

19 a 22 de Setembro de 2023

Foz do Iguaçu - PR

www.rapvenacor.com.br



## m25º Encontro Nacional de Conservação Rodoviária (ENACOR) 48ª Reunião Anual de Pavimentação (RAPv)

### ESTUDO DE CASO: USO DE REDES NEURAIAS NA IDENTIFICAÇÃO AUTOMÁTICA DE PAINÉIS EM PAVIMENTOS FLEXÍVEIS E SEMIFLEXÍVEIS NO DER-MG.

DOI: (a ser preenchido após o envio do código DOI da publicação)

*Érica Francisca de Paula Araújo<sup>1</sup>; Samuel Passos Ribeiro Rodrigues e Silva<sup>1</sup>; Vinicius Vieira Sousa<sup>1</sup>; Maria de Fátima Amazonas de Sá Araújo<sup>1</sup> & Matheus Guimarães Novais<sup>1</sup>*

#### RESUMO

Tendo em vista a necessidade de otimizar os processos de uso, operação e manutenção de uma rodovia, aliada à importância de se conduzir com certa frequência estudos que visam fornecer de maneira confiável a atual situação das condições de sua utilização, a busca por novas tecnologias que facilitem as operações de manutenção rodoviária torna-se uma necessidade constante. O procedimento de avaliação da superfície de rolamento da via é uma etapa que consome bastante recurso pessoal e financeiro, além de apresentar uma longa duração para análise de dados. Por isto, este trabalho busca contribuir com os estudos sobre a utilização de sistemas de aprendizagem profunda, ou *deep learning* no DER-MG. Para tal, foi realizado o treinamento de uma rede com imagens de painéis em rodovias, o que resultou em um modelo capaz de detectar automaticamente este tipo de defeito de pavimento. O estudo foi realizado através de um sistema baseado em redes neurais convolucionais chamado YOLO, abreviação para *You Only Look Once*. O treinamento do modelo foi realizado através de um *dataset* de 200 imagens de vias que apresentavam buracos de formas variadas, tanto em tamanho, quanto em profundidade e quantidade. Ao fim do treinamento foi possível obter uma confiabilidade de 84%, o que, pelo tamanho do *dataset* apresentado, é um resultado bastante satisfatório e ajuda a corroborar a sua viabilidade em aplicações cotidianas em trabalhos de identificação e categorização de defeitos superficiais do pavimento rodoviário.


**PALAVRAS-CHAVE:** Pavimentos Flexíveis; Inteligência Artificial; Redes Neurais Convolucionais.

#### ABSTRACT

Bearing in mind the need to optimize highway use, operation and maintenance processes, combined with the importance of conducting studies with a certain frequency that aim to reliably provide the conditions current situation of its use, the search for new technologies that to facilitate road maintenance operations becomes a constant need. The procedure for evaluating the running surface of the track is a step that consumes a lot of personal and financial resources, in addition to presenting a long duration for data analysis. For this reason, this work seeks to contribute to studies on the use of deep learning systems in DER-MG. To this end, a network was trained with images of pans on highways, which resulted in a model capable of automatically detecting this type of pavement defect. The study was carried out using a system based on convolutional neural networks called YOLO, short for *You Only Look Once*. The training of the model was carried out using a dataset of 200 images of roads that had holes of different shapes, both in size, depth and quantity. At the end of the training, it was possible to obtain a reliability of 84%, which, considering the size of the dataset presented, is a very satisfactory result and helps to corroborate its viability in everyday applications in works of identification and categorization of surface defects of the road pavement.

**KEY WORDS:** Flexible Pavement; Artificial Intelligence; Convolutional Neural Networks..

<sup>1</sup> Departamento de Estradas de Rodagem de Minas Gerais - DER/MG, [erica.araujo@der.mg.gov.br](mailto:erica.araujo@der.mg.gov.br); [samuel.passos@der.mg.gov.br](mailto:samuel.passos@der.mg.gov.br); [vinicius.sousa@der.mg.gov.br](mailto:vinicius.sousa@der.mg.gov.br); [fatima.amazonas@der.mg.gov.br](mailto:fatima.amazonas@der.mg.gov.br); [matheus.novais@der.mg.gov.br](mailto:matheus.novais@der.mg.gov.br)



19 a 22 de Setembro de 2023  
Foz do Iguaçu - PR

[www.rapvenacor.com.br](http://www.rapvenacor.com.br)



## INTRODUÇÃO


Durante o período de uso, operação e manutenção da via, para garantir uma alocação de recursos e tomada de decisões de forma mais eficiente, é adotado por algumas entidades responsáveis por rodovias, um Sistema de Gerência de Pavimento, também chamado pela sigla SGP. Contudo, para que o sistema tenha êxito e consiga fornecer ao usuário final uma faixa de rolamento segura e confortável, deve ser realizada uma série de estudos ao longo do pavimento. Este período intensivo de estudos tende a não somente consumir uma grande quantidade de tempo, como também de recursos, uma vez que, por se tratar de levantamentos que são realizados sempre em caráter de rede, é comum que sejam analisadas centenas, senão, milhares de quilômetros de vias, sendo que estes estudos devem ser repetidos de forma sazonal, de modo a fornecer ao sistema uma visão atualizada e precisa das condições atuais da rodovia mantida.

Uma etapa importante deste momento de estudos é o levantamento e a avaliação das condições superficiais da faixa de rolamento da rodovia, sendo que para tal, são normalmente empregadas várias técnicas, para que em conjunto consigam fornecer um panorama de como se encontra a superfície do pavimento. Além da realização da análise da rugosidade longitudinal do pavimento, por meio da extração do Índice de Irregularidade Internacional (IRI) e do Quociente de Irregularidade (QI), é realizado também o estudo e inventário das manifestações patológicas presentes na superfície do pavimento. Sendo assim, é neste âmbito da análise patológica que este trabalho se insere.

Tradicionalmente, são empregados os modelos de levantamento preconizados através das normas expedidas pelo Departamento Nacional de Infraestrutura de Transportes (DNIT) PRO 008/2003, que estabelece o procedimento para a realização de uma aferição visual contínua de pavimentos flexíveis e semirrígidos, ou da PRO 006/2003, que estabelece os procedimentos para a avaliação objetiva de pavimentos flexíveis e semi-rígidos. Estas normas são de extrema importância e carregam um valor técnico indispensável, contudo, a sua execução tende a demandar o deslocamento e dedicação de mão de obra técnica por longos períodos. Uma vez que, como já mencionado, este tipo de levantamento tende a ocorrer sempre em caráter de rede, cobrindo grandes extensões de vias, é comum que seja empregada, de forma a minimizar esta demanda de mão de obra técnica, a utilização de veículos equipados de câmeras, além de outros sensores.

Todavia, conforme mencionado por Huidrom *et al.* (2013), apesar dos levantamentos realizados por veículos dotados de câmeras apresentarem a vantagem de não exigirem que o técnico se desloque ao local para realização da avaliação do pavimento, ainda assim, em grande parte dos levantamentos, a análise dos dados brutos coletados são feitas predominantemente de forma manual por um corpo técnico qualificado. Este processo acaba sendo caro, além de continuar consumindo um longo período de tempo, para que os vídeos coletados sejam analisados com qualidade, fato que, invariavelmente, desacelera o processo de manutenção da rodovia e aumenta os custos para estes serviços, que naturalmente já são elevados.

Diante desta problemática, vários estudos veem sendo desenvolvidos com o objetivo de viabilizar novas tecnologias, de modo a tornar os processos menos dispendiosos. Uma das possibilidades para otimizar o processo de identificações de patologias em pavimentos é a utilização de softwares para a identificação destes defeitos, uma vez que, conforme comentam Majidifard, Adu-Gyamfi e Buttlar (2020), as abordagens mais promissoras para análise automática de patologias em pavimentos utilizam do processamento de imagens e de visão computacional. Logo, a vasta gama de possibilidades que a área da aprendizagem profunda possibilita, e tendo em vista a necessidade de se promover novas possibilidades no ramo da detecção de patologias no pavimento, este trabalho busca trazer uma contribuição no ramo da utilização de visão computacional e *Deep Learning* para



19 a 22 de Setembro de 2023

Foz do Iguaçu - PR

[www.rapvenacor.com.br](http://www.rapvenacor.com.br)



levantamentos de patologias em pavimentos flexíveis e semiflexíveis. Desta forma, foi escolhida a utilização de redes neurais convolucionais, uma vez que estas, graças à abordagem convolucional, possibilitam a análise de imagens diversas, em arquivos e em diversas resoluções, além de não existir a necessidade de que o objeto estudado esteja centralizado na imagem.

O uso de redes neurais convolucionais, ou no inglês *Convolutional Neural Networks* (CNN), já vem sendo alvo de diversos estudos com sua aplicação voltada para a detecção de patologias em pavimentos, uma vez que esta tecnologia vem sendo usada por muitos autores como Gopalakrishnan (2017) e Shim *et al.* (2022), para a identificação destes defeitos e grandes avanços já foram realizados por outros pesquisadores. Contudo, como exemplificam Maeda *et al.* (2018) e Arya (2021), o uso do CNN é o atual estado da arte no que tange à identificação de objetos em imagens através de modelos computacionais, logo, a utilização de modelos desenvolvidos com este sistema são bastante atrativas para novas pesquisas, uma vez que alguns estudos focam apenas na determinação da existência de defeitos ou não.

Assim, este trabalho tem como objetivo avaliar a utilização de inteligências artificiais baseadas em redes neurais convolucionais para a identificação de patologias na superfície de pavimentos flexíveis e semiflexíveis pelo Departamento de Edificações e Estradas de Rodagem de Minas Gerais (DER/MG).

## REFERENCIAL TEÓRICO

### Identificação de Objetos Através de Redes Neurais – YOLO: Uma abordagem atrativa para o reconhecimento de objetos

Em maio de 2016, os pesquisadores Joseph Redmon, Santosh Divvala, Ross Girshick e Ali Farhadi apresentaram uma nova abordagem à área de detecção de objetos, chamada YOLO, sigla para *You Only Look Once*, um modelo de inteligência artificial baseada em redes neurais convolucionais. O YOLO se destaca diante de outros modelos baseados em CNN, devido à rapidez no processamento dos dados e predição de uma nova detecção. Conforme Redmon *et al.* (2016), o modelo consegue funcionar a uma taxa maior que 150fps, o que, em síntese, significa que é possível utilizá-lo para realizar reconhecimento de imagens em tempo real. Esta agilidade somente é possível devido à abordagem inovadora que este sistema adota ao realizar a análise computacional da imagem, que por sua vez é capaz de proporcionar ao modelo uma capacidade de abstração da imagem maior que a de outros modelos de redes neurais convolucionais como R-CNN ou o Faster R-CNN. O modelo entende a detecção de objetos em uma imagem como um simples problema de regressão, onde, segundo os autores, uma única rede convolucional realiza a predição de várias caixas delimitadoras mínimas, ou no inglês, *bounding boxes*, e a probabilidade de cada classe para estas caixas, como é exemplificado pelos autores através da Figura 1.





Figura 1 - O processamento de uma imagem através do YOLO é simples e direto, o sistema redimensiona a imagem para 428 x 428 e então roda uma única rede convolucional na imagem e ao final delimita os limites dos objetos detectados (REDMON *et al.*, 2016).



19 a 22 de Setembro de 2023  
Foz do Iguaçu - PR

[www.rapvenacor.com.br](http://www.rapvenacor.com.br)



A possibilidade de se detectar vários objetos através de uma única rede convolucional é possível devido à capacidade do modelo de analisar a imagem como um todo, utilizando os elementos presentes nestas imagens para prever os locais onde vão estar localizadas as caixas delimitadoras mínimas. Este mecanismo proporciona ao sistema a possibilidade de realizar o processamento de dados em tempo real e, ainda assim, manter taxas de precisão elevadas. Quando uma imagem é inserida no sistema, ela é gradeada em uma malha de  $S \times S$ , e se o centro do objeto estiver localizado próximo a alguma célula desta malha, ela será responsável pela detecção deste objeto. Essa detecção é feita com cada célula produzindo um número  $N$  de caixas delimitadoras e, em seguida, predizendo a pontuação com a confiança de cada caixa em apresentar algum objeto. Caso a célula não apresente nenhum objeto, a pontuação de confiança será zero (REDMON *et al.*, 2016).

Contudo, apesar deste enorme poder computacional que estes modelos de inteligência artificial baseados em redes neurais convolucionais proporcionam, um grande gargalo para a qualidade e capacidade de operação do sistema é quão bem o modelo é treinado. Isso se dá porque, para realizar uma predição, o modelo deve antes passar por um momento de treinamento, onde ele será alimentado com uma série de imagens, em que o objeto que a máquina irá aprender a identificar deve estar rotulado e indicado por meio de uma caixa delimitadora, conforme pode ser observado em exemplo na Figura 2.




Figura 2 - Exemplo de imagem com etiqueta (AUTORES, 2022).

Este rótulo nada mais é, que um arquivo de texto indicando o pixel inicial e final da caixa e a classe a que o objeto pertence. Assim, cada imagem que irá compor a base de dados, que será responsável por treinar o objeto, deve conter uma etiqueta. A qualidade em que os objetos estão identificados nestas etiquetas é fator fundamental para a qualidade final do modelo, já que o algoritmo terá como tarefa, durante o treinamento, a missão de identificar o objeto para o qual está sendo treinado e, em seguida, é feita a comparação com a delimitação original presente na base de dados. Quanto mais perto o modelo chegar da delimitação original, maior será a sua taxa de confiabilidade. Por isso, e conforme exemplificado por Majidifard *et al.* (2020), o banco de dados apresenta uma enorme importância para a qualidade do resultado do modelo.

## O uso de redes neurais na engenharia rodoviária

Como ressaltado por Majidifard *et al.* (2020), o emprego do aprendizado de máquinas para a detecção automática de patologias em pavimentos já não pode mais ser visto como uma novidade. Segundo Maeda *et al.* (2018), várias tentativas já foram realizadas com a intenção de construir um sistema capaz de analisar as propriedades de uma rodovia através de imagens capturadas por uma câmera



19 a 22 de Setembro de 2023  
Foz do Iguaçu - PR  
[www.rapvenacor.com.br](http://www.rapvenacor.com.br)



acoplada a um veículo, e então processá-las de modo a inspecionar de forma eficiente a via. Os autores ainda citam estudos realizados em *machine-learning* que visam a detecção automática de fissuras em pavimentos, além da detecção de painelas. Contudo, eles também salientam acerca do leque de novas possibilidades que o aprendizado profundo, ou *deep-learning*, possibilita através da utilização de redes neurais. Por isso, Majidifard *et al.* (2020) destacam o fato de como a utilização do *deep-learning* vem se mostrando atrativa no que se refere a pesquisas sobre pavimentos.

Diversos avanços já foram desenvolvidos por outros autores, como exemplificam Maeda *et al.* (2018), ao discorrerem sobre os trabalhos que até então vinham sendo realizados na área. Como exemplo, cita-se o sistema de identificação de painelas proposto por Jo e Ryu em 2015, ou o famoso *CrackNet* de Zhang, em 2017. Inclusive, Maeda *et al.* (2018) propõem o uso de imagens captadas por *smartphones* para que, em conjunto com uma rede neural, possa classificar patologias em pavimentos. Além disto, Majidifard *et al.* (2020) sugerem a utilização de *deep learning* para o desenvolvimento de um novo índice de condição do pavimento.

## METODOLOGIA

Na execução deste trabalho, foi realizado o treinamento de um sistema de aprendizagem profunda baseada em redes neurais convolucionais YOLO, para que este seja capaz de reconhecer patologias do tipo painelas em imagens de pavimentos. Foi realizada a confecção de uma base de dados própria com imagens da patologia escolhida, para que o sistema fizesse a identificação. Buscando obter um *dataset* diversificado, foi realizada a junção de um conjunto de fotos do DER/MG feitas em rodovias estaduais do noroeste mineiro, próximas ao município de Paracatu/MG. Também foram utilizadas fotos extraídas da *internet* com auxílio da ferramenta digital *Google Images*, de autoria da empresa *Google LLC*. Com isso, foi constituída uma base de dados de 200 imagens, das quais 80% (160 imagens) foram utilizadas para a base de treino do modelo, enquanto as 20% restantes foram empregadas no conjunto da validação do modelo.

O processo de etiquetar cada uma das 200 imagens foi executado por meio da ferramenta da *web* chamada *Make Sense Ai*. A ferramenta foi escolhida por ter sido criada no formato JAVA e se mostrar extremamente ágil para a realização dos serviços, já que ela não exige que as imagens sejam carregadas em um servidor externo, para que a ferramenta realize a demarcação dos objetos desejados. A execução da demarcação das patologias pode ser observada através da Figura 3.





Figura 3 - Captura de tela do processo de criação dos *Labels* (AUTORES, 2022).



19 a 22 de Setembro de 2023  
Foz do Iguaçu - PR

[www.rapvenacor.com.br](http://www.rapvenacor.com.br)



Ao final, após a delimitação dos *Labels*, em todo o conjunto de dados, a ferramenta oferece a opção de se realizar o *download* de um arquivo comprimido em formato *.zip*, com todas as etiquetas presentes, já nomeadas de modo a permitir que o modelo YOLO consiga realizar a leitura. Em seguida, foi realizada a criação de um diretório, e dentro dele, outros dois denominados “*Images*” e “*Labels*”, onde foram armazenadas, respectivamente, as imagens com a patologia e as etiquetas. Ao fim, as imagens e etiquetas de treino e validação foram separadas dos conjuntos de treino e colocadas em uma pasta chamada “*train*”, enquanto as de validação em uma pasta chamada “*val*”. Esse processo foi realizado tanto com os arquivos de fotos, quanto com os de etiquetas.

Para o processo de treinamento do modelo, foi escolhida a ferramenta *Google Colab*, desenvolvida para a criação e execução de códigos em linguagem *Python*. Além disto, esta ferramenta apresenta uma interação facilitada com a plataforma de hospedagem de dados *GitHub*, local onde está disponível o diretório do modelo YOLO. Devido à praticidade e grande eficiência do modelo, foram desenvolvidas diversas versões do YOLO. Para este trabalho, foi empregada o YOLO V5, uma vez que ele apresenta atualizações constantes e recentes, encontrando-se já em sua sexta atualização. Sendo assim, o modelo foi exportado e treinado com a base de dados personalizada.

Para realização do treinamento, o modelo extrai do banco de dados um lote de imagens. Este lote consiste em uma única imagem. Para este trabalho, foi realizado um treinamento com uma imagem de 640 x 640 pixels, onde foram alocadas as imagens de treino, formando um mosaico. O tamanho do lote define a quantidade de imagens que vão conter em cada treinamento e, para este, foi adotado um lote igual a 16. Para saber o volume de imagens do banco de dados que serão utilizados em cada treinamento, basta dividir o valor de lado da imagem de treino pelo tamanho do lote, o que resulta em 40 imagens por treino. O processo de treinamento foi realizado por rodadas. Cada rodada de treinamento utilizou um lote, que também são chamados de *batch*. As rodadas de treinamento são denominadas como *epoch* ou épocas. Neste trabalho, foram adotadas 30 épocas. O mesmo processo utilizado para realizar o treinamento foi feito em seguida pelo modelo ao realizar a validação do aprendizado. A Figura 4 exemplifica um lote de treinamento e um lote de validação.

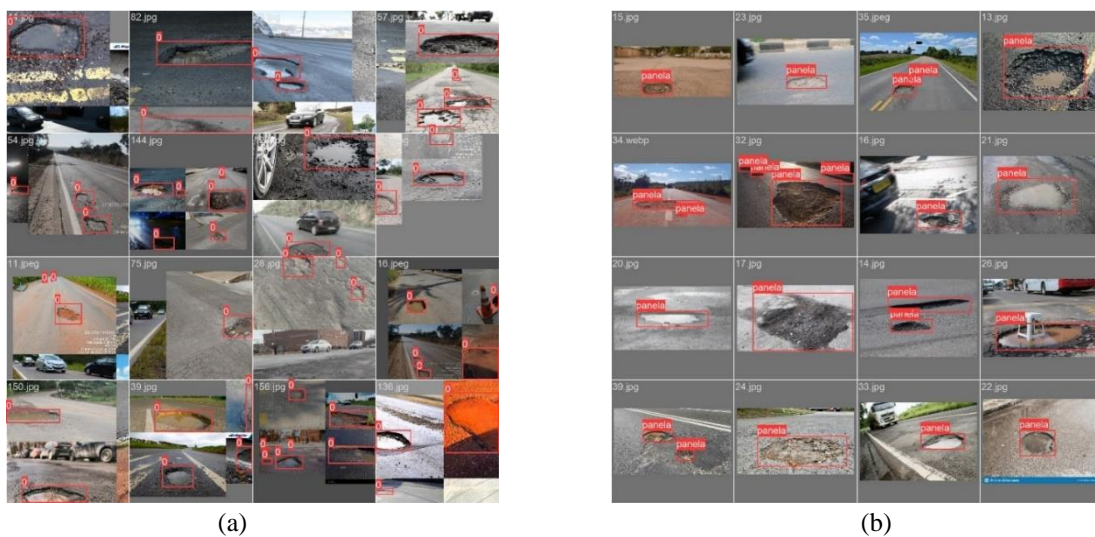



Figura 4 - Lote de treinamento (a) e lote de validação (b) (AUTORES, 2022).



19 a 22 de Setembro de 2023  
Foz do Iguaçu - PR  
[www.rapvenacor.com.br](http://www.rapvenacor.com.br)



## RESULTADOS

A fim de observar o comportamento deste modelo, o qual procura identificar patologias em pavimentos, foi realizado o treinamento conforme a metodologia descrita anteriormente. O treinamento com 30 épocas foi executado, sendo que este processo teve uma duração total de 20,63 horas. Ao final desta etapa de treinamento, foi possível obter uma acurácia igual a 84,2%, o que de maneira geral, é um valor relativamente alto, já que o banco de dados empregado neste modelo foi pequeno e abaixo do ideal. Ao analisar os resultados de validação do modelo, é possível observar que ele foi capaz de identificar a maioria das placas apresentadas. Além disso, é possível observar que as previsões realizadas pelo modelo, de maneira geral, apresentaram uma taxa de confiabilidade relativamente alta. Contudo, quando existe uma fuga do que foi apresentado nos dados de teste, o modelo apresenta problemas para identificar algumas imagens. A Figura 5 apresenta os resultados da etapa de validação do sistema.

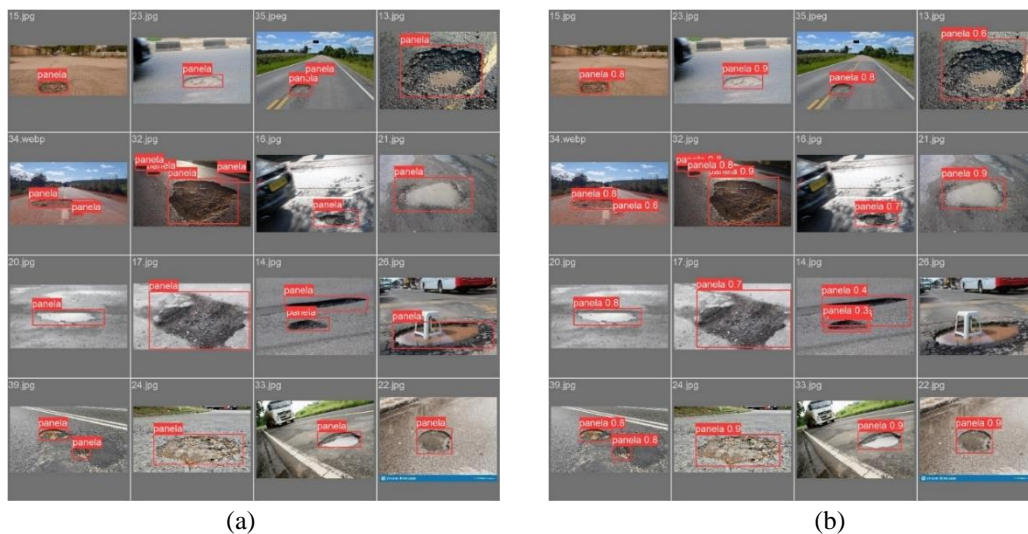



Figura 5 – Lote de validação com as etiquetas (a) e lote de validação onde as etiquetas são as previsões do modelo para onde estão localizadas as placas (b) (AUTORES, 2022).

Assim, é possível observar a presença de certa alteração na área das caixas delimitadoras previstas em algumas previsões, como por exemplo, na quarta imagem da primeira linha. Além disso, verifica-se que o modelo apresentou dificuldades em identificar a patologia quando existia alguma alteração no contexto da imagem, como identificado na quarta imagem da terceira linha, que apresenta um objeto junto ao buraco. Também é possível observar que, nos casos em que o formato e o ângulo que a patologia foi capturada e alterada, o modelo também apresentou dificuldades para identificar o objeto, como pode ser observado na segunda imagem da segunda linha, onde a patologia não foi identificada. Na terceira imagem da terceira coluna, a patologia foi identificada em duplicidade e com a taxa de confiabilidade baixa. Tais erros ocorrem devido à baixa quantidade de fotos utilizadas para realizar o treinamento do modelo. Logo, se houver o treinamento de um modelo com um volume maior de imagens e com as patologias em ângulos e condições variadas, ele certamente irá obter resultados melhores. Contudo, os resultados obtidos são bastante animadores. Ao analisarmos as métricas do modelo, é possível observar que ele apresenta resultados satisfatórios, conforme ilustrado na Figura 6.



19 a 22 de Setembro de 2023  
Foz do Iguaçu - PR

www.rapvenacor.com.br

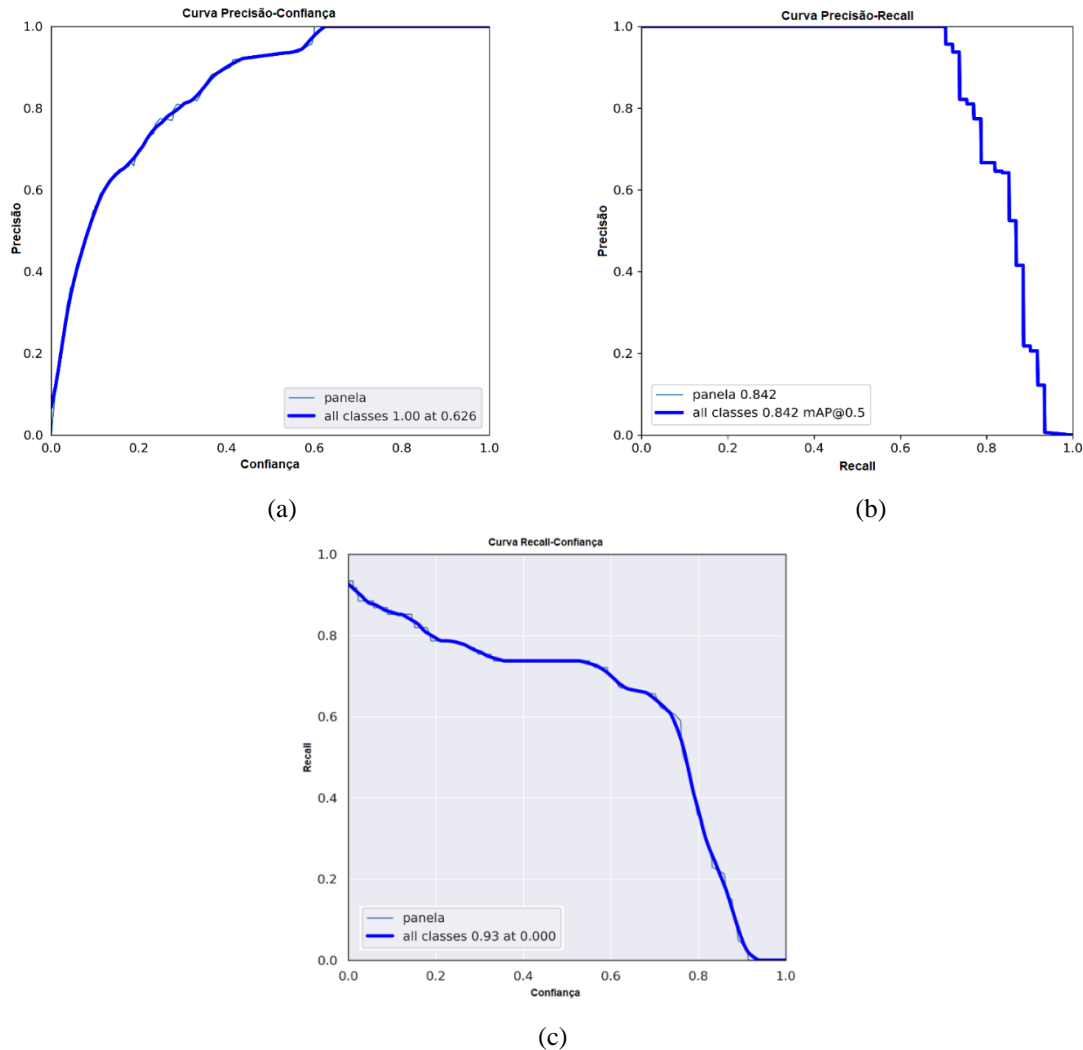


Figura 6 – Curva de Precisão x Confiância (a), Curva de Precisão x *Recall* (b) e Curva de *Recall* x Confiância (c) (AUTORES, 2022).

Em análise às curvas características do modelo, verifica-se que ele apresenta resultados bastante satisfatórios, principalmente como pode ser observado na curva Precisão x *Recall*. Após o término do treinamento do modelo, foram realizados testes com imagens avulsas, sem a presença de caixas delimitadoras pré-definidas. Esta ação teve como objetivo observar como o modelo se comportaria ao tentar realizar novas previsões. Em todas as tentativas, o modelo conseguiu encontrar a patologia e a sinalizar com uma caixa delimitadora, como pode ser verificado na Figura 7. Verificou-se que, para todas as previsões, o modelo apresentou uma taxa de confiança acima de 60%. Essa taxa de confiança é o percentual da certeza que o modelo tem de realmente existir o objeto procurado no interior da caixa delimitadora, que ele desenhou.

Foram realizados testes para ver como o modelo se comportaria quando submetido a um vídeo registro, de forma a expô-lo a uma atividade comum num processo de levantamento de condições de tráfego, para isto foram realizadas gravações na rodovia MG188, em trecho que liga o Município de Paracatu ao Município de Unaí, neste foram coletados vídeos obtidos através de uma câmera de celular e a gravação foi realizada dentro de um veículo em movimento, para isto foram realizadas gravações em velocidades diferentes de forma a analisar como o modelo se comportaria. Foi





19 a 22 de Setembro de 2023  
Foz do Iguaçu - PR

[www.rapvenacor.com.br](http://www.rapvenacor.com.br)



observado que a qualidade das gravações foi um fator mais determinante do que a velocidade imprimida no veículo no que diz respeito a identificação das placas registradas em vídeo. Isto se dá uma vez que o algoritmo realiza a leitura para identificação dos objetos em vídeos frame a frame, desta forma é de maior valor para a identificação a qualidade da gravação e que a câmera esteja posicionada de modo a obter uma boa captura da via, a câmera utilizada para a captura dos vídeos apresenta uma taxa de FPS igual a 30, contudo, gravações com taxas de quadro maiores irão gerar um maior número de frames com imagens mais nítidas, que facilitarão na identificação das patologias, vale ressaltar que o modelo não apresenta um limite de taxa de frames, contudo capturas com altas taxas de FPS irão demandar um maior tempo e capacidade de processamento da máquina utilizada no serviço, o mesmo vale no que diz respeito a resolução das imagens, como a qualidade das capturas, logo em fotos de baixa ou baixíssima resolução o modelo pode ter problemas na identificação das patologias e em imagens de altíssima resolução o modelo vai demandar uma capacidade de processamento maior. Portanto o ideal para este modelo foi a utilização de imagens com taxas de FPS de pelo menos 30 FPS, enquanto a melhor resolução para novas identificações foi a de no mínimo 720x480 pixels.


Já no que diz respeito ao tempo para identificação do modelo, para o processamento total das imagens, o modelo apresentou, em média, um tempo de processamento levemente maior que 200 milissegundos, o que é considerada uma grande quantidade de tempo quando se pretende utilizar o modelo treinado com esses dados em capturas em tempo real. Contudo, é um tempo extremamente baixo, quando comparado com a possibilidade de aplicação em uma situação cotidiana e em utilizá-lo para realizar procedimentos após o processamento de dados. Todavia, ao se examinar esses resultados, é possível inferir que, caso o modelo seja treinado com um volume de imagens em um *dataset* mais robusto, ele facilmente irá possibilitar a identificação desta patologia em períodos menores de tempo e com uma acurácia ainda maior.



Figura 7 – Predição realizada pelo modelo (AUTORES, 2022).

## CONCLUSÃO

Por fim, ao analisar os resultados obtidos com este trabalho, verificou-se a capacidade e potência de análise e aprendizado de um modelo de aprendizagem profunda baseado em redes convolucionais. Foi empregado no treinamento deste modelo um *dataset* relativamente pequeno, com 200 fotos e, ainda assim, foi possível obter resultados extremamente satisfatórios. Espera-se que, caso submetido a *datasets* ideais, o modelo venha a apresentar resultados acima dos 90% de confiança e com um curto período de processamento dos dados. Recomenda-se que seja investido tempo na confecção de um *dataset* robusto, que possibilite o treino de modelos em inteligência artificial, uma vez que, com



19 a 22 de Setembro de 2023  
Foz do Iguaçu - PR

[www.rapvenacor.com.br](http://www.rapvenacor.com.br)



isso, será possível viabilizar modelos capazes de realizar, de forma rápida, eficiente e barata, o trabalho de identificação e classificação dos defeitos presentes na superfície de um pavimento. Vale destacar ainda que a com este trabalho é possível enxergar as possibilidades do uso da visão computacional na análise de patologias em pavimentos, sendo esperado que esta pesquisa se desdobre em novos trabalhos onde a arquitetura YOLO posta a identificar um número maior de patologias em pavimentos flexíveis e desta forma seja possível a concepção de uma ferramenta que forneça índices de gravidade da via de forma automatizada através do uso de redes neurais.

Verifica-se, assim, que este é o caminho que a tecnologia aponta para a evolução de como é tratada e trabalhada a avaliação de pavimentos atualmente, tendo em vista uma enorme economia que ela possibilita, tanto no que diz respeito a custos, quanto no que diz respeito a tempo e mão de obra. De maneira geral, espera-se que estes ganhos devam ser revertidos ao processo de manutenção e melhoria das condições das vias.

## REFERÊNCIAS

- Arya, D.(Dec. De 2021). Deep-Learning based road damage detection and classification for multiple countries. *Automation in construction*, 132.
- Diretoria de Planejamento e Pesquisa / IPR. (2003). *DNIT 008/2003 - PRO - Levantamento visual contínuo para avaliação da*. Rio de Janeiro: Departamento Nacional de Infraestrutura e Transportes.
- Diretoria de Planejamento e Pesquisa / IPR. (2003). *NORMA DNIT 006/2003 - PRO - Avaliação objetiva da superfície de pavimentos flexíveis e semi-rígidos - Procedimento*. Rio de Janeiro: Departamento Nacional de Infraestrutura e Transportes.
- Diretoria de Planejamento e Pesquisa / IPR. (2011). *Manual de Gerenciamento Rodoviário*. Rio de Janeiro: Departamento Nacional de Infraestrutura e Transportes - DNIT.
- Gopalakrishnan, K. e. (30 de Dec. De 2017). Deep Convolutional Neural Networks with transferlearning for computer vision-based data-driven pavement distress detection. *Construction and Building Materials*, pp 322-330. Doi : <https://doi.org/10.1016/j.conbuildmat.2017.09.110>
- Jo, Y., Ryu,S. (19 Nov 2015). Pothole Detection System Using a Black-box Camera. *Sensors in*, doi: <https://doi.org/10.3390/s151129316>.
- Maeda, H., et al. (2021) . Deep Learning -based road damage detection and classification for multiple countries. *Automation in Construction*, 132, 103935.
- Majidifard, H., Adu-Gyamfi, Y., & Buttlar, W. G. (2020). Deep Machine Learning Approach to Develop a New Asphalt Pavement Condition . *Construction and Building Material*, 247, pp 328-339.
- Redmon, J., Divvala, S., Girshick , R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 779-788.
- Shim, S., Kim, J., Lee, S.-W., & Cho, G.-C. (2022). Road damage detection using super-resolution and semi-supervised learning with generative adversarial network. *Automation in Construction*(135).
- Zhang, A. e. (21 Aug 2017). Automated Pixed-Level Pavement Crack Detection on #D Asphalt Surfaces Using a Deep-Learning Network. *Computer-aided civil and infrastructure Engineering*. Doi: <https://doi.org/10.111/mice.12297>.