

**INSTITUTO
FEDERAL**

Amazonas

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO

AMAZONAS - CAMPUS DISTRITO

ENGENHARIA DE CONTROLE E AUTOMAÇÃO

YTALO RIBEIRO DA SILVA PEDROSO

USO DE REDES NEURAIIS PARA IDENTIFICAÇÃO DE EMBARCAÇÕES

MANAUS - AM

2024

YTALO RIBEIRO DA SILVA PEDROSO

USO DE REDES NEURAIIS PARA IDENTIFICAÇÃO DE EMBARCAÇÕES

Trabalho de Conclusão de Curso (TCC) apresentado ao curso de Engenharia de Controle e Automação do INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO AMAZONAS - CAMPUS DISTRITO, como requisito parcial para obtenção do grau de bacharel em Engenharia de Controle e Automação.

Orientador: Prof. Dr. Alyson de Jesus dos Santos

MANAUS - AM

2024

Dados Internacionais de Catalogação na Publicação (CIP)

P372u Pedroso, Ytalo Ribeiro da Silva.
Uso de redes neurais para identificação de embarcações / Ytalo
Ribeiro da Silva. — Manaus, 2024.
49f.: il. color.

Monografia (Graduação) — Instituto Federal de Educação, Ciência e
Tecnologia do Amazonas, *Campus* Manaus Distrito Industrial, Curso de
Engenharia de Controle e Automação, 2024.

Orientador: Prof.º Alyson de Jesus dos Santos, Dr.

1. Inteligência artificial. 2. Redes neurais. 3. Sistemas embarcados. 4.
Hidrovias I. Santos, Alyson de Jesus dos. II. Instituto Federal de
Educação, Ciência e Tecnologia do Amazonas. III. Título.

CDD 629.895

Elaborada por Oziane Romualdo de Souza (CRB11/ nº 734)

ANEXO 7

ATA DE DEFESA PÚBLICA DO TRABALHO DE CONCLUSÃO DE CURSO

Aos 08 dias do mês de Abri, de 2024, às 19 h, o(a) discente Ytaes Ribeiro da Silva Pedroso apresentou o seu Trabalho de Conclusão de Curso para avaliação da Banca Examinadora constituída pelos seguintes integrantes: Prof(a). Alyson de Jesus dos Santos (docente-orientador), Prof(a). _____ (coorientador), Prof(a). Daniel Fonseca de Souza (Membro 1) e Prof(a). Marcos André Silva Rodrigues (Membro 2). A sessão publica de defesa foi aberta pelo(a) presidente da banca, que apresentou a Banca Examinadora e deu continuidade aos trabalhos, fazendo uma breve referência ao TCC, que tem como título Uso de Redes Neurais para Identificação de Embarcações em prol da Segurança Pública. Na sequência, o(a) discente teve até 30 minutos para a comunicação oral de seu trabalho. Cada integrante da banca examinadora fez suas arguições após a defesa do mesmo. Ouvidas as explicações do(a) discente, a banca examinadora, reunida em caráter sigiloso, para proceder à avaliação final, deliberou e decidiu pela APROVAÇÃO com média final 9,7 (Nove, sete)

do referido trabalho.

Foi dada ciência ao(à) discente que a versão final do trabalho deverá ser entregue até o dia 08/05/2024, com as devidas alterações sugeridas pela banca. Nada mais havendo a tratar, a sessão foi encerrada às 20 h 15 min, sendo lavrada a presente ata, que, uma vez aprovada, foi assinada por todos os membros da Banca Examinadora e pelo(a) discente.

Prof.(a) Orientador(a)/Presidente: Alyson de Jesus dos Santos

Prof.(a) Avaliador 1: Daniel Fonseca de Souza

Prof.(a) Avaliador 2: José Pedro

Discente: Ytaes Ribeiro da Silva Pedroso

AGRADECIMENTOS

Primeiramente, gostaria de expressar minha profunda gratidão aos meus pais pelo amor incondicional que têm me dedicado ao longo de toda a minha vida. Seu apoio inabalável tornou possível minha jornada acadêmica e a busca por melhorias em nossas vidas. Para eles, meu eterno agradecimento.

Agradeço imensamente aos meus amigos Paulo e Rafael pelo apoio constante e companheirismo ao longo de todo o período acadêmico, sendo os maiores incentivadores para a conclusão deste trabalho.

Quero agradecer à minha namorada, Bruna, pela sua compreensão e apoio nos momentos em que eu não me senti confiante. Sua presença foi fundamental e sou grato por tudo.

Aos membros da equipe do projeto na matéria de Inteligência Computacional, Pedro Ivan, Rafael(novamente), Rebecca e Vitor, pelo suporte para conseguirmos gerar este dataset.

Também sou grato a todos os amigos que estiveram ao meu lado durante este período acadêmico, oferecendo ajuda e tornando a experiência universitária mais leve e memorável.

Por último, expresso minha gratidão ao meu orientador, o Professor Alyson de Jesus, pelo suporte essencial durante todo o projeto e pela orientação incisiva que foi fundamental para a conclusão bem-sucedida do trabalho.

"Isso é tudo pessoal!"

(Porky Pig)

RESUMO

Devido a sua geografia singular, os rios da Amazônia apresentam um papel relevante no cotidiano da região, inclusive sendo o único acesso em comunidades mais remotas, e a falta de infraestrutura em grande parte desta malha hidroviária torna propícia o transporte de mercadorias ilegais devido a falta de fiscalização.

Ao comparar com áreas urbanas, é possível notar a possibilidade de um auxílio positivo para as autoridades locais com o uso de tecnologias de reconhecimento, mas a falta de estruturas de comunicação prejudica a implementação dessas tecnologias da mesma forma que é feita nas cidades.

Este projeto propõe o desenvolvimento de uma aplicação de rede neural voltada para auxiliar em questões de segurança pública, através da detecção de embarcações em regiões portuárias localizadas no Estado do Amazonas, combinando as técnicas de Inteligência Artificial e os dispositivos de Sistemas Embarcados, sem uso de transmissão de dados em rede. A metodologia consiste em: (a) Aquisição de imagens de embarcações na Marina do Davi e no porto da Manaus Moderna - Estado do Amazonas; (b) Preparação do *dataset* no formato esperado pelo modelo; (c) Instalação, configuração e uso da Placa Jetson Nano no treinamento da Rede Neural; (d) Uso de *Transfer Learning*, aproveitamento de um modelo pré-treinado (YOLOv4 *Tiny*) para geração do modelo no novo conjunto de dados; (e) Validação dos resultados obtidos.

Os resultados mostram que com o uso de versões otimizadas para dispositivos embarcados, foi possível executar o algoritmo YOLOv4 *Tiny*, realizando a classificação das embarcações e contribuindo com novas imagens de embarcações, que entregam maior regionalidade aos dados apresentados.

Palavras-chave: Inteligência Artificial; Redes Neurais; Sistemas Embarcados; Hidrovias Amazônicas; Embarcações; Segurança Pública

ABSTRACT

Due to its unique geography, the rivers of the Amazon play a significant role in the daily life of the region, including being the only access in more remote communities, and the lack of infrastructure in much of this waterway network makes it conducive to the transport of illegal goods due to the lack of supervision.

When compared to urban areas, it is possible to notice the potential for positive assistance to local authorities through the use of recognition technologies, but the lack of communication structures hinders the implementation of these technologies in the same way it is done in cities. This project proposes the development of a neural network application aimed at assisting in public security issues through the detection of vessels in port regions located in the State of Amazonas, combining Artificial Intelligence techniques and Embedded Systems devices, without the use of network data transmission. The methodology consists of: (a) Acquisition of vessel images at Marina do Davi and the port of Manaus Moderna - State of Amazonas; (b) Preparation of the dataset in the expected format for the model; (c) Installation, configuration, and use of the Jetson Nano Board in training the Neural Network; (d) Use of Transfer Learning, leveraging a pre-trained model (YOLOv4 Tiny) for model generation on the new dataset; (e) Validation of the obtained results.

The results show that with the use of versions optimized for embedded devices, it was possible to execute the YOLOv4 Tiny algorithm, performing the classification of vessels and contributing with new vessel images, which provide greater regionality to the presented data.

Keywords: Artificial Intelligence; Neural Networks; Embedded System; Amazon Waterways; Boats; Public Safety

LISTA DE FIGURAS

Figura 1 – Redes Hidroviárias do Narcotráfico na Amazônia.	14
Figura 2 – Portos de Pequeno Porte em Operação.	18
Figura 3 – Lancha.	20
Figura 4 – Barco de Passeio em Porto Amazônico.	21
Figura 5 – Estrutura de Rede Neural.	23
Figura 6 – Aplicação da camada de convolução.	25
Figura 7 – Exemplo de predição realizada pelo <i>You Only Look Once</i> (YOLO).	27
Figura 8 – Exemplos de placas de Sistemas Embarcados.	29
Figura 9 – Placa Jetson Nano.	31
Figura 10 – Fluxo do Trabalho.	35
Figura 11 – Embarcações na Marina do Davi e Porto de Manaus.	36
Figura 12 – Equipe responsável pela captura de imagens.	37
Figura 13 – Formato de rótulo do YOLO.	38
Figura 14 – Ferramenta <i>Make Sense</i>	38
Figura 15 – Site oficial da NVIDIA.	40
Figura 16 – Biblioteca <i>Darknet</i>	40
Figura 17 – mAP do modelo gerado.	43
Figura 18 – Matriz Confusão da Classe Lancha.	45
Figura 19 – Matriz Confusão da Classe Barco de Passeio.	46

LISTA DE TABELAS

Tabela 1 – Projetos Relacionados.	34
Tabela 2 – Especificações da Placa	39
Tabela 3 – Parâmetros de Treinamento	42
Tabela 4 – Métricas Gerais do modelo com as imagens de Treinamento	44
Tabela 5 – Métricas da Classe Lancha com as imagens de Treinamento	44
Tabela 6 – Métricas da Classe Barco de Passeio com as imagens de Treinamento	44
Tabela 7 – Métricas da Classe Lancha com as imagens de Validação	45
Tabela 8 – Métricas da Classe Barco de Passeio com as imagens de Validação	46

LISTA DE ABREVIATURAS E SIGLAS

AP	<i>Average Precision</i>
IA	Inteligência Artificial
mAP	<i>Mean Average Precision</i>
ML	<i>Machine Learning</i>
RNA	Redes Neurais Artificiais
RNC	Redes Neurais Convolucionais
SSD	<i>Single Shot Detector</i>
YOLO	<i>You Only Look Once</i>

SUMÁRIO

1 INTRODUÇÃO	13
1.1 OBJETIVOS	15
1.1.1 Objetivo Geral	15
1.1.2 Objetivos Específicos	16
1.2 JUSTIFICATIVA	16
1.3 ESTRUTURA DO TRABALHO	16
2 REFERENCIAL TEÓRICO	18
2.1 TRANSPORTE HIDROVIÁRIO AMAZÔNICO	18
2.1.1 Meios de Transporte na Região Amazônica	19
2.1.1.1 Lanchas	19
2.1.1.2 Barcos de Passeio	20
2.2 INTELIGÊNCIA ARTIFICIAL (IA)	21
2.2.1 Machine Learning (ML)	22
2.2.2 Redes Neurais Artificiais (RNA)	23
2.2.2.1 Redes Neurais Convolucionais (RNC)	24
2.2.2.1.1 <i>You Only Look Once (YOLO)</i>	26
2.2.3 Transfer Learning	28
2.2.4 Métricas de Avaliação	28
2.3 SISTEMAS EMBARCADOS	29
2.3.1 Jetson Nano	31
3 TRABALHOS CORRELATOS	32
3.1 RESEARCH ON BOAT IDENTIFICATION BASED ON IMPROVED LOSS FUNCTION OF DEEP CONVOLUTIONAL NEURAL NETWORKS	32
3.2 EMBEDDED CNN BASED VEHICLE CLASSIFICATION AND COUNTING IN NON-LANED ROAD TRAFFIC	33
3.3 YOLO-RTUAV: TOWARDS REAL-TIME VEHICLE DETECTION THROUGH AERIAL IMAGES WITH LOW-COST EDGE DEVICES	33

3.4 TABELA COMPARATIVA DOS TRABALHOS RELACIONADOS	34
4 METODOLOGIA	35
4.1 PROCEDIMENTOS METODOLÓGICOS	35
4.1.1 Captura das Imagens	37
4.1.2 Tratamento das imagens	38
4.1.3 Configuração da Placa Jetson Nano	40
4.1.4 Instalação da biblioteca Darknet	41
4.1.5 Treinamento do modelo utilizando <i>Transfer Learning</i>	42
5 RESULTADOS	44
6 CONCLUSÕES E TRABALHOS FUTUROS	48
6.1 TRABALHOS FUTUROS	48
REFERÊNCIAS	50
APÊNDICES	55
APÊNDICE A - Código de Compressão e Redução da Imagem	55

1 INTRODUÇÃO

Na complexa geografia do norte do Brasil, os rios desempenham um papel fundamental como vias de transporte para cargas e passageiros, formando corredores de transporte essenciais que interligam não só as capitais e os centros urbanos, mas também as comunidades isoladas. A malha hidroviária da região, que supera os 16 mil quilômetros de vias navegáveis, é um eixo vital que suporta tanto o desenvolvimento socioeconômico quanto a cultura local. A importância desse sistema é corroborada por estatísticas da Agência Nacional de Transportes Aquaviários (ANTAQ) (2018) em colaboração com a Universidade Federal do Pará, revelando que, em 2017, os rios amazônicos foram responsáveis pelo transporte de 9,7 milhões de passageiros e aproximadamente 3,4 milhões de toneladas de cargas.

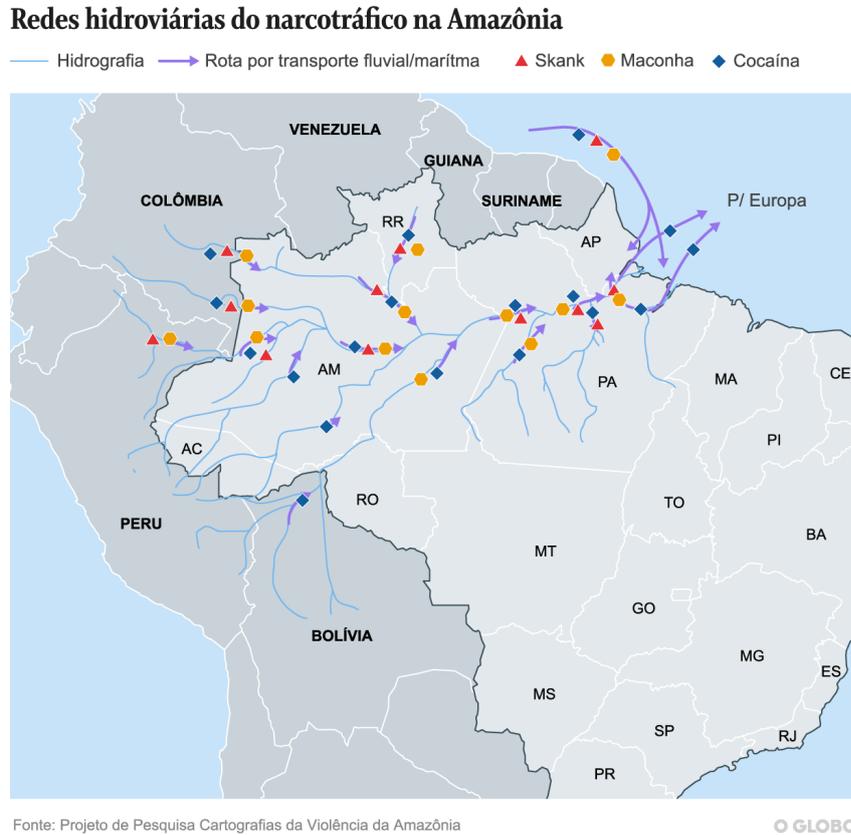
Neste ambiente, o Rio Amazonas se demonstra um reservatório essencial, detentor de aproximadamente um quinto do fornecimento global de água doce líquida e cobrindo uma área de mais de seis milhões de quilômetros quadrados, se destacando como um recurso hídrico sem igual em escala mundial (UNESCO, 2022).

Ao analisarmos especificamente o Estado do Amazonas, podemos observar, com base no relatório da Agência Nacional de Transportes Aquaviários (ANTAQ) (2018), que durante o ano de 2017, aproximadamente 1,7 milhões de passageiros e cerca de um milhão de toneladas de carga foram transportados por essas rotas. Essa intrincada rede hidroviária de transporte tem como epicentro de distribuição, organização e gestão a capital Manaus, conforme mostra a imagem 2, de onde a maioria dessas embarcações parte em direção aos municípios e localidades do estado. É importante ressaltar que essas rotas podem abranger distâncias que variam de dezenas a milhares de quilômetros.

Essa grande extensão aliada a falta de infraestrutura, é propícia ao crescimento da criminalidade na região, de acordo com a publicação Cartografias da violência na Amazônia do Fórum Brasileiro de Segurança Pública (FBSP) (2023), a expansão contínua do crime organizado na região está intrinsecamente ligada à falta de estrutura e fiscalização adequadas das hidrovias. Em meio à disputa entre grupos criminosos pelo interior da Amazônia, uma área estratégica para os negócios ilícitos como mostra a Figura 1, como o escoamento de drogas, garimpo e extração de madeira, a ausência de controle efetivo nas vias fluviais tem contribuído para o aumento desses casos. A pesquisa revela a presença estimada de 22 facções vinculadas ao narcotráfico na região, tanto de grupos nacionais como de países fronteiriços ao Brasil. Estima-se que pelo menos 178 cidades da Amazônia Legal vivenciem a presença desses grupos, afetando cerca de

57,9% da população da região.

Figura 1 – Redes Hidroviárias do Narcotráfico na Amazônia.



Fonte: GLOBO (2020)

O crescimento exponencial das atividades de garimpo, especialmente entre 2018 e 2022, reflete a intensificação do garimpo ilegal, impulsionado pela fragilidade no controle e fiscalização das rotas fluviais. Além disso, o aumento das apreensões de cocaína pelas polícias estaduais e pela Polícia Federal na região, entre 2019 e 2022, destaca a crescente atividade do narcotráfico nas hidroviárias amazônicas. O relatório também ressalta o crescimento das plantações de coca em 2021, apontando para uma ampliação do volume disponível para apreensão em todo o mundo, enfatizando a importância de medidas eficazes de controle e fiscalização nas rotas fluviais para conter o avanço dessas atividades ilícitas.

O uso de inteligências artificiais no cotidiano da sociedade pode se tornar um auxílio relevante no ambiente apresentado, já que essas tecnologias são comuns em metrópoles e adaptadas a cenários urbanos. Nessas áreas a infraestrutura de comunicação permite melhor acesso à informação, onde dados ficam disponíveis ao usuário com maior rapidez. Dentre

as tecnologias disponíveis estão serviços relacionados ao transporte urbano, onde é possível realizar a identificação automática de veículos através de placas ou características específicas dos mesmos.

Porém, em regiões mais remotas e com serviços de comunicação limitados, essa acessibilidade fica comprometida, para essas áreas o acesso a serviços de comunicação de maior velocidade é precário, indisponibilizando tecnologias disponíveis nesses centros urbanos, especialmente na região da Amazônia, onde apenas 76% dos domicílios têm acesso à internet. No estado do Amazonas, a situação é ainda mais restrita, sendo o interior a área mais afetada pela dificuldade de conexão. Os dados do Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (2022), provenientes da Pesquisa sobre o Uso das Tecnologias de Informação e Comunicação nos Domicílios Brasileiros, destacam que a conexão móvel é predominante na região, representando 27% dos acessos, sendo uma conexão com problemas de instabilidade e baixa qualidade de conexão.

Além da questão de comunicação, ao sairmos do ambiente urbano é necessária adaptação para as diferentes localidades, passamos a ter vias, veículos e meios diferentes de locomoção. Essa nova realidade exige de diferentes métodos para auxiliar autoridades públicas a exercerem suas funções e manter a organização nesses ambientes.

Sendo assim, a questão norteadora para esse trabalho, pode ser assim apresentada: “Seria viável o uso de tecnologias de reconhecimento de imagem para embarcações em regiões como a Amazônia?”

Como possível resposta a esse questionamento hipotetizamos o uso de sistemas embarcados, que são dispositivos eletrônicos dedicados a executar tarefas específicas, podendo estes ser móveis e independentes do uso de internet, viabilizando o uso da tecnologia de reconhecimento em áreas remotas. Estes dispositivos teriam a capacidade de implementar soluções como as redes neurais, sendo esta treinada para a identificação de embarcações. Além da questão de conexão, o sistema necessitaria de menor consumo de energia, se tornando mais viável para uso de forma portátil.

1.1 Objetivos

1.1.1 *Objetivo Geral*

Explorar o uso de redes neurais para identificação dos tipos de embarcações, dividindo entre lanchas e barcos de passeio, utilizando dispositivos embarcados para a geração do modelo e validação da eficácia do mesmo, visando entregar mobilidade a essa tecnologia e torná-la disponível em ambientes remotos.

1.1.2 *Objetivos Específicos*

- **Coletar Dados:** capturar imagens de embarcações em ambientes reais (Marina do Davi e Porto da Manaus Moderna) diversificando os ângulos de captura, visando ter maior regionalidade nos dados coletados, para melhor validação no ambiente hidroviário amazônico.
- **Preparar Dataset:** realizar o processo de identificação dos pontos em que as embarcações, de acordo com a sua devida classe (lanchas ou barcos de passeio), estão dispostos em cada imagem para uso dos dados na construção do modelo.
- **Utilizar um dispositivo de sistema embarcado para a geração do modelo:** gerar o modelo utilizando um dispositivo embarcado com alto poder de processamento e independente de conexões de rede, devido as limitações em transmissão de dados, sendo utilizada a placa Jetson Nano.
- **Implementar o conceito de *Transfer Learning*:** aplicar o processo de *Transfer Learning* para a geração do modelo visando ter uma economia de processamento na geração do modelo, sendo utilizado o modelo YOLOv4 *Tiny* como base para o processo, aproveitando de camadas já existentes no modelo consolidado para reduzir o tempo e quantidade de imagens necessárias para a geração de um modelo personalizado com maior acurácia.
- **Validar os resultados obtidos:** verificar a precisão e eficácia do modelo empregando a Jetson Nano e utilizando como dados de entrada imagens presentes na internet e parte do *dataset* feito para a validação.

1.2 Justificativa

A possibilidade de serviços desse tipo em regiões remotas representaria um ganho para segurança e fiscalização de embarcações. Apesar de melhorias de infraestrutura serem

necessárias para uma solução permanente, esta solução seria capaz de obter resultados inclusive nas atuais condições. Do ponto de vista acadêmico teríamos um trabalho relacionado a Redes Neurais visando um ambiente que não é muito explorado, podendo levar a novos *insights* sobre diversas aplicações que podem ter seu uso validado nestes ambientes.

1.3 Estrutura do Trabalho

Com base nos estudos realizados e referenciados por artigos, teses, livros e outros trabalhos de conclusão de curso se deu início a construção do presente trabalho, onde posteriormente foi possível realizar a aplicação dos conhecimentos nos modelos de redes neurais. Sendo este organizado da seguinte forma. No Capítulo 2 é feito o embasamento teórico, apresentando conceitos relevantes a problemática apresentada, sendo estes o Transporte Hidroviário Amazônico e Meios de Transporte utilizados, e também sobre os aportes técnicos do trabalho, mencionando Inteligência Artificial, Redes Neurais e Sistemas Embarcados. No Capítulo 3 temos os trabalhos relacionados usados como referência que fazem uso de Redes Neurais para processos de identificação. No Capítulo 4 é apresentado os processos realizados durante o trabalho, desde a captação das imagens até a geração do modelo no dispositivo embarcado. No Capítulo 5 é apresentado os resultados obtidos com o modelo gerado, através de dados e gráficos sobre o modelo aplicado em novos conjuntos de dados. No Capítulo 6 concluímos com contribuições, aprendizados e novos rumos possíveis para continuidade do trabalho.

Aquaviários (ANTAQ) (2015) sobre vias economicamente navegáveis do país, as principais hidrovias do país são as seguintes: Amazônica (17.651 quilômetros), Tocantins-Araguaia (1.360 quilômetros), Paraná-Tietê (1.359 quilômetros), Paraguai (591 quilômetros), São Francisco (576 quilômetros) e Sul (500 quilômetros). A região amazônica detém 80% das hidrovias, com destaque para o complexo Solimões-Amazonas. Segundo a pesquisa, o transporte hidroviário é significativamente mais econômico em termos de custo, capacidade de carga e impacto ambiental se comparado ao transporte rodoviário e ferroviário, além de ser o único meio disponível na região

Segundo dados do Departamento Nacional de Infraestrutura de Transportes (2018) em 2018, o Rio Amazonas é a principal rota de transporte e distribuição de cargas na região Norte, respondendo por aproximadamente 65% do total transportado na área. Estendendo-se por 1.646 km, atravessa as bacias dos rios Foz do Amazonas, Jatapu, Madeira, Negro, Paru, Tapajós, Trombetas e Xingu, e se conecta à hidrovia do Solimões. Entre suas características notáveis está a navegabilidade praticamente ininterrupta de seus afluentes, devido à profundidade adequada de suas calhas e à ausência de obstáculos como corredeiras na planície amazônica. Essa hidrovia facilita o transporte de passageiros, pequenas cargas e a maior parte do transporte de cargas destinadas aos grandes centros regionais, como Belém (PA) e Manaus (AM). A infraestrutura hidroviária desempenha um papel crucial no comércio interno e externo da região Norte, proporcionando a oferta de produtos a preços competitivos. Atualmente, ela consiste em vias de navegação em corrente livre e trechos de rios canalizados, garantindo o fluxo contínuo de mercadorias e o desenvolvimento econômico da região.

2.1.1 Meios de Transporte na Região Amazônica

A região amazônica, com sua vasta extensão de rios e densa floresta tropical, apresenta desafios únicos em termos de transporte e mobilidade. Meios de transporte aquático desempenham um papel crucial na conectividade e acessibilidade dessa região, permitindo o deslocamento de pessoas, mercadorias e recursos naturais em uma área de difícil acesso por meios terrestres tradicionais. Entre os principais meios de transporte na região amazônica, destacam-se as lanchas e os barcos de passeio (CARVALHO; SOUZA, 2019).

2.1.1.1 Lanchas

As lanchas na região amazônica são embarcações de propulsão a motor que desempenham um papel crucial no transporte fluvial ao longo dos vastos rios da Amazônia(Figura 3). São caracterizadas por sua agilidade, velocidade e capacidade de navegar em águas rasas, tornando-as ideais para a locomoção rápida e eficiente na região(ROSA; SILVA, 2018).

Figura 3 – Lancha.



Fonte: Santin (2010)

Essas embarcações são utilizadas para uma variedade de fins, incluindo transporte de passageiros, entrega de suprimentos, pesca e turismo. São frequentemente encontradas em comunidades ribeirinhas, servindo como meio de transporte essencial para conectar áreas remotas e isoladas às cidades e centros urbanos(COSTA; SOUZA, 2020). Sua versatilidade e adaptabilidade às condições fluviais desafiadoras da Amazônia as tornam uma escolha popular para o transporte regional.

Em resumo, as lanchas na região amazônica desempenham um papel vital no transporte e na conectividade da região, desafiando as condições únicas do ambiente fluvial amazônico.

2.1.1.2 Barcos de Passeio

Os Barcos de passeio(Figura 4) na região amazônica são embarcações essenciais para o transporte de passageiros e mercadorias ao longo dos extensos rios amazônicos(SILVA; MIRANDA, 2020). Estas embarcações, muitas vezes chamadas de "barcos regionais"ou "barcos de linha", desempenham um papel vital na conectividade e no acesso às comunidades remotas e dispersas ao longo das margens dos rios da Amazônia.

Figura 4 – Barco de Passeio em Porto Amazônico.



Fonte: Carvalho (2014)

Os barcos de passeio na região amazônica apresentam uma variedade de formas e tamanhos, desde pequenas embarcações a motor até grandes navios equipados com alojamentos para passageiros e carga(IBAMA, 2018). Sua adaptação às condições fluviais e à geografia da região permite que ofereçam serviços de transporte confiáveis e acessíveis, muitas vezes servindo como a principal via de comunicação e comércio para as populações ribeirinhas.

Essas embarcações são caracterizadas por sua capacidade de navegar em águas rasas e de penetrar em áreas de difícil acesso, tornando-as uma opção viável para alcançar comunidades remotas que não são facilmente acessíveis por outros meios de transporte. Além disso, os barcos de passeio desempenham um papel importante no turismo regional, oferecendo viagens panorâmicas ao longo dos rios amazônicos, proporcionando aos turistas uma oportunidade única de explorar a vasta biodiversidade e as paisagens exuberantes da região(BARBOSA *et al.*, 2017).

2.2 Inteligência Artificial(IA)

Na evolução da produção em vários setores temos máquinas substituindo o esforço humano em busca de evitar expor trabalhadores a trabalhos pesados ou lesões por esforço repetitivo. Mesmo isso sendo muito associado a esforços manuais em que robôs ou outros dispositivos físicos auxiliam os trabalhadores em seus serviços, essa evolução também chega ao campo de análise de dados, onde tecnologias são utilizadas para substituir a capacidade humana de interpretação(WEISS *et al.*, 2017). Os dados que passam por análises mencionados anteriormente, podem se tratar de reconhecimento de voz, imagens, e informações em grande volume.

De acordo com Martins *et al.* (2020), uma Inteligência Artificial (IA) se trata de uma estrutura composta e articulada por softwares e também hardwares, que possui a finalidade de auxiliar os seus usuários a tomar decisões baseados na associação de dados históricos e no reconhecimento de padrões.

Com esses conceitos estabelecidos temos a IA como uma tecnologia criada por pessoas com capacidade de realizar interpretações. Isso não indica que a IA precisa ter interação com pessoas, ou realizar ações humanas, mas que seu maior objetivo será o cumprimento da tarefa na qual foi treinada(DAMACENO; VASCONCELOS, 2018).

Para a criação dessa tecnologia é necessário um processo de aprendizado, havendo diferentes métodos aplicados atualmente, sendo estes determinados de acordo com a aplicação a qual esta tecnologia será projetada.

2.2.1 *Machine Learning (ML)*

Machine Learning (ML) é uma área da IA que trata dos processos de desenvolvimento de algoritmos e técnicas que tornam possível o aprendizado de um sistema. O processo não é realizado através de uma sequência de instruções específicas, mas expondo o sistema a exemplos passados para que o mesmo identifique padrões e possa tomar decisões com os novos dados(BISHOP, 2006). No processo de identificação de padrões existem 3 diferentes técnicas:

- **Aprendizado Supervisionado:** método onde o conjunto de dados está rotulado, dessa forma todas as entradas tem suas saídas definidas e realizados ciclos de treinamento para melhoria da acurácia do sistema, com isso é esperado que o modelo gerado ao final tenha maior confiabilidade para identificar padrões em novos dados(CUNNINGHAM *et al.*,

2008).

- **Aprendizado Não Supervisionado:** método onde o algoritmo realiza inferências sobre os dados de entrada sem ter conhecimento da saída esperada, sendo um método utilizado para agrupamento de dados(MÜLLER; GUIDO, 2016).
- **Aprendizado por Reforço:** método onde o sistema deve aprender a realizar tomada de ações, com base em experiências passadas, visando ser recompensado ao final de suas ações corretas e sofrendo penalidades em casos de erro(SUTTON; BARTO, 2018).

O aprendizado supervisionado é amplamente reconhecido como o método mais utilizado para o desenvolvimento de sistemas de IA para detecção de objetos. Isso é destacado pela adoção generalizada de Redes Neurais Artificiais em tarefas de detecção de objetos, onde o treinamento do modelo é realizado com conjuntos de dados anotados que especificam a localização e a classificação dos objetos nas imagens.

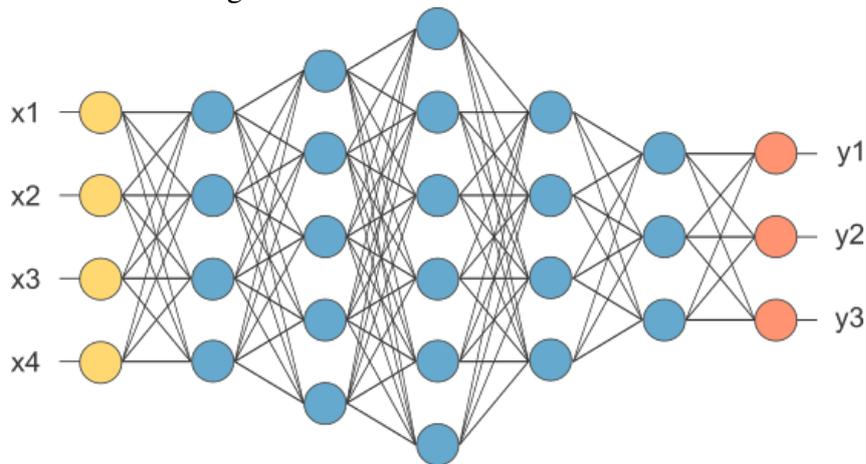
2.2.2 *Redes Neurais Artificiais (RNA)*

As Redes Neurais Artificiais (RNA) se referem a modelos de aprendizado de Inteligência Artificial que possuem a capacidade de adaptação e aprendizado de determinadas tarefas partindo da análise de um conjunto de exemplos dados(OSORIO, 2000).

É denominado dessa forma por conter em sua estrutura fundamental o neurônio lógico, criando uma relação com o cérebro humano, onde diversos neurônios estão conectados em uma rede através de conexões sinápticas, que são pontos de transmissão entre os neurônios(HAYKIN, 1999).

Seu funcionamento ocorre com base nos padrões encontrados no conjunto de exemplos dados, onde o algoritmo busca definir quais padrões melhor representam o seu objetivo de busca(KOPIER *et al.*, 2019). Na criação desses padrões os neurônios recebem pesos de acordo com sua relevância, que determina a força e a direção (positiva ou negativa) do sinal transmitido entre os neurônios, e são criadas as ligações definindo quais padrões possuem relação (Figura 5). Esse modelo é muito empregado no processamento de imagens devido a características como: robustez, generalização, paralelismo e tolerância ao ruído.

Figura 5 – Estrutura de Rede Neural.



Fonte: Networks (2018)

- **Robustez:** descreve a capacidade do sistema de manter o desempenho frente a perturbações ou incertezas, como dados ruidosos ou incompletos. De acordo com Kitano (2008) a robustez é uma propriedade fundamental dos sistemas biológicos, refletindo em sistemas de RNAs a capacidade de lidar eficientemente com erros e variações nos dados de entrada.
- **Generalização:** se refere à capacidade do modelo de performar bem em novos dados, não vistos durante o treinamento, indicando que o modelo aprendeu as características gerais dos dados ao invés de memorizar especificidades do conjunto de treinamento. A generalização é crucial para a aplicabilidade prática das RNAs em tarefas reais, onde o objetivo é fazer inferências ou previsões precisas sobre dados desconhecidos ou futuros (CARMINATI, 2018).
- **Paralelismo:** capacidade de processar múltiplas operações simultaneamente, graças à sua estrutura composta por numerosos neurônios artificiais. Este atributo é particularmente valioso para implementações em hardware especializado, como GPUs, que podem acelerar significativamente o treinamento e a inferência de modelos de RNA.
- **Tolerância à Ruído:** capacidade de filtrar distorções e focar em características significativas para realizar tarefas de classificação, regressão, ou qualquer outra aplicação relevante. Esta característica é fundamental em cenários do mundo real, onde os dados coletados raramente são perfeitos ou completos (HONG; CHANG, 2002).

Após o processo de aprendizado, as RNA, com suas ligações e peso dos neurônios já definidos, captam as informações fornecidas pelas entradas e através das conexões e dos pesos estabelecidos tomam decisões para realizar suas previsões. A complexidade do sistema,

relacionada também a sua confiabilidade e poder de processamento, será baseada pelo número de neurônios e camadas presentes nele(FERNEDA, 2006).

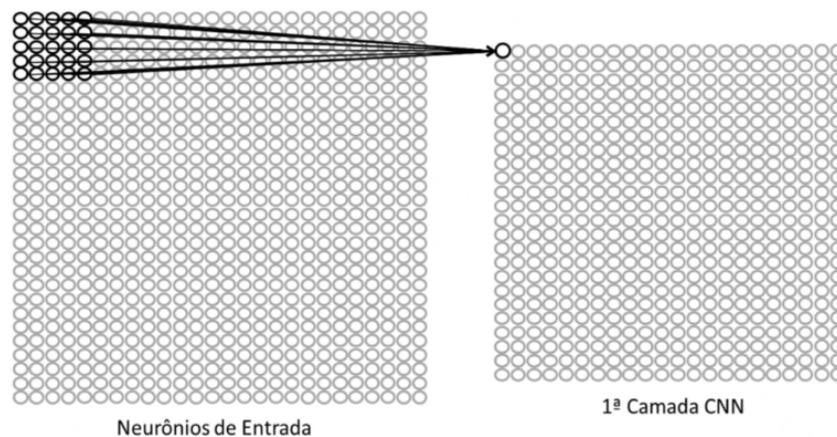
Suas características o tornam úteis para uma ampla gama de tarefas, havendo uma subdivisão que tem melhor aplicabilidade para processamento de dados com uma topologia de grade, como imagens, vídeos e dados sequenciais de áudio, sendo estas as (Redes Neurais Convolucionais (RNC)) (PACHECO, 2019).

2.2.2.1 *Redes Neurais Convolucionais (RNC)*

As RNC são semelhantes às RNA tradicionais, pois consistem na mesma estrutura de ligação de neurônios em seus processos. Sendo seu padrão de entradas e saídas nos neurônios seguindo a mesma operação encontrada nas RNA. A diferença mais notável entre as RNC e as RNA é que as RNC são usadas principalmente no campo do reconhecimento de padrões em imagens. Por permitir a extração de características específicas das imagens na arquitetura, a rede é mais adequada para tarefas focadas em imagens e reduzindo o número de parâmetros necessários para configuração do modelo(O'SHEA; NASH, 2015). Alguns pontos relevantes na arquitetura das RNC são:

- **Camadas Convolucionais:** A primeira etapa em uma RNC é geralmente uma camada convolucional. Nesta camada, filtros (ou kernels) são aplicados à imagem de entrada para criar mapas de características. Cada filtro é projetado para detectar características específicas, como bordas ou ângulos. A operação de convolução envolve deslizar o filtro sobre a imagem e calcular o produto escalar do filtro com a parte da imagem sobre a qual ele está posicionado, resultando em um mapa de ativação que indica onde uma característica específica aparece na imagem. Com as características destacadas, a matriz na saída apresenta uma redução no tamanho em comparação com os dados de entrada, conforme mostra a Figura 6.

Figura 6 – Aplicação da camada de convolução.



Fonte: Tech (2022)

- **Camadas de *Pooling*:** O processo de *Pooling* ou Agrupamento é uma técnica comumente empregada em redes neurais convolucionais para reduzir a dimensionalidade dos mapas de características, preservando informações essenciais enquanto diminui o tamanho dos mapas. Isso é alcançado através de operações como Max Pooling, que mantém apenas os valores máximos em regiões do mapa, ou Average Pooling, que calcula a média. O pooling ajuda a reduzir o número de parâmetros na rede, torna o processamento mais eficiente e confere invariância de translação, embora possa levar à perda de detalhes finos nas características (GOODFELLOW *et al.*, 2016).
- **Camadas Totalmente Conectadas:** As camadas totalmente conectadas em RNC são fundamentais para consolidar e transformar as características extraídas das camadas convolucionais em uma forma adequada para a tarefa final, como classificação ou regressão. Conectando cada neurônio a todos os neurônios da camada anterior, essas camadas são usadas no final da rede para mapear as características aprendidas para as classes de saída, permitindo representações mais complexas e abstratas dos dados de entrada. No entanto, elas aumentam o número de parâmetros na rede, o que pode levar a problemas de overfitting e aumentar a complexidade computacional (CHOLLET, 2018).
- **Funções de Ativação:** A função de ativação em RNC desempenha um papel crucial na introdução de não-linearidades nas saídas das camadas convolucionais, permitindo que a rede aprenda e represente relações complexas nos dados de entrada. Essas funções, como ReLU (Rectified Linear Activation), tanh (tangente hiperbólica) e *sigmoid*, são aplicadas após as operações de convolução e pooling em cada neurônio, transformando os valores

de entrada em uma forma mais útil para a tarefa final, como classificação ou detecção de objetos. A função ReLU é uma das mais utilizadas devido à sua simplicidade e eficácia computacional, enquanto outras funções como tanh e sigmoid são úteis em determinados contextos, especialmente quando a saída precisa estar em um intervalo específico. A escolha da função de ativação pode ter um impacto significativo no desempenho e na capacidade de aprendizado da rede, influenciando fatores como velocidade de convergência, capacidade de generalização e prevenção de problemas como o desaparecimento do gradiente. Portanto, a seleção adequada da função de ativação é essencial para o sucesso de uma RNC em uma determinada tarefa.

Devido as características apresentadas, as RNC têm sido amplamente utilizadas em aplicações de visão computacional, fornecendo uma abordagem eficaz para extrair características discriminativas de imagens. Um dos avanços significativos nesse campo é o YOLO (*You Only Look Once*), uma arquitetura de detecção de objetos em tempo real que se baseia em RNC para realizar detecções precisas e rápidas em uma única passagem pela rede.

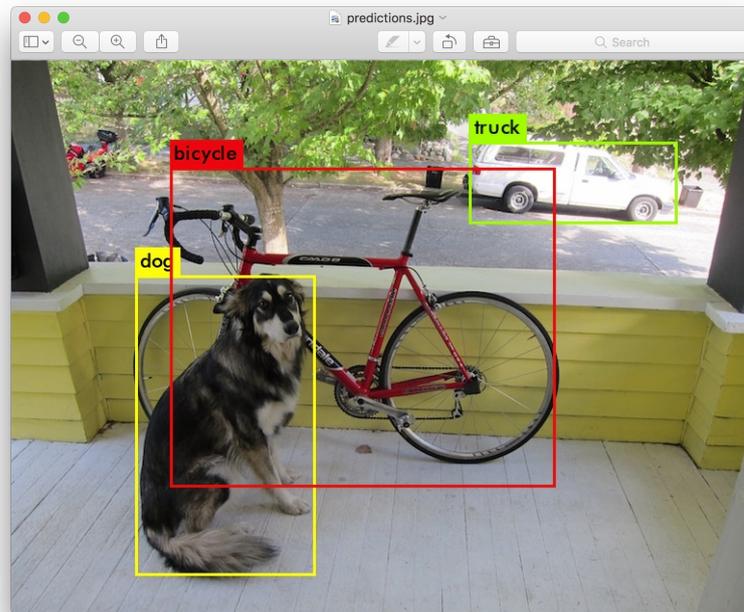
2.2.2.1.1 *You Only Look Once* (YOLO)

O YOLO é uma arquitetura de RNC usada para detecção de objetos em imagens. Desenvolvido por Joseph Redmon e Santosh Divvala em 2016, o YOLO se destaca por sua capacidade de realizar detecção de objetos em tempo real com alta precisão (REDMON *et al.*, 2016).

Nesta arquitetura o problema de detecção de objetos é abordado como um problema de regressão de caixas delimitadoras e probabilidades de classe, permitindo que objetos sejam identificados instantaneamente em uma imagem, conforme mostrado na Figura 7. Sua abordagem divide a imagem de entrada em uma grade de células e, para cada célula, prevê caixas delimitadoras e probabilidades de classe, resultando em detecções eficientes e precisas.

Ao contrário de métodos tradicionais baseados em propostas de região, que exigem múltiplas passagens pela rede, o YOLO realiza detecções e localização dos objetos em uma única passagem, indicando que a arquitetura faz uso do método *Single Shot Detector (SSD)*, tornando-o especialmente adequado para aplicações onde a velocidade é crítica, como veículos autônomos e sistemas de monitoramento de segurança (BOCHKOVSKIY *et al.*, 2020).

Figura 7 – Exemplo de predição realizada pelo YOLO.



Fonte: Redmon e Farhadi (2016)

Desde sua introdução, o YOLO passou por várias iterações, como YOLOv2 e YOLOv3, chegando atualmente ao YOLOv5, cada uma introduzindo melhorias incrementais em termos de precisão e eficiência computacional (REDMON; FARHADI, 2018). Com sua capacidade de fornecer detecções rápidas e precisas, o YOLO se estabeleceu como um dos frameworks mais populares para detecção de objetos em tempo real.

O YOLO é uma arquitetura eficiente e poderosa para detecção de objetos em imagens em tempo real. No entanto, embora seja altamente eficaz em detectar uma ampla variedade de objetos em cenários genéricos, pode surgir a necessidade de adaptá-lo para tarefas específicas ou conjuntos de dados exclusivos, com isso é necessário o uso do processo de *Transfer Learning*.

2.2.3 *Transfer Learning*

Transfer learning é uma técnica que permite adaptar modelos de aprendizado de máquina pré-treinados em tarefas gerais para tarefas mais específicas, aproveitando o conhecimento adquirido durante o treinamento inicial. Sendo particularmente útil quando o conjunto de dados obtidos para a tarefa específica é reduzido ou quando o objetivo é detectar classes de objetos diferentes das presentes no conjunto de dados original (PAN; YANG, 2010).

A aplicação do *transfer learning* geralmente envolve o uso de um modelo pré-treinado em um conjunto de dados maior que contém uma ampla variedade de classes de objetos. Em seguida, esse modelo é *fine-tuned* em um conjunto de dados específico, sendo esse um processo onde os pesos das camadas convolucionais são ajustados para que aprendam a detectar objetos relevantes para a nova tarefa (YOSINSKI *et al.*, 2014). Esse processo de *fine-tuning* pode ajudar a melhorar significativamente o desempenho do modelo no conjuntos de dados específicos, especialmente quando há uma escassez de dados de treinamento disponíveis.

O modelo gerado ao fim do processo precisa ser validado, baseado em métricas relevantes de acordo com a tarefa realizada pelo modelo. Nesse contexto, a definição e o cálculo de métricas apropriadas desempenham um papel crucial.

2.2.4 Métricas de Avaliação

Métricas de avaliação são medidas quantitativas usadas para avaliar o desempenho de modelos de aprendizado de máquina em uma determinada tarefa (PROVOST; FAWCETT, 2013). Essas métricas fornecem uma maneira objetiva de entender o desempenho do modelo e oferecer *insights* úteis para ajustes e melhorias dos modelos. No campo da análise de imagens, algumas métricas relevantes são:

- **Precisão (*Accuracy*):** A precisão mede a proporção de exemplos classificados corretamente pelo modelo em relação ao total de exemplos.
- **AP (*Average Precision*):** Precisão das detecções para uma classe específica em diferentes níveis de confiança.
- **mAP (*Mean Average Precision*):** Medida geral da precisão da detecção considerando todas as classes de objetos presentes no conjunto de dados.
- **Revocação (*Recall*):** A revocação mede a proporção de exemplos positivos corretamente identificados pelo modelo em relação ao total de exemplos positivos na base de dados.
- **F1-Score:** O F1-Score é a média harmônica entre precisão e revocação e fornece uma medida única que equilibra ambas as métricas.
- **Matriz de Confusão (*Confusion Matrix*):** Uma matriz que resume o desempenho do modelo, mostrando o número de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos.
- **IoU (*Intersection over Union*):** Uma métrica comum em detecção de objetos que mede a sobreposição entre as caixas delimitadoras previstas e as caixas delimitadoras reais.

Após a geração e validação do modelo de rede neural, este pode ser implementando em diferentes tipos de hardware. Com a evolução de tecnologias móveis, dispositivos de menor dimensão apresentam capacidades mais avançadas para processar essas tarefas, sendo relevante o uso de Sistemas Embarcados na implementação do sistema.

2.3 Sistemas Embarcados

Um Sistema Embarcado é definido, por Malinowski e Yu (2011), como “um sistema computacional que faz parte de um sistema maior e implementa alguns dos requerimentos deste sistema”. Sistemas Embarcados são sistemas completos e independentes capazes de realizar determinadas tarefas conforme sua programação, o avanço no desenvolvimentos dessas tecnologias contribui para a miniaturização desses dispositivos, onde temos hardwares cada vez menores com capacidade de processamento mais elevada.

Figura 8 – Exemplos de placas de Sistemas Embarcados.



Fonte: Victor (2018)

Nessa questão temos dispositivos com capacidade de realizar processamentos que antes requeriam de máquinas com hardware mais avançado ou com grande dependência de estruturas de comunicação de dados, desempenhando um papel crucial em uma variedade de aplicações, desde dispositivos domésticos inteligentes até equipamentos médicos e sistemas de controle industrial(WOLF, 2008). Seguem algumas características relevantes dos sistemas embarcados:

- **Eficiência Energética:** Os sistemas embarcados são projetados para operar com baixo consumo de energia, muitas vezes alimentados por baterias ou fontes de energia limitadas. Isso é essencial para dispositivos móveis, Internet das Coisas e outras aplicações onde a eficiência energética é uma preocupação primordial(BENINI; BOGLIOLO, 2000).
- **Tamanho Compacto:** Os sistemas embarcados geralmente têm um tamanho físico reduzido, ocupando pouco espaço e sendo facilmente integrados em dispositivos menores. Isso os torna ideais para aplicações onde o espaço é limitado, como dispositivos vestíveis e sistemas embarcados em veículos, ampliando assim suas possibilidades de aplicação(PONT; SOTIRIADES, 2017).
- **Desempenho Específico:** Os sistemas embarcados são otimizados para tarefas específicas e geralmente têm um conjunto limitado de recursos de hardware e software. Eles são projetados para atender aos requisitos de desempenho das aplicações para as quais são destinados, fornecendo o poder de processamento necessário para executar as tarefas de forma eficiente(LEE *et al.*, 2016).
- **Confiabilidade:** Devido ao seu uso em aplicações críticas, como sistemas de controle de aviões e dispositivos médicos, os sistemas embarcados devem ser altamente confiáveis e capazes de operar de forma consistente em uma variedade de condições ambientais e de operação.
- **Tempo Real:** Muitos sistemas embarcados são projetados para operar em tempo real, o que significa que eles devem responder a eventos e entradas dentro de prazos estritos e previsíveis. Isso é crucial em aplicações como controle de processos industriais, automação e sistemas de segurança.
- **Baixo Custo:** Os sistemas embarcados são frequentemente produzidos em grande escala e devem ser economicamente viáveis. Isso requer uma combinação de hardware e software otimizados para reduzir custos de produção e manutenção.
- **Comunicação e Conectividade:** Com o crescimento da Internet das Coisas, muitos sistemas embarcados precisam ser capazes de se comunicar com outros dispositivos e sistemas, exigindo suporte para uma variedade de tecnologias de comunicação, como Wi-Fi, Bluetooth, e redes celulares.

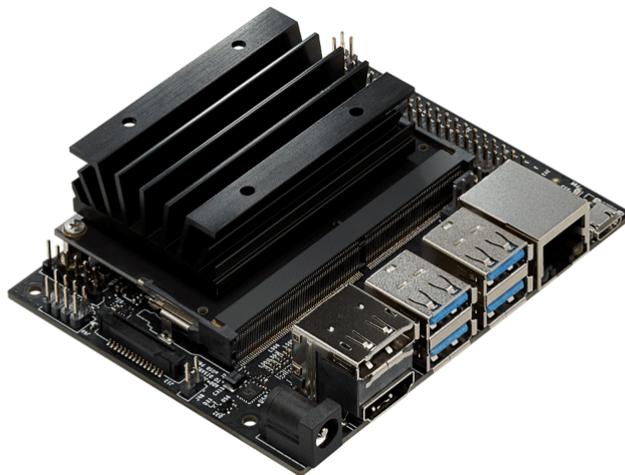
Essas características os tornam ideais para uma ampla gama de dispositivos e sistemas, desde dispositivos portáteis até sistemas críticos em tempo real. Um exemplo notável de sistema embarcado é a placa Jetson Nano da NVIDIA, uma plataforma de desenvolvimento

que combina poder de processamento de alto desempenho com eficiência energética e tamanho compacto.

2.3.1 *Jetson Nano*

A Jetson Nano é uma placa de desenvolvimento computacional voltada para aplicações de inteligência artificial e aprendizado de máquina em sistemas embarcados. Fabricada pela NVIDIA, essa placa oferece uma plataforma de baixo custo e baixo consumo de energia, mas com capacidade de processamento de alto desempenho, permitindo a execução de modelos de redes neurais complexos em tempo real. Equipada com uma GPU NVIDIA Maxwell de 128 núcleos CUDA, a Jetson Nano é capaz de realizar tarefas de inferência de redes neurais profundas de forma eficiente, tornando-a adequada para uma ampla variedade de aplicações, incluindo visão computacional, reconhecimento de padrões e sistemas autônomos. Além disso, sua arquitetura compacta e sua variedade de interfaces de conectividade tornam-na uma escolha popular entre pesquisadores, estudantes e desenvolvedores que buscam explorar e implementar soluções de IA em dispositivos embarcados.

Figura 9 – Placa Jetson Nano.



Fonte: Lima (2019)

3 TRABALHOS CORRELATOS

Neste capítulo será apresentado trabalhos correlatos ao problema apresentado. Na revisão da literatura foi notado que o desenvolvimento de sistemas de reconhecimento de veículos tem sido objeto de intensa pesquisa devido à sua ampla gama de aplicações em diferentes domínios, incluindo segurança pública, monitoramento de tráfego, controle de fronteiras, vigilância marítima, entre outros. Esses sistemas visam identificar e classificar veículos em ambientes variados, como estradas, áreas urbanas, corpos d'água e até mesmo no espaço aéreo, contribuindo para uma melhor compreensão e gerenciamento dos fluxos de transporte e mobilidade.

No contexto terrestre, numerosos estudos têm explorado técnicas de visão computacional e aprendizado de máquina para o reconhecimento de veículos em estradas, estacionamentos e áreas urbanas. Esses sistemas são capazes de identificar diferentes tipos de veículos, como carros, ônibus, caminhões e motocicletas, com base em características visuais específicas, como forma, tamanho e padrões de movimento. No contexto aquático, o reconhecimento de embarcações é fundamental para o monitoramento de atividades marítimas, controle de fronteiras e segurança costeira. Projetos nesta área empregam técnicas de processamento de imagem e análise de padrões para identificar navios, barcos, lanchas e outras embarcações em rios, lagos e oceanos, contribuindo para a proteção de recursos naturais e prevenção de atividades ilegais.

Nesta seção de trabalhos correlatos, serão apresentados alguns projetos relevantes de reconhecimento de veículos, abrangendo tanto o ambiente terrestre e aquático, destacando suas metodologias, resultados e contribuições para o avanço da área.

3.1 Research on Boat Identification Based on Improved Loss Function of Deep Convolutional Neural Networks

No trabalho de Guo *et al.* (2019) foi realizada a identificação de embarcações no monitoramento do tráfego marítimo, focando na dificuldade de identificar precisamente embarcações relativamente pequenas em cenas complexas. Diante dessa situação, este artigo propõe ajustes nos parâmetros do modelo YOLOv3 e criação de um novo modelo SSD YOLO-H. Este modelo resolve efetivamente o problema da baixa precisão do modelo devido ao desequilíbrio das amostras. Para provar a eficácia do modelo, foi utilizado o conjunto de dados MS-COCO para avaliação. Os resultados experimentais mostram que o YOLO-H na MS-COCO realiza um *Average Precision (AP)* de teste do COCO de 34.3, sendo o valor obtido 1,3 pontos mais

alto do que o YOLOv3. Na tarefa real de identificação de embarcações, é testado o problema de baixa resolução e difícil detecção de alvos pequenos, sendo comprovado pelos resultados experimentais que o modelo YOLO-H pode identificar efetivamente alvos pequenos.

3.2 Embedded CNN based vehicle classification and counting in non-laned road traffic

O trabalho proposto por Chauhan *et al.* (2019) aborda a classificação e contagem de veículos no tráfego rodoviário, uma tarefa de grande importância no campo da engenharia de transporte. No entanto, a ampla variedade de veículos (como motocicletas, triciclos, carros, ônibus, caminhões etc.) circulando em estradas de regiões em desenvolvimento, sem qualquer disciplina de faixa, torna a classificação e contagem de veículos um problema difícil de automatizar. Neste artigo, são utilizados múltiplas versões do modelo YOLO e treinados para várias classes de veículos utilizando um dataset próprio de dados de estradas de Delhi. Os resultados mostram uma *Mean Average Precision* (mAP) de até 75% em uma divisão de treinamento-teste de 80-20, usando 5562 quadros de vídeo de quatro locais diferentes. Além disso, devido à conectividade de rede de dados ser escassa em certas regiões para transmissões contínuas de vídeo das estradas para servidores em nuvem, também foi avaliado o uso de diferentes sistemas embarcados para inferência dos modelos testados.

3.3 YOLO-RTUAV: Towards Real-Time Vehicle Detection through Aerial Images with Low-Cost Edge Devices

O trabalho de Koay *et al.* (2021) foca na questão da detecção de veículos baseado em imagens aéreas, que tem sido uma área de pesquisa ativa devido ao aumento de disponibilidade de veículos aéreos não tripulados (VANTs). No entanto, as imagens aéreas apresentam desafios, como grandes variações e tamanhos de objetos geralmente pequenos, resultando em menor precisão de detecção. Neste trabalho, exploramos o uso de técnicas de detecção de objetos de aprendizado profundo de ponta em hardware de sistemas embarcados. Com isso é apresentado o modelo YOLO-RTUAV, uma versão aprimorada do YOLOv4-Tiny, como solução proposta. Os experimentos foram realizados nos *datasets* VAID e COWC, comparando o desempenho do modelo gerado com várias contrapartes de estado da arte. O modelo proposto demonstrou uma precisão média superior (mAP) e quadros por segundo (FPS) em comparação com outros modelos YOLO Tiny, especificamente quando implantados na placa Jetson Nano 2 GB.

3.4 Tabela comparativa dos trabalhos relacionados

A Tabela 1 apresenta o comparativo dos trabalhos baseado nos seguintes pontos: modelo utilizado, objetos de interesse, dataset utilizado e hardware utilizado.

Tabela 1 – Projetos Relacionados.

Trabalhos	(GUO <i>et al.</i>, 2019)	(CHAUHAN <i>et al.</i>, 2019)	(KOAY <i>et al.</i>, 2021)	Trabalho Proposto
Modelo Utilizado	YOLOv3	YOLOv5	YOLOv4 Tiny	YOLOv4 Tiny
Objetos de Interesse	Veículos Marinhos	Veículos Terrestres	Veículos Terrestres	Veículos Fluviais
Dataset Utilizado	MS-COCO	Próprio (Veículos de Delhi)	VAID and COWC	Próprio (Embarcações em Manaus)
Hardware Implementado	Desktop	Múltiplos Sistemas Embarcados	Jetson Nano 2GB	Jetson Nano 2GB

Fonte: Próprio Autor (2024)

Todos os estudos abordados adotaram o YOLO como o modelo comum, servindo como referência para suas implementações, mesmo em versões distintas, destacando assim a importância desse modelo no campo do reconhecimento de imagens. As pesquisas de Chauhan *et al.* (2019) e Koay *et al.* (2021) concentraram-se principalmente no uso de dispositivos embarcados e aplicados em ambientes terrestres, onde a quantidade de estudos relacionados é maior. Por outro lado, o estudo de Guo *et al.* (2019) foi o único a utilizar *hardware desktop* e a abordar veículos em ambientes aquáticos, especificamente no meio marinho. Tanto os estudos de Guo *et al.* (2019) quanto os de Koay *et al.* (2021) utilizaram conjuntos de dados preexistentes para validação, enquanto o estudo de Chauhan *et al.* (2019) empregou um conjunto de dados próprio com imagens de veículos de Nova Delhi, destacando as particularidades buscadas pelo estudo em um ambiente real.

O trabalho proposto baseia-se em aspectos dos estudos mencionados, utilizando o modelo YOLO como base para a criação de um modelo personalizado, especificamente a versão YOLOv4 Tiny, e também focando em veículos aquáticos, porém em um ambiente fluvial. O conjunto de dados utilizado é próprio, visando especificar os objetos de interesse de acordo com a região. Além disso, sua implementação é realizada em um dispositivo de sistema embarcado, a placa Jetson Nano 2GB, com o intuito de proporcionar maior mobilidade ao projeto.

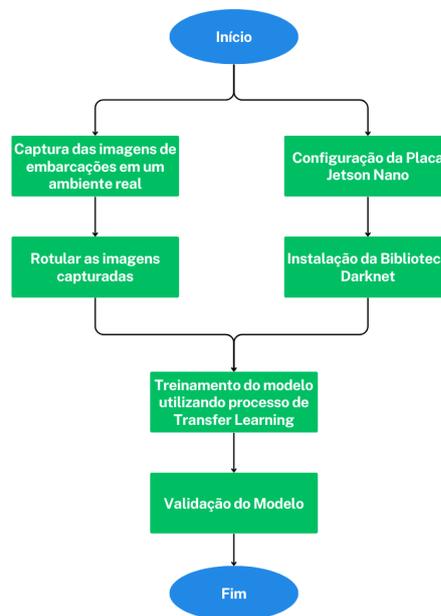
4 METODOLOGIA

Este trabalho se baseará, de acordo com Silveira e Cordova (2009), na metodologia de abordagem quali-quantitativa, visto que focaremos na aplicação do sistema e seus resultados, e também avaliaremos dados referentes as embarcações e especificidades dos locais inseridos. Quanto a sua natureza, de acordo com Silva e Menezes (2005), consideraremos como pesquisa exploratória, devido a baixa informação sobre pesquisas relacionadas dentro do ambiente proposto.

4.1 Procedimentos Metodológicos

Neste trabalho será gerado um modelo de Rede Neural através do processo de *Transfer Learning* utilizando a placa Jetson Nano para reconhecimento de embarcações, seguindo o fluxograma indicado na Figura 10.

Figura 10 – Fluxo do Trabalho.



Fonte: Próprio Autor (2024)

O primeiro passo envolve a coleta de imagens de embarcações de variados tamanhos, capturadas em locais reais como o Porto da Manaus Moderna e a Marina do Davi. Segue-se então o processo de tratamento e rotulação dessas imagens no formato compatível com o modelo

YOLO. Simultaneamente, procede-se com a configuração do sistema operacional na placa Jetson Nano e a instalação da biblioteca *Darknet*, habilitando assim o uso do *framework* YOLO. Com as imagens preparadas no formato adequado e a placa devidamente configurada, é possível avançar para a fase de treinamento do modelo, utilizando a técnica de *Transfer Learning*. A etapa final consiste na validação dos resultados obtidos com o modelo treinado.

4.1.1 Captura das Imagens

Com o objetivo de incorporar uma maior representatividade regional aos dados utilizados para desenvolver o modelo, optou-se pela coleta de imagens de embarcações em locais reais. As locações escolhidas foram a Marina do Davi e o Porto de Manaus (Figura 11), ambos reconhecidos como centros de intensa atividade de transporte fluvial. Isso se deve, principalmente, à elevada procura por serviços de transporte que atendam tanto a destinos turísticos quanto a viagens intermunicipais, respectivamente (GASPAR *et al.*, 2021).

Figura 11 – Embarcações na Marina do Davi e Porto de Manaus.



Fonte: Próprio Autor (2024)

As imagens foram obtidas sob duas perspectivas: uma estática, na qual a embarcação é vista em relação ao porto, e outra dinâmica, na qual a embarcação é vista em relação a outra embarcação. Procurou-se variar os ângulos de captura de uma mesma embarcação, além de registrar embarcações de diferentes tamanhos para facilitar a classificação entre lanchas, que são de menor porte, e barcos de passeio, que são de maior porte. As fotos foram tiradas em equipe (Figura 12), utilizando câmeras de celulares, e também foram capturados vídeos para fins de validação. Após uma seleção inicial para excluir imagens de baixa qualidade, um total de 1000 imagens foram mantidas para ser utilizado no modelo.

Figura 12 – Equipe responsável pela captura de imagens.



Fonte: Próprio Autor (2024)

4.1.2 *Tratamento das imagens*

Para reduzir o processamento necessário durante o treinamento do modelo, foi empregado um script em Python (ver Apêndice A) com o objetivo de diminuir as dimensões das imagens para 1200 pixels de largura por 900 pixels de altura, bem como a qualidade das mesmas. Seguidamente, procedeu-se com a rotulação de cada imagem, inicialmente classificando-as como lancha e barco de passeio, nesta sequência específica a fim de evitar erros no processo de rotulação. Para o modelo YOLO, além da imagem, é essencial a criação de um arquivo em formato *text*, nomeado da mesma forma que a imagem correspondente.

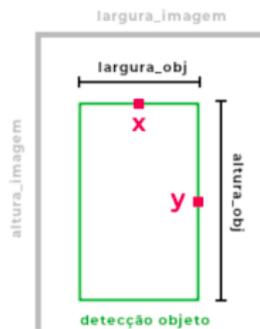
Esse arquivo deve compreender 5 valores estruturados da seguinte forma: **<classe-id> <x> <y> <largura> <altura>**, referentes à identificação e localização (conforme ilustrado na Figura 13) do objeto, com cada valor especificando:

- **classe-id**: um número inteiro que identifica o objeto, utilizado como índice para o nome das classes, começando em 0.
- **x**: um valor decimal de 0 a 1 que representa a localização central do retângulo de detecção no eixo horizontal.
- **y**: um valor decimal de 0 a 1 que marca a localização central do retângulo de detecção no

eixo vertical.

- **largura:** um valor decimal de 0 a 1 que define a largura do retângulo de detecção.
- **altura:** um valor decimal de 0 a 1 que determina a altura do retângulo de detecção.

Figura 13 – Formato de rótulo do YOLO.

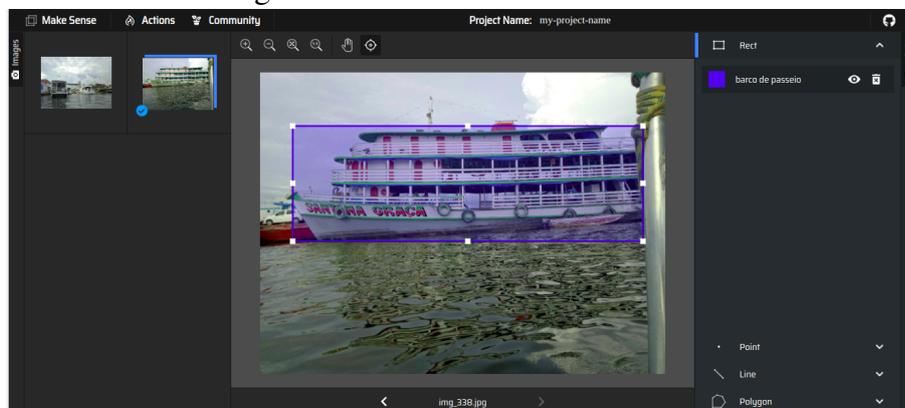


Fonte: Academy (2024)

Os valores, situados no intervalo de 0 a 1, representam o percentual da localização dos pontos em relação à imagem, permitindo que as dimensões da imagem sejam alteradas sem que haja perda de informações.

A ferramenta *Make Sense*, um serviço online acessível diretamente pelo navegador sem a necessidade de instalação ou configurações adicionais, foi empregada para a rotulação das imagens. O processo começou com o *upload* das imagens para o serviço, seguido pela identificação manual dos objetos presentes em cada imagem(Figura 14).

Figura 14 – Ferramenta *Make Sense*.



Fonte: Próprio Autor (2024)

Depois de completar esses procedimentos em todas as imagens, procede-se à exportação dos arquivos. Nesta fase, os arquivos são salvos no formato *text*, mantendo o nome original da imagem correspondente e incluindo as coordenadas mencionadas anteriormente.

4.1.3 Configuração da Placa Jetson Nano

Em paralelo as etapas já apresentadas, é possível realizar a configuração da placa Jetson Nano, sendo utilizado o modelo Jetson Nano Developer Kit 2GB neste trabalho, suas especificações indicadas na Tabela 2.

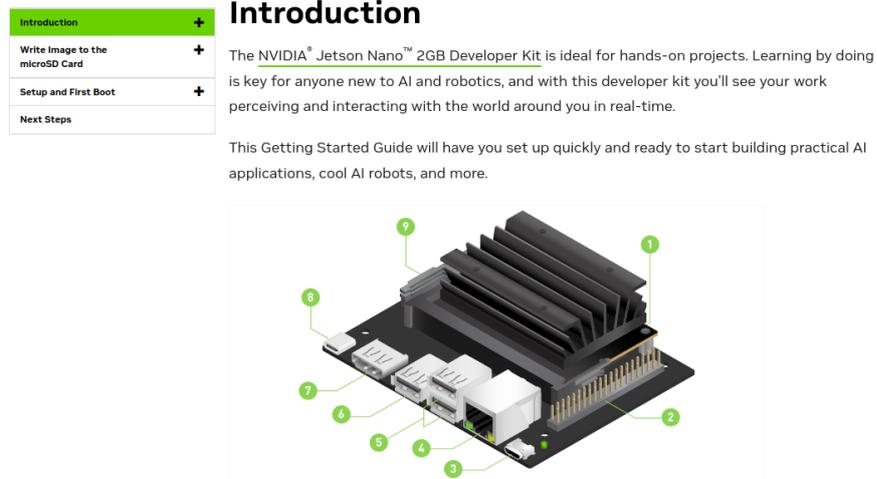
Tabela 2 – Especificações da Placa

Especificação	Jetson Nano 2GB
Processador	ARM Cortex-A57 quad-core de 64 bits
GPU	NVIDIA Maxwell com 128 núcleos CUDA
Memória RAM	2 GB de memória LPDDR4
Armazenamento	Slot para cartão microSD
Conectividade	Gigabit Ethernet
Interface de E/S	HDMI, USB 3.1 type A, USB 2.0 type A, câmera CSI, GPIO e I2C

Fonte: NVIDIA (2024)

O sistema operacional a ser configurado na placa foi obtido diretamente do site oficial da NVIDIA. O processo é realizado fazendo o download em um computador da imagem a ser transferida para o cartão de memória, que irá servir de armazenamento da placa. Para o projeto foi utilizado o Cartão de Memória Kingston Canvas Select Plus SDCS2/128 GB Class 10, visando ter maior eficiência no processamento e uso do sistema na placa. Todas as etapas de configuração são indicadas no site da própria fabricante(Figura 15).

Figura 15 – Site oficial da NVIDIA.



Fonte: NVIDIA (2024)

Outra particularidade no trabalho está relacionado a memória RAM disponível no modelo utilizado, que possui apenas 2GB, resultando em uma capacidade de processamento inferior em comparação com outros modelos. Para mitigar essa limitação, emprega-se o processo de SWAP, que aloca parte do espaço de armazenamento destinado a arquivos como memória RAM adicional, especialmente quando os processos excedem a capacidade de processamento da placa(SILBERSCHATZ *et al.*, 2018).

4.1.4 Instalação da biblioteca Darknet

Figura 16 – Biblioteca *Darknet*.



Fonte: Github (2024)

Para a instalação da biblioteca *Darknet*(Figura 16) é necessário fazer uma cópia do código-fonte disponível no *Github*. Antes de gerar o arquivo executável é necessário realizar algumas alterações no arquivo *Makefile*. Sendo estas referentes as variáveis:

- **GPU:** alterada para 1, permitindo o uso do GPU presente na placa;
- **CUDNN:** alterada para 1, permitindo uma otimização no uso do GPU;
- **OPENCV:** alterada para 1, para uso da biblioteca *OpenCV* ao exibir resultados.

Após realizar as modificações necessárias, é possível executar o comando para gerar o arquivo executável. O código-fonte também contém arquivos necessários para gerar previsões com o *Darknet* e verificar se a instalação funcionou corretamente. Após essas etapas o hardware está habilitado para iniciar o processo de treinamento.

4.1.5 *Treinamento do modelo utilizando Transfer Learning*

Após a rotulação das imagens e a configuração da placa, torna-se necessário estabelecer alguns pontos essenciais para o treinamento. O primeiro passo é a distribuição das imagens destinadas ao treinamento, teste e validação, alocadas em proporções de 70%, 20% e 10%, respectivamente. Essa distribuição foi efetuada por meio de um *script*, que seleciona de forma aleatória as imagens para cada categoria. O caminho das imagens de treinamento e teste são organizadas dentro de arquivos de texto, para serem utilizados na criação do modelo.

Um aspecto adicional a considerar é a seleção do modelo para o processo de *Transfer Learning*. Neste contexto, optou-se pelo *YOLO Tinyv4*, uma alternativa mais compacta em comparação à versão completa do *YOLO*. Esta escolha se deve à sua adequação para a detecção de objetos em dispositivos com capacidades computacionais restritas, oferecendo uma solução eficiente para tais ambientes.

Após definir esses pontos é necessário alterar alguns parâmetros presentes no arquivo de configuração do modelo, sendo estes:

- **max_batches:** o número máximo de iterações de treinamento;
- **steps:** referente a 80% e 90% do parâmetro anterior;
- **classes:** número de classes a serem identificadas, alterada apenas nas camadas *yolo*;
- **filters:** valor equivalente a operação $(classes + 5) \times 3$, alterado apenas nas camadas convolucional que precedem camadas *yolo*.

Com essas alterações os principais parâmetros do treinamento estão indicados na tabela 3.

Tabela 3 – Parâmetros de Treinamento

Parâmetro	Valor
<i>height</i>	416
<i>width</i>	416
<i>max_batches</i>	6000
<i>steps</i>	4800, 5400
<i>anchors</i>	10,14, 23,27, 37,58, 81,82, 135,169, 344,319
<i>learning_rate</i>	0.00261

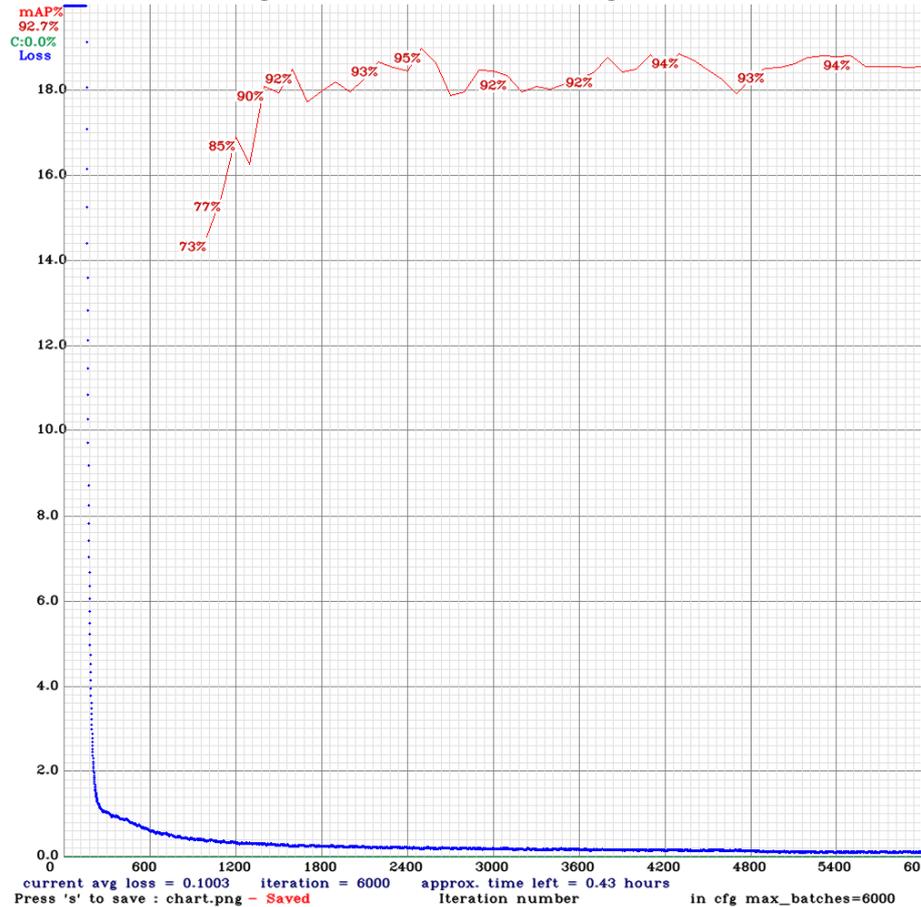
Fonte: Próprio Autor (2024)

Uma vez que os parâmetros foram estabelecidos, tornou-se viável iniciar o processo de treinamento na placa Jetson Nano.

5 RESULTADOS

Após o início do treinamento, não houve falhas para a geração do modelo. De acordo com o gráfico gerado pelo script, o modelo atingiu estabilidade nos valores de mAP após 1500 iterações, oscilando entre valores em torno de 90% e 95% (Figura 17).

Figura 17 – mAP do modelo gerado.



Fonte: Próprio Autor (2024)

Entre os arquivos de pesos criados ao término do treinamento, optou-se pelo **yolov4-tiny-obj_best.weights**, que foi produzido por volta da iteração 2500, momento no qual a precisão alcançou cerca de 95%. Com o uso desses pesos específicos, foi viável calcular métricas baseando-se nas imagens destinadas ao teste do modelo, conforme apresentado na Tabela 4. Além disso, métricas específicas para cada tipo de embarcação, sendo elas lancha (Tabela 5) e barco de passeio (Tabela 6), também foram obtidas.

Para a validação dos resultados, recorreu-se ao conjunto de imagens designadas para validação, compreendendo um total de 126 imagens. Destas, 93 foram obtidas nos locais

Tabela 4 – Métricas Gerais do modelo com as imagens de Treinamento

Métrica	Valor
mAP	94.89%
<i>Precision</i>	87%
<i>Recall</i>	91%
<i>F1-score</i>	89%
<i>Average IoU</i>	69.02%

Fonte: Próprio Autor (2024)

Tabela 5 – Métricas da Classe Lancha com as imagens de Treinamento

Métrica	Valor
ap	98.24%
TP	70
FP	7

Fonte: Próprio Autor (2024)

Tabela 6 – Métricas da Classe Barco de Passeio com as imagens de Treinamento

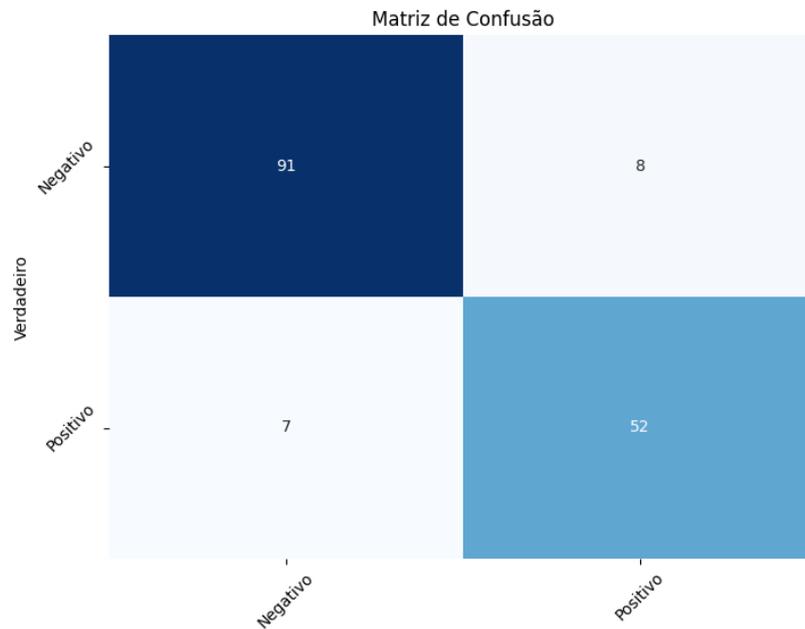
Métrica	Valor
ap	91.54%
TP	184
FP	30

Fonte: Próprio Autor (2024)

especificados para captura, enquanto as 33 imagens restantes de embarcações foram adquiridas online.

Para a classe lancha segue a Matriz de Confusão(Figura 18) com os dados de validação, e métricas relevantes (Tabela 7):

Figura 18 – Matriz Confusão da Classe Lancha.



Fonte: Próprio Autor (2024)

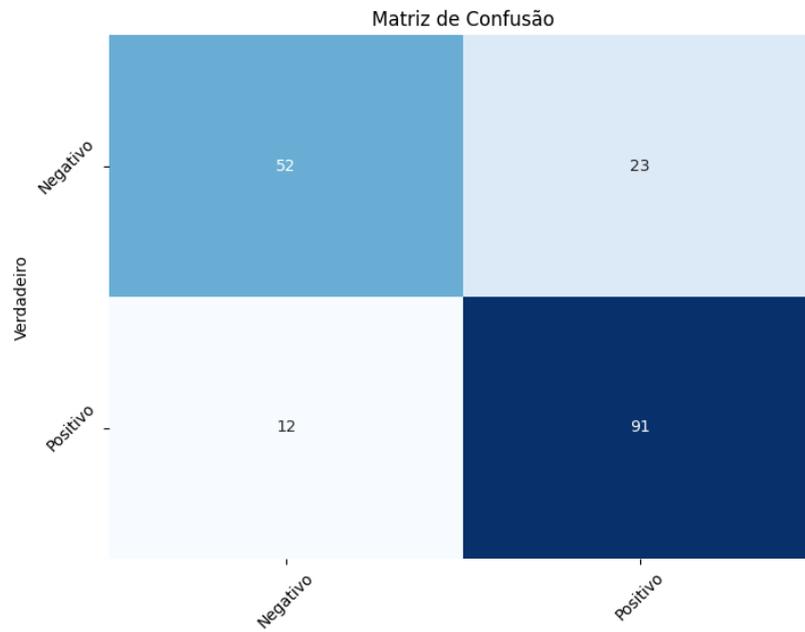
Tabela 7 – Métricas da Classe Lancha com as imagens de Validação

Métrica	Valor
Precisão	86.67%
<i>Recall</i>	88.14%
Especificidade	91.92%
<i>F1-Score</i>	87.39%

Fonte: Próprio Autor (2024)

Para a classe barco de passeio segue a Matriz de Confusão(Figura 19) com os dados de validação, e métricas relevantes (Tabela 8):

Figura 19 – Matriz Confusão da Classe Barco de Passeio.



Fonte: Próprio Autor (2024)

Tabela 8 – Métricas da Classe Barco de Passeio com as imagens de Validação

Métrica	Valor
Precisão	79.82%
<i>Recall</i>	88.35%
Especificidade	69.33%
<i>F1-Score</i>	83.87%

Fonte: Próprio Autor (2024)

6 CONCLUSÕES E TRABALHOS FUTUROS

Este estudo conduziu uma investigação inicial sobre a aplicabilidade de redes neurais no reconhecimento de embarcações na região fluvial da Amazônia. A análise dos resultados obtidos demonstra a eficiência do modelo proposto, onde teve seus valores de mAP em 94.89% no dataset de treinamento e 83.24% no dataset de validação, onde teve capacidade de reconhecer embarcações também em imagens obtidas da internet. Além disso, a utilização da placa Jetson Nano mostrou-se efetiva nos experimentos realizados.

Na realização deste projeto, o principal desafio encontrado foi o processo de aquisição e preparação das imagens. Apesar de o conjunto de dados não ser tão amplo quanto aqueles disponíveis em plataformas especializadas, a tarefa de identificar as embarcações em condições reais apresentou obstáculos, especialmente devido ao ambiente ruidoso e à presença de múltiplos objetos nos entornos portuários. Contudo, paradoxalmente, a complexidade e desordem do cenário contribuíram positivamente para a precisão das previsões, permitindo que o modelo demonstrasse eficiência na detecção dos objetos de interesse.

6.1 Trabalhos Futuros

Este estudo se mostrou uma base relevante para a aplicação de tecnologias de Inteligência Artificial no apoio a questões pertinentes à região Amazônica, com um enfoque particular nos desafios do transporte hidroviário. Para dar prosseguimento a este projeto, algumas sugestões de direções futuras incluem:

- **Avaliação comparativa da eficácia entre diferentes modelos:** empregar uma variedade de modelos para comparar a velocidade e a precisão de detecção, utilizando o dataset gerado;
- **Ampliação do dataset existente:** incrementar a coleção de imagens de embarcações, diversificando os momentos de captura em diferentes horários e condições climáticas, explorando novos locais portuários e adicionando registros de embarcações em deslocamento;
- **Implementação de algoritmos complementares:** expandir o projeto para incluir algoritmos de Processamento de Linguagem Natural (PLN), com o objetivo de extrair informações adicionais, como os nomes inscritos nas embarcações;
- **Aplicação da Raspberry Pi:** Com o intuito de reduzir os custos de implementação do

projeto em ambientes reais, seria relevante avaliar o desempenho da Raspberry Pi, que apresenta um custo inferior em relação à Jetson Nano;

- **Desenvolvimento para aplicação prática:** criar um sistema capaz de analisar imagens de portos em tempo real utilizando o modelo desenvolvido.

REFERÊNCIAS

- ACADEMY, I. E. **Referência dos pontos indicados pela anotação YOLO**. 2024. Acesso em: 23/02/2024. Disponível em: <<https://iaexpert.academy/cursos-online-assinatura/deteccao-de-objetos-com-yolo-darknet-opencv-e-python/>>.
- Agência Nacional de Transportes Aquaviários (ANTAQ). **Relatório executivo da pesquisa de satisfação dos usuários do serviço de transporte longitudinal de passageiros e misto na navegação interior da região amazônica**. Brasília, 2015. Disponível em: <http://www.antaq.gov.br/Portal/pdf/20150623_BRASIL.RelatorioExecutivo_PesquisaSatisfacaoNavegacaoInteiror.pdf>.
- Agência Nacional de Transportes Aquaviários (ANTAQ). **Caracterização da Oferta e da Demanda do Transporte Fluvial de Passageiros e Cargas na Região Amazônica**. [S.l.], 2018. 96 p.
- ARIMA, E. Y.; RICHARDS, P.; WALKER, R. T.; CALDAS, M. M. Urbanization patterns in the brazilian amazon: a landscape-level analysis of spatial patterns and drivers. **Urban Ecosystems**, Springer, v. 17, n. 3, p. 643–659, 2014.
- BARBOSA, L. F.; OLIVEIRA, R. A.; COSTA, G. A. O turismo de cruzeiros fluviais na amazônia: análise preliminar. In: **Anais do Congresso Brasileiro de Pesquisa e Desenvolvimento em Turismo**. [S.l.: s.n.], 2017. v. 10.
- BENINI, L.; BOGLIOLO, A. A survey of design techniques for system-level dynamic power management. **IEEE Transactions on Very Large Scale Integration (VLSI) Systems**, v. 8, n. 3, p. 299–316, 2000.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. [S.l.]: Springer, 2006.
- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. Yolov4: Optimal speed and accuracy of object detection. **arXiv preprint arXiv:2004.10934**, 2020.
- CARMINATI, L. Generalizability in qualitative research: A tale of two traditions. **Qualitative Health Research**, v. 28, p. 2094 – 2101, 2018.
- CARVALHO, A. A. d.; SOUZA, E. R. O transporte fluvial na amazônia legal: uma análise a partir das viagens intermunicipais realizadas por barcos de passageiros. **Revista de Economia e Sociologia Rural**, v. 57, n. 1, p. 25–42, 2019.
- CARVALHO, C. **Imagem de estudo sobre uso de madeiras amazônicas na construção de barcos**. 2014. <<https://www.fapeam.am.gov.br/estudo-analisa-uso-de-madeiras-amazonicas-para-a-construcao-de-barcos/>>. Acesso em: 22/03/2024.
- Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação. **TIC Domicílios 2022**. 2022. <https://cetic.br/media/analises/tic_domicilios_2022_coletiva_imprensa.pdf>.
- CHAUHAN, M. S.; SINGH, A.; KHEMKA, M.; PRATEEK, A.; SEN, R. Embedded cnn based vehicle classification and counting in non-laned road traffic. In: **Tenth International Conference on Information and Communication Technologies and**

Development (ICTD '19). Ahmedabad, India: ACM, 2019. p. 11. Disponível em: <<https://doi.org/10.1145/3287098.3287118>>.

CHOLLET, F. **Deep Learning with Python**. [S.l.]: Manning Publications, 2018.

COSTA, E. S.; SOUZA, L. M. Perspectivas de desenvolvimento do turismo fluvial na amazônia: o papel das lanchas como meio de transporte. **Turismo em Análise**, v. 31, n. 2, p. 245–260, 2020.

CUNHA, E. F. d. O.; JR., A. S. I. O desafio na regulação do transporte hidroviário intermunicipal no amazonas / the challenge in regulating intermunicipal water transport in amazonas. **Brazilian Journal of Development**, v. 6, n. 3, p. 15736–15752, Mar. 2020. Disponível em: <<https://ojs.brazilianjournals.com.br/ojs/index.php/BRJD/article/view/8197>>.

CUNNINGHAM, P.; CORD, M.; DELANY, S. J. Supervised learning. In: _____. **Machine Learning Techniques for Multimedia: Case Studies on Organization and Retrieval**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 21–49. ISBN 978-3-540-75171-7. Disponível em: <https://doi.org/10.1007/978-3-540-75171-7_2>.

DAMACENO, S. S.; VASCONCELOS, R. O. Inteligência artificial: Uma breve abordagem sobre seu conceito real e o conhecimento popular. **Cadernos de Graduação - Ciências Exatas e Tecnológicas**, v. 5, n. 1, p. 11–16, Outubro 2018.

Departamento Nacional de Infraestrutura de Transportes. **DNIT - Hidrovia do Amazonas**. 2018. <<https://www.gov.br/dnit/pt-br/assuntos/aquaviario/old/hidrovia-do-amazonas>>.

DNIT. **Mapa de Instalações Portuárias de Pequeno Porte**. 2024. Acesso em: 23/03/2024. Disponível em: <https://www.gov.br/dnit/pt-br/assuntos/aquaviario/atlas-aquaviario/20240328_Atlas_Aquavirio_Maro_VF.pdf>.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, v. 35, 08 2006.

Fórum Brasileiro de Segurança Pública (FBSP). **Cartografias da violência na Amazônia**. Fórum Brasileiro de Segurança Pública, 2023. ISBN 978-65-89596-33-2. Disponível em: <<https://publicacoes.forumseguranca.org.br/handle/123456789/233>>.

GASPAR, A. F. d. S.; FARIAS, J. N. L. F.; GUIMARAES, M. R. C.; FONSECA, M. H. d. S.; BATISTA, S. P. M. Oferta turística no transporte fluvial de passageiros: Amostra das embarcações de grande e médio porte em manaus, amazonas, brasil. **Rosa dos Ventos**, v. 13, n. 2, 2021. Disponível em: <<https://www.redalyc.org/articulo.oa?id=473569969005>>.

GLOBO, O. **Redes Hidroviárias do Narcotráfico na Amazônia**. 2020. Acesso em: 25/03/2024. Disponível em: <<https://oglobo.globo.com/politica/novas-cidades-entram-na-rota-do-narcotrafico-na-amazonia-1-24786333>>.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT press Cambridge, 2016.

GUO, Y.; WANG, S.; HE, H.; SUN, L.; MA, S. Research on boat identification based on improved loss function of deep convolutional neural networks. In: IEEE. **2019 WRC Symposium on Advanced Robotics and Automation (WRC SARA)**. [S.l.], 2019. p. 278–283.

- HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. 2nd. ed. Delhi, India: Pearson, 1999.
- HONG, Y.; CHANG, T. A comprehensive review of tolerancing research. **International Journal of Production Research**, v. 40, p. 2425 – 2459, 2002.
- IBAMA. **Impactos ambientais do transporte fluvial na Amazônia**. [S.l.], 2018.
- KITANO, H. Biological robustness. **Nature Reviews Genetics**, v. 5, p. 826–837, 2008.
- KOAY, H.; CHUAH, J.; CHOW, C.-O.; CHANG, Y.-L.; YONG, K. Yolo-rtuav: Towards real-time vehicle detection through aerial images with low-cost edge devices. **Remote Sensing, Multidisciplinary Digital Publishing Institute**, v. 13, n. 21, p. 4196, 2021. Disponível em: <<https://doi.org/10.3390/rs13214196>>.
- KOPIER, A. A.; SILVA, V. N. A. S.; OLIVEIRA, L. A. A. *et al.* Redes neurais artificiais e suas aplicações no setor elétrico. **Revista de Engenharia da Faculdade Salesiana**, n. 9, p. 27–33, 2019.
- LEE, J.; YOO, S.; KIM, S. **Design and Implementation of Embedded Real-Time Systems**. [S.l.]: Springer, 2016.
- LIMA, T. **NVIDIA apresenta a Jetson Nano Developer Kit**. 2019. Imagem extraída da página web. Disponível em: <<https://embarcados.com.br/nvidia-jetson-nano-developer-kit/>>.
- MALINOWSKI, A.; YU, H. Comparison of embedded system design for industrial applications. **IEEE Transactions on Industrial Informatics**, v. 7, n. 2, p. 244–254, 2011.
- MARTINS, D. G. d. M.; OLIVEIRA, V. I. D.; JUNGER, A. P.; FACó, J. F. B. O conceito de inteligência artificial usado no mercado de softwares, na educação tecnológica e na literatura científica. **Educação Profissional e Tecnológica em Revista**, v. 4, n. 2, p. 98–109, ago. 2020. Disponível em: <<https://ojs.ifes.edu.br/index.php/ept/article/view/557>>.
- MÜLLER, A. C.; GUIDO, S. **Introduction to Machine Learning with Python: A Guide for Data Scientists**. [S.l.]: O'Reilly Media, 2016.
- NETWORKS, O. N. **Ligações em uma Rede Neural**. 2018. Acesso em: 02/04/2024. Disponível em: <<https://www.opennn.net/>>.
- NVIDIA. **Página de Desenvolvimento de Produto do Jetson Nano**. 2024. <<https://www.nvidia.com/pt-br/autonomous-machines/embedded-systems/jetson-nano/product-development/>>.
- O'SHEA, K.; NASH, R. An introduction to convolutional neural networks. **CoRR**, abs/1511.08458, 2015. Disponível em: <<http://arxiv.org/abs/1511.08458>>.
- OSORIO, F. Sistemas inteligentes baseados em redes neurais artificiais aplicados ao processamento de imagens. In: **I Workshop de Int. Artificial - UNISC**. Santa Cruz do Sul: [s.n.], 2000. p. 1–30.
- PACHECO, A. G. C. Classificação de espécies de peixe utilizando redes neurais convolucionais. **ArXiv**, abs/1905.03642, 2019.
- PAN, S. J.; YANG, Q. A survey on transfer learning. **IEEE Transactions on Knowledge and Data Engineering**, v. 22, n. 10, p. 1345–1359, 2010.

PONT, M. J.; SOTIRIADES, E. **Embedded Systems and Wireless Technology: Theory and Practical Applications**. [S.l.]: IGI Global, 2017.

PROVOST, F.; FAWCETT, T. **Data Science for Business: What You Need to Know about Data Mining and Data-Analytic Thinking**. [S.l.]: O'Reilly Media, Inc., 2013.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. 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.

REDMON, J.; FARHADI, A. **YOLO: Real-Time Object Detection**. 2016. Imagem extraída da página web. Disponível em: <<https://pjreddie.com/darknet/yolo/>>.

REDMON, J.; FARHADI, A. YOLOv3: An incremental improvement. **arXiv**, 2018.

ROSA, R. C.; SILVA, J. F. Análise da frota de lanchas na região amazônica: desafios e perspectivas. **Revista de Engenharia Naval**, v. 12, n. 2, p. 78–93, 2018.

SANTIN, W. **Fotografia**. 2010. Acesso em: data de acesso. Disponível em: <<https://www.flickr.com/photos/wsantin/4778122980/>>.

SILBERSCHATZ, A.; GALVIN, P. B.; GAGNE, G. **Operating System Concepts**. 10. ed. [S.l.]: John Wiley Sons, 2018.

SILVA, E. D.; MENEZES, E. **Metodologia da Pesquisa e Elaboração de Dissertação**. [S.l.: s.n.], 2005.

SILVA, M. R. d.; MIRANDA, A. F. d. Desafios e perspectivas para o transporte hidroviário na amazônia. **Caderno Prudentino de Geografia**, v. 42, n. 1, p. 47–64, 2020.

SILVEIRA, D. T.; CORDOVA, F. P. Unidade 2 - a pesquisa científica. In: GERHARDT, T. E.; SILVEIRA, D. T. (Ed.). **Métodos de Pesquisa**. Porto Alegre: Editora da UFRGS, 2009. p. 31–42.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. [S.l.]: MIT Press, 2018.

TECH, D. **Ligações em uma Rede Neural Convolutional**. 2022. Acesso em: 02/04/2024. Disponível em: <<https://didatica.tech/introducao-a-redes-neurais-convolucionais/>>.

UNESCO. **Enhancing Cooperation and Integrated Water Management in the Amazon River Basin**. 2022. <<https://www.unesco.org/en/articles/enhancing-cooperation-and-integrated-water-management-amazon-river-basin>>. Acesso em: 4 de abril de 2024.

VICTOR, F. **Raspberry Pi e Arduino: Qual é a diferença e qual é o melhor para o seu projeto?** 2018. Imagem extraída da página web. Disponível em: <<https://www.tecstudio.com.br/tecnologia/raspberry-pi-e-arduino-qual-e-a-diferenca-e-qual-e-o-melhor-para-o-seu-projeto/>>.

WEISS, M. C.; BERNARDES, R. C.; CONSONI, F. L. Cidades inteligentes: casos e perspectivas para as cidades brasileiras. **Revista Tecnológica da Fatec Americana**, v. 5, n. 1, p. 1–13, Setembro 2017. Disponível em: <http://www.fatec.edu.br/revista_ojs/index.php/RTecFatecAM/article/view/137/115>.

WOLF, W. **Embedded System Design**. [S.l.]: Morgan Kaufmann, 2008.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? In: **Advances in neural information processing systems**. [S.l.: s.n.], 2014. p. 3320–3328.

APÊNDICE A – CÓDIGO DE COMPRESSÃO E REDUÇÃO DA IMAGEM

```
1 import cv2
2 import numpy as np
3 import os
4
5 def save(path, image, jpg_quality=None, png_compression=
    None):
6     if jpg_quality:
7         cv2.imwrite(path, image, [int(cv2.IMWRITE_JPEG_QUALITY)
            , jpg_quality])
8     elif png_compression:
9         cv2.imwrite(path, image, [int(cv2.
            IMWRITE_PNG_COMPRESSION), png_compression])
10    else:
11        cv2.imwrite(path, image)
12
13 def main():
14     dir_original = "comprimido"
15     dir_destino = "padronizado"
16     imgs = os.listdir(dir_original)
17     i = 0
18     txt = ''
19     down_width = 1200
20     down_height = 900
21     down_points = (down_width, down_height)
22
23     for img in imgs:
24         txt += f"{img} -- {i}\n"
25         imgpath = f"{dir_original}/{img}"
26         img = cv2.imread(imgpath)
27         outpath_jpeg = f"{dir_destino}/img_{i}.jpg"
```

```
28     i += 1
29     resized = cv2.resize(img, down_points, interpolation=
cv2.INTER_LINEAR)
30     cv2.imwrite(outpath_jpeg, resized)
31     save(outpath_jpeg, img, jpg_quality=35)
32
33 if __name__ == "__main__":
34     main()
```

Código-fonte 1 – Código Python