

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE
MINAS GERAIS - *CAMPUS* BETIM
BACHARELADO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

Letícia Fernandes dos Reis

**IDENTIFICAÇÃO DE POTENCIAIS FOCOS DE DENGUE USANDO
REDES NEURAIS ARTIFICIAIS COM DADOS DE SENSORIAMENTO
REMOTO**

Betim
2023

LETÍCIA FERNANDES DOS REIS

**IDENTIFICAÇÃO DE POTENCIAIS FOCOS DE DENGUE USANDO
REDES NEURAIS ARTIFICIAIS COM DADOS DE SENSORIAMENTO
REMOTO**

Trabalho de Conclusão de Curso apresentado à banca examinadora do curso de Engenharia de Controle e Automação do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais *Campus* Betim, como parte dos requisitos para obtenção do título de Bacharel em Engenharia de Controle e Automação.

Orientador: Prof. Dr. Leandro Freitas de Abreu

Coorientador: Prof. Me. Virgil Del Duca Almeida

Betim
2023

FICHA CATALOGRÁFICA

R375i Reis, Leticia Fernandes dos
Identificação de potenciais focos de dengue usando redes neurais artificiais com dados de sensoriamento remoto / Leticia Fernandes dos Reis. – 2023.

43 f. : il.

Trabalho de conclusão de curso (Bacharelado em Engenharia de Controle e Automação) - Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais, Câmpus Betim, 2023.

Orientador: prof. Dr. Leandro Freitas de Abreu
Coorientador: prof. Me. Virgil Del Duca Almeida

1. Redes neurais (Computação). 2. Processamento de imagens. 3. Dengue. 4. Automação. I. Reis, Leticia Fernandes dos. II. Título.

CDU: 681.5

Letícia Fernandes dos Reis

**IDENTIFICAÇÃO DE POTENCIAIS FOCOS DE DENGUE USANDO
REDES NEURAIS ARTIFICIAIS COM DADOS DE SENSORIAMENTO
REMOTO**

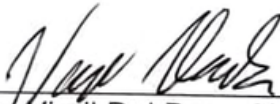
Trabalho de Conclusão de Curso apresentado à banca examinadora do curso de Engenharia de Controle e Automação do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais Campus Betim, como parte dos requisitos para obtenção do título de Bacharel em Engenharia de Controle e Automação.

Betim, 18 de dezembro de 2023.

BANCA EXAMINADORA



Prof. Dr. Leandro Freitas
DAUTI – IFMG Campus Betim (orientador)



Prof. Me. Virgil Del Duca Almeida (co-orientador)
DAUTI – IFMG Campus Betim



Prof. Me. Fernando Thomé de Azevedo Silva
DAUTI – IFMG Campus Betim



Prof. Me. Michelle Mendes Santos
DAUTI – IFMG Campus Betim

Gostaria de dedicar este trabalho para minha mãe, cujo apoio e suporte foram combustíveis para que eu pudesse chegar com sucesso no final dessa jornada.

AGRADECIMENTOS

Gostaria de agradecer primeiramente ao Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais, Campus Betim, essencial no meu processo de formação profissional, pela dedicação, e por tudo o que aprendi ao longo dos anos do curso.

Aos professores, em especial Leandro e Virgil, por terem sido meus orientadores, pelas correções e ensinamentos que me permitiram apresentar um melhor desempenho no meu processo de formação acadêmica ao longo do curso.

Aos meus pais Luciane e Isaías e minha irmã Lívia que me acompanharam de perto desde o primeiro dia de aula e viram minhas tristezas e alegrias ao longo do curso e me impulsionaram sempre a não desistir. Ao Marconi que não me deixa duvidar do meu potencial. Aos meus amigos que me incentivaram nos momentos difíceis. E a Deus pela a saúde e determinação para chegar ao final dessa etapa.

RESUMO

Este trabalho tem como objetivo verificar a viabilidade de usar uma rede neural artificial (RNA) em imagens de sensoriamento remoto para identificar grandes focos de mosquito da dengue, proporcionando uma maneira automática e eficaz aliada ao combate à doença. O foco escolhido no trabalho foi a piscina, que possui uma grande área, não fica abastecida apenas no período de chuva e quando não está tratada se torna um grande criadouro dos mosquitos *Aedes aegypti* e *Aedes albopictus* transmissores da doença. Para isso foi necessário definir o tipo adequado de rede neural artificial para fazer a detecção automática de piscinas usando imagens de sensoriamento remoto, foi utilizada a rede neural convolucional (CNN) YOLOv8, pela sua notoriedade no desempenho de detecção de imagem. Em seguida foi preparado o banco de dados para o treinamento da rede, separando os dados de treinamento e validação, transformando as anotações COCO em anotações YAML, que podem ser identificadas corretamente pelo modelo. E nos resultados foi analisado o desempenho e a eficácia das respostas obtidas nas etapas de treinamento e validação e observar o comportamento do modelo em um novo conjunto de dados.

Palavras-chave: CNN; YOLO; YOLOv8; Detecção de Imagem; Dengue.

ABSTRACT

This work aims to verify the feasibility of using artificial neural network (RNA) in remote sensing images to identify large dengue mosquito outbreaks, providing an automatic and effective way of combating the disease. The focus chosen for the work was the swimming pool, which has a large area, is not filled only during the rainy season and, when untreated, becomes a major breeding ground for the *Aedes aegypti* and *Aedes albopictus* mosquitoes that transmit the disease. To do this, it was necessary to define the appropriate type of artificial neural network to perform automatic detection of swimming pools using remote sensing images. The Convolutional Neural Networks (CNN) YOLOv8 network was used, due to its notoriety in image detection performance. The database for training the network was then prepared by separating the training and validation data, transforming the COCO annotations into YAML annotations, which can be correctly identified by the model. The results analyzed the performance and effectiveness of the answers obtained in the training and validation stages and observed the model's behavior on a new dataset.

Keywords: CNN; YOLO; YOLOv8; Image detection; Dengue Fever.

LISTA DE ILUSTRAÇÕES

Figura 1 – a evolução da doença nos países Panamericanos..	12
Figura 2 – Mosquito <i>Aedes Aegypti</i>	13
Figura 3 – Piscina sem tratamento, potencial foco do mosquito da dengue.	15
Figura 4 – O neurônio artificial de McCulloch e Pitts.	16
Figura 5 – Estrutura geral de uma rede Perceptron.	17
Figura 6 – Exemplo de uma rede profunda.	17
Figura 7 – Linha do tempo de versões da rede YOLO.	19
Figura 8 – Funcionamento de uma detecção de objetos com uma rede YOLO.	20
Figura 9 – Arquitetura da rede YOLOv8.	20
Figura 10 – Matriz de Confusão.	21
Figura 11 – Exemplos de imagens presentes no conjunto de dados com caixas delimitadas em torno das piscinas.	22
Figura 12 – Formato de caixa delimitadora: COCO vs YOLO.	23
Figura 13 – Estrutura do conjunto de dados.	24
Figura 14 – Conteúdo do arquivo descritor do conjunto de dados.	25
Figura 15 – Modelos de rede neurais propostos YOLOv8.	25
Figura 16 – Amostragem com imagens rotuladas pela rede na primeira batelada de treinamento, modelo nano.	26
Figura 17 – Representação dos eixos nos gráficos de perda das figuras 18,19,20 e 21 fornecidos pelo modelo YOLOv8.	28
Figura 18 – Gráficos de perda, para as etapas de treinamento e validação com modelo de tamanho nano.	29
Figura 19 – Gráficos de perda, para as etapas de treinamento e validação com modelo de tamanho pequeno.	30
Figura 20 – Gráficos de perda, para as etapas de treinamento e validação com modelo de tamanho médio.	31
Figura 21 – Gráficos de perda, para as etapas de treinamento e validação com modelo de tamanho grande.	32
Figura 22 – Curva de métricas, modelo de tamanho nano.	33
Figura 23 – Curva de métricas, modelo de tamanho pequeno.	34
Figura 24 – Curva de métricas, modelo de tamanho médio.	35
Figura 25 – Curva de métricas, modelo de tamanho grande.	36
Figura 26 – Desempenho do modelo de tamanho nano nos dados de teste.	38
Figura 27 – Desempenho do modelo de tamanho pequeno nos dados de teste.	38
Figura 28 – Desempenho do modelo de tamanho médio nos dados de teste.	39
Figura 29 – Desempenho do modelo de tamanho grande nos dados de teste.	39

LISTA DE TABELAS

Tabela 1 – Matriz de Confusão Modelo de Tamanho Nano	27
Tabela 2 – Matriz de Confusão Modelo de Tamanho Pequeno	27
Tabela 3 – Matriz de Confusão Modelo de Tamanho Médio	27
Tabela 4 – Matriz de Confusão Modelo de Tamanho Grande	27
Tabela 5 – Avaliação de Desempenho dos Modelos	37

LISTA DE ABREVIATURAS E SIGLAS

IFMG	Instituto Federal de Minas Gerais
SE	Semana Epidemiológica
FHD	Febre Hemorrágica da Dengue
IA	Inteligência Artificial
Anvisa	Agência Nacional de Vigilância Sanitária
SUS	Sistema Único de Saúde
MS	Ministério da Saúde
RNA	Redes Neurais Artificiais
SESAB	Secretaria de Saude do Estado da Bahia
SVSA	Secretaria de Vigilância em Saúde e Ambiente
DNN	Deep Neural Networks
CNN	Convolutional Neural Networks
YOLO	You Only Look Once
COCO	Common Objects in Context
GPU	Unidade de Processamento Gráfico
XML	Extensible Markup Language
YAML	Ain't Markup Language
SGD	Stochastic Gradient Descent
mPA	Mean Average Precision
VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
FP	Falso Positivo
FN	Falso Negativo


SUMÁRIO

1	INTRODUÇÃO	12
1.1	Justificativa	14
1.2	Objetivos	15
1.3	Organização do Texto	15
2	REVISÃO BIBLIOGRÁFICA	16
3	METODOLOGIA	22
3.1	Adaptação do Banco de Dados Para o Treinamento dos Modelos	22
3.2	Treinamento das Redes Neurais Artificiais	25
3.3	Resultado do Treinamento das Redes Neurais	26
4	RESULTADOS	37
4.1	Teste das Redes Neurais	37
5	CONCLUSÃO E TRABALHOS FUTUROS	40
5.1	Trabalhos Futuros	40
	REFERÊNCIAS	41

1 INTRODUÇÃO

Nos países Panamericanos os casos de dengue no ano de 2019 atingiram os maiores números registrados até o momento: 3.139.335. Dentre eles 28.169, ou seja 0,9%, foram classificados como dengue hemorrágica e 1.538 mortes foram causadas pela doença. O Brasil foi o país que apresentou o maior número de casos 2.226.865, que correspondem a 70,93% dos registros. Já no ano de 2023, na América do Sul, até a 24ª Semana Epidemiológica (SE) foram reportados 2.102.848 casos, sendo o Brasil com 1.515.460 registros, liderando o número de casos (PAHO, 2023). Com esses números, é possível ver como o comportamento da dengue é crescente e a necessidade de tomar medidas mais efetivas para combatê-la. A Figura 1 mostra a distribuição dos casos notificados de dengue e proporção de casos graves por ano em Países Panamericanos, de 1999 a 2021 (até a 22ª semana de 2021)

Figura 1 – a evolução da doença nos países Panamericanos..



Fonte: PAHO, 2021.

A Dengue é classificada como uma Arbovirose, que são doenças causadas pelo arbovírus, transmitido na natureza entre hospedeiros susceptíveis e indivíduos infectados. Esse tipo de doença era encontrado em sua grande maioria em ambientes silvestres, mas a urbanização trouxe esse problema para as grandes cidades (ROSA, 2000).

A dengue pode ser assintomática ou apresentar sintomas graves, neste caso sendo classificada como Febre Hemorrágica da Dengue (FHD). Os sintomas comuns da doença são febre alta de início súbito, dor de cabeça, prostração, dor muscular e nas articulações, náuseas, vômitos, erupção e pruridos cutâneos, que podem durar de cinco a sete dias. A forma mais grave da doença, FHD, é caracterizada por um histórico de febre de sete dias, quantidade baixa de plaquetas no sangue, tendências hemorrágicas como sangramentos de mucosas do trato gastrointestinal e

outros, além do aumento na permeabilidade vascular e extravasamento de plasma, que pode ser diagnosticado por exame de sangue (DIAS *et al.*, 2010).

Estudos para encontrar a Vacina estão em andamento e no Brasil existem duas Vacinas aprovadas pela Anvisa: a Dengvaxia, aprovada em 2015 e a Qdenga aprovada em 2023 (FERNANDES *et al.*, 2023). Mesmo com o avanço na vacinação, o SUS não disponibiliza gratuitamente as vacinas e o tratamento específico para a doença não existe, apenas foca no alívio dos sintomas e na reposição de líquidos (ROSA, 2000). A melhor forma de prevenção se torna a inibição da proliferação do vetor, mosquito *Aedes*, visto na Figura 2, de preferência nos estágios iniciais, ovos e larvas. O combate aos potenciais focos deve ser priorizado. Essa espécie gosta de água limpa e para botar seus ovos. Nas áreas urbanas piscinas em desuso podem servir como criadouros ideais.

Figura 2 – Mosquito *Aedes Aegypti*.



Fonte: SESAB, 2016.

Este trabalho tem como objetivo fazer a detecção automática, usando Redes Neurais Artificiais (RNAs), de piscinas como possíveis focos da dengue. As RNAs surgiram com a necessidade de fazer com que as máquinas fossem capazes de apresentar um comportamento inteligente. Inspiradas na biologia, as redes são compostas por neurônios, podendo ser agrupados em diversas maneiras e aptos a receber uma entrada, fazer uma soma ponderada e passar o resultado adiante até chegar na saída. Nesse trabalho será desenvolvida uma RNA que utiliza imagens de sensoriamento remoto que possuem áreas com uma grande incidência de piscinas para alimentar a entrada da rede e como saída a rede produzirá a localização das possíveis áreas identificadas como piscina na imagem apresentada.

Contando com RNAs, vários problemas de reconhecimento de padrões complexos de imagem foram resolvidos e essa tecnologia vem ganhando atenção e notoriedade nos últimos anos. Elas são capazes de solucionar questões complexas de classificação e detecção automática após ser devidamente treinada para os objetivos desejados.

1.1 Justificativa

A Organização Mundial da Saúde (OMS) publicou em 1995 um programa de ações para guiar as estratégias que deveriam ser adotadas em todo mundo. Foram delimitados cinco pilares: controle do vetor com participação ativa da comunidade; acompanhamento dos casos da doença através do fortalecimento do sistema de comunicação da saúde; preparação de atendimentos de emergência; capacitação e treinamento; pesquisa de controle de vetores (WHO, 1995).

No documento de 2012 a OMS propôs métodos proativos de prevenção para evitar a sobrecarga do sistema de saúde; prevenir a queda da economia e, o mais importante, manter a qualidade de vida das pessoas. As estratégias tinham como objetivo reduzir o número de casos da doença em 50% e a mortalidade em 25% e reforçou que a pesquisa tem um papel importante para melhorar os métodos de acompanhamento, prevenção e controle da dengue (WHO *et al.*, 2012).

Nos dois documentos, citados previamente, a OMS enfatiza a necessidade de usar a pesquisa como ferramenta do controle de vetores e é nessa área que o presente trabalho se encontra ao aplicar o uso de RNA para detecção automática de focos da dengue.

Duas espécies do mosquito, *Aedes aegypti* e *Aedes albopictus*, são os vetores responsáveis pela doença e possuem uma grande capacidade de adaptação. A incidência do vetor foi associada às altas temperaturas, estações chuvosas, altitudes e ventos (DONALÍSIO; GLASSER, 2002), fazendo os países tropicais e subtropicais os mais acometidos pela doença.

O *Aedes aegypti*, predominante nas áreas urbanas, possui hábitos domésticos e diurnos, escolhe locais com a presença de água limpa para colocar seus ovos (CLARO; TOMASSINI; ROSA, 2004), mais de 80% se reproduzem dentro das residências (DONALÍSIO; GLASSER, 2002), utiliza vários criadouros que não dependem necessariamente da água da chuva e podem ser os mais diversos, como uma piscina, uma caixa d'água, um coletor de água de vasos de plantas, dentre outros.

Uma pesquisa feita no Rio de Janeiro (MACHADO; MACHADO; BARROS, 2009) mostra que os grandes criadouros, como casas abandonadas, borracharias, cemitérios, terrenos baldios, imóveis fechados e piscinas em desuso como da Figura 3 devem receber atenção prioritária, por aumentar exponencialmente a densidade populacional do mosquito.

Uma rede neural pode ser usada no processamento de imagens aéreas em tarefas de reconhecimento e classificação de padrões, tratamento de imagens e visão computacional. Seu uso traz benefícios como: robustez, generalização, paralelismo e tolerância ao ruído; que são marcas dessa ferramenta da inteligência artificial (OSÓRIO; BITTENCOURT, 2000).

Nesse cenário é possível identificar os desafios que as políticas públicas enfrentam e o crescente número de casos aponta que as medidas aplicadas não estão apresentando a eficácia planejada.

Figura 3 – Piscina sem tratamento, potencial foco do mosquito da dengue.



Fonte: BAND, 2015.

1.2 Objetivos

Este trabalho tem como objetivo verificar a viabilidade de usar RNA em imagens de sensoriamento remoto para identificar grandes focos de mosquito da dengue, proporcionando uma maneira automática e eficaz aliada ao combate à dengue. Com base no objetivo geral da pesquisa foi possível elencar os seguintes objetivos específicos:

- Adequar o banco de dados para o treinamento da rede;
- Avaliar a aplicação da YOLOv8 na detecção automática de piscinas usando imagens de sensoriamento remoto;
- Analisar o desempenho e a eficácia das respostas obtidas.

1.3 Organização do Texto

Este trabalho está dividido em seis capítulos. O capítulo atual contextualizou e delimitou o tema, falando sobre a doença e a importância de novas ferramentas para enfrentá-la, no capítulo 2 será visto uso de Redes Neurais Convolucionais (CNN's) em problemas similares. O capítulo 3 mostra o tipo de RNA escolhida e a preparação das imagens para do banco de dados. O capítulo 4 mostra o desempenho da rede em três configurações diferentes e no capítulo 5 pode-se ver qual rede performou melhor e as considerações finais do trabalho.


2 REVISÃO BIBLIOGRÁFICA

As redes neurais têm ganhado notoriedade na sociedade devido às ferramentas de inteligência artificial como o ChatGPT, um assistente virtual inteligente no formato chatbot online, lançado em novembro de 2022 pela OpenAI. Porém, o primeiro conceito de neurônio artificial foi apresentado em 1943 nos Estados Unidos pelo (MCCULLOCH; PITTS, 1943) neurofisiologista Warren Sturgis McCulloch e pelo cientista cognitivo Walter Pitts no artigo “*A logical calculus of the ideas immanent in nervous activity*” publicado no *Bulletin of Mathematical Biophysics*.

Nesse artigo, McCulloch e Pitts estabeleceram as bases para o campo da neurociência computacional, ao propor um modelo matemático que descreve o funcionamento básico de um neurônio biológico. Inspirados pela estrutura e atividade dos neurônios do cérebro, eles desenvolveram um sistema lógico simplificado que capturava os princípios essenciais do processamento de informações neuronais.

O neurônio artificial proposto por McCulloch e Pitts, visto na Figura 4, era uma unidade de processamento binário, cuja saída era determinada por uma combinação linear das entradas, seguida de uma função de ativação. Essa função de ativação define um limiar acima do qual o neurônio é ativado, produzindo um sinal de saída. Essa abordagem pioneira permitiu a representação de processos complexos de tomada de decisão e resolução de problemas em termos de operações matemáticas simples.

Figura 4 – O neurônio artificial de McCulloch e Pitts.




Fonte: MEDIUM, 2018.

Na década de 1950, o perceptron, de Frank Rosenblatt foi proposto como um dos primeiros modelos de rede neural desenvolvidos, tornando-se um avanço significativo no campo da inteligência artificial. Rosenblatt em 1958 apresentou o perceptron como um modelo capaz de armazenar e organizar informações no cérebro. Ele propôs que a rede fosse um sistema que pudesse aprender, reconhecer padrões e generalizar, permitindo respostas inteligentes tanto a situações familiares quanto a novas situações, nunca antes encontradas (ROSENBLATT, 1958).

O perceptron é uma rede neural de alimentação direta, também conhecida como *feed-forward*, composta por um único neurônio artificial, inspirada no neurônio artificial proposto por McCulloch e Pitts (MCCULLOCH; PITTS, 1943) realiza tarefas de classificação, onde dados de entrada são atribuídos a uma ou mais categorias. A rede recebe um vetor de entrada x , composto por valores numéricos, e aplica pesos, w , às entradas, realiza uma soma ponderada dessas entradas, seguida de uma função de ativação, geralmente uma função degrau. A função de ativação determina se o neurônio será ativado e emite um sinal de saída, como pode ser visto na Figura 5.


Figura 5 – Estrutura geral de uma rede Perceptron.



Fonte: RASCHKA, 2016.

Com aplicações em reconhecimento de imagens as redes neurais profundas (DNNs) representam uma classe de modelos que consiste em múltiplas camadas de unidades de processamento. Elas são conhecidas por sua eficácia em espaços de alta dimensionalidade e sua capacidade de generalização para conjuntos de dados complexos. Elas são compostas por:

Figura 6 – Exemplo de uma rede profunda.



Fonte: NASCIMENTO; OLIVEIRA, 2016.

1. Estrutura em Camadas: uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, como pode ser vista na figura 6;

2. **Aprendizado Hierárquico de Recursos:** Camadas mais baixas podem aprender representações simples, enquanto camadas mais altas podem combinar essas representações para formar conceitos mais complexos;
3. **Ativações Não Lineares:** Cada camada normalmente aplica uma função de ativação não linear nas suas entradas, como a função ReLU (Rectified Linear Unit), sigmoide, ou tangente hiperbólica. Essas funções introduzem não linearidades nas redes, permitindo-as aprender padrões mais complexos.
4. **Treinamento com Retropropagação:** As DNNs são treinadas usando o algoritmo de retropropagação (*backpropagation*)
5. **Vanishing Gradient e Exploding Gradient:** Um desafio nas DNNs é o problema do gradiente que desaparece (*vanishing gradient*) ou explode (*exploding gradient*) durante o treinamento. Isso pode ser mitigado usando inicializações de peso adequadas e normalizações, como a Normalização em Lotes (*Batch Normalization*).

Exemplos de DNNs populares incluem Redes Neurais Convolucionais (CNNs) para processamento de imagens e Redes Neurais Recorrentes (RNNs) para dados sequenciais, como texto ou séries temporais. São amplamente utilizadas, incluindo reconhecimento de imagem, processamento de linguagem natural, tradução automática, jogos, diagnóstico médico, entre outros. Vários *frameworks*, como *TensorFlow*, *PyTorch* e *Keras*, facilitam a implementação e treinamento de DNNs.

Na identificação automática de imagens vários tipos de redes neurais podem ser usados de acordo com a aplicação desejada, tendo como fonte de dados o sensoriamento remoto, que consiste em uma tecnologia capaz de adquirir informações sobre a superfície terrestre sem a realização de contato. O uso dessa tecnologia tem sido cada vez mais incentivado como ferramenta para a prevenção de doenças endêmicas pelo avanço dos sensores a bordo dos satélites (CORREIA *et al.*, 2004).

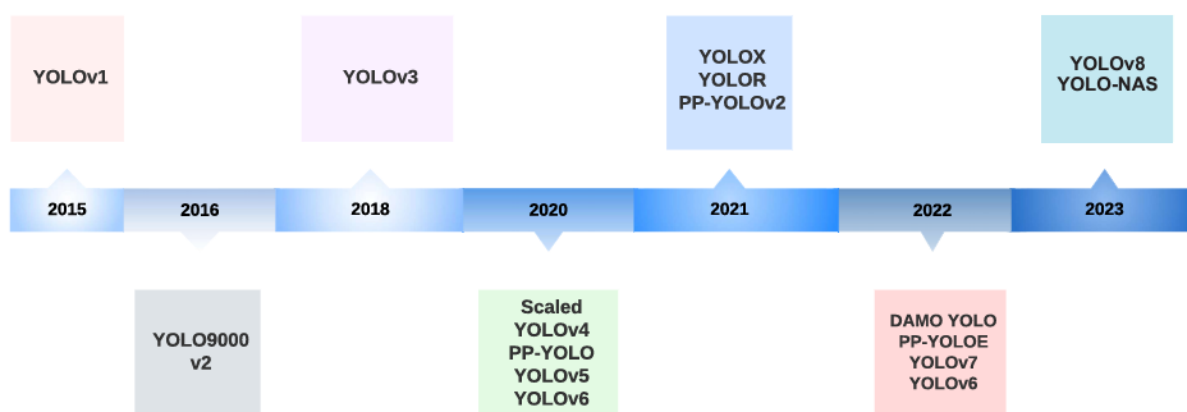
Em um estudo que analisou seis redes na classificação de imagens de sensoriamento remoto (NOGUEIRA; PENATTI; SANTOS, 2017), as redes escolhidas foram todas do tipo convolucional, muito utilizadas na área de visão computacional por possuir a capacidade de aplicar filtros em dados visuais e manter a relação de pixels na imagem durante o processamento na rede (VARGAS; PAES; VASCONCELOS, 2016). Também chamadas de CNN, apresentam características diferentes de acordo com a arquitetura. A escolha da rede mais adequada será feita com base na capacidade de identificar e aprender padrões.

Dentre os tipos de CNNs existentes atualmente, foi escolhida a YOLO (*You Only Look Once*), pela sua notoriedade no desempenho de detecção e segmentação de imagem. Um estudo que realizou a detecção de objetos em imagens aéreas de veículos aéreos não tripulados (VANTs)

(WANG *et al.*, 2023), utilizou o modelo YOLOv8 modificado para obter precisão sem aumentar o consumo de recursos computacionais.

Criada em 2015 por Joseph Redmon e Ali Farhadi na University de Washington, YOLO ganhou rapidamente popularidade pela sua alta velocidade e precisão. O modelo está em sua oitava versão e durante sua trajetória teve melhorias em desempenho, flexibilidade e eficiência. Segundo a Ultralytics, empresa responsável pela distribuição das versões 5 e 8 do modelo a YOLOv8 (JOCHER; CHAURASIA; QIU, 2023) tem suporte para várias tarefas de uma inteligência artificial (AI) como detecção, segmentação, estimativa de localização, monitoramento e classificação. A Figura 7 mostra a evolução das versões dessa rede.

Figura 7 – Linha do tempo de versões da rede YOLO.



Fonte: TERVEN; CORDOVA-ESPARZA, 2023.

Para realizar a detecção de objetos o modelo YOLO separa a imagem em uma grade de $S \times S$ células (ALVES, 2020), se o centro de um objeto estiver dentro de uma célula ela será responsável pela detecção do objeto. Em seguida cada célula irá realizar a predição da caixa delimitadora (S), podendo ser mais de uma dependendo da quantidade de objetos na célula, retorna também o valor de confiança de sua predição. A célula fornece uma previsão de classe juntamente ao seu valor de probabilidade para cada uma das classes possíveis. O valor de confiança para a caixa delimitadora e a predição da classe são combinados em uma pontuação final, que vai nos dizer a probabilidade dessa caixa conter um objeto específico. Apenas as caixas cuja pontuação final seja 30% ou mais serão consideradas. O passo a passo pode ser visto na figura 8.

YOLOv8 é um grupo de modelos de rede neural que são treinados no conjunto de dados COCO (LIN *et al.*, 2014) que possui 80 tipos de imagens diferentes. Para o treinamento e validação da rede neural foi necessário primeiro preparar o ambiente, baixando o pacote ultralytics e importando a classe YOLO.

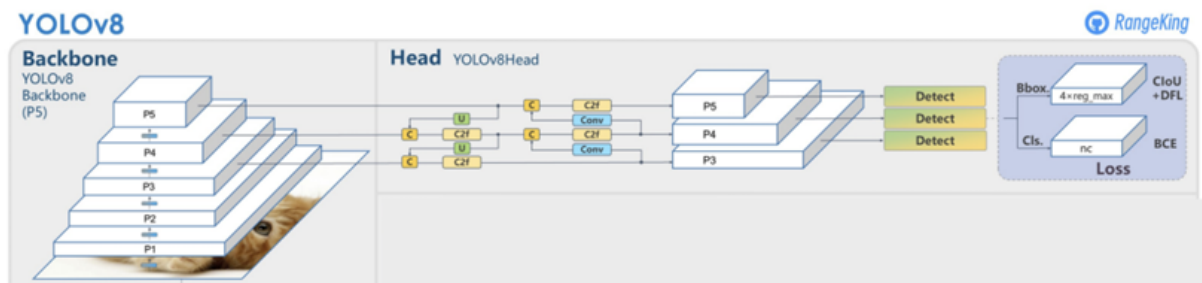
A arquitetura do modelo YOLOv8, vista na Figura 9, se baseia nas versões anteriores utilizando uma CNN que pode ser dividida entre a cabeça e a coluna vertebral. A coluna é formada por 53 camadas convolucionais e emprega conexões parciais entre estágios para melhorar o fluxo de informações entre as diferentes camadas (VENKATKUMAR, 2023).

Figura 8 – Funcionamento de uma detecção de objetos com uma rede YOLO.



Fonte: ALVES, 2020.

Figura 9 – Arquitetura da rede YOLOv8.



Fonte: KING, 2023.

A cabeça apresenta diversas camadas convolucionais seguidas por uma série de camadas totalmente conectadas. Essas camadas são responsáveis pela previsão de caixas delimitadoras, pontuações de assertividade e probabilidades de classe para os objetos detectados em uma imagem (VENKATKUMAR, 2023).

Os modelos YOLO são pré-treinados em grandes conjuntos de dados, como COCO (*Common Objects in Context*) (LIN *et al.*, 2014) e ImageNet (RUSSAKOVSKY *et al.*, 2015). Isso lhes dá a capacidade de fornecer previsões altamente precisas sobre as classes nas quais foram pré-treinados e também podem aprender novas classes com relativa facilidade. O modelo fornece também gráficos com informações sobre o desempenho do modelo na detecção de objetos. Elas são baseadas nos seguintes parâmetros:

1. P (Precisão): A precisão dos objetos detectados, indicando quantas detecções estavam corretas;
2. Ap (Precisão média): se trata da média das precisões corretas do modelo (P);
3. R (Recall): A capacidade do modelo de identificar todas as instâncias de objetos nas imagens;
4. mAP: é a média aritmética das médias (AP);

5. mAP50: precisão média calculada em um limite de interseção sobre união (IoU) de 50%. É uma medida da precisão do modelo considerando apenas as detecções "fáceis";
6. mAP50-95: a média da precisão calculada em limites de IoU variados, variando de 50% a 95%. Ela fornece uma visão abrangente do desempenho do modelo em diferentes níveis de dificuldade de detecção.

É possível analisar os parâmetros também através de gráficos de perda de caixa, de classe e de desfocagem. Onde *box_loss* mede o erro na previsão das coordenadas das caixas delimitadoras, fazendo com que o modelo ajuste as caixas delimitadoras previstas para as alinhar com as caixas rotuladas; *cls_loss* quantifica o erro na previsão da classe do objeto para cada caixa delimitadora, garantindo precisão na identificação de categoria do objeto; *dfl_loss* é um componente de perda especializado que ajuda a melhorar a detecção de objetos em cenários com imagens desfocadas ou embaçadas.

Uma rede neural usualmente apresenta quatro tipos de resultados, também conhecidos como matriz de confusão, vista na Figura 10, no caso do modelo deste trabalho pode ser interpretado da seguinte forma:

1. Verdadeiro positivo (VP): o modelo acusa a existência de uma piscina onde realmente existe uma piscina;
2. Verdadeiro Negativo (VN): o modelo acusa a existência de uma piscina onde não existe uma;
3. Falso Positivo (FP): o modelo, de maneira correta, não identifica uma piscina numa dada região, pois realmente a piscina não existe;
4. Falso Negativo (FN): o modelo diz não existir uma piscina no local, quando na verdade existe.

Figura 10 – Matriz de Confusão.

	Real Positivo = 1	Real Negativo = 0
Predito Positivo = 1	VP	FP
Predito Negativo = 0	FN	VN

Fonte: PRATES, 2021.

Com os valores obtidos com os parâmetros de resultados será possível inferir como o modelo escolhido irá performar com imagens fora do banco de dados que foi treinado.

3 METODOLOGIA

O Capítulo 2 apresentou a revisão bibliográfica. Neste capítulo será apresentada a metodologia do trabalho que será utilizada na pesquisa. Tendo em vista atingir os objetivos gerais e específicos citados no Capítulo 1, a preparação do banco de dados para treinamento da rede será o tema abordado a seguir.

3.1 Adaptação do Banco de Dados Para o Treinamento dos Modelos

Um estudo realizou a detecção de piscinas e classificação da qualidade da água (JHA, 2020). Com base nele, o primeiro passo é criar dados para o treinamento das redes - fotos com diferentes piscinas em diversas condições e ângulos. Para realizar a detecção na pesquisa foram classificadas em torno de 2000 piscinas no sul da Califórnia, Estados Unidos. Tomando como base o estudo, foi utilizada uma base de dados com imagens de mais de 1000 piscinas identificadas com 512x512 pixels de tamanho (ALEX, 2022). A base de dados será utilizada para o treinamento das RNAs. Na figura 11 pode-se ver alguns exemplos de imagens rotuladas presentes no *dataset*.

Figura 11 – Exemplos de imagens presentes no conjunto de dados com caixas delimitadoras em torno das piscinas.



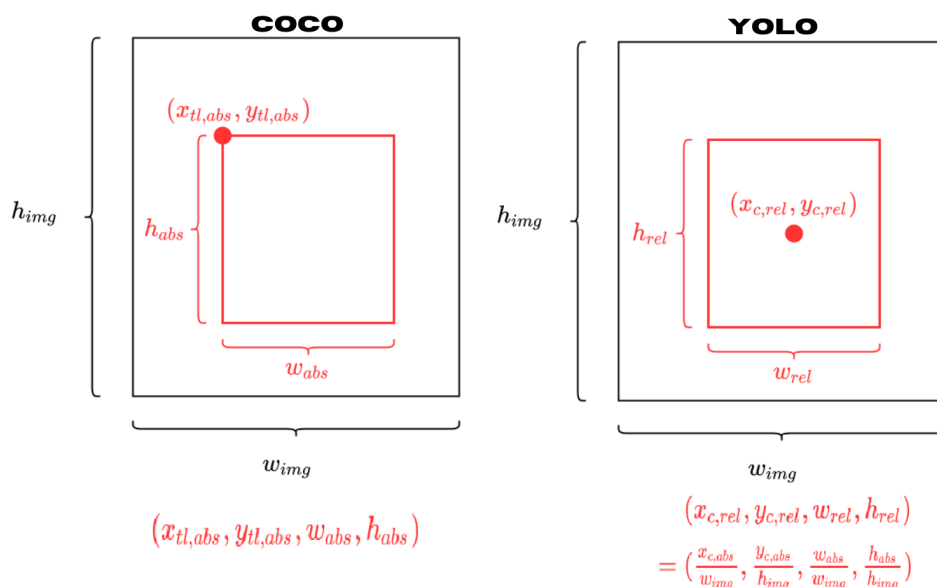
Fonte: ALEX, 2022.

Este trabalho foi desenvolvido na linguagem Python através da ferramenta Colaboratory, um produto do Google, que oferece unidades de processamento gráfico (GPU's), e é utilizado para fins educacionais, análise de dados e aprendizagem de máquina. Usando o Colaboratory foi possível conectar o Notebook ao banco de dados que se encontrava em uma pasta do Drive, o serviço de armazenamento e sincronização de arquivos do Google.

Para o trabalho de detecção, a primeira tarefa foi separar no banco de dados apenas as imagens que continham piscinas e já estavam previamente rotuladas. De 2401, tamanho total do banco de dados, obteve-se 1224 imagens utilizáveis, ou seja, continham piscinas e um arquivo com uma linguagem de marcação que define um conjunto de regras para codificação de documentos (XML) correspondente. Os dados vieram identificados com um XML em COCO, formato padrão para armazenamento de informações de imagens e vídeos. Das 1224 imagens 70% foram separadas aleatoriamente para serem dados de treinamento, outros 15% para validação e os demais 15% para teste.

A etapa seguinte foi a preparação dos dados para que a rede YOLO pudesse interpretar. O conjunto estava rotulado em arquivos XML com o mesmo nome de cada imagem, formatados em COCO e a rede necessita receber rótulos arquivos TXT no formato YAML. Como pode ser visto figura 12, as caixas delimitadoras no formato COCO são descritas através de um par de coordenadas absolutas, ou seja, todas as referências partem sempre do encontro dos 2 eixos. No COCO este ponto está localizado no canto superior esquerdo da caixa delimitadora do objeto, juntamente com sua altura absoluta e comprimento absoluto. Já o formato YAML, utilizado pela YOLO, recebe o par de coordenadas do centro relativo, ou seja, a posição central em relação a caixa delimitadora e sua altura e comprimento relativo, as informações são armazenadas em um arquivo TXT de acordo com a pasta direcionada.

Figura 12 – Formato de caixa delimitadora: COCO vs YOLO.



As Equações a seguir (TAN, 2022) apresentam a conversão da cada variável usada para transformar a anotação COCO para a anotação YAML,

$$x_{yolo} = (x_{coco} + \frac{w_{coco}}{2})/w_{img}; \quad (3.1)$$

$$y_{yolo} = (y_{coco} + \frac{h_{coco}}{2})/h_{img}; \quad (3.2)$$

$$w_{yolo} = w_{coco}/w_{img}; \quad (3.3)$$

$$h_{yolo} = h_{coco}/h_{img}; \quad (3.4)$$

onde 3.1 demonstra o valor de x_{YOLO} em relação ao par ordenado na coordenada absoluta de COCO e a largura da imagem, 3.2 demonstra o valor de y_{YOLO} em relação ao par ordenado na coordenada absoluta de COCO e a altura da imagem, 3.3 mostra que a largura w_{YOLO} será a largura absoluta COCO sobre a largura da imagem e 3.4 mostra que a altura h_{YOLO} será a altura absoluta COCO sobre a altura da imagem.

Neste trabalho, o produto final da conversão foram dois arquivos, um para treinamento com todas as anotações de imagens desse diretório e o segundo com as anotações das imagens separadas para validação. Para que o modelo faça a leitura corretamente, é necessário que o diretório formado tenha a estrutura da Figura 13.

Figura 13 – Estrutura do conjunto de dados.



Fonte: Elaborado pelo autor, 2023.

O último passo foi a criação do arquivo descritor do conjunto de dados, **data.yaml**, que continha o diretório da pasta de treinamento, o diretório da pasta de validação, o número de classes e seus nomes. O conteúdo do arquivo pode ser visto na Figura 14.

Figura 14 – Conteúdo do arquivo descritor do conjunto de dados.

```
data.yaml x
1 train: /content/drive/MyDrive/Colab Notebooks/TCC/TRAIN/images
2 val: /content/drive/MyDrive/Colab Notebooks/TCC/VAL/images
3 nc: 1
4 names: ['pool']
```

Fonte: Elaborado pelo autor, 2023.

3.2 Treinamento das Redes Neurais Artificiais

Para a tarefa de detecção, a YOLOv8 oferece cinco opções, vistas na Figura 15. Os tipos de modelos variam de acordo com o tamanho: n - nano, s - pequeno, m - médio, l - grande e x - muito grande. Quanto maior o modelo maior será a qualidade de predição. Porém o tempo de processamento será maior. Para o trabalho foram escolhidos quatro modelos: nano, pequeno, médio e grande. Variando os tamanhos dos modelos é possível avaliar qual apresenta melhor relação entre tempo de processamento e assertividade do modelo.

Figura 15 – Modelos de rede neurais propostos YOLOv8.

Model	Filenames	Task	Inference	Validation	Training	Export
YOLOv8	<pre>yolov8n.pt yolov8s.pt yolov8m.pt yolov8l.pt yolov8x.pt</pre>	Detection	✓	✓	✓	✓

Fonte: JOCHER, 2023.

Para iniciar o treinamento do modelo com os dados do conjunto escolhido é necessário passar como parâmetros obrigatórios para o modelo o arquivo data.yaml e a quantidade de épocas. Época por sua vez se trata da quantidade de vezes que o conjunto de dados é analisado pela rede neural. Os quatro modelos foram treinados com 50 épocas.

A função de treinamento do modelo é dividida em treinamento e validação (GERMANOV, 2023). O treinamento primeiro seleciona e extrai aleatoriamente um lote de imagens da pasta de mesmo nome, passa essas imagens pelo modelo e recebe as caixas delimitadoras resultantes dos objetos e classes detectados, no caso deste trabalho, as piscinas. Em seguida o resultado é transmitido para a função de perda, que calcula a quantidade do erro, usada para comparar a saída recebida com o resultado correto dos arquivos de anotação para essas imagens. O resultado


da função de perda é passado para o otimizador para ajustar os pesos do modelo com base na quantidade de erros, reduzindo os erros no próximo ciclo. Por ser o padrão do modelo o otimizador método do gradiente estocástico (SGD) foi utilizado para os testes.

Na etapa de validação o modelo irá receber 15% das imagens do conjunto de dados que foram separados aleatoriamente. O modelo então analisa as caixas delimitadoras detectadas na fase anterior para essas imagens. Após esta análise ocorre a comparação do resultado gerado com os valores reais das caixas delimitadoras rotuladas. A precisão do modelo é calculada com base na diferença entre os resultados reais e os encontrados.

3.3 Resultado do Treinamento das Redes Neurais

A seguir, na Figura 15 pode-se ver um exemplo de uma batelada de imagens que o modelo de tamanho nano previu em sua fase de validação, juntamente com as caixas delimitadoras e o nome da classe encontrada.

Figura 16 – Amostragem com imagens rotuladas pela rede na primeira batelada de treinamento, modelo nano.



Fonte: Elaborado pelo autor, 2023.

A rede YOLO fornece saídas para a análise de desempenho da rede. O primeiro deles a ser analisado foi a matriz confusão que fornece uma visão detalhada dos resultados, mostrando as contagens de VP, VN, FP e FN para cada classe. Em todos os modelos podemos perceber que ainda existe a possibilidade de aumentar o número de épocas para

A matriz de confusão vista na Tabela 1, referente ao modelo de tamanho nano, mostra que na fase de treinamento a rede foi capaz de acertar corretamente 94% das piscinas apresentadas deixando de detectar corretamente 6% das piscinas.

Tabela 1 – Matriz de Confusão Modelo de Tamanho Nano

		Real Positivo	Real Negativo
Valor Previsto	Positivo	94%	100%
Valor Previsto	Negativo	6%	0%

A matriz de confusão vista na Tabela 2, referente ao modelo de tamanho pequeno, mostra que na fase de treinamento a rede foi capaz de acertar corretamente 96% das piscinas apresentadas deixando de detectar corretamente 4% das piscinas.

Tabela 2 – Matriz de Confusão Modelo de Tamanho Pequeno

		Real Positivo	Real Negativo
Valor Previsto	Positivo	96%	100%
Valor Previsto	Negativo	4%	0%

A matriz de confusão vista na Tabela 3, referente ao modelo de tamanho médio, mostra que na fase de treinamento a rede foi capaz de acertar corretamente 95% das piscinas apresentadas deixando de detectar corretamente 5% das piscinas.

Tabela 3 – Matriz de Confusão Modelo de Tamanho Médio

		Real Positivo	Real Negativo
Valor Previsto	Positivo	95%	100%
Valor Previsto	Negativo	5%	0%

A matriz de confusão vista na Tabela 4, referente ao modelo de tamanho grande, mostra que na fase de treinamento a rede foi capaz de acertar corretamente 92% das piscinas apresentadas deixando de detectar corretamente 8% das piscinas.

Tabela 4 – Matriz de Confusão Modelo de Tamanho Grande

		Real Positivo	Real Negativo
Valor Previsto	Positivo	92%	100%
Valor Previsto	Negativo	8%	0%

Analisando as tabelas das matrizes de confusão dos quatro modelos é possível perceber que o apresentaram desempenhos similares, nos resultados verdadeiros positivos a rede com o modelo de tamanho pequeno conseguiu a maior porcentagem de acertos, já o modelo de tamanho grande teve o pior desempenho alcançando a menor porcentagem de acertos.

Os gráficos a seguir fornecidos como resultados pela rede YOLO mostram o comportamento de perda das redes nas etapas de treinamento e validação. Onde o eixo X representa o

Figura 17 – Representação dos eixos nos gráficos de perda das figuras 18,19,20 e 21 fornecidos pelo modelo YOLOv8.




Fonte: Elaborado pelo autor, 2023.

número de épocas do modelo e o eixo Y mostra o valor de perda em cada caso, como representado na figura 17.

No modelo de tamanho nano, Figura 18, pode ser notado que os valores de perda decaem ao longo das épocas para os gráficos de treinamento mostrando que o modelo está realizando o ajuste de seus parâmetros corretamente para minimizar os erros. Na etapa de validação ocorre uma variabilidade maior para os gráficos de perda de caixa e de desfocagem porém eles continuam apresentando bons resultados finais.


Figura 18 – Gráficos de perda, para as etapas de treinamento e validação com modelo de tamanho nano.



Fonte: Elaborado pelo autor, 2023.

O modelo de tamanho pequeno, Figura 19, mostra que os valores de perda decaem ao longo das épocas para os gráficos de treinamento mostrando que o modelo está realizando o ajuste de seus parâmetros corretamente para minimizar os erros. Na etapa de validação ocorre uma variabilidade maior para todos os gráficos de perda desempenho similar ao modelo nano.


Figura 19 – Gráficos de perda, para as etapas de treinamento e validação com modelo de tamanho pequeno.



Fonte: Elaborado pelo autor, 2023.

Já o modelo de tamanho médio, Figura 20, pode ser notado que os valores de perda de treinamento e validação decaem ao longo das épocas e possuem uma variabilidade menor mostrando que o modelo está realizando o ajuste de seus parâmetros corretamente para minimizar os erros.


Figura 20 – Gráficos de perda, para as etapas de treinamento e validação com modelo de tamanho médio.



Fonte: Elaborado pelo autor, 2023.

Já no modelo de tamanho grande, Figura 21, assim como o modelo de tamanho médio os valores de perda de treinamento e validação decaem ao longo das épocas e possuem uma variabilidade menor mostrando que o modelo está realizando o ajuste de seus parâmetros corretamente para minimizar os erros.


Figura 21 – Gráficos de perda, para as etapas de treinamento e validação com modelo de tamanho grande.



Fonte: Elaborado pelo autor, 2023.

Os gráficos de métricas 22, 23, 24 e 25 fornecem informações sobre o desempenho do modelo na detecção de objetos, tendo o eixo X como número de épocas e o eixo Y com valores de precisão, *recall*, mAP50 e mAP50-95 para cada um dos modelos. O modelo nano, Figura 22, mostra que os valores de *recall* possuem uma variabilidade maior mostrando que o modelo apresentou durante seu treinamento uma dificuldade para com FP enquanto os demais gráficos apresentam uma variação controlada.


Figura 22 – Curva de métricas, modelo de tamanho nano.



Fonte: Elaborado pelo autor, 2023.

Já o modelo pequeno, 23, apresenta variabilidade maior de precisão e de *recall* ao longo das épocas, mostrando que os parâmetros da rede eram ajustados com valores maiores que os necessários para os dados.


Figura 23 – Curva de métricas, modelo de tamanho pequeno.



Fonte: Elaborado pelo autor, 2023.

O modelo de tamanho médio, 24, apresenta pouca variabilidade em suas métricas ao longo das épocas, mostrando que os parâmetros da rede eram ajustados com os valores que necessários.


Figura 24 – Curva de métricas, modelo de tamanho médio.



Fonte: Elaborado pelo autor, 2023.

Por último o modelo de tamanho grande, 25, apresenta uma variedade maior nas métricas iniciais, que podem ter sido causadas por sua quantidade maior de parâmetros no modelo pré-treinado e ao longo das épocas se torna mais estável.

Figura 25 – Curva de métricas, modelo de tamanho grande.



Fonte: Elaborado pelo autor, 2023.

4 RESULTADOS

Neste capítulo são apresentados os resultados alcançados na etapa de teste realizada nos quatro modelos de rede neural.

4.1 Teste das Redes Neurais

Para testar a rede em um ambiente que ela não foi treinada foi separado do conjunto de dados 15% dos dados para que analisar o desempenhos dos modelos. A Tabela ?? montada com os resultados de avaliação dos modelos mostra os valores de P, R, mAP50 e mAP50-95.

Tabela 5 – Avaliação de Desempenho dos Modelos

Modelos	Classe	Imagens	Ocorrências	P	R	mAP50	mAP50-95
Nano	Piscina	183	440	92.30%	92.70%	97.10%	62.20%
Pequeno	Piscina	183	440	91.40%	93.60%	97.10%	62.10%
Médio	Piscina	183	440	93.50%	93.40%	96.90%	59.70%
Grande	Piscina	183	440	96.10%	90.30%	96.30%	60.10%

Ao analisar a tabela é possível ver que os quatro modelos apresentaram uma precisão P para detecção de piscinas mínima de 91.40%, para o modelo pequeno, sendo a rede de tamanho grande em destaque tendo a maior precisão entre os modelos chegando a 96.10%. O valor R de Recall visto mostra que o modelo de tamanho grande apesar de ter a maior precisão para identificar as caixas delimitadoras que teve a menor porcentagem, 90.30%, de piscinas corretamente identificadas em relação ao total de ocorrências na base de dados.

O mPA é usado como referência para avaliar a robustez de um modelo de detecção de imagem, modelos com um maior valor de mPA são mais confiáveis. Ao analisar os resultados de teste de cada modelo, conforme Tabela ?. Os modelos de tamanho nano e pequeno apresentam uma precisão média maior que 97%, e quando esse valor é avaliado entre 50% e 95% a precisão caiu para 62%. Nos modelos de tamanho médio e grande o mAP foi de mais baixo 60% demonstrando que a média de precisão nos acertos não aumentou proporcionalmente com a dimensão dos modelos utilizados.

Nas imagens 26, 27, 28e 29 é possível ver as caixas delimitadoras e o valor de precisão de cada previsão dada pelos modelos ao ser testado, em sua segunda batelada.

Figura 28 – Desempenho do modelo de tamanho médio nos dados de teste.



Fonte: Elaborado pelo autor, 2023.

Figura 29 – Desempenho do modelo de tamanho grande nos dados de teste.



Fonte: Elaborado pelo autor, 2023.

5 CONCLUSÃO E TRABALHOS FUTUROS

Através deste trabalho foi possível verificar que as redes neurais artificiais podem ser importantes aliadas na prevenção e combate à dengue ao conseguir realizar a detecção de objetos em possíveis grandes focos usados para a reprodução dos vetores da doença. A rede YOLOv8 conseguiu alcançar durante o treinamento uma assertividade entre 92% a 96% de VPs, sendo que o menor valor foi alcançado na matriz de confusão do modelo de tamanho grande, e a maior porcentagem pela matriz de tamanho pequeno.

Nos resultados de teste observou-se que as redes de tamanho nano e pequeno chegaram em valores de precisão média de até 50% de 97.10% das vezes em suas predições e quando o limiar de precisão média subiu para 50% e 95% o valor foi de 62.20% para nano e 62.10% para o modelo pequeno, sendo ideais para a implementação da rede unindo uma maior velocidade de processamento, menor uso de recursos computacionais e maior precisão.

5.1 Trabalhos Futuros

Em trabalhos futuros pode ser realizada a criação de uma aplicação WEB, desenvolvida para fiscalização e acompanhamento de regiões mais afetadas pelos órgãos governamentais responsáveis, que permita a submissão de imagens de sensoriamento remoto para serem analisadas pela rede e correlacionadas com o clima da região fornecida pelo usuário, criando alertas de limpezas dos focos de piscinas e também de caixas de água identificados e notificar cidadãos que estejam próximos a áreas de risco.

REFERÊNCIAS

- ALEX. **Aerial images of swimming pools**. 2022. Disponível em: <<https://www.kaggle.com/datasets/alexj21/swimming-pool-512x512/data>>. Acesso em: 16 jul 2023. Citado na página 22.
- ALVES, G. **Deteção de Objetos com YOLO – Uma abordagem moderna**. 2020. Disponível em: <<https://iaexpert.academy/2020/10/13/deteccao-de-objetos-com-yolo-uma-abordagem-moderna/>>. Acesso em: 12 dez 2023. Citado 2 vezes nas páginas 19 e 20.
- BAND. **SP: piscinas abandonadas proliferam a dengue**. 2015. Disponível em: <<https://noticias.band.uol.com.br/noticias/100000743612/sppiscinasabandonadasproliferamadengue.html>>. Acesso em: 2 jul 2020. Citado na página 15.
- CLARO, L. B. L.; TOMASSINI, H. C. B.; ROSA, M. L. G. Prevenção e controle do dengue: uma revisão de estudos sobre conhecimentos, crenças e práticas da população. **Cadernos de Saúde Pública**, Escola Nacional de Saúde Pública Sergio Arouca, Fundação Oswaldo Cruz, v. 20, n. 6, p. 1447–1457, Nov 2004. ISSN 0102-311X. Disponível em: <<https://doi.org/10.1590/S0102-311X2004000600002>>. Citado na página 14.
- CORREIA, V. R. d. M.; CARVALHO, M. S.; SABROZA, P. C.; VASCONCELOS, C. H. Remote sensing as a tool to survey endemic diseases in brazil. **Cadernos de Saúde Pública**, SciELO Public Health, v. 20, p. 891–904, 2004. Citado na página 18.
- DIAS, L. B. A.; ALMEIDA, S. C.; HAES, T. M.; MOTA, L. M.; RORIZ-FILHO, J. S. Dengue: transmissão, aspectos clínicos, diagnóstico e tratamento. **Medicina (Ribeirão Preto)**, Medicina (Ribeirão Preto), v. 43, n. 2, p. 143–152, 2010. Disponível em: <<https://www.revistas.usp.br/rmrp/article/view/171>>. Citado na página 13.
- DONALÍSIO, M. R.; GLASSER, C. M. Vigilância entomológica e controle de vetores do dengue. **Revista Brasileira de Epidemiologia**, Associação Brasileira de Saúde Coletiva, v. 5, n. 3, p. 259–279, Dec 2002. ISSN 1415-790X. Disponível em: <<https://doi.org/10.1590/S1415-790X2002000300005>>. Citado na página 14.
- FERNANDES, H. C.; REBELATTO, G.; MONTEIRO, M.; BUSATO, M. A. Vacinas contra dengue aprovadas no brasil: Revisão integrativa da literatura. In: **Congresso Internacional em Saúde**. [S.l.: s.n.], 2023. Citado na página 13.
- GERMANOV, A. **How to Detect Objects in Images Using the YOLOv8 Neural Network**. 2023. Disponível em: <https://www.freecodecamp.org/news/how-to-detect-objects-in-images-using-yolov8/#get_started>. Acesso em: 15 nov 2023. Citado na página 25.
- JHA, D. **Swimming pool detection and classification using deep learning**. 2020. Disponível em: <<https://medium.com/geoai/swimming-pool-detection-and-classification-using-deep-learning-aaf4a3a5e652>>. Acesso em: 16 apr 2022. Citado na página 22.
- JOCHER, G. **YOLOv8**. 2023. Disponível em: <<https://docs.ultralytics.com/models/yolov8/#usage-examples>>. Acesso em: 15 nov 2023. Citado na página 25.
- JOCHER, G.; CHAURASIA, A.; QIU, J. **Ultralytics YOLOv8**. 2023. Disponível em: <<https://github.com/ultralytics/ultralytics>>. Citado na página 19.

- KING, R. **Brief summary of YOLOv8 model structure 189**. 2023. Disponível em: <<https://github.com/ultralytics/ultralytics/issues/189>>. Acesso em: 01 dez 2023. Citado na página 20.
- LIN, T.-Y. *et al.* Microsoft coco: Common objects in context. In: SPRINGER. **Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part V 13**. [S.l.], 2014. p. 740–755. Citado 2 vezes nas páginas 19 e 20.
- MACHADO, S. W. S.; MACHADO, M. dos S.; BARROS, A. M. A. de. O controle dos criadouros do mosquito da dengue no rio de janeiro. **V Seminário Internacional de Defesa Civil - DEFENCIL**, Universidade Federal Fluminense, p. 1–9, Nov 2009. Disponível em: <https://defesacivil.uff.br/wp-content/uploads/sites/325/2020/10/O-controle-dos-criadouros-do-mosquito-da-dengue-no-Rio-de-Janeiro_Defencil.pdf>. Citado na página 14.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, p. 115–133, 1943. Citado 2 vezes nas páginas 16 e 17.
- MEDIUM. **Entendendo o funcionamento de uma Rede Neural Artificial**. 2018. Disponível em: <<https://medium.com/brasil-ai/entendendo-o-funcionamento-de-uma-rede-neural-artificial-4463fcf44dd0>>. Acesso em: 20 jul 2022. Citado na página 16.
- NASCIMENTO, E. O. do; OLIVEIRA, L. N. de. Sensitivity analysis of cutting force on milling process using factorial experimental planning and artificial neural networks. **IEEE Latin America Transactions**, IEEE, v. 14, n. 12, p. 4811–4820, 2016. Citado na página 17.
- NOGUEIRA, K.; PENATTI, O. A.; SANTOS, J. A. D. Towards better exploiting convolutional neural networks for remote sensing scene classification. **Pattern Recognition**, Elsevier, v. 61, p. 539–556, 2017. Citado na página 18.
- OSÓRIO, F. S.; BITTENCOURT, J. R. Sistemas inteligentes baseados em redes neurais artificiais aplicados ao processamento de imagens. In: SN. **I Workshop de inteligência artificial**. [S.l.], 2000. Citado na página 14.
- PAN AMERICAN HEALTH ORGANIZATION. **Epidemiological Update: Dengue in the region of the americas**. Washington, D.C., 2021. 1-12 p. Citado na página 12.
- _____. **Epidemiological Update: Dengue in the region of the americas**. Washington, D.C., 2023. 1-16 p. Citado na página 12.
- PRATES, W. R. **O que é a Matriz de Confusão?** 2021. Disponível em: <<https://cienciaenegocios.com/o-que-e-a-matriz-de-confusao/>>. Acesso em: 21 dez 2023. Citado na página 21.
- RASCHKA, S. **What is the difference between a Perceptron, Adaline, and neural network model?** 2016. Disponível em: <<https://www.quora.com/What-is-the-difference-between-a-Perceptron-Adaline-and-neural-network-model>>. Acesso em: 25 jul 2023. Citado na página 17.
- ROSA, e. a. Amélia Paes de A. T. Arboviroses. **MEDSI**, v. 1, n. 68, p. 986–1015, 2000. Citado 2 vezes nas páginas 12 e 13.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958. Citado na página 16.

RUSSAKOVSKY, O. *et al.* ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision (IJCV)**, v. 115, n. 3, p. 211–252, 2015. Citado na página 20.

SESAB. Ministério da saúde oferta novas iniciativas no combate ao aedes aegypti. **Secretaria de Saude do Estado da Bahia**, Secretaria de Saude do Estado da Bahia, 2016. Disponível em: <<https://www.saude.ba.gov.br/2014/01/29/ministerio-da-saude-oferta-novas-iniciativas-no-combate-ao-aedes-aegypti/>>. Citado na página 13.

TAN, H. **Annotation Conversion: COCO JSON to YOLO Txt**. 2022. Disponível em: <<https://haobin-tan.netlify.app/ai/computer-vision/object-detection/coco-json-to-yolo-txt/>>. Acesso em: 01 dez 2023. Citado 2 vezes nas páginas 23 e 24.

TERVEN, J.; CORDOVA-ESPARZA, D. A comprehensive review of yolo: From yolov1 and beyond. **arXiv preprint arXiv:2304.00501**, 2023. Citado na página 19.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: SN. **Proceedings of the xxix conference on graphics, patterns and images**. [S.l.], 2016. v. 1, n. 4. Citado na página 18.

VENKATKUMAR. **YoloV8 Architecture & Cow Counter With Region Based Dragging Using YoloV8**. 2023. Disponível em: <https://medium.com/@VK_Venkatkumar/yolov8-architecture-cow-counter-with-region-based-dragging-using-yolov8-e75b3ac71ed8>. Acesso em: 01 dez 2023. Citado 2 vezes nas páginas 19 e 20.

WANG, G. *et al.* Uav-yolov8: A small-object-detection model based on improved yolov8 for uav aerial photography scenarios. **Sensors**, MDPI, v. 23, n. 16, p. 7190, 2023. Citado na página 19.

WHO. **Report of the Consultation on Key Issues in Dengue Vector Control Toward the Operationalization of a Global Strategy: WHO, Geneva, 6-10 June 1995**. World Health Organization, 1995. Disponível em: <<https://books.google.com.br/books?id=V-OSYgEACAAJ>>. Citado na página 14.

WHO *et al.* Global strategy for dengue prevention and control 2012-2020. World Health Organization, 2012. Citado na página 14.