas como o estado do Ceará.

Na seção 2, revisaremos conceitos-chave que são fundamentais para compreender o contexto deste estudo. Na seção 3, serão apresentados trabalhos relacionados que serviram de base para o desenvolvimento desta pesquisa, delineando a metodologia adotada para alcançar os resultados. Na seção 4, detalharemos como conduzimos a construção do conjunto de dados e a implementação dos experimentos. Na seção 5 iremos apresentar um protótipo como prova de conceito da aplicação do projeto Nauplius em ambientes reais. A avaliação quantitativa dos resultados obtidos será realizada na seção 6, onde faremos comparações com algoritmos de detecção de objetos em imagens e aprofundaremos também a discussão sobre os aspectos relevantes dos algoritmos utilizados e suas implicações. Finalmente, na seção 7, apresentaremos os objetivos alcançados, destacaremos as lacunas de pesquisa identificadas e apontaremos direções para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

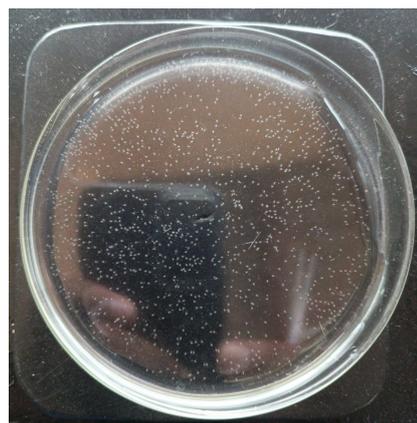
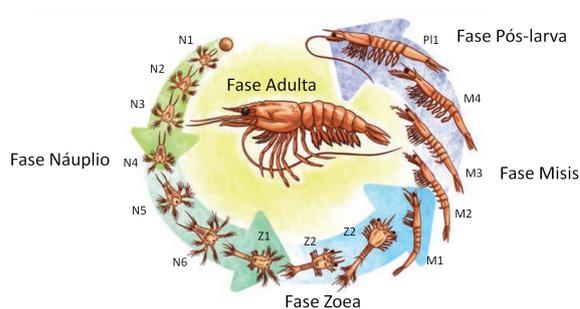
2.1 Náuplios e Contagem de Náuplios

A contagem precisa de náuplios desempenha um papel crítico na otimização da produção de camarões. Essa gestão ocorre em dois segmentos distintos na indústria especializada: a maturação e a larvicultura. O processo de maturação concentra-se no acasalamento e na desova. Machos e fêmeas são alojados em tanques específicos até que o acasalamento ocorra. Posteriormente, as fêmeas fecundadas são transferidas para os tanques de desova, onde aguardam o momento da desova (marcado como hora zero). Após essa etapa, as fêmeas retornam aos tanques de maturação para um novo ciclo (MOURA et al., 2021).

Durante a incubação nos tanques de desova, entre a 15^a e a 16^a hora, as ovas de camarão eclodem, marcando o início da fase inicial de desenvolvimento conhecida como náuplio. Esta etapa tem duração aproximada de 48 horas após a eclosão e é subdividida em seis subfases, de N1 a N6 (conforme ilustrado na Figura 1a). As larvas passam por metamorfose nesse estágio, avançando para a fase de protozoa, onde começam a requerer alimentação através do uso de ração (NUNES, 2001). Entretanto, na vigésima primeira hora de incubação, as larvas, então na fase náuplios N3, são coletados para contagem, antes de serem transferidos para o setor de larvicultura.

No processo de transferência para a larvicultura, uma amostra padrão de 12 ml é retirada de cada reservatório, com o intuito de quantificar a população de náuplios. Essas amostras são posteriormente encaminhadas ao laboratório, onde são cuidadosamente dispostas em placas de Petri (Figura 1b). O laboratorista, então, conduz a contagem minuciosa dos náuplios de forma manual.

A etapa de contagem de náuplios é uma prática comum em laboratórios, especialmente durante os períodos de armazenamento, com o objetivo de quantificar a densidade de estocagem (ou seja, o número de animais em um ambiente aquático específico). Esse dado é de vital



(a)

(b)

Figura 1 – (a) Ciclo de vida do camarão peneídeo, adaptado de (SENAR, 2016) e (b) amostra de 12 ml contendo náuplios de camarão na fase N3, sendo preparada para contagem, fonte: próprio autor.

importância, uma vez que a manutenção adequada dos náuplios nos tanques de *Larvicultura* é crucial para atender às metas de densidade desejadas. A elevada densidade pode resultar em uma série de desafios, como baixa taxa de crescimento, aumento da mortalidade, ocorrência de canibalismo e possíveis alterações nos parâmetros da água (FRÓES et al., 2013; BESSA-JUNIOR, 2014). Em contraste, densidades abaixo do ideal podem impulsionar o crescimento das pós-larvas, contudo, podem não traduzir-se na rentabilidade almejada. Em outras palavras, uma contagem de náuplios eficaz evita despesas desnecessárias com alimentação e probióticos durante a fase de pós-larva.

O fato da contagem de náuplios ser realizado manualmente nos laboratórios, nos impulsionou a procurarmos meios pelo qual fosse possível realizar essa contagem de forma automatizada. Para isso, buscamos entender sobre a detecção de objetos, a mesma é uma área crucial para a automação da aquicultura.

2.2 Detecção de objetos

A detecção de objetos em imagens, uma tecnologia essencial empregada pela Nauplius no desenvolvimento da solução, engloba a identificação e localização precisa de objetos específicos dentro de uma cena. O processo abrangente pode ser desmembrado em etapas que variam de acordo com o algoritmo selecionado. (SILVA et al., 2018)

Primeiramente, ocorre a extração de características, na qual o algoritmo automaticamente processa a cena, realçando as características relevantes dos objetos, tais como bordas, texturas, cores e formatos. Na etapa subsequente, são identificadas as regiões de interesse na imagem. Isso frequentemente é realizado por meio de algoritmos que buscam padrões de características em várias partes da imagem. A etapa seguinte se concentra na classificação dos objetos detectados. Cada região de interesse passa por uma avaliação para determinar se abriga ou não o objeto em questão. Nesse estágio, empregam-se algoritmos de reconhecimento de padrões baseados

em aprendizado de máquina (machine learning). Por fim, temos a etapa de aprimoramento e pós-processamento, onde se aprimora a precisão da detecção, eliminando detecções redundantes e refinando a localização das detecções.

Disposmos de diversos exemplos notáveis de algoritmos documentados e amplamente conhecidos:

You Only Look Once (REDMON et al., 2016) Um algoritmo de detecção de objetos em tempo real que segmenta a imagem em uma grade e prevê diretamente as caixas delimitadoras e as classes dos objetos. Reconhecido por sua eficácia e velocidade ao detectar múltiplos objetos em uma única passagem.

Faster R-CNN (Region-based Convolutional Neural Network) (REN et al., 2015) Introduce uma rede neural convolucional para gerar propostas de regiões de interesse. A junção da geração de regiões com a classificação de objetos resulta em maior eficiência.

SSD (Single Shot MultiBox Detector) (LIU et al., 2016) Semelhante ao YOLO, o SSD também detecta objetos em uma única passagem, agilizando o processo. Emprega múltiplas escalas de detecção em diferentes camadas da rede neural convolucional para abranger objetos de variados tamanhos.

Mask R-CNN (HE et al., 2017) Uma extensão do Faster R-CNN que adicionalmente gera máscaras de segmentação precisas para cada objeto detectado. Isso permite uma segmentação precisa de objetos individuais na imagem.

Haar Cascade Classifier (VIOLA; JONES, 2001) Diferente das redes neurais, este é um algoritmo clássico de detecção de objetos. Utiliza características de Haar para identificar objetos, sendo amplamente empregado em aplicações como a detecção facial. A seleção do melhor algoritmo depende das particularidades da aplicação, incluindo tamanho e resolução das imagens e dos objetos nela contidos, bem como das necessidades de tempo real (velocidade de processamento e resposta do sistema). Esse trabalho tem focado utilizar a tecnologia YOLO, especialmente a versão 5.

Para implementar qualquer um desses algoritmos, a coleta de imagens contendo o objeto de interesse é essencial. É nesse ponto que nossa empresa parceira Maris, auxilia, disponibilizando as informações necessárias para darmos andamento a solução proposta. Utilizando as imagens de uma primeira coleta, realizamos a anotação (marcação manual dos objetos de interesse nas imagens) e treinamos o algoritmo YOLO versão 5 para efetuar nossa *Prove of Concept* (Poc), A Figura 2 mostra como é a placa de pretri contendo os náuplios, e como fica após ser passada no algoritmo treinado.

A próxima seção explorará como a implementação do YOLO para detecção de objetos na aquicultura representa um salto significativo na automação e no aprimoramento dos processos de monitoramento.

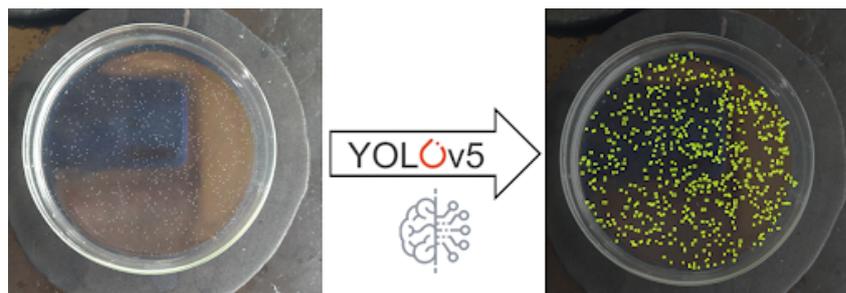


Figura 2 – Aplicação do modelo de aprendizado de máquina YOLO Versão 5 aos dados iniciais anotados para detecção de náuplios (N3). Fonte: Próprio autor

2.3 YOLO

YOLO é um algoritmo de detecção de objetos em tempo real que revolucionou a área de visão computacional. Desenvolvido por Joseph Redmon e Santosh Divvala, (OTONE, 2023) a mesma aborda o desafio de detecção de objetos de maneira única, dividindo a imagem de entrada em uma grade e realizando integração diretamente. Diferentemente das abordagens tradicionais que dividem o processo em várias etapas, como propostas de regiões e classificação, o YOLO realiza a detecção de objetos em uma única passagem.

A metodologia do YOLO envolve a divisão da imagem em uma grade, onde cada célula da grade é responsável por prever caixas delimitadoras e as classes dos objetos contidos nelas. Isso significa que, em vez de analisar a imagem várias vezes, o YOLO realiza essa tarefa simultaneamente, o que resulta em uma eficácia notável e uma velocidade impressionante, sendo capaz de detectar múltiplos objetos em tempo real (GOMES, 2022).

A arquitetura do YOLO tem evoluído ao longo do tempo, com diferentes versões sendo lançadas para melhorar ainda mais os resultados e eficiência. Sua abordagem única se tornou uma escolha popular em aplicações que desabilitam detecção de objetos em tempo real, como veículos autônomos, vigilância por vídeo, reconhecimento facial e muito mais. (REIS et al., 2023),(MOURA; CLARO; GONDIM, 2021), (MATUCK et al., 2023) Além disso, o YOLO tem sido amplamente adotado na comunidade de aprendizado profundo, simplesmente como base para pesquisas e implementações em uma variedade de domínios. Sua capacidade de equilíbrio, precisão e velocidade tornou-se uma ferramenta avançada para desenvolvedores e pesquisadores que buscam soluções eficientes na detecção de objetos.

Segundo (YANG et al., 2020) Joseph Redmon, o autor original do algoritmo YOLO, anunciou que interromperia todas as pesquisas na área de visão computacional depois de ficar insatisfeito com as aplicações militares e de privacidade de seu algoritmo de código aberto. Foi aí então, que Alexey Bochkovskiy publicou um artigo e deu continuidade ao desenvolvimento da série YOLO em 23 de abril de 2020, e posteriormente recebeu a aprovação oficial do YOLO.

A eficácia notável do YOLO na detecção de objetos em tempo real abriu caminho para inovações contínuas na área de visão computacional. Como evolução natural desse progresso, a YOLO versão 5 surge como uma iteração significativa, representando a constante busca por melhorias na detecção de objetos em imagens.

2.3.1 YOLO versão 5 e Justificativa de uso nesse trabalho

A YOLO versão 5, a quinta iteração da renomada arquitetura, representa uma evolução notável em comparação com suas versões anteriores. Desenvolvida por Glenn Jocher, fundador e CEO da Ultralytics, a YOLO versão 5 apresenta melhorias significativas em sua estrutura para melhorar a detecção de objetos em imagens. Um dos aprimoramentos-chave é a adoção da arquitetura de backbone CSPDarknet53, uma variante eficiente do Darknet53. Essa escolha visa aprimorar a proteção de características das imagens, elevando assim a capacidade de detecção de objetos da rede.

Além disso, a incorporação da Feature Pyramid Network (FPN) no YOLO versão 5 é crucial para permitir que a rede capture informações em várias escalas de resolução na imagem. Isso torna o YOLO versão 5 mais versátil, sendo capaz de detectar objetos de diferentes tamanhos e distâncias. O uso estratégico de âncoras na previsão de caixas delimitadoras de objetos também se destaca. Essas âncoras são dimensionadas para acomodar objetos de diversas proporções, ampliando a capacidade da rede de detectar objetos de formas variadas. Além disso, a capacidade de detecção multiescala do YOLO versão 5 se torna adequada para uma ampla gama de objetos, desde os pequenos e próximos até os grandes e distantes.

A eficiência do treinamento é uma compreensão determinante na YOLO versão 5. Estratégias inteligentes, como treinamento em resoluções reduzidas no início do processo de treinamento e, posteriormente, treinamento em resoluções mais altas para melhorar a precisão, são inovadoras. Desenvolvido por Joseph Redmon e Santosh Divvala, o YOLO versão 5 não apenas aprimora a precisão na detecção de objetos, mas também otimiza o desempenho em tempo real. Com técnicas de tração por hardware e otimizações de código, o YOLO versão 5 é especialmente adequado para aplicações que detectam em tempo real, como em veículos autônomos. Essas melhorias destacam o YOLO versão 5 como uma ferramenta avançada e eficiente para desenvolvedores e pesquisadores que buscam soluções sólidas em detecção de objetos.

A YOLO tem sido amplamente adotada em diversas aplicações, incluindo: (SGANDERLA et al., 2021) Detecção e Classificação de objetos presentes em imagens aéreas de drones de Ambientes Urbanos: Essa detecção e classificação ajudaria a manter certo controle nos ambientes urbanos, como identificar lotações em ruas, ou veículos pequenos e grandes, embora a presença de veículos grandes não seja tão presente em ambientes urbanos, tal identificação poderia ajudar a evitar congestionamentos.

Em (OLIVEIRA, 2023) é feito um Reconhecimento automático de placas de licença automotiva em ambientes restritos: neste trabalho a YOLO é usada para identificar e rastrear objetos em tempo real para assim evitar erros humanos nas portarias de condomínios e ambientes restritos.

Quanto a identificação e contagem de objetos a YOLO tem sido aplicada em inúmeras áreas como na criação de abelhas Albuquerque et al. (2022) ajudando na identificação de castas. Não tem sido diferente na aquicultura, que também tem optado pelo o uso das tecnologias

para realizar contagens de forma automatizada. Trabalhos como Li et al. (2023) e Bessa (2022) mostram como é possível automatizar processos de contagens na aquicultura.

Albuquerque et al. (2022) propõe um sistema de reconhecimento de objetos implementado para dispositivos móveis. O trabalho tem como objetivo principal, reconhecer castas de abelhas melíferas, de forma a identificar operárias e zangões. O conjunto de dados utilizado para realização do experimento foi obtido através da plataforma *StreamBee* (BEESTREAM, 2023) para realizar as anotações, o mesmo utilizou o *software LabelImg*, que possibilita o compartilhamento das anotações para a YOLO. O conjunto de dados utilizado se encontra desbalanceado, contendo cerca de 777 imagens de abelhas operárias e 277 de zangões.

Para realização do projeto, foi utilizado a YOLO versão 5, fazendo uso do método *cross validation*. Nesse método, separou-se o conjunto de dados em 5 conjuntos de imagens anotadas, ficando 4 conjuntos para treinamento e um para testes. Isso resulta em cinco divisões de 80% das amostras para treinamento e 20% para testes. Treinou-se cinco versões de modelo, onde cada uma delas foram analisados pelo resultado de *precision*, *recall*, *AP50* e *AP75*. A versão que mais se destacou foi a versão 4, onde obteve-se *precisão* de 96,0%, *mAP50* de 97,0% e *maP75* de 82%. Quanto ao *recall*, quem se saiu melhor foi a versão 2, obtendo 91,0%.

Com tamanha relevância em trabalhos que envolve detecção de objetos, a YOLO versão 5 tem se mostrado uma excelente opção para aplicarmos para detecção e contagem de Nauplios de camarão.

3 TRABALHOS RELACIONADOS

Li et al. (2023) propõe um aplicativo para detecção e contagem automática de larvas de camarão da espécie *Penaeus monodon* por meio da captura de uma imagens com o uso de smartphone. Para implementação do algoritmo de contagem o autor criou o seu próprio *dataset*, onde foram capturadas muitas imagens da larva em um recipiente específico, a uma distância de 300 mm a 500 mm. Para garantir que o processo de contagem obteria a mesma exatidão independente do operador da câmera, cinco pessoas se revezavam na captura de 50 imagens. A Figura 3 exemplifica a arquitetura do sistema de contagem de pós-larvas.

Para uma boa eficiência na contagem de larvas, a pesquisa baseou-se em PLCs e HRNet-w48. Os PLCs (Controladores Lógicos Programáveis) são dispositivos eletrônicos usados na automação industrial para controlar máquinas e processos por meio de lógica programável. HRNet-w48 é uma arquitetura de rede neural para visão computacional que mantém detalhes de alta resolução em todas as camadas, sendo útil em tarefas de detecção e segmentação de objetos em imagens. Com isso o aplicativo proposto pelos autores localiza aproximadamente a posição de cada larva na imagem, além de mostrar o número de larvas na imagem. Quanto aos resultados obtidos, o *mean Average Precision* (mAP) atingiu 93,79%, com *Mean Absolute Error*(MAE) de 33,69% e *Mean Squared Error* (MSE) de 34,74%.

O CountThings (2011-2023) é uma plataforma e um conjunto de aplicativos que oferecem soluções avançadas de contagem e análise de objetos por meio de tecnologias de visão com-

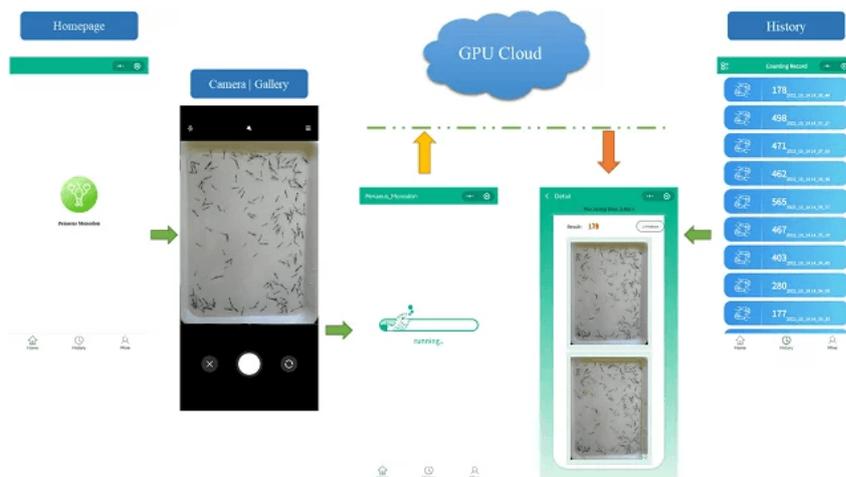


Figura 3 – Diagrama esquemático da plataforma de contagem de larvas de camarão. Fonte: (LI et al., 2023)

putacional e aprendizado de máquina. Essa plataforma é projetada para automatizar tarefas de contagem e medição em várias indústrias, proporcionando maior eficiência, precisão e economia de tempo. O aplicativo utiliza a câmera do smartphone para capturar imagens dos objetos a serem contados, e então emprega algoritmos de visão computacional para identificar e contar automaticamente esses objetos na imagem. A Figura 4 demonstra a interface do aplicativo sendo testado para contagens de náuplios.

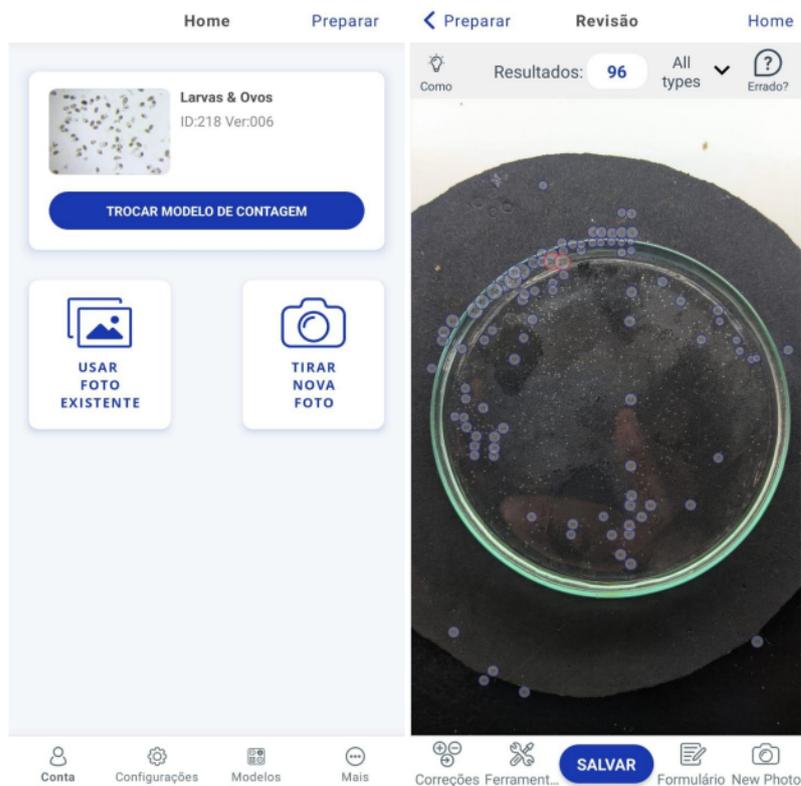


Figura 4 – Telas do aplicativo Count Things demonstrando a interface genérica e baixa exatidão na contagem. Fonte: Próprio autor

Este aplicativo pode ser eficiente e preciso, entretanto, pontos negativos decorrem de sua versatilidade. O CountThings é um software de aplicação geral para contagem de objetos na indústria e requer configuração/treinamento de inteligência artificial para adaptar à aplicação de contagem de náuplios na fase larval. O custo é outro ponto negativo. Apesar do aplicativo ter um período para teste de 7 dias gratuitos, após esse período, é necessário assinar um plano (24 horas - U\$24,00, mensal - U\$600,00 e anual - U\$2.400,00).

LarvIA, um software que trabalha com visão computacional e inteligência artificial para gerar relatórios de produção de camarão com 99% de precisão, apenas 15 segundos após tirar uma foto com um smartphone comum. Ajuda a monitorar o processo de crescimento em todas as etapas (pós-larvas, juvenis e adultos) e condição geral, como peso estimado, tamanho, uniformidade, pigmentação, contagem exata e local onde a foto foi tirada. É uma ferramenta em tecnologias semelhantes ao usado pelo CountThings, mas desenvolvida especificamente para criadouros de camarão, laboratórios, fazendas e varejistas de produtos de aquicultura. A Figura 5 demonstra a interface do aplicativo em uso.

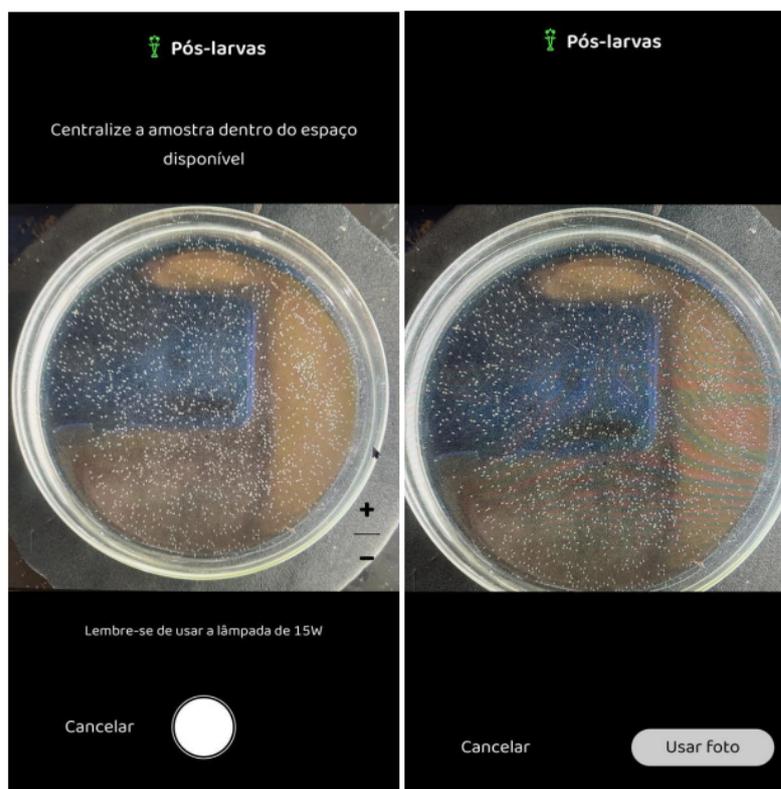


Figura 5 – Telas do aplicativo Larvia demonstrando a interface de aquisição de imagens para contagem de pós-larva. Fonte: Proprio autor

Quando procuramos pelo custo da ferramenta LarvIA, não conseguimos levantar essa informação no site da empresa, então consultamos um usuário em nossa empresa parceira que nos informou que o custo do pacote com 80 análises era de U\$40,00. Com nossa demanda atual de 316 análises por mês, disse ele, o custo do uso dessa ferramenta seria de U\$158,00 mensais.

O Snappart é um sistema de contagem automatizada de alimentos vivos que são utilizados na aquicultura, a INVE Aquaculture e a Aris são empresas que já atuam no mercado da

aquicultura já a bastante tempo e colaboraram fortemente para apresentação e lançamento do (INVE, 2023) um sistema revolucionário que realiza contagem e detecção de náuplios de artêmia, o mesmo utiliza um modelo de aprendizado profundo, onde detecta e contabiliza o número de náuplios de artêmia na amostra em segundos, além de gerar relatórios personalizados. Embora seja um sistema revolucionário para a aquicultura, seu alto custo o deixa de difícil acesso aos produtores de laboratórios. A Figura 6 demonstra o software.



Figura 6 – Sistema de contagem de náuplios de artêmia. Fonte: (INVE, 2023)

Silva et al. (2023) propõe um sistema automatizado e eficiente para monitoramento em tempo real do influxo de pólen em colmeias de abelhas. Para construir o conjunto de dados, foi necessário fazer uso de uma *playlist* do *YouTube* contendo 17 vídeos, onde obtiveram 630.344 imagens. Dessas 1290 imagens foram anotadas e formaram a base de dados que foi utilizada para esse experimento. No trabalho, avalia-se seis modelos de identificação de objetos, que estão divididos em dois grupos: modelos de estágio único e modelos de estágio múltiplo. Os modelos de estágio único utilizados foram: YOLO v7, YOLO X e CenterNet. Quanto aos modelos de estágio múltiplo, foram utilizados os seguintes modelos Faster R-CNN, Cascade R-CNN e Deformable DETR.

Para realização dos experimentos, semelhante ao artigo anterior, foi utilizado o método *cross validation*, onde o conjunto de dados foi dividido em 5 partições iguais para treinamento e validação. De forma que possibilitou o treinamento de todos os modelos. Segundo o Silva et al. (2023), o Deformable DETR atingiu a maior precisão média, mas seu alto custo computacional o torna inadequado para aplicações em tempo real. Diante disso percebeu-se que os modelos YOLO versão 7 com mAP50 95.1% e o CenterNet com mAP50 93.7% são os mais adequados para a detecção em tempo real do influxo de pólen nas colmeias.

Em Bessa (2022) se propõe um projeto com objetivo geral de realizar a criação de mecanismos capazes de auxiliar o processo de contagem de alevinos e pós-larvas, através do desenvolvimento de modelos de predição utilizando técnicas de aprendizagem profunda *deep*

learning e visão computacional. O dataset utilizado para realização deste trabalho foi feito em parceria do autor com IFCE e também obtiveram imagens de uma fazenda que fica localizada no Acre. Para realizar o pré-processamento das imagens fez-se um fork do repositório *labeling*, o código passou por algumas alterações para melhor se adaptar ao problema.

O modelo abordado pelo autor nesse trabalho foi YOLO versão 4 e YOLO versão 4-tiny, onde a o YOLO versão 4 com os melhores resultados, alcançando um mAP de 98,63% e accuracy de 98,66%. O dataset foi formado com 1011 imagens, onde foram divididas em três subconjuntos, sendo eles 60% para treinamento, 20% para validação e 20% para teste.

A Tabela 1 foi criada pelos autores com intuito de visualizar o comparativo feito entre todos os trabalhos e aplicações citadas nos trabalhos relacionados, bem como a Nauplius. Desta forma a tabela compara algumas funcionalidades e características relevantes destas aplicações.

| Interface | Yang | Counthirg | LarvIa | SnapPart | Nauplius |
|--|-------------|------------------|---------------|-----------------|-----------------|
| Conta náuplios de camarão | Não | Não | Não | Não | Sim |
| Acesso gratuito ao código | Não | Não | Não | Não | Sim |
| Detecta através da câmara e da galeria | Não | Não | Não | Não | Sim |
| Disponível em português | Sim | Sim | Sim | Não | Sim |
| Atua na aquicultura | Sim | Não | Sim | Sim | Sim |

Tabela 1 – Tabela comparativa entre as aplicações semelhantes ao projeto

Através das pesquisas realizadas pelos autores, foi notado que ainda não existe sistemas para a contagens de náuplios de camarão. Como visto na tabela, o grande diferencial do trabalho aqui exposto, é a detecção e contagem destes seres tão pequenos.

4 METODOLOGIA

4.1 Base de imagens

Para os experimentos, foi utilizado um conjunto de dados de autoria própria, contendo 1000 imagens de amostras de imagens de placas de Petri contendo náuplios na fase N3. Cada amostra possui um número estimado de náuplios entre 500 a 1300. As imagens foram capturadas em parceria com o laboratório Maris, uma empresa que atua há mais de 20 anos no ramo da aquicultura. Essas imagens foram tiradas utilizando três modelos de *smartphone* da marca *Xiaomi*, sendo eles *Redmi Note 8*, *Redmi Note 12* e *Redmi Note 11 pro + 5G*, com proporção (4 : 3) do modelo clássico, mas para não nos prendermos a uma única proporção, capturamos imagens com todas as proporções disponíveis nos aparelhos.

Para obtermos um número significativo de imagens e com qualidade, utilizamos um suporte que foi impresso em uma impressora 3D no LEMA, laboratório do IFCE campus de Aracati. Na Figura 7 apresento a imagem do suporte sendo utilizado para realizar a captura das imagens. Com esse suporte, foi possível normalizar a captura das imagens, a câmera dos aparelhos ficaram a uma distância de 13,0 cm de altura da placa de Petri onde está localizado a amostra contendo os náuplios.



Figura 7 – Suporte de celular para realização da captura das imagens, fonte:Próprio autor.

A detecção de objetos com YOLO, utiliza caixas delimitadoras (*bounding boxes*), as mesmas descrevem o posicionamento dos objetos na imagem e também informam a classe ao qual pertence. Para realizarmos as anotações nas imagens, utilizamos a plataforma *RoboFlow*, cuja sua interface é bastante intuitiva e de fácil manuseio, além disso, o *software* exporta as anotações com as seguintes informações de cada caixa: classe, coordenadas (x, y) do seu centro, largura e altura. Logo, as informações são as mesmas que são aceitas pela YOLO. Na Figura 8 é possível ver as marcações sendo realizadas pelos *RoboFlow* e a maneira que ele guarda as informações, como coordenadas x e y de cada (*bounding boxes*).

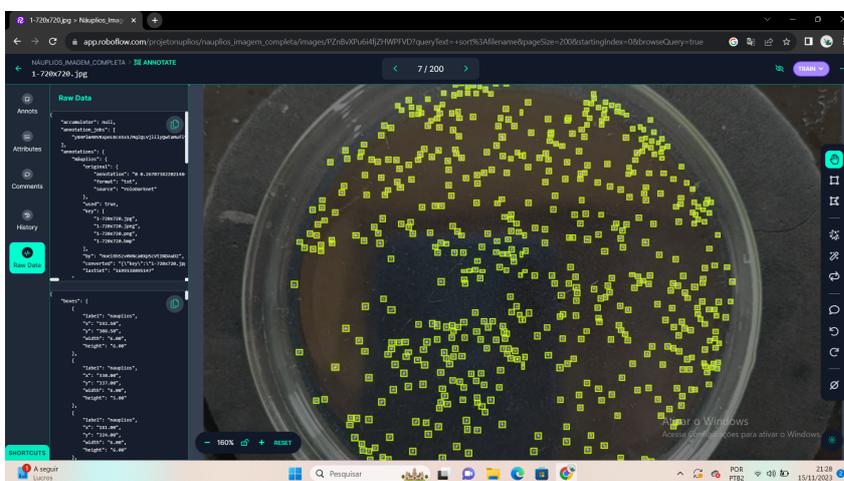


Figura 8 – Tela do *RoboFlow* mostrando as marcações sendo realizadas e as informações que são guardadas como coordenadas x e y.

A fim de melhorar o desempenho das marcações, recortamos cada imagem em 16 partes iguais. Dessa forma, nosso conjunto de dados passou-se a ter 16.000 amostras de imagens a serem anotadas. O processo de anotações foi feito de forma semi-supervisionado, na qual, realizamos marcações em um conjunto inicial de 100 imagens, realizamos o primeiro treinamento e, de posse do modelo parcial, utilizamos o assistente de etiquetagens na marcação do próximo grupo de 100 imagens de maneira assistida pelo modelo recém-criado, assim realizamos a rotulação de todas as imagens. Com isso, concluímos o processo de marcações das imagens de forma mais rápida, progressivamente avaliando os modelos intermediários.

4.2 Treinamento

Para darmos início aos treinamentos, o conjunto de dados anotado foi dividido em conjuntos de treinamento, validação e teste, com proporções de 70%, 20% e 10%, respectivamente. Isso foi feito para garantir uma avaliação precisa do desempenho do modelo em dados não vistos durante o treinamento. O modelo de treinamento abordado foi o supervisionado, onde cada exemplo do conjunto de treinamento incluía tanto a imagem quanto as anotações correspondentes das posições dos náuplios na fase N3.

O processo de treinamento foi realizado em várias etapas. Inicialmente, treinamos o modelo em um conjunto menor de dados para ajustar os pesos iniciais da rede neural. Em seguida, gradualmente aumentamos o conjunto de dados durante iterações subsequentes de treinamento para melhorar a generalização do modelo.

Como métricas de avaliação, utilizamos o (mAP), Precisão e Recall para a classe de objeto, com foco especial na detecção precisa de náuplios na fase N3. A escolha dessas métricas é fundamental para garantir a confiabilidade do modelo na tarefa específica da proposta.

Durante o treinamento, monitoramos o desempenho do modelo em relação às métricas mencionadas e ajustamos hiperparâmetros, como taxa de aprendizado e tamanho do lote (*batch size*), para otimizar o desempenho. A utilização da GPU no Google Colab permitiu treinamentos mais rápidos e eficientes em comparação com o uso exclusivo de CPU.

É importante ressaltar que o sucesso do treinamento dependeu significativamente da qualidade das anotações iniciais e da representatividade do conjunto de dados. O processo iterativo de treinamento, avaliação e ajuste de hiperparâmetros foi fundamental para alcançar um modelo final com desempenho satisfatório na detecção de náuplios na fase N3 em placas de Petri.

Após a conclusão do treinamento, realizamos testes extensivos do modelo em conjuntos de dados não vistos anteriormente. A análise dos resultados e ajustes adicionais foram feitos para garantir a robustez e a eficácia do modelo em diferentes ângulos da captura da imagem, proporções de imagem e variações na quantidade de Náuplios nas amostras.

O modelo treinado mostrou-se promissor na detecção de náuplios na fase N3, abrindo caminho para aplicações práticas na área de aquicultura. No entanto, é fundamental continuar aprimorando o modelo com dados adicionais e refinamentos contínuos para garantir sua eficácia em laboratórios de pós-larva.

5 A SOLUÇÃO: O APLICATIVO NÁUPLIOS

O Nauplius é um aplicativo inteligente com a habilidade de realizar cálculos e identificar camarões em sua fase larval, os náuplios, por meio de uma amostra simples.

O uso do mesmo acontece em 3 passos rápidos e intuitivos: 1) Após a instalação do aplicativo em seu dispositivo móvel, o usuário deverá abrir o mesmo e apontar a câmera do seu celular para a amostra disposta em uma placa de petri. 2) O aplicativo irá receber a imagem da

amostra e enviar a mesma para o servidor, onde a contagem e a marcação são executadas por algoritmos de inteligência artificial. 3) Alguns segundos após, o aplicativo fornece ao usuário, um resumo da contagem, incluindo o número de náuplios na amostra, uma estimativa da quantidade de náuplios no tanque e uma imagem com os náuplios marcados para validação pelo mesmo.

Para avaliar o conceito inovador do aplicativo Nauplius, concebemos um mínimo produto viável (MVP) que já está em operação no laboratório Maris Pescados, na cidade do Aracati, estado do Ceará. A Figura 9 mostra as principais telas de operação do aplicativo.



Figura 9 – Telas do aplicativo *Nauplius* mostrando o passo a passo para a realização da contagem

5.1 Arquitetura da Solução

A arquitetura da solução aqui proposta abrange desde o processamento da imagem até a entrega do resultado ao usuário final, com a colaboração de várias camadas, incluindo o papel fundamental do servidor. A seguir, detalhamos como cada componente da arquitetura se integra. A Figura 10 mostra a arquitetura da solução porposta.

5.1.1 Divisão da Imagem

O processo se inicia com a captura de uma imagem da amostra de náuplios, que é enviada ao servidor para processamento. No servidor, a imagem é dividida em 16 pedaços menores. Essa divisão facilita o processamento, pois permite que o algoritmo trabalhe em blocos menores da imagem, otimizando a identificação de náuplios e garantindo que áreas de maior densidade ou com menor contraste visual sejam adequadamente processadas.

5.1.2 Processamento pelo Algoritmo no Servidor

Cada um dos 16 pedaços da imagem é então processado por um algoritmo de detecção de objetos hospedado no servidor. Este algoritmo foi treinado para identificar náuplios de maneira eficiente, utilizando modelos de aprendizado profundo. O algoritmo aplica bounding boxes – caixas delimitadoras – ao redor de cada náuplio detectado em cada um dos fragmentos.

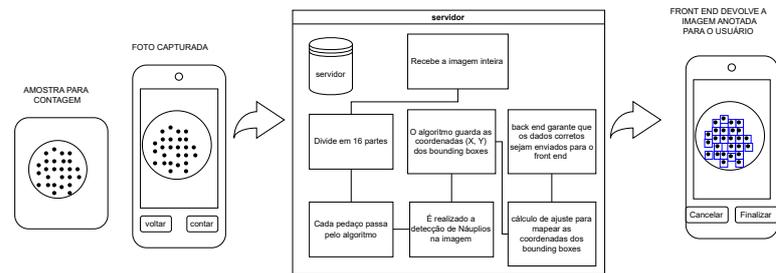


Figura 10 – Arquitetura da solução *Nauplius*

5.1.3 Armazenamento das Coordenadas

Enquanto o algoritmo no servidor processa cada pedaço, as coordenadas (X, Y) dos bounding boxes correspondentes aos náuplios detectados são armazenadas em uma lista. Essas coordenadas inicialmente estão relativas ao fragmento da imagem onde o náuplio foi detectado. O servidor mantém essa lista para cada pedaço da imagem processado.

5.1.4 Ajuste da Posição dos Bounding Boxes

Uma vez que todas as 16 partes da imagem foram processadas, o servidor realiza um cálculo de ajuste para mapear as coordenadas dos bounding boxes de cada fragmento para a imagem completa. Como os bounding boxes inicialmente se referem a cada fragmento separado, esse ajuste é necessário para consolidar a posição de cada náuplio detectado na escala da imagem original.

5.1.5 Papel do Servidor na Comunicação com o Frontend

Após o processamento completo e o cálculo das posições ajustadas dos bounding boxes, o servidor envia as coordenadas dos náuplios detectados para o frontend. Nesse momento, o backend desempenha um papel crucial na gestão da comunicação entre o algoritmo e o aplicativo que o usuário está utilizando, garantindo que os dados corretos sejam enviados com eficiência.

5.1.6 Exibição no Frontend

Ao receber as coordenadas das detecções, o frontend marca visualmente a imagem completa com os bounding boxes em torno de cada náuplio detectado. Essa marcação é feita em

tempo real, permitindo que o usuário visualize imediatamente a contagem e a distribuição dos náuplios na amostra.

5.1.7 Função de Monitoramento e Armazenamento no Servidor

Além do papel central no processamento e comunicação, o servidor também atua como um repositório de armazenamento de dados e registro de logs. Ele armazena os resultados das contagens, as imagens processadas e suas anotações, possibilitando análises posteriores e fornecendo um histórico valioso para o controle da densidade de náuplios ao longo do tempo.

A arquitetura da solução Nauplius é robusta, utilizando uma abordagem distribuída que envolve tanto o processamento eficiente no servidor quanto a exibição dinâmica no frontend. O servidor desempenha um papel fundamental, não apenas processando as imagens com o algoritmo de detecção de objetos, mas também realizando ajustes nas coordenadas, gerenciando a comunicação com o frontend e, potencialmente, armazenando dados para análise futura. Isso garante que a contagem de náuplios seja realizada de maneira precisa, em tempo real, proporcionando um ganho significativo de eficiência e precisão no controle da densidade em sistemas de larvicultura.

5.2 Treinamento da Solução Náuplios

O artigo apresentado aqui emprega duas iterações do sofisticado algoritmo de detecção de objetos conhecido como YOLO. Especificamente, utilizamos tanto a YOLO versão 5 quanto a YOLO versão 8.

No caso da Versão 5, conduzimos dois treinamentos distintos, cada um iniciando com conjuntos de dados separados. O primeiro conjunto compreendia 1000 imagens, que foram meticulosamente segmentadas em 16 partes para facilitar a marcação precisa dos náuplios em cada imagem. Esse procedimento resultou em uma expansão notável de nosso conjunto de dados, totalizando 16.000 imagens.

Quanto à segunda iteração da YOLO versão 5, baseou-se em um conjunto de dados contendo 1280 imagens, originalmente rotuladas utilizando a versão anterior. Posteriormente, realizamos uma revisão minuciosa das marcações para que a próxima versão pudesse ser treinada com as imagens intactas, evitando assim a segmentação anterior. Este método revelou-se altamente eficaz, culminando em um desempenho substancialmente superior em comparação com a iteração anterior, que apresentava uma leve sobreposição nas marcações dos náuplios nas imagens. Já a segunda versão não mostrava sobreposições nas marcações.

No que tange à YOLO versão 8, optamos por utilizar o mesmo conjunto de dados composto por 1280 imagens para conduzir os treinamentos. Dentre as várias variantes disponíveis da versão 8, a escolha da iteração a ser aplicada neste projeto resultou de uma série de testes exaustivos para determinar a mais adequada. Após uma meticulosa análise, decidimos pela YOLO v8nobb, pois esta não demanda um alto consumo de GPU durante os treinamentos. Essa

característica possibilitou uma execução mais eficiente e um desempenho otimizado do modelo durante as etapas de treinamento.

6 RESULTADOS

6.1 Validação

Para validação da ideia de criarmos um algoritmo de Inteligência Artificial para fazer a contagem e detecção de náuplios em uma placa de petri, foi necessário realizar visitas técnicas em laboratórios que possuem o setor de maturação (setor responsável pela produção dos náuplios). Foram realizado 4 visitas técnicas, onde buscava-se encontrar possíveis necessidades dentro dos laboratórios onde fosse possível fazer uso de I.A para a automatização de tarefas. Em cada visita, foi realizado também entrevistas com os funcionários desses laboratórios, de forma a conseguir validar uma possível solução para os problemas abordados nas entrevistas.

Ao longo das entrevistas, foi notável a necessidade de uma solução que auxiliasse na contagem de náuplios e também de outras classificações das larvas dentro dos laboratórios, como por exemplo, a contagem de pós larva.

Atualmente essa contagem é realizada manualmente e é muito sujeito a erros, além de ser uma tarefa repetitiva e enfadonha. Foi dito também nas entrevistas que a contagem de náuplios deixa os funcionários com dores nos olhos, devido ao esforço constante para contar esses seres tão pequenos. Também foi dito que a maior dificuldade é a quantidade de náuplios que precisa ser contada. Às vezes, há a necessidade de dividir a amostra em duas para realizar a contagem, devido ao número de náuplios presentes.

Para entendermos o impacto de erros na contagem de náuplios para a produção de pós-larva, perguntamos também aos entrevistados qual era esse impacto. Quase todos apontaram para problemas com a sobrevivência final, além de gastos desnecessários com alimentação a mais ou a menos, pois toda a alimentação das larvas são calculadas em cima da quantidade de náuplios que foi passada da maturação para a larvicultura. Foi dito ainda, que em situações onde ocorre um erro de contagem, onde será passado um valor a mais do que a quantidade real de náuplios que será transferido para a larvicultura, deixando assim com uma baixa densidade, pode fazer com que a água dos tanques fiquem mais sujas devido a quantidade de alimentação que está em excesso nos tanques. O contrário, seria uma alta densidade, onde teria mais larvas que o valor que foi passado. Isso pode gerar outra série de problemas, bem como uma taxa de mortalidade por conta do oxigênio, além de gerar canibalismo, onde as larvas passam a comer umas às outras por falta de alimento.

Diante disso, o artigo aqui presente, tem trabalhado diretamente com a possibilidade de solucionar essa dor dos laboratórios na contagem de náuplios, com o uso de inteligência artificial.

6.2 Alcance da Nauplius

Nessa subseção passaremos maiores informações sobre o alcance do projeto nauplius, como seu uso em laboratórios, seu alcance no mundo e eventos onde o nauplius tem chegado.

6.2.1 Apresentação em Eventos

No ano de 2023 nós da Nauplius tivemos a oportunidade de participarmos do Siará Tech Summit 2023, o evento foi realizado no centro de eventos de Fortaleza nos dias 7 e 8 de novembro de 2023. O mesmo é considerado o maior evento de inovação do norte e nordeste, na oportunidade fomos visitados por muitas pessoas no nosso stand além de investidores que estavam também presentes no evento. Aqui avaliamos ideias de futuras funcionalidades para nosso aplicativo, além de possibilitar a experiência real dos visitantes poderem testar o método de contagem manual e o método utilizando o aplicativo para realização da detecção e contagem de náuplios automaticamente. A Figura 11 mostra membros da equipe Nauplius participando do Siará Tech Summit.



Figura 11 – Registro de parte da equipe da Nauplius no Siará Tech Summit

6.2.2 Uso na Maris

O laboratório Maris Pescados tem sido um braço forte para o desenvolvimento do aplicativo. Por meio de uma parceria com o laboratório foi possível realizarmos a captura das imagens para a construção do dataset que utilizamos para realização dos treinamentos. Além disso, a Maris Pescado tem sido nosso maior ponto de apoio para realização de testes do aplicativo, onde temos obtido muitos *feedbacks*. Um dos entrevistados falou que com o uso do aplicativo, irá gerar resultados mais precisos e confiáveis, fazendo com que não haja dúvidas e

desconfianças entre os setores de larvicultura e maturação. Outro funcionário disse ainda que com o aplicativo eles irão ganhar tempo, além de que os náuplios levaram menos tempo dentro do baldes de 40 litros, com isso, além da contagem ser rápida e precisa ainda influenciará em mais rapidez e eficiência no momento da estocagem. A maioria dos entrevistados deram a indicação para outros tipos de contagens dentro dos laboratórios de pós-larva.

6.2.3 *Participação no AWC 2023/2024*

No ano de 2023 submetemos o projeto nauplius para o AWC, programa que dá incentivo financeiro para tornar TCC's em negócios.¹ Fomos aprovados para participarmos do programa e desde então temos passado por mentorias, participado de workshops e feito muitos networks. O programa tem agregado muito valor ao projeto, nos levando a realizarmos entrevistas com potenciais clientes e validando cada ideia de negócio. O encerramento do programa se deu após oito meses de atividades, onde os projetos que se mantiveram no programa, tiveram a oportunidade de apresentarem suas startups na 8º Feira de Investimento da AWC. Na Figura 12 estou realizando a apresentação da startup Nauplius.



Figura 12 – Registro da apresentação da startup Nauplius na 8º Feira de Investimento da AWC

6.2.4 *Submissão e Aprovação no SBSI*

No início de 2024 submetemos uma versão do artigo Nauplius, para o Simpósio Brasileiro de Sistemas de Informação SBSI, o evento está em sua 20º edição e trá por tema "Perspectivas e Tendências dos Sistemas de Informação na Agricultura Digital". Com tamanho impacto do tema, o evento nos chamou atenção como oportunidade de publicação. Submetemos então o artigo e no dia 26 de março recebemos um e-mail nos informando da aprovação do artigo para publicação e apresentação no evento.² Nos dias 20 a 23 de maio de 2024 foi realizado o SBSI em sua 20º

¹ <https://awc.institutotim.org.br/>

² <https://sol.sbc.org.br/index.php/sbsi_estendido/article/view/28612>

edição na cidade de Juiz de Fora-MG, onde então, tivemos a oportunidade de estarmos realizando a apresentação do Artigo Nauplius. Na figura 12 mostro o registro da nossa apresentação.



Figura 13 – Apresentação do artigo Nauplius no 20º SBSI em Juiz de Fora - MG

Na próxima seção será apresentado os resultados obtidos ao longo dos testes, também o passo a passo utilizado para validar a proposta, bem como nossas visitas técnicas em laboratórios.

6.3 Resultados alcançados e Discussão

Os resultados obtidos para o dataset de imagens que foram cortadas em 16 partes e que foi dividido em 70% para treinamento, 20% para validação e 10% para testes, estão expostos na Tabela 2, destacando a evolução dos treinamentos realizados, levando em consideração as métricas de Precisão, recall e AP@50.

Inspecionando a Tabela 2, é possível observar a evolução da arquitetura escolhida para a problemática abordada ao longo deste trabalho. Como visto na tabela, a versão 5 ganhou maior destaque, ficando com precisão de 97.3% e AP@50 de 98.1%. Essas métricas nos mostram que o modelo conseguiu de maneira eficiente identificar e contar o número de náuplios nas imagens.

| Interface | Precisão | Recall | AP@50 |
|------------------|-----------------|---------------|--------------|
| Versão 1 | | | |
| Náuplios | 66.7 | 66.5 | 55.2 |
| Versão 2 | | | |
| Náuplios | 73.4 | 72.8 | 63.4 |
| Versão 3 | | | |
| Náuplios | 80.9 | 77.0 | 72.9 |
| Versão 4 | | | |
| Náuplios | 84.1 | 80.7 | 77.5 |
| Versão 5 | | | |
| Náuplios | 97.3 | 94.8 | 98.1 |

Tabela 2 – Tabela de evolução dos treinamentos, da yolo v5 com o dataset das imagens cortadas em 16 partes

Como visto na subseção 5.1, foram realizados ainda outros treinamentos visando buscar melhores resultados com um novo modelo da YOLO, bem como uma outra versão do dataset que

por sua vez, foi utilizado as imagens inteiras. Para realização dos novos treinamentos, foi feito uso da yolo v5 novamente e da yolo v8 n. As imagens que foram utilizadas para construção do novo dataset, foram as mesmas utilizadas no treinamento da versão anterior, porém, as mesmas foram utilizadas inteiras e sem cortes e obteve ainda um acréscimo de mais 674 imagens.

O novo dataset ficou com 1674 imagens, todas foram devidamente rotuladas utilizando o roboflow. Com o novo conjunto de dados já pronto, realizamos treinamentos simultâneos com os modelos YOLO V5 e YOLO V8 n, ao longo dos treinamentos foi observado a evolução das métricas de Precisão, Recall e AP@50.

O modelo da YOLO V5 obteve um bom desempenho nos treinamentos, porém não superou as métricas obtidas para o modelo que fez uso do dataset contendo as imagens cortadas em partes. A melhor versão deste modelo com o dataset das imagens inteiras, obteve as seguintes métricas: P 0.96 % R 0.47% IoU 0.71

Quanto ao modelo da Yolo v8 n, também se mostrou promissor na detecção de náuplios nas imagens. Um dos pontos principais que se observou referente o modelo é que o mesmo não mostrava sobreposição de *Bounding Box* nas imagens. Porém as métricas de avaliação não foram tão satisfatórias quantos aos modelos anteriores, pois ficou com P 0.80 %, R 0.42% e IoU 0.64

Fazendo um comparativo entre os modelos e versões, é possível ver de forma clara que o modelo que melhor se enquadra para aplicação real em laboratórios de pós larvas de camarão é a versão da yolo v5 que foi treinada a partir do dataset que foi construído com as imagens cortadas em 16 partes. Na Tabela 3 é apresentado as métricas utilizadas para avaliação dos modelos, bem como os valores atingidos por cada modelo.

| Modelos | Precisão | Recall | AP@50 |
|------------------|-----------------|---------------|--------------|
| Yolo v5 | | | |
| Dataset - partes | 97.3 | 94.8 | 98.1 |
| Yolo v5 | | | |
| Imagens inteiras | 96.6 | 47.7 | 71.4 |
| Yolo v8 n | | | |
| Imagens inteiras | 80.6 | 42.4 | 64.1 |

Tabela 3 – Tabela de evolução dos treinamentos, da yolo v5 com o dataset das imagens cortadas em 16 partes

Vale destacar que para uma boa detecção dos náuplios a imagem precisa estar significativamente com boa qualidade, de forma a ser possível ver os náuplios e então realizar a detecção e contagens da classe dentro da placa de Petri. A Figura 14 apresenta detecções realizadas com a versão 5, modelo que mostrou melhores resultados. Para fazermos uso do modelo que foi treinado com as partes, para contagem em imagens inteiras, fizemos uso de outro algoritmo para pegar a imagem inteira e cortá-la em 16 partes, na sequência a imagem passa pelo algoritmo de contagem e posteriormente o algoritmo junta as partes da imagem novamente, retornando a imagem inteira marcada.

A fim de mostrar resultados reais de testes realizados nos laboratórios da Maris, expinho na Tabela 4 resultados de algumas das contagens realizadas pelos técnicos responsáveis,

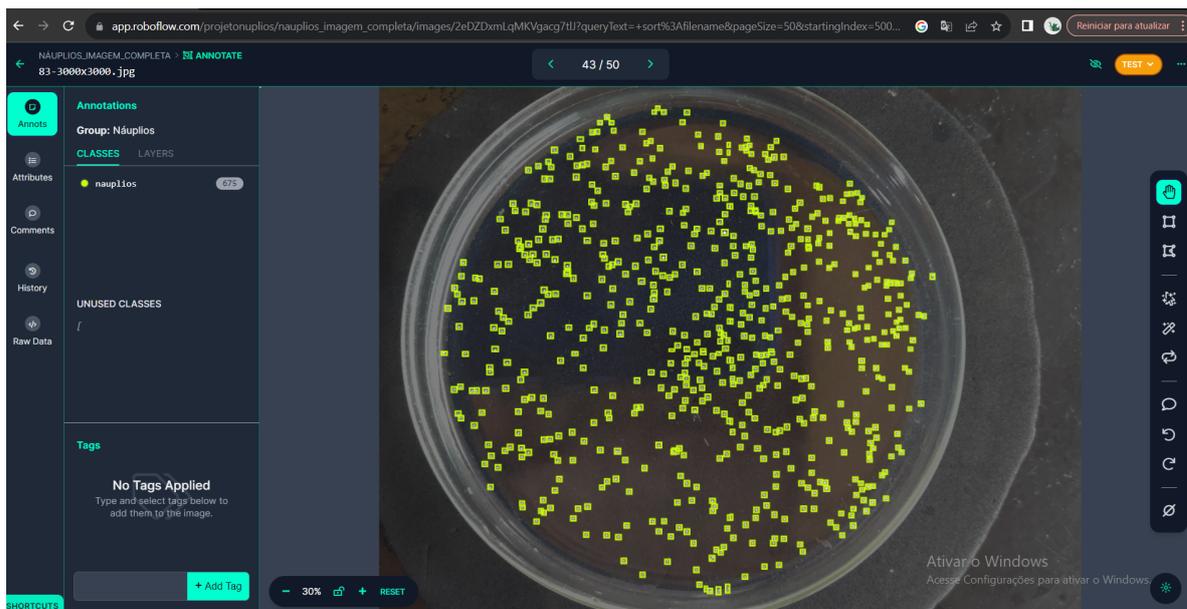


Figura 14 – Tela do *RoboFlow* mostrando as marcações realizadas com a versão 5 aplicando para imagem inteira

bem como contagens realizadas pelo algoritmo. Com o propósito de explorarmos o máximo de situações possíveis, realizamos testes com quantidades diferentes, semelhante ao método tradicional. Ao invés de colocar a amostra toda de uma vez só para realizar a contagem, em algumas dividimos a amostra em três, realizando então a contagem de forma gradativa com um número menor de náuplios em cada amostra como vemos nas datas 23/02/2024 a 25/03/2024 onde obtive se um número menor de náuplios para cada amostra.

| Data das contagens | Técnico | Nauplius | Diferença |
|--------------------|---------|----------|-----------|
| 23/02/2024 | 400 | 404 | 1% |
| 23/02/2024 | 240 | 244 | 1% |
| 24/02/2024 | 340 | 365 | 6% |
| 24/02/2024 | 525 | 530 | 1% |
| 25/02/2024 | 590 | 597 | 1% |
| 25/02/2024 | 1190 | 1205 | 1% |
| 25/02/2024 | 735 | 740 | 1% |
| 28/02/2024 | 896 | 904 | 0,008% |
| 28/02/2024 | 945 | 951 | 0,006% |
| 01/03/2024 | 1233 | 1253 | 1% |
| 01/03/2024 | 1245 | 1260 | 1% |
| 01/03/2024 | 1304 | 1339 | 2% |

Tabela 4 – Tabela de resultados comparativos entre a contagem realizada pelos técnicos e o melhor modelo da Nauplius

7 CONCLUSÃO

Este estudo apresenta avanços substanciais na detecção de náuplios na fase N3 em placas de Petri, utilizando uma abordagem inovadora que integra aprendizado de máquina e dispositivos móveis. Os resultados obtidos indicam que o modelo treinado demonstrou um desempenho promissor, destacando-se na tarefa específica de identificação precisa desses organismos em diferentes condições de captura de imagem.

A colaboração com o laboratório Maris e a utilização de smartphones, aliados ao suporte de impressão 3D desenvolvido no laboratório do IFCE, proporcionaram um ambiente controlado para a captura de imagens, garantindo consistência nos dados coletados. A abordagem semi-supervisionada na anotação das imagens, empregando a plataforma *RoboFlow*, mostrou-se eficaz na aceleração do processo, permitindo a marcação de um grande volume de dados de maneira eficiente.

O processo iterativo de treinamento, avaliação e ajuste de hiperparâmetros foi fundamental para otimizar o desempenho do modelo. As métricas de avaliação, incluindo AP@50, Precisão e Recall, foram criteriosamente monitoradas durante o treinamento, assegurando a confiabilidade do modelo na detecção de náuplios na fase N3. A utilização da GPU no Google Colab contribuiu para treinamentos mais rápidos e eficientes em comparação com abordagens que dependem exclusivamente de CPU.

No entanto, reconhecemos que o sucesso do treinamento depende significativamente da qualidade das anotações iniciais e da representatividade do conjunto de dados. A continuidade do aprimoramento do modelo é crucial, envolvendo a inclusão de dados adicionais e refinamentos contínuos para garantir sua eficácia em ambientes de laboratórios de pós-larva em aquicultura.

Os resultados desta pesquisa têm implicações práticas significativas para a área de aquicultura, oferecendo uma ferramenta promissora para a detecção automatizada de náuplios na fase N3. A metodologia desenvolvida neste estudo pode servir como base para futuras pesquisas na aplicação de técnicas de aprendizado de máquina em ambientes aquáticos, contribuindo para o avanço da monitorização e manejo de organismos aquáticos em contextos de aquicultura.

REFERÊNCIAS

- ALBUQUERQUE, D. et al. Aplicando um modelo yolo para detectar e diferenciar por imagem castas de abelhas melíferas de forma automatizada. In: **Anais do XIII Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais**. Porto Alegre, RS, Brasil: SBC, 2022. p. 51–60. ISSN 2595-6124. Disponível em: <<https://sol.sbc.org.br/index.php/wcama/article/view/20696>>.
- ARAÚJO, C. et al. Socioeconomic impacts of aquaculture development in coastal communities: A case study in northeastern brazil. **Aquaculture Economics & Management**, v. 24, n. 4, p. 415–430, 2020.
- BEESTREAM. 2023. <<https://beemon.cs.appstate.edu/>>. Acessado em: 31 ago. 2023.
- BESSA-JUNIOR, A. Cultivo de camarão marinho em tanques-rede/culture of marine shrimp in cages. **Acta of Fisheries and Aquatic Resources**, v. 2, n. 2, p. 65–81, 2014.

BESSA, W. R. B. Soluções baseadas em redes neurais convolucionais para contagem automática de animais aquáticos. Centro de Ciências Exatas e Naturais-CCEN, 2022.

COSTA, E. L. da et al. Produção de alimento vivo para larvicultura de tambaqui colossoma macropomum. **Educamazônia-Educação, Sociedade e Meio Ambiente**, v. 17, n. 01, p. 78–88, 2024.

COUNTTHINGS. **CountThings**. 2011–2023. Aplicativos de contagem automática para automação industrial e transformação digital. Disponível em: <<https://countthings.com/>>.

FRÓES, C. et al. Densidade de estocagem na engorda de camarão-branco cultivado em sistema de biofoco. **Pesquisa Agropecuária Brasileira**, SciELO Brasil, v. 48, p. 878–884, 2013.

GOMES, H. et al. Artificial intelligence in aquaculture: A review. **Computers and Electronics in Agriculture**, v. 163, p. 104861, 2019.

GOMES, J. V. E. Detecção de objetos com a arquitetura yolo. 2022.

HE, K. et al. Mask r-cnn. In: **Proceedings of the IEEE international conference on computer vision**. [S.l.: s.n.], 2017. p. 2961–2969.

INVE. **Snappart**. 2023. SNAPPART: UMA SOLUÇÃO REVOLUCIONÁRIA PARA QUANTIFICAÇÃO ULTRAPRECISA DE ARTEMIA E ROTÍFEROS. Disponível em: <<https://www.inveaquaculture.com/snappart-a-revolutionary-solution-for-ultra-precise-artemia-and-rotifer-quantification/>>.

JATOBÁ, A. et al. Automation and control systems in shrimp farming: A review. **Computers and Electronics in Agriculture**, v. 137, p. 1–12, 2017.

JUNIOR, G. F. G. **Avaliação do uso de náuplios de Artemia salina em conserva no cultivo larval do camarão marinho Litopenaeus vannamei**. Dissertação (B.S. thesis) — Brasil, 2021.

LI, X. et al. Automatic penaeus monodon larvae counting via equal keypoint regression with smartphones. **Animals**, v. 13, n. 12, 2023. ISSN 2076-2615. Disponível em: <<https://www.mdpi.com/2076-2615/13/12/2036>>.

LIU, W. et al. Ssd: Single shot multibox detector. In: SPRINGER. **Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14**. [S.l.], 2016. p. 21–37.

LOPES, M.; SANTOS, R. Technological innovations in shrimp farming: A review. **Aquaculture**, v. 491, p. 69–78, 2018.

MATUCK, G. R. et al. Reconhecimento facial com inteligência artificial utilizando a plataforma roboflow. **Revista Prociências**, v. 6, n. 2, p. 114–131, 2023.

MOURA, I. R. de et al. Modelo de avaliação de laboratórios produtores de pós-larva de camarão marinho utilizando o método fitradeoff. **Brazilian Journal of Development**, v. 7, n. 1, p. 1385–1400, 2021.

MOURA, N.; CLARO, D. B.; GONDIM, J. M. Análise experimental para a detecção de objetos em vídeos de câmeras de vigilância: Uma abordagem para porte de arma, incêndio e pichação. In: SBC. **Anais Estendidos do XXVII Simpósio Brasileiro de Sistemas Multimídia e Web**. [S.l.], 2021. p. 37–40.

NUNES, A. J. P. O cultivo de camarões marinhos no nordeste do Brasil. **Panorama da Aquicultura**, v. 11, n. 65, p. 26–33, 2001.

OLIVEIRA, C. L. Atalaia: Aperfeiçoamento de sistema para reconhecimento automático de placas de licença automotiva e construção de um produto para segurança de áreas restritas. DCOMP-Departamento de Computação–Engenharia de Computação–São Cristóvão . . . , 2023.

OTONE, G. S. Detecção automática da região de identificação de vagões utilizando visão computacional. Serra, 2023.

REDMON, J. et al. You only look once: Unified, real-time object detection. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2016. p. 779–788.

REIS, G. et al. Avaliação de técnicas de detecção de pedestres para veículos autônomos. In: SBC. **Anais do XXII Workshop em Desempenho de Sistemas Computacionais e de Comunicação**. [S.l.], 2023. p. 61–72.

REN, S. et al. Faster r-cnn: Towards real-time object detection with region proposal networks. **Advances in neural information processing systems**, v. 28, 2015.

SENAR. **Larvicultura de camarão marinho: do náuplio a pós-larva**. Brasília, 2016.

SGANDERLA, G. et al. Detecção e classificação de objetos presentes em imagens aéreas de drones de ambientes urbanos. In: **Anais Estendidos do XXXIV Conference on Graphics, Patterns and Images**. Porto Alegre, RS, Brasil: SBC, 2021. p. 223–227. ISSN 0000-0000. Disponível em: <https://sol.sbc.org.br/index.php/sibgrapi_estendido/article/view/20043>.

SILVA, D. et al. Applying computer vision models to detect in real time the pollen flow at the input of honeybee hives (apis mellifera l.). In: **Anais do XIV Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais**. Porto Alegre, RS, Brasil: SBC, 2023. p. 21–30. ISSN 2595-6124. Disponível em: <<https://sol.sbc.org.br/index.php/wcama/article/view/25091>>.

SILVA, G. R. et al. Detecção de objetos em imagens utilizando técnicas de aprendizagem profunda. Florianópolis, SC, 2018.

VALENTI, W. C. et al. Processo de produção de pós-larvas do camarão-da-amazônia. 2020.

VIOLA, P.; JONES, M. Rapid object detection using a boosted cascade of simple features. In: IEEE. **Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. CVPR 2001**. [S.l.], 2001. v. 1, p. I–I.

YANG, G. et al. Face mask recognition system with yolov5 based on image recognition. In: IEEE. **2020 IEEE 6th International Conference on Computer and Communications (ICCC)**. [S.l.], 2020. p. 1398–1404.