

UNIVERSIDADE DE PASSO FUNDO

PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA CIVIL E AMBIENTAL

Área de concentração: Infraestrutura e Meio Ambiente

Dissertação de Mestrado

OTIMIZAÇÃO DE HIPERPARÂMETROS DE REDES
NEURAS PARA IDENTIFICAÇÃO DE TRINCAS EM
PAVIMENTOS FLEXÍVEIS

Yohan Casiraghi

Passo Fundo

2021



CIP – Catalogação na Publicação

- C339o Casiraghi, Yohan
Otimização de hiperparâmetros de redes neurais para identificação de trincas em pavimentos flexíveis [recurso eletrônico] / Yohan Casiraghi. – 2022.
30.4 MB ; PDF.
- Orientador: Prof. Dr. Francisco Dalla Rosa.
Coorientador: Prof. Dr. Rafael Rieder.
Dissertação (Mestrado em Engenharia) – Universidade de Passo Fundo, 2022.
1. Pavimentos flexíveis – Defeitos – Identificação.
2. Pavimentos – Gerência. 3. Redes neurais (Computação).
4. Inteligência artificial. I. Dalla Rosa, Francisco, orientador.
II. Rieder, Rafael, coorientador. III. Título.

CDU: 625.021

Universidade de Passo Fundo
Faculdade de Engenharia e Arquitetura
Programa de Pós-Graduação em Engenharia Civil e Ambiental

A Comissão Examinadora aprova a dissertação de mestrado Otimização de hiperparâmetros de redes neurais para identificação de trincas em pavimentos flexíveis, elaborada por Yohan Casiraghi, como requisito parcial para a obtenção do título de Mestre em Engenharia.

Data da aprovação: 13 de maio de 2022.

Comissão Examinadora:

Professor Doutor Lélío Antônio Teixeira de Brito
Universidade Federal do Rio Grande do Sul – UFRGS

Professor Doutor Lucas Feitosa de Albuquerque Lima Babadopulos
Universidade Federal do Ceará – UFC

Professor Doutor Moacir Kripka
Universidade de Passo Fundo – UPF

Professor Doutor Francisco Dalla Rosa
Orientador

Professor Doutor Rafael Rieder
Coorientador

RESUMO

Métodos de detecção de trincas utilizando redes neurais vêm sendo utilizados para analisar pavimentos devido a sua versatilidade, adaptabilidade e por terem um impacto mínimo no tráfego da rede viária. Nesse contexto, ainda existem desafios a serem explorados, sendo a otimização de hiperparâmetros das redes neurais um deles. Os hiperparâmetros podem ser relacionados à arquitetura de rede (tamanho dos filtros, profundidade da rede) ou treinamento (taxa de aprendizado, *dropout*), e podem impactar no desempenho da rede de forma significativa. O presente estudo tem como foco a seleção de melhores arquiteturas de rede, e posterior otimização dos hiperparâmetros. A obtenção das imagens 2D dos pavimentos asfálticos, ocorreu por meio de um veículo aéreo não tripulado (VANT) no Campus I da Universidade de Passo Fundo. A partir de imagens com resolução de 5472 x 3078 *pixels*, tratou-se e foram manipulados recortes de 256x256 *pixels*, em escala de cinza e colorido. Em seguida, utilizando como base a arquitetura das redes MobileNet, AlexNet, DenseNet, SqueezeNet, VGG19, ResNet18, ResNet50, ResNet101, iniciou-se a etapa de treinamento das redes neurais, as quais utilizaram 40.000 imagens, em que 80% foram utilizados para treinamento, e 20% para a fase de validação. Com base nesses dados, realizou-se um estudo comparativo dos valores de precisão, *recall*, erro e tempo de inferência gerados por cada uma das redes treinadas, de forma que foi possível definir as quatro melhores arquiteturas de rede, e otimizá-las. Por fim, definiu-se a arquitetura AlexNet, com acurácia de 97,14%, *F1-Score* de 86,96% como sendo a melhor escolha de arquitetura, devido ao baixo tempo de inferência, de cerca de 34 milissegundos, e pela eficácia na detecção de trincas, com a menor utilização de poder computacional.

Palavras-chave: Inteligência Artificial, *Deep Learning*, Detecção de Trincas, Otimização Bayesiana, Sistema de Gerência de Pavimentos

ABSTRACT

In recent years many methods of crack detection using neural networks have started to be used due to their versatility, adaptability, their minimal impact on traffic, for significantly increasing safety, time use efficiency, and the possibility of being able to cover the entire road network. Despite the wide use of neural networks, many challenges still need to be better explored, the optimization of hyperparameters of neural networks being one of them. Hyperparameters can be related to net architecture (filter size, net depth) or training (learning rate, dropout) and can significantly impact the network's performance. The present study focuses on the optimized selection of hyperparameters for 2D images of asphalt pavements, obtained through an unmanned aerial vehicle (UAV) at Campus I of Universidade de Passo Fundo. With the acquisition of the 5472 x 3078 pixels images by the UAV, it was possible to start the pre-processing stage, dividing the image into 256x256 pixels, cropping, and converting the images to grayscale. Afterwards, using the architecture of the MobileNet, AlexNet, DenseNet, SqueezeNet, VGG19, ResNet18, ResNet50, and ResNet101 networks as a model, the neural network training stage began, using 40,000 images, of which 80% were used for training, and 20% for the validation phase. Based on these data, a comparative study of accuracy, recall, error, and inference time values were generated by each of the trained networks was performed, then it was possible to define the four best network architectures and optimize them. Finally, the AlexNet architecture, with an accuracy of 97.14%, and F1-Score of 86,96%, was defined as the best choice of architecture, due to its low inference time of about 34 milliseconds, and its effectiveness in detecting cracks, with the lowest use of computational power.

Keywords: artificial intelligence, deep learning, crack detection, hyperparameter tuning, PMS.

LISTA DE FIGURAS

FIGURA 1 - RELAÇÃO ENTRE OS CAMPOS DE ESTUDO	20
FIGURA 2 - ARQUITETURA DA REDE ALEXNET	23
FIGURA 3 - ARQUITETURA DA REDE DENSENET	23
FIGURA 4 - ARQUITETURA DA REDE SQUEEZENET	24
FIGURA 5 - ARQUITETURA DA REDE VGG19	25
FIGURA 6 - TAXA DE APRENDIZADO BAIXA	31
FIGURA 7 - TAXA DE APRENDIZADO ALTA	32
FIGURA 8 - BUSCA EM GRADE	33
FIGURA 9 - BUSCA ALEATÓRIA	34
FIGURA 10 - LOCALIZAÇÃO DA ÁREA DE ESTUDO	37
FIGURA 11 – VOO DRONE / TRINCA EM VIA PAVIMENTADA	38
FIGURA 12 - INTERFACE GOOGLE COLLABORATORY	39
FIGURA 13 - IMAGENS ANTES DA CLASSIFICAÇÃO	40
FIGURA 14 – CONSTRUÇÃO DO BANCO DE DADOS	41
FIGURA 15 - PREDIÇÃO DA REDE NEURAL	43
FIGURA 16 - INFERÊNCIA EM DUAS REDES DISTINTAS	43
FIGURA 17 - CORRELAÇÃO PIXEL/MILÍMETROS	44
FIGURA 18 - RESUMO DOS PROCEDIMENTOS METODOLÓGICOS UTILIZADOS ..	44
FIGURA 19 - TEMPO DE INFERÊNCIA DE CADA REDE.	46
FIGURA 20 - ABERTURA DE TRINCAS	47
FIGURA 21 - PREDIÇÃO NA REDE RESNET152 X MOBILENET	48

FIGURA 22 - RELAÇÃO ACURÁCIA X TAXA DE APRENDIZADO X DROPOUT E TAXA DE DECAIMENTO 49

FIGURA 23 - RELAÇÃO ACURÁCIA X TAXA DE APRENDIZADO X DROPOUT E TAXA DE DECAIMENTO ALEXNET 51

FIGURA 24 – RELAÇÃO ACURÁCIA X TAXA DE APRENDIZADO X DROPOUT E TAXA DE DECAIMENTO SQUEEZENET 52

FIGURA 25 - RELAÇÃO ACURÁCIA X TAXA DE APRENDIZADO X DROPOUT E TAXA DE DECAIMENTO VGG19..... 53

LISTA DE QUADROS

QUADRO 1 - RESPOSTAS DO ALGORITMO ATRAVÉS DE CLASSIFICADORES BINÁRIOS	25
--	----

LISTA DE TABELAS

TABELA 1 - ARQUITETURA DA REDE MOBILENET	22
TABELA 2 - ARQUITETURA DAS REDES RESNET	25
TABELA 3 - TABELA DE VALORES DA REDE MOBILENET CINZA	49
TABELA 4 - TABELA DE VALORES DA REDE MOBILENET COLORIDO	49
TABELA 5 - TABELA DE VALORES DA REDE ALEXNET CINZA.....	50
TABELA 6 - TABELA DE VALORES DA REDE ALEXNET COLORIDO	50
TABELA 7 - TABELA DE VALORES DA REDE SQUEEZENET CINZA	51
TABELA 8 - TABELA DE VALORES DA REDE SQUEEZENET COLORIDO	52
TABELA 9 - TABELA DE VALORES DA REDE VGG19 CINZA	53
TABELA 10 - TABELA DE VALORES DA REDE VGG19 COLORIDO	53
TABELA 11 - TABELA DE VALORES DA REDE DENSENET CINZA	54
TABELA 12 - TABELA DE VALORES DA REDE DENSENET COLORIDO	54
TABELA 13 - TABELA DE VALORES DA REDE RESNET50 CINZA	55
TABELA 14 - TABELA DE VALORES DA REDE RESNET50 COLORIDO	55
TABELA 15 - TABELA DE VALORES DA REDE RESNET101 CINZA	55
TABELA 16 - TABELA DE VALORES DA REDE RESNET101 COLORIDO	56
TABELA 17 - TABELA DE VALORES DA REDE RESNET152 CINZA	56
TABELA 18 - TABELA DE VALORES DA REDE RESNET152 COLORIDO	56
TABELA 19 - ORDENAÇÃO DAS REDES COM MELHOR RELAÇÃO F1/TEMPO	57
TABELA 20 - ORDENAÇÃO DAS REDES COM MELHOR RELAÇÃO F1/TEMPO, CONSIDERANDO OTIMIZAÇÃO	57

SUMÁRIO

1	INTRODUÇÃO	13
1.1	PROBLEMÁTICA DA PESQUISA.....	14
1.2	JUSTIFICATIVA.....	15
1.3	OBJETIVOS	17
1.3.1	OBJETIVO GERAL	17
1.3.2	OBJETIVOS ESPECÍFICOS.....	17
2	REVISÃO BIBLIOGRÁFICA.....	18
2.1	GERÊNCIA DE PAVIMENTOS	18
2.1.1	COLETA DE DADOS	18
2.2	APRENDIZAGEM DE MÁQUINA	20
2.3	REDES NEURAIS ARTIFICIAIS	20
2.3.1	MOBILE NET.....	21
2.3.2	ALEXNET	22
2.3.3	DENSENET	23
2.3.4	SQUEEZENET	24
2.3.5	VISUAL GRAPHIC GROUP - VGG19	24
2.3.6	RESIDUAL NEURAL NETWORK – RESNET.....	25
2.4	MÉTRICAS DE AVALIAÇÃO DE DESEMPENHO	26
2.4.1	ACURÁCIA.....	26
2.4.2	PRECISÃO	27
2.4.3	RECALL.....	27

2.4.4 F1-SCORE	27
2.4.5 RELAÇÃO F1-SCORE / TEMPO.....	27
2.5 REDES NEURAS CONVOLUCIONAIS	28
2.5.1 USO DE REDES NEURAS CONVOLUCIONAIS NA DETECÇÃO DE TRINCAS	28
2.5.2 PARÂMETROS DO MODELO	29
2.5.3 HIPERPARÂMETROS	30
2.5.4 OTIMIZAÇÃO DE HIPERPARÂMETROS.....	32
3 METODOLOGIA	37
3.1 AQUISIÇÃO DE IMAGENS	37
3.2 AMBIENTE DE DESENVOLVIMENTO	38
3.3 RECORTE DAS IMAGENS DO BANCO DE DADOS	39
3.4 ELIMINAÇÃO DE IMAGENS.....	40
3.5 OTIMIZAÇÃO DAS REDES NEURAS	41
3.6 COMPARAÇÃO DE RESULTADOS	42
4 RESULTADOS E DISCUSSÃO	46
4.1 DIMENSÕES DETECTÁVEIS DE TRINCA	47
4.2 MOBILENET.....	48
4.3 ALEXNET	50
4.4 SQUEEZENET	51
4.5 VGG19	52
4.6 DENSENET	54
4.7 RESNET50.....	54

4.8	RESNET101.....	55
4.9	RESNET152.....	56
4.10	ORDENAMENTO DOS RESULTADOS.....	57
5.	CONCLUSÃO.....	60
	REFERÊNCIAS BIBLIOGRÁFICAS	61

1 INTRODUÇÃO

De acordo com DNIT (2003), os revestimentos tendem a trincar em algum estágio de suas vidas, por meio das ações do tráfego e das condições ambientais. A trinca é um defeito que enfraquece o pavimento e permite a entrada de água, comprometendo a estrutura. As trincas, após consolidadas, aumentam de tamanho e severidade ao ponto de provocar a desintegração do pavimento. Devido a isto, o aparecimento de trincas é um critério importante na decisão da realização de manutenções nos pavimentos.

Os mecanismos de degradação dos revestimentos asfálticos são processos complexos, em que vários fatores podem ser a origem do aparecimento do trincamento. Podem estar relacionados aos processos de fadiga, ou à reflexão de trincas por meio de recapeamento asfáltico.

O processo de degradação pode ocorrer por processos endógenos e exógenos, como ciclos de variações da temperatura, características dos agregados, rigidez do concreto asfáltico, teor de ligante na mistura ou compactação das camadas. (Bastos, 2010)

Manter as rodovias em boas condições é vital para a segurança dos usuários e é uma tarefa importante para os departamentos de transporte estadual e federal. Para que essa tarefa seja executada, é necessário monitorar a degradação das condições da rodovia, o que implica na utilização da mão de obra especializada.

A avaliação das condições do pavimento e estimativa de deterioração são parte integrante de sistema de gestão de pavimentos. Para que a avaliação seja viável, é necessário a interpretação de informações, que cada vez mais provêm de meios de aquisição automáticos.

Uma alternativa para a interpretação das informações adquiridas por meios automáticos e semiautomáticos é o uso de redes neurais artificiais, as quais são inspiradas na estrutura neural biológica. Essas estruturas computacionais são capazes de aprender a reconhecer padrões considerando um processo de treinamento, de modo que, uma vez treinadas, possam ser capazes de utilizar o conhecimento prévio para aplicá-lo a novos dados.

As redes neurais artificiais têm a convolução como uma das principais operações, a qual é uma operação linear que a partir de duas funções, gera uma terceira, normalmente chamada de *feature map*. No contexto de imagens, pode-se entender esse processo como um filtro, ou *kernel*, que transforma uma imagem de entrada.

As Redes Neurais Convolucionais (RNC) estão sendo utilizadas por métodos de visão computacional para classificação de imagens e detecção de objetos. Por estas razões, surgiram

estudos que utilizaram algoritmos baseados nas RNC para a detecção de trincas em diversas infraestruturas. Como por exemplo, Xu (2019) desenvolveu um sistema automatizado para detecção de trincas em superfícies de concreto em pontes, Nguyen (2021) utilizou RNC para detecção em imagens com ruídos e de baixa qualidade, e Feng (2020) utilizou para detecção de trincas na superfície de barragens.

A detecção automatizada de trincas torna o processo mais seguro, com menor custo, mais eficiente e mais objetivo. Por estes motivos, este tipo de pesquisa tem se tornado atrativo, tanto para a academia quanto para a indústria.

1.1 Problemática da Pesquisa

Segundo o Anuário 2021 do CNT do Transporte, houve um crescimento de 57,1% na frota de veículos em relação a 2011, na qual, de toda a malha rodoviária, 61,9% das rodovias apresentavam algum tipo de problema no estado geral, sendo que 52,2% dos trechos possuíam algum problema no pavimento, e 46,9% dos trechos avaliados possuíam algum problema de desgaste, trincas ou corrugação. A grande quantidade de pavimentos com algum tipo de defeito gera impactos para a sociedade em geral, pois reduzem o conforto dos usuários, aumentam o risco de acidentes, reduzem a velocidade de tráfego e trazem custos em geral para os usuários.

De forma a reduzir os impactos dos pavimentos danificados, faz-se necessário a utilização de sistemas de gerência de pavimentos, para que os gestores possam ter informações das condições dos pavimentos, de modo a tomarem decisões mais eficientes e acertadas.

Para a obtenção de informações fidedignas que irão alimentar o sistema de gestão de pavimentos é necessário empregar alguma metodologia que possibilite a realização de coletas de dados por avaliadores. Estas metodologias podem ser inspeções manuais, semiautomáticas ou automáticas. Metodologias manuais e semiautomáticas dependem do conhecimento de cada avaliador, podendo contribuir para um aumento na variabilidade das informações, e redução na confiabilidade dos dados levantados.

Assim, torna-se importante a utilização de meios automáticos para reduzir a variabilidade do levantamento, possibilitar inspeção de maior cobertura da malha viária, e tornar mais eficiente o tempo utilizado para a inspeção. Uma forma de utilizar os métodos automáticos de inspeção de pavimentos é através de redes neurais profundas, que são uma das mais conhecidas e populares ferramentas de aprendizagem e permitem a extração de características complexas.

Ao contrário dos algoritmos padrão de extração de características, as redes neurais profundas usam várias camadas ocultas para aprender hierarquicamente a representação de alto nível de uma imagem. Por exemplo, a primeira camada pode detectar bordas e curvas na imagem, a segunda camada pode detectar partes do corpo do objeto, a terceira camada pode detectar o objeto inteiro.

Para que um sistema de inspeção automatizada, utilizando visão computacional, funcione, é importante que haja compreensão das funções e dos parâmetros utilizados, sendo que o progresso atual na visão computacional tem sido baseado no desenvolvimento de recursos que minimizam a lacuna entre as representações de alto nível, interpretadas por humanos, e os recursos de baixo nível detectados pelos algoritmos. (Triggs, 2005) Portanto, a problemática que motiva o presente estudo é a busca por parâmetros, configurações e modelos de inspeção automatizada que sejam mais eficientes na detecção de trincas no pavimento, fazendo com o que o poder computacional despendido seja menor.

Acredita-se que com a utilização de Redes Neurais Convolucionais será possível minimizar a lacuna entre as interpretações dos defeitos no pavimento feitos pelo humano, do interpretado pela máquina, o que gera maior confiança e confiabilidade nas interpretações dos dados obtidos.

1.2 Justificativa

Devido ao desenvolvimento da rede viária e do aumento no tráfego, a manutenção dos pavimentos torna-se cada vez mais urgente e necessária. Por esta razão, a coleta e interpretação dos dados de condição do pavimento devem ser feitas de forma célere e confiável. Como resultado, migra-se cada vez mais de sistemas manuais para sistemas semiautomáticos ou automáticos na detecção e interpretação de informações.

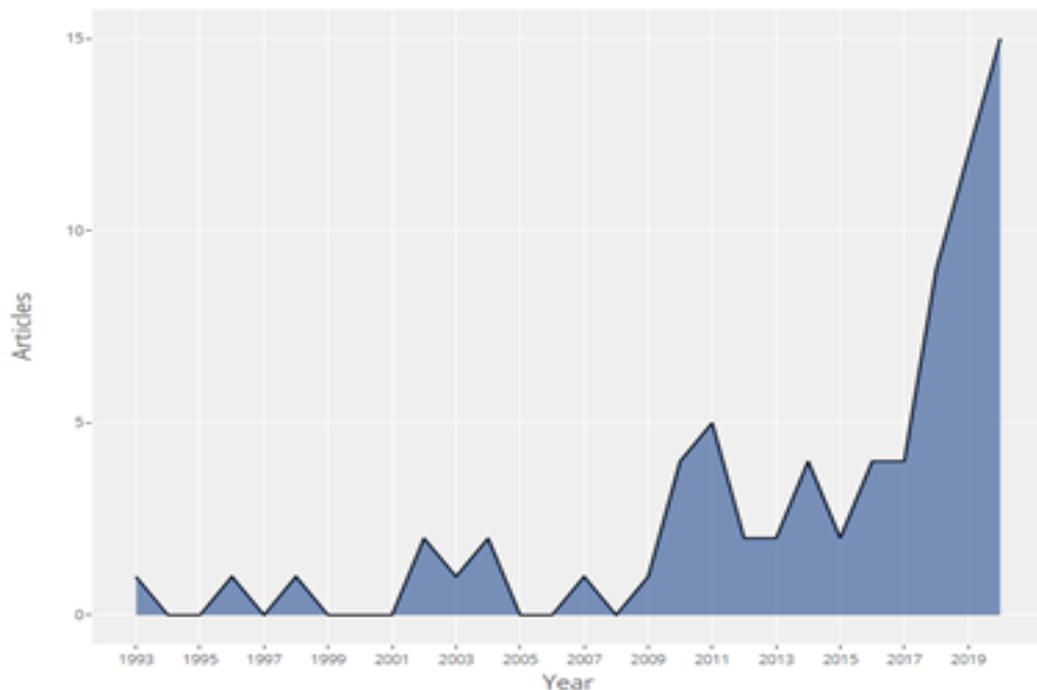
Os dados coletados por meio de imagens da superfície do pavimento para análise posterior podem ser sensíveis ao brilho, condições climáticas, objetos na estrada, como manchas de óleo, entre outros. Por esta razão, os algoritmos precisam ter capacidade de eliminar os ruídos, e demonstrar resultados com maior confiabilidade.

Segundo Dhital (2012), a detecção de trincas em estágio inicial é uma das formas de prevenir que danos mais graves ocorram, ou que haja a falha completa da infraestrutura analisada. No Brasil, cerca de 31,9% da extensão da superfície do pavimento possui trincas em malha, ou remendos. (CNT, 2018)

Por estas razões, a detecção automatizada de trincas nos pavimentos é uma importante tarefa para auxiliar inspeções rodoviárias em infraestruturas de transporte. Assim como por se tratar de uma forma de inspeção não-destrutiva, despertando um crescente interesse no desenvolvimento dessas técnicas.

O interesse dos pesquisadores pode ser mensurado pela quantidade de artigos publicados nos últimos anos. De acordo com uma análise bibliométrica utilizando o pacote bibliometrix do *software* R (<https://bibliometrix.org>), 145 documentos foram encontrados para uma busca de artigos com as palavras Convolutional Neural Network, Pavement e Crack. Entre os artigos, nenhum foi publicado por pesquisadores brasileiros, e a maioria vem sendo publicado nos últimos quatro anos, conforme pode ser visto na Figura 1, o rápido crescimento de publicações a partir do ano de 2017.

Figura 1 - Produção Científica Anual de artigos



Fonte: Próprio autor (2021).

Segundo McGhee (2004), pelo ponto de vista financeiro, demonstrou-se que o custo total da coleta de dados das condições do pavimento e processamento para a análise da situação do mesmo variava entre \$30 a \$125 dólares por milha (cerca de R\$ 90 a R\$ 380 por quilômetro), além da coleta automatizada possuir um impacto mínimo no tráfego, um aumento significativo na segurança, eficiência no uso do tempo, e a possibilidade de cobrir a totalidade da rede viária.

É importante também otimizar a rede neural, com as melhores configurações possíveis para que sejam utilizados menos recursos computacionais, diminuindo o tempo de classificação, e utilizando um volume de dados maior em menos tempo.

Ao se fazer a classificação automatizada utilizando a rede neural, poupa-se tempo também dos operadores humanos, o que implica na redução de custos, ou tempo livre para outras tarefas que sejam necessárias.

Por estas razões, justifica-se o uso das redes neurais como uma alternativa à detecção de defeitos no pavimento, assim como a necessidade de conhecer as melhores configurações e redes neurais para esta utilização.

1.3 Objetivos

1.3.1 Objetivo Geral

Treinar e comparar o desempenho de Redes Neurais Convolucionais destinadas à detecção de trincas em pavimentos flexíveis para definir a melhor rede e as configurações otimizadas de hiperparâmetros.

1.3.2 Objetivos Específicos

- a) Adquirir e tratar conjunto de fotografias de pavimentos com utilização de drone, realizando análise visual e computacional de cada segmento de imagem em estudo.
- b) Treinar oito Redes Neurais Convolucionais consolidadas e gerar modelos inteligentes para detecção de trincas em pavimentos flexíveis, estabelecendo o erro entre o real e o determinado pela rede.
- c) Comparar as redes utilizando diferentes configurações de hiperparâmetros, para estabelecer as melhores definições, e elencar melhores parâmetros e melhor rede neural para detecção de trincas em pavimentos.

2 REVISÃO BIBLIOGRÁFICA

2.1 Gerência de Pavimentos

Entre as principais economias mundiais, o Brasil é o país com maior concentração rodoviária de passageiros e de transporte de cargas. Segundo CNT (2021), 65% do transporte de mercadorias e 95% do transporte de passageiros é feito no modo rodoviário.

Por estar relacionado com grande parte da movimentação de cadeias produtivas, o modo rodoviário se faz cada vez mais relevante, sendo importante manter seu desempenho adequado e intervenções de manutenção frequentes.

De toda a extensão da malha rodoviária brasileira, somente 12,4% é pavimentada. Destas, 30% são compostas de rodovias federais, enquanto 70% são rodovias estaduais e municipais. Destas, 61,8% das rodovias avaliadas apresentam algum tipo de problema no estado geral, sendo que 46,9% dos trechos avaliados têm problemas no pavimento, contendo desgaste, trincas isoladas ou em malha, corrugação, entre outros defeitos. (CNT, 2018)

De acordo com Li (2017) e Radopoulou (2017), a avaliação da condição do pavimento é fundamental para projetar, determinar cronogramas, métodos, orçamentos e decidir sobre programas de manutenção eficazes. Além disso, o Departamento Nacional de Infraestrutura de Transportes (DNIT, 2011) indica que a interrupção ou redução dos serviços necessários para a manutenção do pavimento está associada ao aumento dos custos operacionais dos veículos, assim como maior investimento para a recuperação do pavimento.

Por esta razão, a gerência de pavimentos é um importante instrumento de apoio na tomada de decisões, permitindo a busca de meios mais eficientes para a correção de defeitos na estrutura e no funcionamento dos pavimentos, fazendo com que ocorra uma melhor alocação de recursos e promovendo uma manutenção de qualidade nos pavimentos urbanos.

A gerência de pavimentos é um processo amplo, no qual está envolvido o ciclo de vida dos pavimentos, servindo de base para a tomada de decisão em todos os estágios, desde o projeto e orçamentação do pavimento, construção, e monitoramento das condições dos pavimentos, permitindo a manutenção da qualidade e maior vida útil dos pavimentos. (Lima, 2006)

2.1.1 Coleta de Dados

O levantamento visual das condições do pavimento pode ser realizado de três maneiras: manual, semiautomático ou automático. Levantamentos visuais manuais são realizados a pé ou

em viagens de baixa velocidade por especialistas, que documentam os defeitos existentes observados. (Pierce, 2019). Atualmente o levantamento visual é um dos métodos mais utilizados para avaliação das condições físicas e funcionais das rodovias.

As principais normas utilizadas para a coleta de dados são do Departamento Nacional de Infraestrutura de Transportes (DNIT), que definem criteriosamente as condições e procedimentos para o levantamento e avaliação dos pavimentos. São elas:

Norma DNIT nº 005/2003 – TER, que define os termos empregados em defeitos que ocorrem nos pavimentos flexíveis e semirrígidos;

Norma DNIT nº 006/2003 – PRO, que estabelece condições exigíveis para a avaliação objetiva da superfície de pavimentos rodoviários flexíveis e semirrígidos;

Norma DNIT nº 007/2003 – PRO, que trata da avaliação da condição de superfície de rodovias de pavimentos flexíveis e semirrígidos;

Norma DNIT nº 008/2003 – PRO, que institui procedimentos para o levantamento visual contínuo, exigíveis na avaliação da superfície de pavimentos flexíveis e semirrígidos;

Norma DNIT nº 009/2003 – PRO, que fixa procedimentos para a avaliação subjetiva da superfície de pavimentos flexíveis e semirrígidos com base no seu Valor de Serventia Atual (VSA), indicando o grau de conforto e suavidade ao rolamento proporcionado pelo pavimento ao usuário.

Há também outras referências como o Manual para Identificação de Defeitos de Revestimentos Asfálticos de Pavimentos (MID) e o Highway Capacity Manual (HCM – Manual de Capacidade Rodoviária).

Dentre as normas citadas, as inspeções ocorrem principalmente pela norma DNIT 008/2003 – PRO, que indica o uso de um veículo equipado com velocímetro/odômetro, o qual deve operar a uma velocidade média de 40 km/h.

O processo de levantamento das condições do pavimento é feito através do preenchimento de um formulário com a observação da frequência de cada defeito abrangido pelo formulário: trincas, remendos, panelas, afundamento, ondulações, escorregamento do revestimento, exsudação e desgaste.

Métodos semiautomáticos necessitam algum tipo de interação humana, normalmente um especialista faz a identificação visual dos defeitos do pavimento através de imagens obtidas do pavimento.

Os métodos automáticos não envolvem interação humana na detecção e classificação dos defeitos. Nesse método o algoritmo é usado para visualizar as imagens e automaticamente

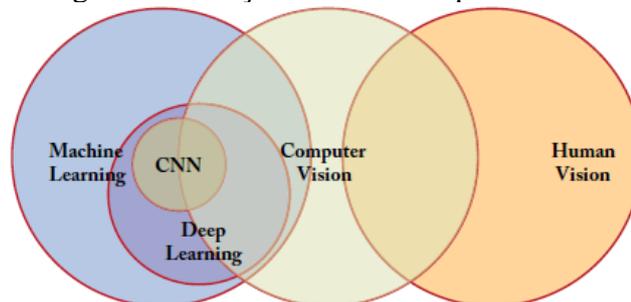
identificar e classificar os defeitos, medindo a extensão e severidade, e compilando os resultados em um banco de dados. (Pierce, 2019)

2.2 Aprendizagem de Máquina

Segundo Samarasinghe (2016), a aprendizagem de máquina é um tipo de inteligência artificial que permite ao computador aprender a partir de dados sem ter sido explicitamente programado. O objetivo é permitir criar modelos que consigam aprender a partir de dados de treinamento, sem regras ou lógica a partir de um humano. Os métodos de aprendizagem podem ser supervisionados, semi-supervisionados, ou não supervisionados. Este trabalho terá como enfoque o aprendizado supervisionado utilizando aprendizagem profunda, mais especificamente Redes Neurais Convolucionais.

A Figura 2 demonstra como as Redes Neurais Convolucionais estão relacionadas com outros campos de estudo, e são pertencentes ao campo de estudo de aprendizagem profunda e aprendizagem de máquina. Este tópico se relaciona com a utilização de ferramentas de visão computacional, os quais possibilitaram avanços na classificação de imagens em diversos campos de estudo.

Figura 2 - Relação entre os campos de estudo



Fonte: Khan (2018).

2.3 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são modelos computacionais distribuídos e paralelos compostos de unidades de processamento, os neurônios, densamente conectados. Elas têm a propensão natural de armazenar conhecimento experimental e torná-lo disponível para o uso com base em modelos matemáticos, ou seja, tais técnicas adquirem conhecimento através da experiência (Reis, 2018).

A propriedade que é de importância primordial para uma rede neural é a sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem. Ocorre com o tempo de acordo com alguma medida preestabelecida. Uma rede neural aprende acerca do seu ambiente através de um processo iterativo de ajustes aplicados a seus pesos. (Haykin, 2001)

Segundo Samarasinghe (2006), todas as redes neurais possuem conexões que ligam as entradas aos neurônios e os neurônios à saída. Estas conexões são chamadas de pesos, os quais permitem à rede se adaptar ao ambiente. Esta adaptação ocorre através de aprendizagem, que pode ser supervisionado ou não.

A forma mais comum de aprendizagem é a supervisionada. Neste caso, o autor da rede neural deve ter conhecimento do ambiente, e passar este conhecimento através de uma série de exemplos de entrada e saída. O entendimento por parte da rede ocorre através de treinamento (Haykin, 2009).

Durante o treinamento, por exemplo, a rede é alimentada com uma imagem e produz uma saída na forma de um vetor de pontuação, em cada categoria possível de saída. O resultado determinado pela rede é aquele com a pontuação mais alta, porém dificilmente será o resultado correto antes do treinamento.

Desta forma, mede-se o erro do resultado dado pela rede, para o resultado esperado, ajustando-se os pesos. Este ajuste é feito com base na variação do erro, ou seja, ao aumentar um determinado peso o erro pode aumentar ou diminuir (Lecun, 2015).

Após o processo de treinamento, é feita a avaliação do desempenho do algoritmo através de uma série de exemplos, chamado de processo de validação. O objetivo deste procedimento é testar a capacidade de generalização da rede, medindo a habilidade de produzir bons resultados com dados que não foram utilizados durante o treinamento.

2.3.1 Mobile Net

A rede MobileNet foi criada em 2017 com o intuito de ser uma rede neural convolucional mais simplificada, com a possibilidade de ser utilizada de forma embarcada em aplicações relacionadas à visão computacional.

Conforme Howard *et al.* (2017), as redes MobileNet possuem camadas de convoluções separáveis em profundidade, isso modifica a convolução tradicional fazendo com que seja executada em dois passos distintos. A Tabela 1 demonstra as camadas da rede MobileNet, onde

há primeiramente, a aplicação de um filtro para cada canal de entrada, e posteriormente essas saídas são combinadas em uma convolução ponto a ponto.

Tabela 1 - Arquitetura da rede MobileNet

Type / Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5×	Conv dw / s1	$3 \times 3 \times 512$ dw
	Conv / s1	$1 \times 1 \times 512 \times 512$
Conv dw / s2	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw / s2	$3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool 7×7	$7 \times 7 \times 1024$
FC / s1	1024×1000	$1 \times 1 \times 1024$
Softmax / s1	Classifier	$1 \times 1 \times 1000$

Fonte: Howard *et al.*, (2017).

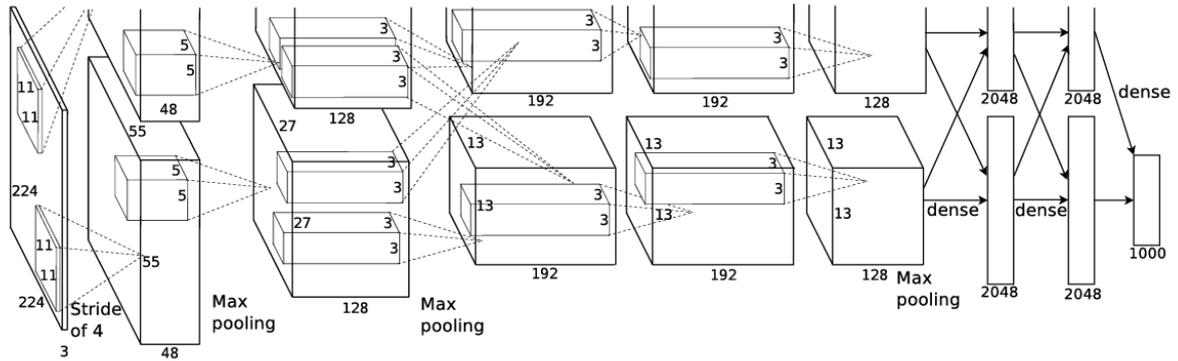
2.3.2 AlexNet

A rede AlexNet foi criada em 2012 por Krizhevsky *et al.* (2012), e possui oito camadas, nas quais as cinco primeiras são camadas de convolução, e as três últimas completamente conectadas. Em sua última camada há um softmax, o qual realiza uma distribuição de probabilidade entre as 1000 classes do banco de dados do ImageNet. (Souza, 2020)

A rede neural AlexNet possui uma arquitetura com 60 milhões de parâmetros, e utiliza métodos de aumento dos dados através de duas formas distintas, sendo a primeira a translação e reflexão horizontal, e a segunda uma alteração na intensidade dos canais de cores nas imagens em treinamento. (Krizhevsky, 2012)

A Figura 3 demonstra as oito camadas da rede Alexnet, além de outros detalhes de transformações ocorridas entre cada uma das camadas, finalizando em camadas totalmente conectadas.

Figura 3 - Arquitetura da rede AlexNet



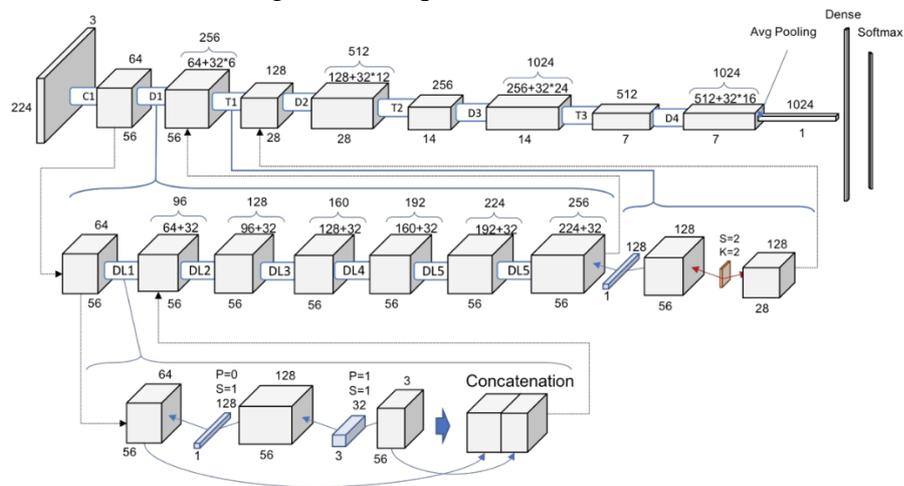
Fonte: Krizhevsky *et al.*, (2012).

2.3.3 DenseNet

Na rede DenseNet, cada camada obtém informações das camadas predecessoras, e tem como saída informações que serão passadas para todas as próximas camadas. Desta forma, usa-se a concatenação para que haja informações comuns a todas as camadas.

Com isso, procura-se ter uma maior eficiência computacional e na utilização da memória, de forma que essas redes requerem um menor número de parâmetros do que outras redes tradicionais, e não necessitam fazer o aprendizado de modo redundante. (Ruiz, 2018)

Figura 4 - Arquitetura da rede DenseNet



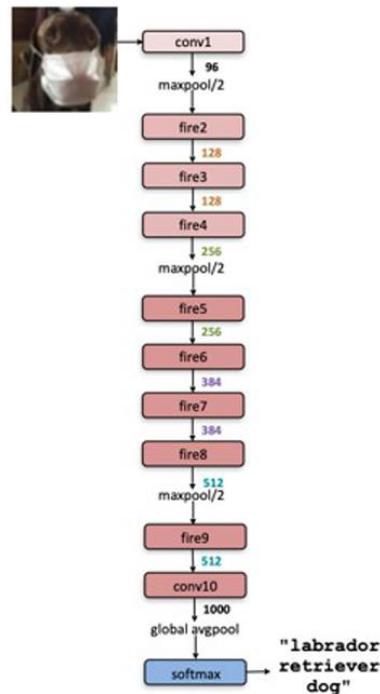
Fonte: Huang *et al.*, (2017).

2.3.4 SqueezeNet

A rede SqueezeNet propõe a substituição de convoluções tradicionais por convoluções separáveis em profundidade, de forma que seja uma arquitetura reduzida, mas com boa taxa de acerto.

A rede ainda teria vantagens em relação a ter um treinamento distribuído de maneira mais eficiente, possuindo menor sobrecarga ao exportar novos modelos e a possibilidade de implementação em sistemas embarcados. (Souza, 2020)

Figura 5 - Arquitetura da rede SqueezeNet



Fonte: Adaptado de Iandola *et al.*, (2016).

2.3.5 Visual Graphic Group - VGG19

A rede VGG foi criada em 2014 com objetivo de compreender os efeitos da quantidade de camadas de uma rede neural convolucional em sua acurácia. Utilizaram-se diversos experimentos com uma mesma base de arquitetura, mas com um número diferente de camadas de convolução (Simonyan, 2015).

A rede VGG19 possui convoluções que utilizam sempre *kernels* de tamanho 3x3 e *stride* 1. Há também camadas de *max-pooling* após as convoluções de número 2, 4, 8, 12 e 16. E ao

2.4 Métricas de avaliação de desempenho

A avaliação do modelo é composta de métricas, entre as quais as mais utilizadas são acurácia, precisão, *recall* e *F1-Score*. É importante considerar um conjunto abrangente de métricas para que seja viável compreender como cada parâmetro afeta a rede neural, e quais são as vantagens e desvantagens de suas utilizações.

Os resultados obtidos pela rede neural podem ser divididos em quatro, conforme pode ser visto no Quadro 1: verdadeiro positivo (VP), que representa a porcentagem de imagens positivas classificadas corretamente, falso positivo (FP), indicando a porcentagem de negativos classificados incorretamente, falso negativo (FN), estabelecendo aqueles que deveriam ser classificados como positivos, mas foram determinados como negativos, e verdadeiro negativo (VN), cuja porcentagem apresenta a correta classificação dos negativos (Hoang, 2018).

Quadro 1 - Respostas do algoritmo através de classificadores binários.

		Detectado	
		Sim	Não
Real	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

2.4.1 Acurácia

A acurácia é usada para indicar a qualidade do resultado de determinada tarefa. O fato de que as RNC podem alcançar precisão em estado da arte em uma ampla gama de tarefas é uma das principais razões que impulsionam a popularidade e ampla utilização nos dias de hoje. A Acurácia pode ser definida pela Equação 1.

$$\text{Acurácia} = \frac{\text{Verdadeiros Positivos (TP)} + \text{Verdadeiros Negativos (VN)}}{\text{Total}} \quad (1)$$

2.4.2 Precisão

É considerado como a porcentagem de padrões classificados como pertencentes à classe positiva e que realmente pertencem à classe positiva, definida pela Equação 2.

$$\text{Precisão} = \frac{\text{Verdadeiros Positivos (TP)}}{\text{Verdadeiros Positivos (TP)} + \text{Falsos Positivos (FP)}} \quad (2)$$

2.4.3 Recall

Proporção de padrões da classe positiva identificada corretamente. Indica o quão bom o modelo é para identificar a classe positiva, e é definida pela Equação 3.

$$\text{Recall} = \frac{\text{Verdadeiros Positivos (TP)}}{\text{Verdadeiros Positivos (TP)} + \text{Falsos Negativos (FN)}} \quad (3)$$

2.4.4 F1-Score

Essa métrica (Equação 4) combina precisão e *recall* de modo a trazer um número único que indique a qualidade geral do modelo e trabalha bem até mesmo com conjuntos de dados que possuem classes desproporcionais. (Leal, 2017)

$$F1 = \frac{2 * \text{precisão} * \text{recall}}{\text{precisão} + \text{recall}} \quad (4)$$

2.4.5 Relação F1-Score / Tempo

Também se fez utilização de dois parâmetros importantes, que foram relacionados para que a comparação pudesse levar em consideração o tempo de inferência e as imagens classificadas de forma errônea.

$$\text{Índice F1 - Score/Tempo} = \frac{\text{F1 - Score (\%)}}{\text{Tempo de Inferência (ms)}} \quad (5)$$

Para tal, calculou-se a relação $F1-Score/Tempo$, pela simples divisão dos valores de $F1-Score$ e o tempo de inferência em milissegundos. O cálculo é dado pela fórmula 5, e os resultados serão discutidos no tópico 4.

Definiu-se como métrica de avaliação da pesquisa a relação $F1-Score /Tempo$, pois a pesquisa pretende levar em consideração também o tempo de inferência, visando uma possível aplicação prática em tempo real.

2.5 Redes Neurais Convolucionais

Segundo Khan (2018) as RNCs são uma classe de modelos úteis tanto para paradigmas de aprendizagem supervisionada quanto não supervisionada.

O mecanismo de aprendizagem supervisionada é aquele onde a entrada para o sistema e as saídas desejadas são conhecidas e o modelo aprende um mapeamento entre os dois. Já no mecanismo de aprendizagem não supervisionada, os rótulos para um determinado conjunto de entradas não são conhecidos, e o modelo visa estimar a distribuição subjacente das amostras de dados das entradas.

As RNCs aprendem a mapear uma determinada imagem para a categoria correspondente, detectando uma série de características abstratas, que vão desde as mais simples até as mais complexas. Estas características discriminatórias são então utilizadas dentro da rede para prever a categoria correta de uma imagem de entrada.

2.5.1 Uso de Redes Neurais Convolucionais na Detecção de Trincas

Zhang *et al.* (2017) utilizaram uma RNC para detecção de trincas em superfícies 3D que atingiu precisão de 90,13% na fase de treinamento e de 87,63% na fase de validação, com uma medida F de 88,86%. Os autores constataram que o maior desafio da detecção de trincas está em atingir alto desempenho em ambientes complexos e diferentes entre si.

Pauly *et al.* (2017) obtiveram 91,3% de acurácia quando o algoritmo foi testado com imagens do mesmo local das imagens de treinamento, e 90,1% quando utilizadas imagens de um pavimento diferente. Concluíram, portanto, que o local de origem das imagens é um ponto importante a ser destacado, podendo ser um obstáculo na universalização de uma RNC. Também destacaram que quanto mais densa é a rede, melhor é o desempenho em termos de acurácia.

Hoang (2018) relata que as RNCs têm vantagem quando usadas para identificar a presença de trincas em pavimentos. Em sua pesquisa, o autor comparou o desempenho de uma rede neural convolucional com um método de detecção de bordas. A RNC alcançou melhor resultado, apresentando acurácia de 92,08% contra 79,99% do outro método.

O estudo desenvolvido por Domitrović *et al.* (2018) conseguiu determinar corretamente a existência de trincas em cerca de 95% dos casos. Wang *et al.* (2017) propuseram uma RNC que atingiu acurácia de 96,32% na fase de treinamento e de 94,29% na fase de validação. Os autores constataram que os erros ocorreram principalmente ao redor das trincas e nas bordas das imagens.

Jiale (2022) desenvolveu uma rede para o cálculo de índice de qualidade do pavimento, baseando-se na visão computacional das trincas para o cálculo da condição do pavimento. Jiale utilizou Redes Neurais Convolucionais e algoritmos genéticos e obteve acurácia de 98% com tempo de inferência de 47 milissegundos.

Em relação à otimização de hiperparâmetros na detecção de trincas, Zhou (2020) utilizou imagens 3D obtidas por meio de scanner a laser, utilizando 36 combinações diferentes de arquitetura de rede, com o tamanho de *kernel* variando de 3x3 *pixels* até 11x11 *pixels*, profundidade de 5 a 8 camadas ocultas, e *width* de 16 a 96 *kernels* em cada camada de convolução. Após a seleção das melhores configurações de arquitetura, definiram-se parâmetros de treinamento das taxas de aprendizado, fator *dropout* e *min-batch*.

2.5.2 Parâmetros do modelo

Em um algoritmo de *Machine Learning*, os parâmetros são ajustados diretamente pelo processo de aprendizado e influenciam diretamente no desempenho do algoritmo. Os coeficientes de uma regressão linear, os pesos de uma rede neural, as camadas, filtros, todos os parâmetros que se ajustam ao treinar o modelo preditivo para um conjunto de dados. (Miura, 2020)

2.5.2.1 Camadas

Uma rede neural convolucional é composta de camadas, algumas dessas camadas podem ter diferentes funções, como por exemplo a normalização, *pooling*, convolução e camadas totalmente conectadas. A camada mais importante é a de convolução, a qual aplica uma série de filtros que geram uma resposta de saída.

2.5.2.2 Filtros

Os filtros são matrizes de números discretos, no qual o peso de cada filtro é aprendido durante o treinamento da rede neural. O filtro é utilizado para extrair características das imagens de entrada. Os filtros se movem ao longo das imagens por meio da definição do valor de Stride.

2.5.2.3 Stride

O stride é um parâmetro das Redes Neurais Convolucionais que modifica o movimento dos filtros sobre uma imagem. Ele pode reduzir a resolução da imagem de saída, e é utilizada para ajustar a dimensionalidade dos dados efetivamente. Quanto maior o valor do stride, mais resumido os dados serão, e quanto menor, maior será a sobreposição dos filtros, e maior será a quantidade de dados.

2.5.2.4 Funções de Perda

A função de perda é utilizada para avaliar uma combinação de pesos, procurando minimizar os valores de erro. A escolha da função de perda está diretamente relacionada à função de ativação utilizado na camada de saída da rede neural. É importante definir a função de perda corretamente para que ela represente o modelo, e obtenha os resultados satisfatórios.

2.5.3 Hiperparâmetros

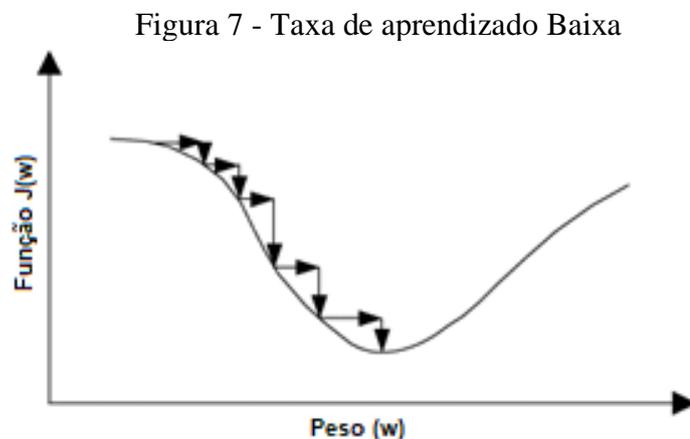
No treinamento de um algoritmo de aprendizado, os hiperparâmetros são variáveis que, de alguma forma, governam o espaço do modelo ou o procedimento de ajuste do mesmo, visando assim à redução do seu erro de generalização. Se, por um lado, esta característica peculiar dos hiperparâmetros possibilita a obtenção de modelos com melhores desempenho de predição, por outro, paga-se um preço pelo esforço inerente à estimação dos valores ótimos.

Os hiperparâmetros são variáveis que controlam o próprio processo de treinamento. Por exemplo, faz parte da configuração de uma rede neural profunda decidir quantas camadas ocultas de nós precisam ser usadas entre a camada de entrada e a camada de saída, bem como quantos nós cada camada precisa usar. Essas variáveis não estão diretamente relacionadas aos dados de treinamento. Elas são variáveis de configuração. Os parâmetros mudam durante um o

treinamento, enquanto os hiperparâmetros geralmente permanecem constantes. (Cloud Google, 2020)

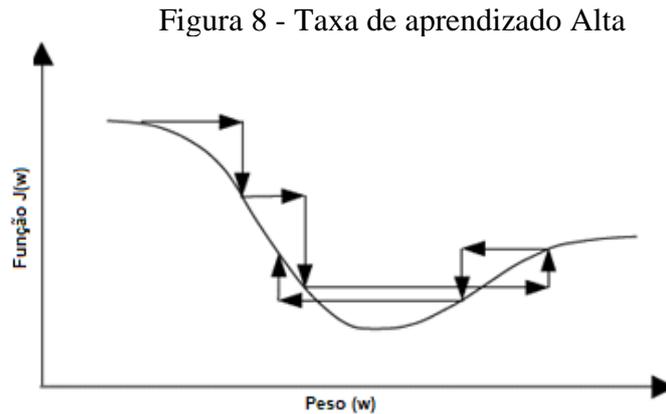
2.5.3.1 Taxa de aprendizado

A taxa de aprendizado especifica a rapidez com que a aprendizagem ocorre. Um valor de zero indica que não há aprendizado e, à medida que o valor aumenta, o modelo aprende a uma velocidade mais rápida. Valores maiores para a taxa de aprendizado podem acelerar o processo de treinamento, no entanto, também podem induzir oscilações que podem retardar a convergência para uma solução aceitável. Tem sido comum usar um valor entre 0 e 1. Deve-se utilizar uma taxa de aprendizado menor para guiar lenta e suavemente a descida em direção aos pesos ideais, conforme a Figura 7.



Fonte: Samarasinghe, 2016

A Figura 8 mostra o efeito de uma grande taxa de aprendizado. Demonstrando que o erro pode inicialmente diminuir, mas devido à grande taxa de aprendizado, os incrementos de peso também podem ser tão grandes que o mínimo global da superfície do erro pode ser alcançado após um longo tempo ou a solução pode oscilar em torno do mínimo e nunca o alcançar. (Samarasinghe, 2006)



Fonte: Samarasinghe, 2016

2.5.3.2 Momento

O momento é outra abordagem de aproximação que proporciona estabilidade ao atingir os pesos ideais durante o aprendizado, e pode ser útil para alguns problemas, especialmente no aprendizado de máquina. Este método basicamente marca a média das mudanças de peso do passado no novo incremento de peso a cada mudança de peso, suavizando assim a mudança de peso total.

2.5.3.3 Dropout

Durante o treinamento da rede, cada neurônio é ativado com uma probabilidade fixa, geralmente 0,5 ou definido usando um conjunto de validação. Esta amostragem aleatória de uma sub-rede dentro da rede em escala real introduz um efeito de conjunto durante a fase de teste, onde a rede completa é usada para realizar a previsão. O *dropout* funciona bem para fins de regularização e dá um aumento significativo no desempenho em dados não vistos na fase de teste. (Khan, 2019)

2.5.4 Otimização de Hiperparâmetros

A estimação hiperparamétrica ótima possui desafios que estão ligados ao tipo de algoritmo de aprendizado utilizado, à função de custo empregada, aos conjuntos de dados de treinamento e teste, dentre outros. Na maior parte dos casos, a otimização hiperparamétrica é tipicamente abordada como um problema de derivada inexistente, mono-objetivo e de domínio restrito (Alvarenga, 2018).

O ajuste do hiperparâmetro é o processo de determinação da combinação correta de hiperparâmetros que permite que o modelo maximize o desempenho. A determinação da combinação correta de hiperparâmetros é a única maneira de obter o máximo desempenho dos modelos.

Segundo Alvarenga (2018), existe um apelo por parte da comunidade científica por métodos automáticos para realizar a otimização hiperparamétrica de modelos. Várias abordagens diferentes são encontradas na literatura para lidar com este problema, como: a Busca em Grade, a Busca Aleatória, a Otimização baseada no Gradiente, métodos de Computação Evolucionária e a Otimização Bayesiana.

2.5.4.1 Ajuste Hiperparamétrico Manual

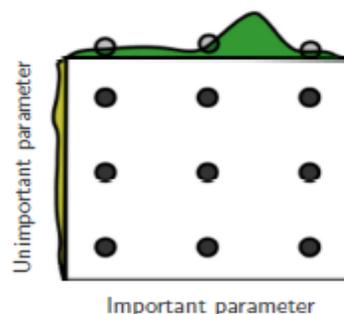
O ajuste manual de hiperparâmetros é realizado usando diferentes combinações de hiperparâmetros, selecionados e configurados manualmente. Esse processo se torna demorado e muitas vezes impraticável caso haja muitos hiperparâmetros a serem testados.

2.5.4.2 Busca em Grade

A estratégia da Busca em Grade é um método tradicionalmente utilizado na otimização hiperparamétrica de modelos com um número reduzido de hiperparâmetros. Esta técnica apresenta uma forma de resolução simples e direta, possuindo como características: fácil implementação e paralelização. (Alvarenga, 2018)

Esta é uma busca exaustiva no espaço de parâmetros em que todas as combinações possíveis são testadas, o que pode ser demorado. Normalmente funciona melhor quando há três ou menos hiperparâmetros e, para cada hiperparâmetro, o usuário seleciona um pequeno conjunto finito de valores para explorar.

Figura 9 - Busca em grade



Fonte: Bergstra e Bengio, 2012

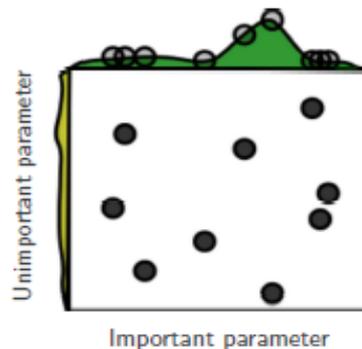
A busca em grade normalmente não é utilizada na prática, pois o número de combinações possíveis a serem buscadas cresce exponencialmente conforme aumentam os números de hiperparâmetros a serem treinados.

Isso ocorre, pois o algoritmo precisará fazer uma busca exaustiva, de maneira sequencial em todas as combinações possíveis, o que não é eficiente computacionalmente, nem mesmo em relação ao tempo despendido.

2.5.4.3 Busca Aleatória

Em vez de fazer uma análise exaustiva de todos os valores de hiperparâmetros possíveis, a Busca Aleatória escolhe alguns pontos aleatórios no espaço de parâmetros (Bergstra, 2012). A busca aleatória tem mostrado convergir mais rapidamente para bons valores dos hiperparâmetros, em comparação com a busca em grade.

Figura 10 - Busca Aleatória



Fonte: Bergstra e Bengio, 2012

2.5.4.4 Otimização Bayesiana

A otimização bayesiana é uma estratégia do estado-da-arte na otimização de funções computacionalmente custosas e complexas. É considerada bem estabelecida, e vem sendo utilizada desde a década de 1970. Um exemplo é o trabalho de Mockus (1978) que utilizou métodos bayesianos para a busca de valores extremos em otimizações globais.

Outros autores, como Lizotte (2008), demonstraram as aplicações práticas da utilização da otimização bayesiana. O autor otimizou a maneira de andar e a trajetória de robôs, encontrando parâmetros para que a caminhada ocorresse com maior efetividade, e em menor número de tentativas do que algoritmos competidores.

Especificamente aplicada a redes neurais, a otimização bayesiana é utilizada há cerca de 30 anos. MacKay (1992) demonstrou uma metodologia prática de integrar otimização bayesiana em algoritmos de retropropagação, afirmando que o método é bem fundamentado teoricamente, e que possui possibilidade de utilização prática.

Snoek (2015) utilizou otimização Bayesiana para ajustar os hiperparâmetros de um modelo, ajustando os valores de taxa de aprendizado, momento, *dropout* e quantidade de camadas, e demonstraram empiricamente que o modelo treinado obteve resultados competitivos em tarefas de classificação de imagem como CIFAR-10 e CIFAR-100.

Os métodos Bayesianos tentam construir uma distribuição de probabilidade sobre uma possível função que estima quão bom o modelo pode ser para uma determinada escolha de hiperparâmetros, utilizando-se do conhecimento das iterações anteriores do algoritmo.

A otimização Bayesiana treina o modelo com diferentes valores hiperparamétricos, e observa a função gerada para o modelo por cada conjunto de valores de parâmetro. Isso é feito repetidamente, cada vez que valores hiperparâmetros ligeiramente diferentes são selecionados, e ajudam a traçar o próximo segmento relevante.

Similar aos métodos de amostragem estatística, o algoritmo termina com uma lista de possíveis conjuntos de valores de hiperparâmetros e funções do modelo, a partir dos quais ele prevê a função ótima em todo o conjunto de problemas.

2.6 Trincas em Pavimentos Flexíveis

A norma DNIT (005/2003 TER) apresenta a seguinte definição para o defeito chamado de fenda em pavimentos flexíveis: “Qualquer descontinuidade na superfície do pavimento, que conduza a aberturas de menor ou maior porte, apresentando-se sob diversas formas.”

A ruptura por fadiga nos revestimentos asfálticos é consequência de três processos básicos: início do fissuramento que consome apenas pequena parcela da vida de fadiga; crescimento estável da trinca que corresponde à maior parcela da vida de fadiga e propagação instável da trinca, que culmina na ruptura (Bastos, 2010).

Dentre as diversas formas que as aberturas podem se apresentar, as trincas por fadiga são as que ocorrem devido às repetições do tráfego. Inicialmente ocorrem trincas de pequena severidade, na direção do eixo da rodovia, e geralmente aparecem nas trilhas-de-roda. Já as trincas do tipo bloco dividem a superfície do revestimento em peças retangulares, causado pela contração da camada asfáltica devido à alternância diária de temperatura, revelando o enrijecimento da camada.

As trincas de borda geralmente ocorrem em rodovias cujos acostamentos não são pavimentados. Consiste na ruptura, normalmente situada ao longo de uma faixa de 30 a 60 cm da borda do pavimento ou da junção onde o pavimento sofreu alargamento. Já as trincas longitudinais são aquelas paralelas à linha central do pavimento, tendo como prováveis causas recalques diferenciais ou a contração da capa asfáltica, não sendo necessariamente associadas às cargas do tráfego (Bastos, 2010).

Por fim, as trincas transversais são as que apresentam direção perpendicular à linha central do pavimento, podendo ter como causa principal a contração da capa asfáltica, devido a baixas temperaturas ou enrijecimento do asfalto.

3 METODOLOGIA

Os procedimentos metodológicos tratam da aquisição das imagens, detalhes das arquiteturas escolhidas para o treinamento das redes neurais, bibliotecas escolhidas para a otimização bayesiana, e a forma que os resultados são comparados.

3.1 Aquisição de imagens

A aquisição das imagens para o treinamento das redes neurais se deu por meio de um drone DJI Mavic 2 Pro com resolução de imagens de 5472×3078 pixels. O local de estudo foi o campus I da Universidade de Passo Fundo, localizado no interior do Rio Grande do Sul, em latitude $-28,246773^\circ$ e longitude $-52,3883627^\circ$.

Figura 11 - Localização da área de estudo



Fonte: Google Earth, 2022

A Figura 11 representa a localização estudada, e a trajetória percorrida pelo drone próxima ao Centro Tecnológico – CETEC. A distância do trajeto percorrido foi de cerca de 500 metros, por volta das 11 horas do dia 12 de maio de 2021.

Figura 12 – Voo drone / Trinca em via pavimentada



Fonte: Próprio Autor, 2021

As imagens capturadas foram obtidas nas vias de pavimento flexível da Universidade de Passo Fundo. A estrutura do pavimento é composta de revestimento de 5 cm, base de brita graduada 20 cm, sub-base de 20 cm de rachão, com CBR aproximado do subleito igual a 5%.

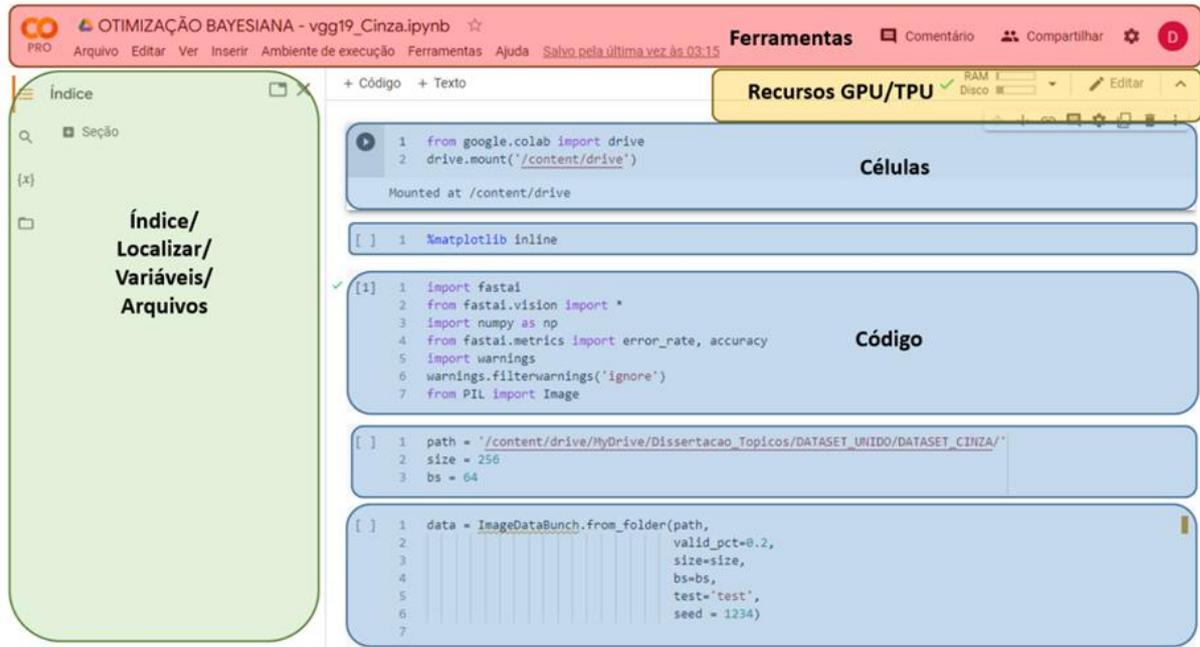
O objetivo do voo foi o de identificar as áreas com ocorrência de trincamento, como pode ser visto na Figura 12. O drone voou a uma altura média de 15 metros, sendo que, a parte mais à direita é um exemplo de imagem captada no levantamento.

3.2 Ambiente de Desenvolvimento

Para realizar toda a parte relacionada com a programação dos algoritmos, recorte de imagens, treinamento de todas as redes neurais e posterior otimização, foi utilizado o *Google Colaboratory*, o qual permite escrever e executar códigos Python diretamente no navegador.

O *Google Colaboratory* conta com acesso gratuito a placas de vídeo (GPU), e reduzem a necessidade de configuração de bibliotecas e ambientes. A Figura 13 demonstra como o ambiente do *Google Colaboratory* é interativo, no qual o código pode ser escrito e executado em partes diferentes através das células.

Figura 13 - Interface Google Colaboratory



Fonte: Próprio Autor, 2022

Para a realização deste trabalho, devido à intensa utilização computacional, foi necessário adquirir a versão Google Colab Pro, a qual disponibiliza, além de Placas de Vídeo (GPU) mais potentes, NVIDIA Tesla V100 e P100, a possibilidade de utilizar Unidades de Processamento de Tensores (TPU), desenvolvido especificamente para aplicações de aprendizagem de máquina.

3.3 Recorte das imagens do banco de dados

O recorte de cada uma das imagens foi feito por meio do código Python a seguir, que tem como função abrir cada imagem e recortá-la em quadrados de 256x256 *pixels*, salvando em uma nova imagem.

Os recortes foram realizados com a importação de três bibliotecas Python. A biblioteca padrão OS, para auxiliar nas operações envolvendo a manipulação de arquivos no sistema operacional.

Utilizou-se também a biblioteca Glob, a qual tem como função a manipulação dos caminhos dentro do sistema dos arquivos utilizados, e a biblioteca Pillow para o processamento e manipulação das imagens. O Algoritmo 1 demonstra a lógica de programação utilizada no recorte das 42 mil imagens.

Algoritmo 1 – Recorte de imagens

```

1 Importar bibliotecas
2
3 imgdir = "diretório para a imagem"
4
5 lista de arquivos = [arquivos no diretório com extensão .jpg],
6 savedir = "diretório para salvar novas imagens"
7 posição inicial = posição inicial_x, posição inicial_y = (0, 0)
8 tamanho da imagem recortada = largura, altura = (256, 256)
9
10 for arquivo in lista de arquivos:
11     img = abrir arquivo
12     largura, altura = img.size
13
14     número do recorte = 1
15     for coluna_i in range(0, largura, w):
16         for linha_i in range(0, altura, h):
17             recorta a imagem
18             salva com nome do recorte altura e largura
19             passa para o próximo recorte da imagem

```

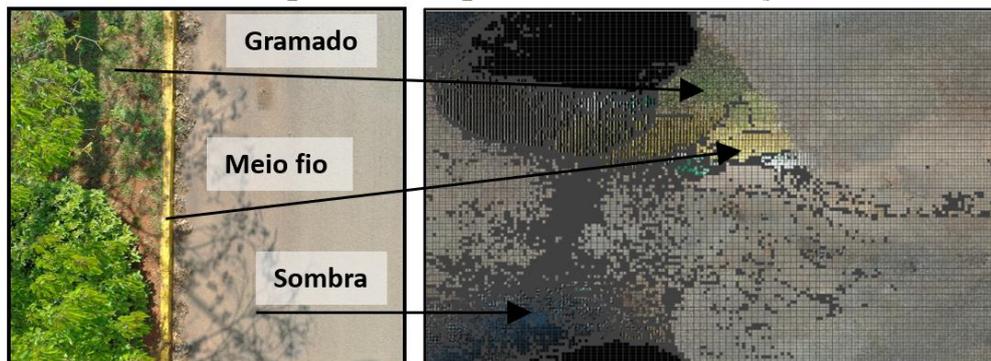
Fonte: Próprio autor, 2022

3.4 Eliminação de imagens

Por intermédio da ferramenta de classificação por cores *ImageSorter V4* (<https://imagesorter.software.informer.com>), foi possível excluir grande parte das imagens que não faziam parte do objeto de estudo, como calçadas, carros, gramados e quaisquer outros ruídos presentes.

A Figura 14 mostra a interface do *software* utilizado, onde pode-se perceber em amarelo a reunião de todos os recortes do banco de dados referentes aos meios-fios do pavimento, os quais puderam ser facilmente descartados, não interferindo no treinamento das redes neurais.

Figura 14 - Imagens antes da classificação

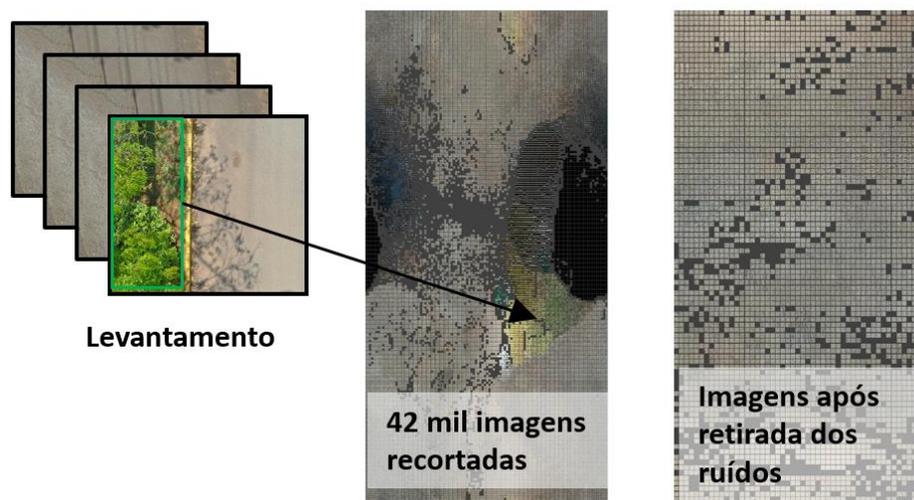


Fonte: Próprio autor, 2021

Por razão da utilização de grande parte da memória RAM para o carregamento das imagens, foi necessário fazer o carregamento em quantidades de no máximo 10 mil imagens por vez durante a classificação.

Após a seleção e exclusão de todas as imagens classificadas como ruídos, o banco de dados tornou-se perceptivelmente mais homogêneo, como pode ser visto na Figura 15. Este tipo de ferramenta permitiu que o tempo de retirada de ruídos do banco de dados fosse menor, facilitando encontrar imagens destoantes do geral.

Figura 15 – Construção do banco de dados



Fonte: Próprio autor, 2021

Em seguida houve a conversão em escala de cinza de todo o banco de dados utilizando a biblioteca de código aberto OpenCV (<https://www.opencv.org>), a qual possibilita a utilização de ferramentas de visão computacional.

Posteriormente, as imagens selecionadas passaram por classificação manual, para a formação do *ground truth*, ou seja, as imagens foram categorizadas uma a uma por avaliador humano, de forma que as imagens estivessem categorizadas corretamente para o início do treinamento das redes.

3.5 Otimização das Redes Neurais

Foram utilizados inicialmente os hiperparâmetros e parâmetros de arquitetura de rede padrão para cada uma das redes, e, a partir destes, feitas a otimização da rede neural utilizando o método de busca bayesiana citada no item 2.4.4.4.

A otimização de hiperparâmetros foi feita através da biblioteca de código livre “*BayesianOptimization*” (Nogueira, 2014), a qual permite a otimização bayesiana nos

frameworks de aprendizagem de máquina mais utilizados atualmente, como Keras (<https://keras.io/>), Pytorch (<https://pytorch.org/>) e FastAI (<https://www.fast.ai/>). Para a otimização dos parâmetros utilizou-se valores limítrofes de taxa de aprendizado, de 0,00001 à 0,01, taxa de decaimento de 0,0001 à 0,4, e *dropout* de 0,01 à 0,6.

A otimização bayesiana funciona através da construção de uma distribuição posterior de funções em um processo gaussiano, que melhor descreve a função que se pretende otimizar. Conforme há um aumento no número de observações, a distribuição posterior melhora, e o algoritmo se torna mais certo de que regiões e espaços de parâmetros valem a pena explorar. (Nogueira, 2014)

Cada imagem de 20 *megapixels* gerada com o drone foi transformada em até 294 imagens de 256x256 *pixels* por meio de um algoritmo, e foram posteriormente separados manualmente por dois avaliadores entre imagens que apresentam trincas, e imagens que não apresentam trincas, e divididos entre imagens de treinamento, cerca de 80% do total, e imagens de validação, cerca de 20% restantes.

A separação entre imagens de treinamento e validação ocorreu de forma aleatória para impossibilitar algum viés na escolha das imagens. Através do uso de uma função de semente aleatória o algoritmo definiu um conjunto de imagens, que foi reutilizado em todos os treinamentos, garantindo que as imagens sorteadas fossem sempre as mesmas, e garantindo reprodutibilidade ao algoritmo.

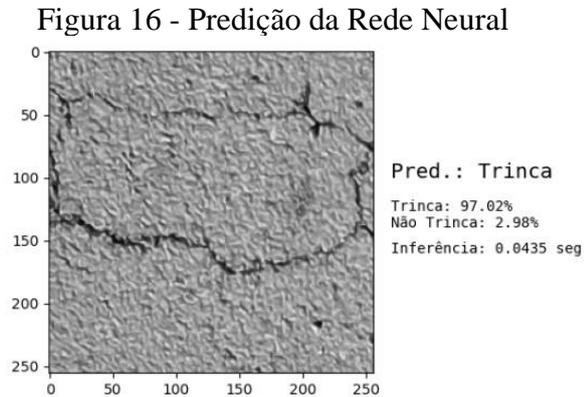
As imagens foram processadas utilizando a linguagem de programação Python, versão 3.0, em conjunto com o *framework* FastAI, versão 2.5.6, o qual fornece diversos componentes de alto nível relacionados a *deep learning*, possibilitando maior rapidez e facilidade no desenvolvimento das redes neurais.

As oito redes selecionadas neste trabalho fazem parte das opções disponíveis no *framework* FastAI, o qual faz a importação de parte dos modelos disponíveis no *framework* Pytorch. Desta forma foi possível realizar o treinamento das redes com a utilização do ambiente *Google Colaboratory*.

3.6 Comparação de Resultados

A comparação dos resultados se deu principalmente por meio da correlação entre as a relação de imagens analisadas corretamente, e o tempo de inferência. Foram, portanto, considerados na análise os valores de precisão, *recall*, *F1-Score* e o tempo despendido para a inferência das imagens.

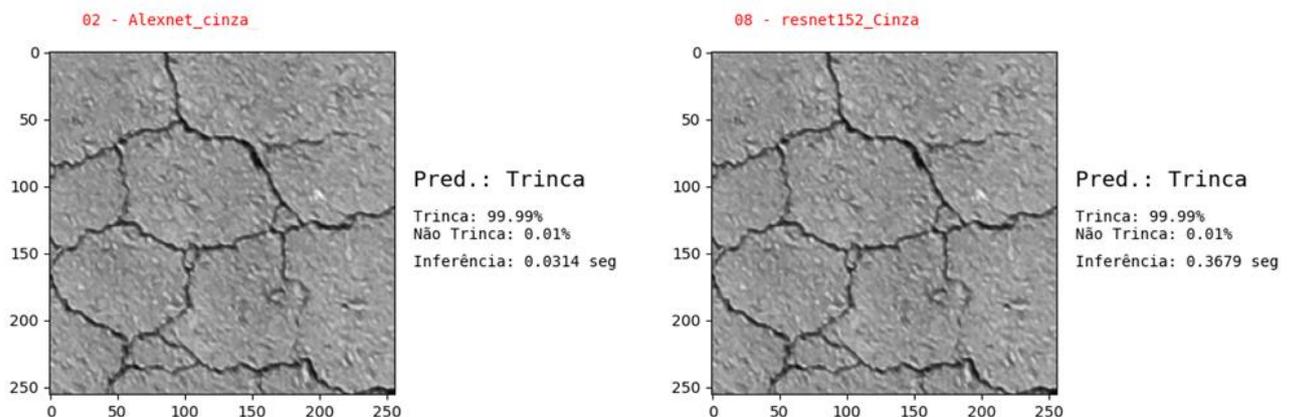
A inferência de cada imagem gera uma nova imagem com o nome da rede responsável pela predição, a categoria na qual ela se encaixa, a porcentagem de certeza de que a rede possui em relação a esta classificação, e o tempo de inferência desta imagem. A Figura 16 demonstra um exemplo de inferência na qual a rede AlexNet fez a inferência em 43 milissegundos, com 97,02% de probabilidade de a predição ser uma trinca.



Fonte: Próprio autor, 2021

A Figura 17 exemplifica a necessidade de levar em consideração, na escolha das melhores redes, o tempo de inferência. Neste exemplo, tanto a rede AlexNet, quanto a rede ResNet152 fizeram a mesma predição correta em relação à imagem, com mesmos valores de certeza sobre a predição, porém, a rede ResNet152 o fez em tempo de inferência cerca de 11 vezes maior, impossibilitando a aplicação prática em tempo real.

Figura 17 - Inferência em duas redes distintas



Fonte: Próprio autor, 2021

Outra informação importante é a abertura detectável pela rede neural, o que está fortemente relacionado com a altura de voo do drone no levantamento e à resolução da imagem.

A Figura 18 demonstra a relação entre a medida real e os *pixels*, de modo que cada *pixel* nas imagens do levantamento representam cerca de 3 milímetros.

Figura 18 - Correlação *pixel*/milímetros



Fonte: Próprio autor, 2021

A Figura 19 resume os procedimentos citados, demonstrando graficamente cada etapa, desde a construção do banco de dados, com o recorte e limpeza dos ruídos, passando pela preparação do *ground truth*, treinamento e otimização, até a definição da rede com as características que melhor se adequem na relação *F1-Score*/Tempo de inferência.

Figura 19 - Resumo dos procedimentos metodológicos utilizados



Fonte: Próprio autor, 2022

Portanto, ao todo foram treinadas 8 arquiteturas diferentes de redes neurais, cada uma com um banco de dados colorido e em escala de cinza, totalizando 16 redes treinadas, e 4 redes otimizadas. As redes diferem na quantidade de camadas e arquiteturas de rede.

Em cada treinamento, obtiveram-se valores de verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos, com os quais calculou-se os valores de acurácia, precisão, *recall* e *F1-Score*.

Pelo fato de a otimização ser um processo computacionalmente custoso, definiu-se que somente as redes neurais com tempo de inferência menor de 100 milissegundos seriam analisadas. A razão desta escolha se deve ao fato de que, mesmo que as redes mais lentas alcançassem acurácia e *F1-Score* máximo, a métrica *F1-Score*/Tempo não sofreria modificação significativa. Desta forma, escolheu-se otimizar as redes Alexnet, SqueezeNet, VGG e MobileNet.

4 RESULTADOS E DISCUSSÃO

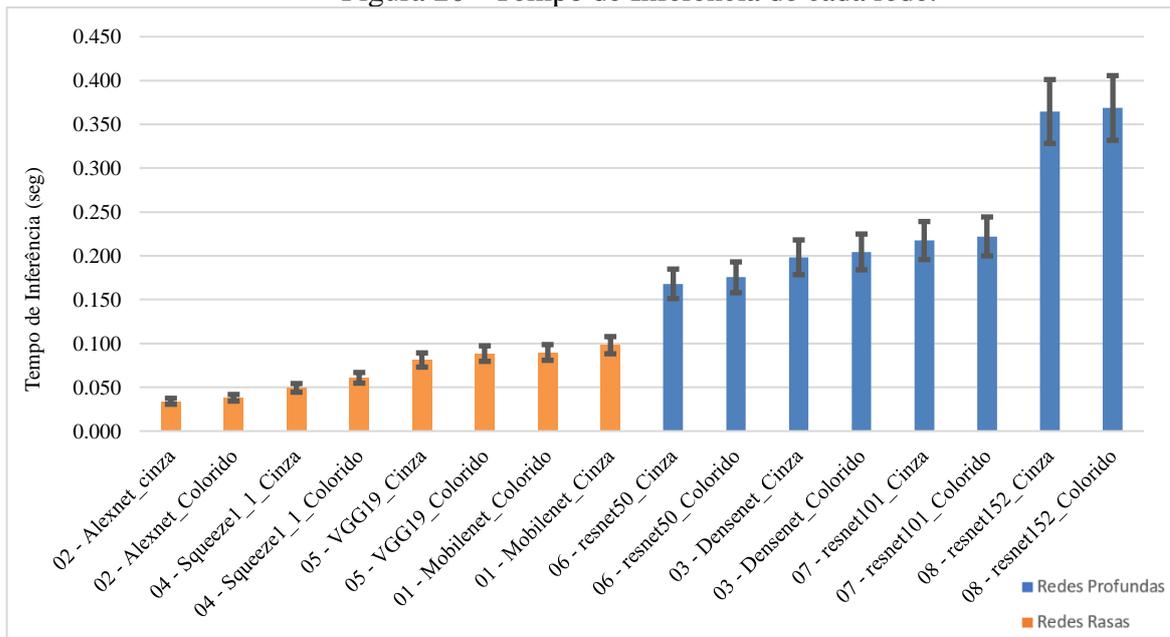
Percebeu-se que as redes neurais treinadas em escala de cinza e as redes treinadas em colorido obtiveram valores de acurácia e *F1-Score* muito próximos, isso pode indicar que imagens de menor qualidade podem ser utilizadas sem grande perda na detecção de trincas.

Além disso, especula-se que imagens advindas de diferentes meios, como por exemplo imagens infravermelhas podem ser utilizadas nas redes treinadas em escala de cinza sem prejuízos de acurácia.

Redes mais profundas, com cerca de 50 camadas, dispenderam muito mais tempo para a inferência, chegando há valores de até 350 milissegundos, enquanto as redes mais rasas, de até 25 camadas, conseguiram processar as imagens em tempos menores, de cerca de 22 milissegundos.

Levou-se em consideração o tempo de inferência de cada imagem testada, e calculou-se a média de tempo que cada rede neural demorou para fazer a inferência de 100 imagens teste. A Figura 20 demonstra em ordem crescente as redes mais rápidas para as mais lentas.

Figura 20 - Tempo de Inferência de cada rede.



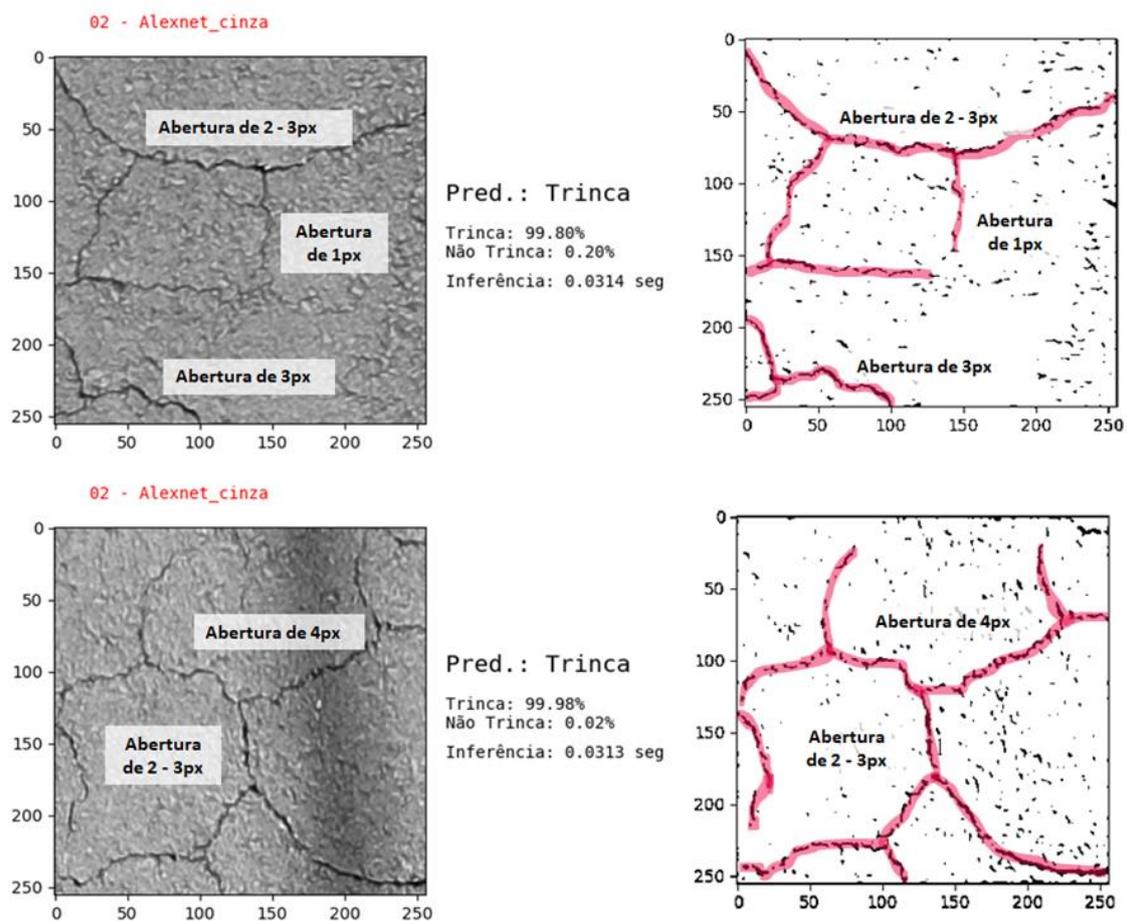
Fonte: Próprio autor, 2021

A rede mais rápida foi a Alexnet treinada com o banco de dados de imagens em escala de cinza, a qual performou com 97,18% de acurácia em 34,07 ms. Do ponto de vista de tempo de inferência, este foi o melhor desempenho, e que obteve a melhor relação de *F1-Score*/Tempo.

4.1 Dimensões detectáveis de trinca

Notou-se que as redes mais rasas somente começam a acertar a predição quando, na imagem a ser inferida, houvesse alguma abertura de trinca acima de 2 *pixels*, equivalentes a 6 milímetros. No caso da Figura 21, em ambas as imagens é visível a ocorrência de trincas de 3 a 4 *pixels*, possibilitando uma predição acertada, com alto grau de confiança e em baixo tempo de inferência.

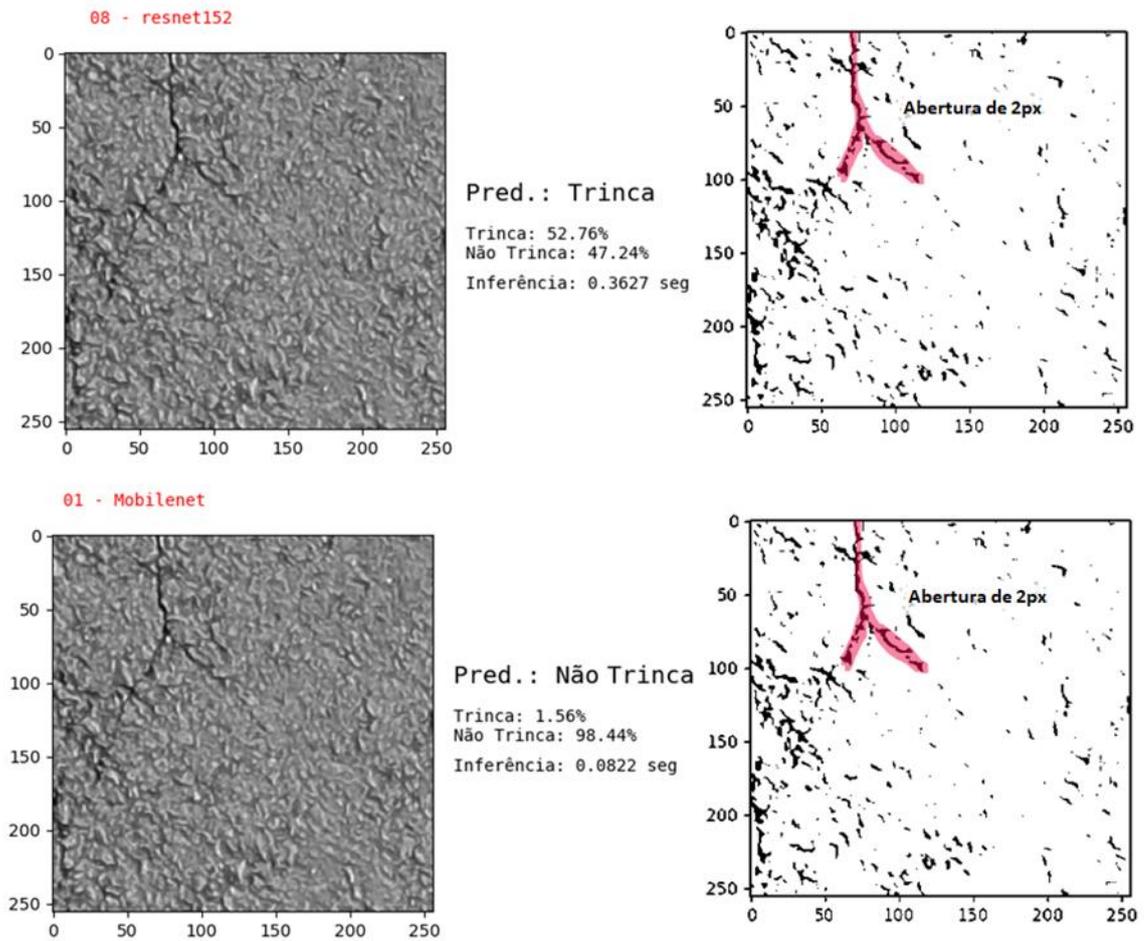
Figura 21 - Abertura de trincas



Fonte: Próprio autor, 2022

Diferentes redes demonstraram sensibilidades diferentes à detecção de trincas pelo tamanho das aberturas. Redes mais superficiais, e com tempo de inferência menor possuem dificuldade em detectar trincas com seis milímetros (2 *px*) ou menos. Por outro lado, redes mais profundas conseguem fazer a detecção de trincas com dois *pixels*, em troca de um tempo de inferência cerca de 11 vezes maior.

Figura 22 - Predição na rede ResNet152 x MobileNet



Fonte: Próprio autor, 2022

Na Figura 22, embora a rede ResNet152 tenha feito inferências corretas em relação a trincas de menor abertura, a confiança da rede de que a resposta esteja correta é baixa, atribuindo valor de 52,70% para a categoria trinca. Por outro lado, para as redes mais superficiais, as trincas de menor abertura resultam em erros consideráveis, com 98,40% atribuído à categoria incorreta.

4.2 MobileNet

A rede MobileNet em escala de cinza performou com tempo médio de inferência de 98,05 ms, acurácia de 96,88% e *F1-Score* de 86,53%. Enquanto a rede colorida teve tempo de inferência de 89,77 ms, acurácia de 96,63% e *F1-Score* de 85,72%. Conforme pode ser visto na Tabela 3.

Tabela 3 - Tabela de valores da rede MobileNet Cinza

MOBILE NET (CINZA)					
Trinca	Verdadeiro Positivo	842		ACURÁCIA	96.89%
Detec. trinca erroneamente	Falso Positivo	100		PRECISÃO	89.38%
Não Trinca	Verdadeiro Negativo	7308		RECALL	83.86%
Detec. não trinca erroneamente	Falso Negativo	162		F1-SCORE	86.54%

Fonte: Próprio autor, 2021

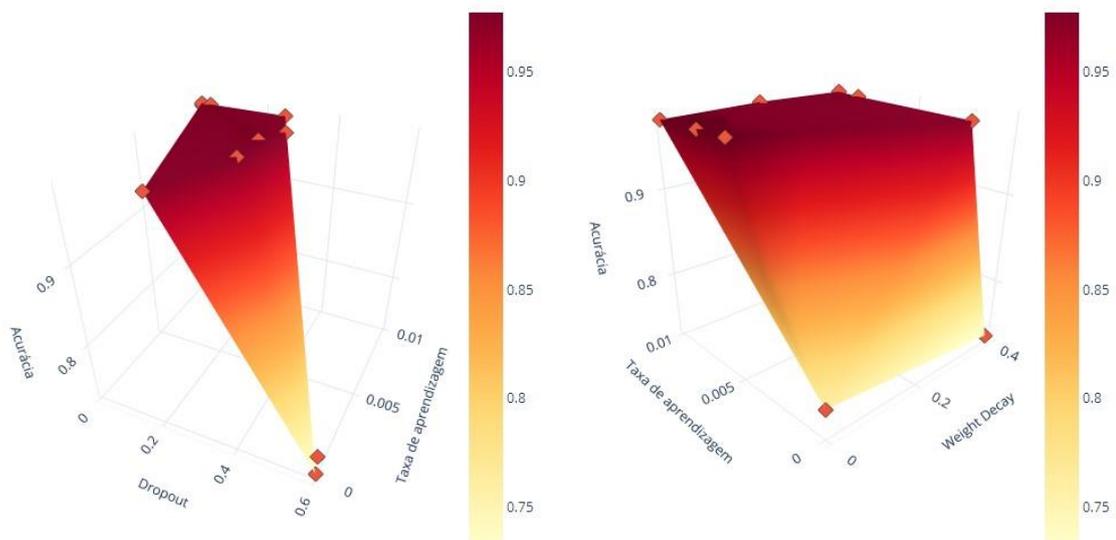
Tabela 4 - Tabela de valores da rede MobileNet Colorido

MOBILE NET (COLORIDO)					
Trinca	Verdadeiro Positivo	850		ACURÁCIA	96.64%
Detec. trinca erroneamente	Falso Positivo	129		PRECISÃO	86.82%
Não Trinca	Verdadeiro Negativo	7279		RECALL	84.66%
Detec. não trinca erroneamente	Falso Negativo	154		F1-SCORE	85.73%

Fonte: Próprio autor, 2021

A rede MobileNet, por ter sido uma das mais rápidas foi escolhida para a etapa de otimização, obtendo os valores de acurácia de 97,71%, com *dropout* de 0,2578, taxa de aprendizado de 0,01 e taxa de decaimento de 0,20. Estes valores demonstram um aumento de 0,82% na acurácia, mantendo o tempo de inferência.

A Figura 23 demonstra a relação entre os hiperparâmetros e a acurácia, sendo uma superfície de busca complexa, formando um platô na relação taxa de aprendizado e taxa de decaimento. Quanto menor os valores de taxa de aprendizado, menor a acurácia, assim como valores muito altos de *dropout* obtiveram valores baixos de acurácia.

Figura 23 - Relação acurácia x taxa de aprendizado x *dropout* e taxa de decaimento

Fonte: Próprio autor, 2021

4.3 AlexNet

A rede AlexNet em escala de cinza performou com tempo médio de inferência de 32,40 ms, acurácia de 97,14% e *F1-Score* de 86,97%. Enquanto a rede colorida teve tempo de inferência de 31,60 ms, acurácia de 97,00% e *F1-Score* de 86,54%. conforme pode ser visto na Tabela 5 e na Tabela 6.

Tabela 5 - Tabela de valores da rede AlexNet Cinza

ALEX NET (CINZA)					
Trinca	Verdadeiro Positivo	804		ACURÁCIA	97.14%
Detec. trinca erroneamente	Falso Positivo	41		PRECISÃO	95.15%
Não Trinca	Verdadeiro Negativo	7367		RECALL	80.08%
Detec. não trinca erroneamente	Falso Negativo	200		F1-SCORE	86.97%

Fonte: Próprio autor, 2021

Tabela 6 - Tabela de valores da rede AlexNet Colorido

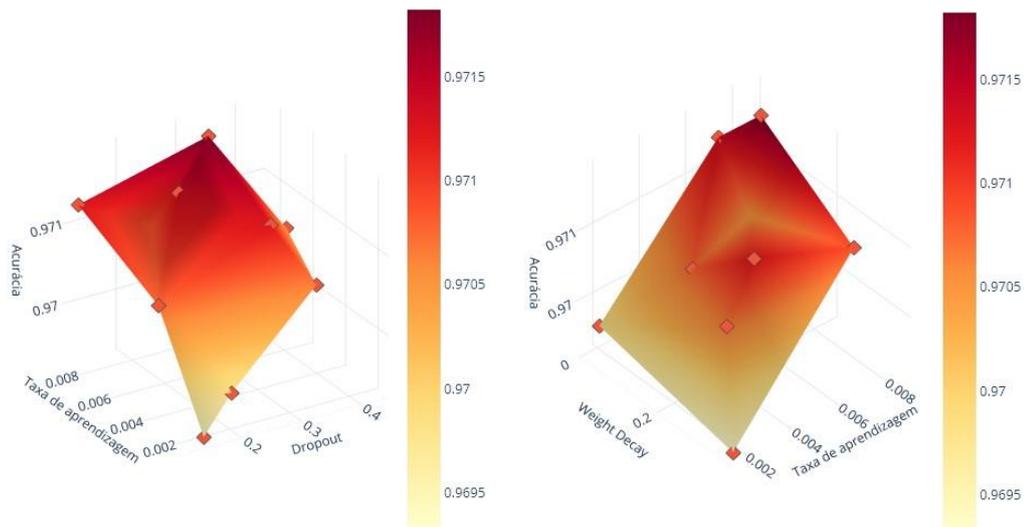
ALEX NET (COLORIDO)					
Trinca	Verdadeiro Positivo	810		ACURÁCIA	97.00%
Detec. trinca erroneamente	Falso Positivo	58		PRECISÃO	93.32%
Não Trinca	Verdadeiro Negativo	7350		RECALL	80.68%
Detec. não trinca erroneamente	Falso Negativo	194		F1-SCORE	86.54%

Fonte: Próprio autor, 2021

A rede AlexNet, por ter sido a mais rápida a performar foi escolhida para a etapa de otimização, obtendo os valores de acurácia de 97,18%, com *dropout* de 0,3240, taxa de aprendizado de 0,0078 e taxa de decaimento de 0,070. Estes valores demonstram um aumento de 0,04% na acurácia, mantendo o tempo de inferência. A Figura 24 demonstra esta relação entre os hiperparâmetros da rede.

Em comparação a valores encontrados na literatura, a rede performou dentro do esperado, resultados similares a Kim (2018), que propôs uma técnica de detecção de trincas em superfícies de concreto, baseando-se em Redes Neurais Convolucionais. Kim (2018) utilizou a rede AlexNet para o treinamento de imagens obtidas da internet, e as classificou em cinco categorias diferentes, sendo elas superfícies intactas, superfícies com diferentes padrões de trincas, e plantas. Concluiu que a técnica proposta é altamente aplicável e adaptável para detecção de trincas *in situ*, com uma acurácia média de 92,35% e *recall* de 89,28%.

Figura 24 - Relação acurácia x taxa de aprendizado x *dropout* e taxa de decaimento AlexNet



Fonte: Próprio autor, 2022

Outro estudo, de Rajadurai (2021) também utilizou a rede AlexNet para a detecção de trincas em superfícies de concreto, treinando sua rede com 2000 imagens, e validando com 4000 imagens. Rajandurai (2021) obteve acurácia, precisão, *recall* e *F1-Score* na inferência de 99,9%. A otimização dos hiperparâmetros foi feita pelo gradiente descendente estocástico.

Pelos bons resultados obtidos no treinamento da rede, e na literatura, pode-se considerar satisfatório o desempenho do treinamento da rede AlexNet na detecção de trincas em pavimentos flexíveis.

4.4 SqueezeNet

A rede SqueezeNet em escala de cinza performou com tempo médio de inferência de 45,26 ms, acurácia de 96,67% e *F1-Score* de 84,32%. Enquanto a rede colorida teve tempo de inferência de 50,25 ms, acurácia de 96,97% e *F1-Score* de 86,54%.

Tabela 7 - Tabela de valores da rede SqueezeNet Cinza

SQUEEZE NET (CINZA)					
Trinca	Verdadeiro Positivo	753		ACURÁCIA	96.67%
Detec. trinca erroneamente	Falso Positivo	29		PRECISÃO	96.29%
Não Trinca	Verdadeiro Negativo	7379		RECALL	75.00%
Detec. não trinca erroneamente	Falso Negativo	251		F1-SCORE	84.32%

Fonte: Próprio autor, 2021

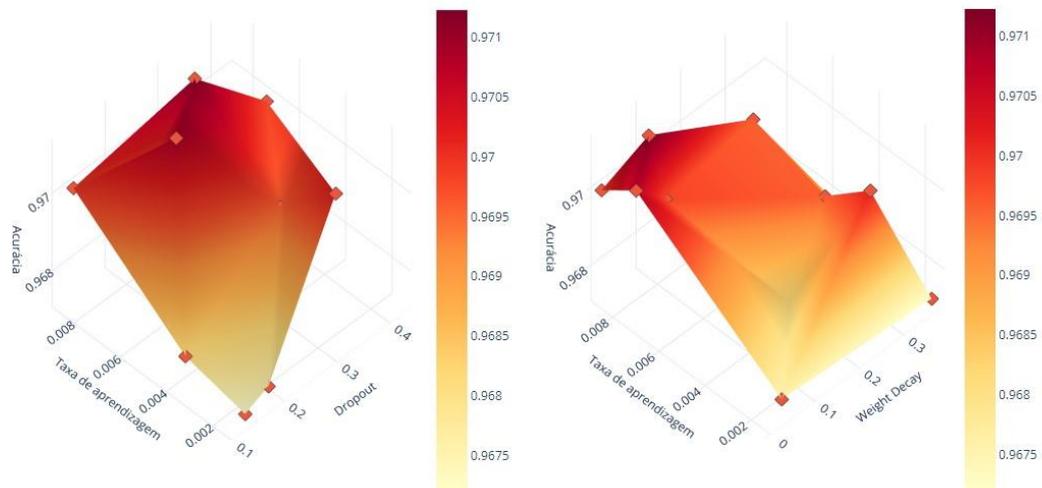
Tabela 8 - Tabela de valores da rede SqueezeNet Colorido

SQUEEZE NET (COLORIDO)					
Trinca	Verdadeiro Positivo	820		ACURÁCIA	96.97%
Detec. trinca erroneamente	Falso Positivo	71		PRECISÃO	92.03%
Não Trinca	Verdadeiro Negativo	7337		RECALL	81.67%
Detec. não trinca erroneamente	Falso Negativo	184		F1-SCORE	86.54%

Fonte: Próprio autor, 2021

A Figura 25 demonstra que a rede SqueezeNet, após etapa de otimização, obteve valores de acurácia de 97,12%, com *dropout* de 0,3240, taxa de aprendizado de 0,0078 e taxa de decaimento de 0,070. Estes valores demonstram um aumento de 0,15% na acurácia, mantendo o tempo de inferência.

Figura 25 – Relação acurácia x taxa de aprendizado x *dropout* e taxa de decaimento SqueezeNet



Fonte: Próprio autor, 2022

4.5 VGG19

A rede VGG19 em escala de cinza performou com tempo médio de inferência de 83,68 ms, acurácia de 97,23% e *F1-Score* de 87,92%. Enquanto a rede colorida teve tempo de inferência de 93,65 ms, acurácia de 97,29% e *F1-Score* de 88,37%.

Tabela 9 - Tabela de valores da rede VGG19 Cinza

VGG19 (CINZA)					
Trinca	Verdadeiro Positivo	848		ACURÁCIA	97.23%
Detec. trinca erroneamente	Falso Positivo	77		PRECISÃO	91.68%
Não Trinca	Verdadeiro Negativo	7331		RECALL	84.46%
Detec. não trinca erroneamente	Falso Negativo	156		F1-SCORE	87.92%

Fonte: Próprio autor, 2021

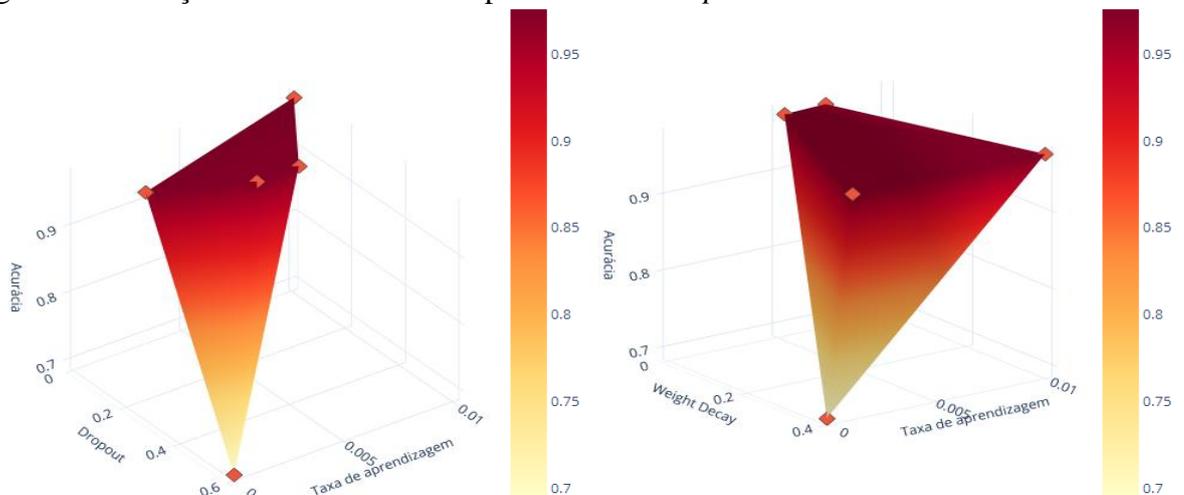
Tabela 10 - Tabela de valores da rede VGG19 Colorido

VGG19 (COLORIDO)					
Trinca	Verdadeiro Positivo	866		ACURÁCIA	97.29%
Detec. trinca erroneamente	Falso Positivo	90		PRECISÃO	90.59%
Não Trinca	Verdadeiro Negativo	7318		RECALL	86.25%
Detec. não trinca erroneamente	Falso Negativo	138		F1-SCORE	88.37%

Fonte: Próprio autor, 2021

A Figura 26 demonstra a busca por hiperparâmetros que levem a maior acurácia para a rede VGG19. Os hiperparâmetros encontrados foram o de acurácia de 97,62%, com *dropout* de 0,01, taxa de aprendizado de 0,01 e taxa de decaimento de 0,4.

Percebe-se que taxas de aprendizagem abaixo de 0,005, relacionadas a valores de *dropout* altos, acima de 0,4, e taxa de decaimento muito altas, valores de 0,4, fazem com que a acurácia da rede apresente um pior desempenho.

Figura 26 - Relação acurácia x taxa de aprendizado x *dropout* e taxa de decaimento VGG19

Fonte: Próprio autor, 2022

4.6 DenseNet

A rede DenseNet em escala de cinza performou com tempo médio de inferência de 186,63 ms, acurácia de 97,19% e *F1-Score* de 87,87%. Enquanto a rede colorida teve tempo de inferência de 193,50 ms, acurácia de 97,03% e *F1-Score* de 87,23%.

Tabela 11 - Tabela de valores da rede DenseNet Cinza

DENSE NET (CINZA)					
Trinca	Verdadeiro Positivo	855		ACURÁCIA	97.19%
Detec. trinca erroneamente	Falso Positivo	87		PRECISÃO	90.76%
Não Trinca	Verdadeiro Negativo	7321		RECALL	85.16%
Detec. não trinca erroneamente	Falso Negativo	149		F1-SCORE	87.87%

Fonte: Próprio autor, 2021

Tabela 12 - Tabela de valores da rede DenseNet Colorido

DENSE NET (COLORIDO)					
Trinca	Verdadeiro Positivo	854		ACURÁCIA	97.03%
Detec. trinca erroneamente	Falso Positivo	100		PRECISÃO	89.52%
Não Trinca	Verdadeiro Negativo	7308		RECALL	85.06%
Detec. não trinca erroneamente	Falso Negativo	150		F1-SCORE	87.23%

Fonte: Próprio autor, 2021

Foi uma das redes com melhores valores de *F1-Score*, indicando boa detecção tanto de trincas quanto de não trincas. Foi somente ultrapassada pelas redes VGG19 e MobileNet. Porém, devido ao grande tempo de inferência, de em média 198 milissegundos, não obteve bons resultados na relação *F1-Score*/Tempo, não sendo selecionada para a etapa de otimização.

4.7 ResNet50

A rede ResNet em escala de cinza performou com tempo médio de inferência de 170,21 ms, acurácia de 96,93% e *F1-Score* de 86,76%. Enquanto a rede colorida teve tempo de inferência de 189,10 ms, acurácia de 97,04% e *F1-Score* de 87,33%.

Tabela 13 - Tabela de valores da rede ResNet50 Cinza

RESNET50 (CINZA)					
Trinca	Verdadeiro Positivo	845		ACURÁCIA	96.93%
Detec. trinca erroneamente	Falso Positivo	99		PRECISÃO	89.51%
Não Trinca	Verdadeiro Negativo	7309		RECALL	84.16%
Detec. não trinca erroneamente	Falso Negativo	159		F1-SCORE	86.76%

Fonte: Próprio autor, 2021

Tabela 14 - Tabela de valores da rede ResNet50 Colorido

RESNET50 (COLORIDO)					
Trinca	Verdadeiro Positivo	858		ACURÁCIA	97.04%
Detec. trinca erroneamente	Falso Positivo	103		PRECISÃO	89.28%
Não Trinca	Verdadeiro Negativo	7305		RECALL	85.46%
Detec. não trinca erroneamente	Falso Negativo	146		F1-SCORE	87.33%

Fonte: Próprio autor, 2021

Outros autores como Chun (2021) utilizaram a rede ResNet50 para a detecção de trincas em pavimentos, coletando imagens de 256 x 256 *pixels* que foram categorizadas incorretamente, para utilizar no treinamento e aprimorar a acurácia.

Porém, apesar da alta acurácia e *F1-Score* a rede ResNet50 obteve tempo de inferência relativamente alto, não obtendo boa relação *F1-Score*/Tempo. A Tabela 13 e Tabela 14 demonstram a quantidade de imagens classificadas pela rede.

4.8 ResNet101

A rede ResNet101 em escala de cinza performou com tempo médio de inferência de 218,70 ms, acurácia de 97,14% e *F1-Score* de 87,66%. Enquanto isso, a rede colorida teve tempo de inferência de 225,42 ms, acurácia de 97,18% e *F1-Score* de 87,71%.

Tabela 15 - Tabela de valores da rede ResNet101 Cinza

RESNET101 (CINZA)					
Trinca	Verdadeiro Positivo	856		ACURÁCIA	97.14%
Detec. trinca erroneamente	Falso Positivo	93		PRECISÃO	90.20%
Não Trinca	Verdadeiro Negativo	7315		RECALL	85.26%
Detec. não trinca erroneamente	Falso Negativo	148		F1-SCORE	87.66%

Fonte: Próprio autor, 2021

Tabela 16 - Tabela de valores da rede ResNet101 Colorido

RESNET101 (COLORIDO)					
Trinca	Verdadeiro Positivo	846		ACURÁCIA	97.18%
Detec. trinca erroneamente	Falso Positivo	79		PRECISÃO	91.46%
Não Trinca	Verdadeiro Negativo	7329		RECALL	84.26%
Detec. não trinca erroneamente	Falso Negativo	158		F1-SCORE	87.71%

Fonte: Próprio autor, 2021

Assim como as outras redes ResNet, foram obtidos bons valores de *F1-Score* e Acurácia, mas os valores de inferência foram muito altos, de em média 221 milissegundos, fazendo com que a relação *F1-Score*/Tempo desta rede fosse a segunda pior colocada.

4.9 ResNet152

A rede ResNet152 em escala de cinza performou com tempo médio de inferência de 361,17 ms, acurácia de 97,15% e *F1-Score* de 87,14%. Enquanto a rede colorida teve tempo de inferência de 367,45 ms, acurácia de 97,24% e *F1-Score* de 87,76%.

Tabela 17 - Tabela de valores da rede ResNet152 Cinza

RESNET152 (CINZA)					
Trinca	Verdadeiro Positivo	813		ACURÁCIA	97.15%
Detec. trinca erroneamente	Falso Positivo	49		PRECISÃO	94.32%
Não Trinca	Verdadeiro Negativo	7359		RECALL	80.98%
Detec. não trinca erroneamente	Falso Negativo	191		F1-SCORE	87.14%

Fonte: Próprio autor, 2021

Tabela 18 - Tabela de valores da rede ResNet152 Colorido

RESNET152 (COLORIDO)					
Trinca	Verdadeiro Positivo	832		ACURÁCIA	97.24%
Detec. trinca erroneamente	Falso Positivo	60		PRECISÃO	93.27%
Não Trinca	Verdadeiro Negativo	7348		RECALL	82.87%
Detec. não trinca erroneamente	Falso Negativo	172		F1-SCORE	87.76%

Fonte: Próprio autor, 2021

A ResNet152, assim como as outras redes ResNet, obteve valores altos de inferência, e por este motivo foi a pior rede na relação *F1-Score*/Tempo. Esta rede chegou a valores de inferência cerca de 11 vezes mais lento do que a rede AlexNet, considerada a mais rápida.

4.10 Ordenamento dos resultados

A Tabela 19 demonstra o compilado dos resultados obtidos, com valores de tempo de inferência, acurácia, *F1-Score* e Relação *F1-Score*/Tempo. Nesta tabela estão consideradas apenas as redes anteriores ao processo de otimização.

Tabela 19 - Ordenação das redes com melhor relação F1/Tempo

Rede	Tempo (ms)	Acurácia	F1-SCORE	Relação F1/Tempo
02 - Alexnet_cinza	34.07	97.14%	86.97%	2.55
02 - Alexnet_Colorido	38.02	97.00%	86.54%	2.28
04 - Squeeze1_1_Cinza	49.34	96.67%	84.32%	1.71
04 - Squeeze1_1_Colorido	60.83	96.97%	86.54%	1.42
05 - VGG19_Cinza	81.15	97.23%	87.92%	1.08
05 - VGG19_Colorido	88.50	97.29%	88.37%	1.00
01 - Mobilenet_Colorido	89.77	96.64%	85.73%	0.95
01 - Mobilenet_Cinza	98.05	96.89%	86.54%	0.88
06 - Resnet50_Cinza	168.08	96.93%	86.76%	0.52
06 - Resnet50_Colorido	175.50	97.04%	87.33%	0.50
03 - Densenet_Cinza	198.33	97.19%	87.87%	0.44
03 - Densenet_Colorido	204.43	97.03%	87.23%	0.43
07 - Resnet101_Cinza	217.41	97.14%	87.66%	0.40
07 - Resnet101_Colorido	222.12	97.18%	87.71%	0.39
08 - Resnet152_Cinza	364.66	97.15%	87.14%	0.24
08 - Resnet152_Colorido	368.71	97.24%	87.76%	0.24

Fonte: Próprio autor, 2021

Após a otimização das redes neurais propostas, a ordenação das melhores redes mudou. Porém, o ganho com a otimização dos hiperparâmetros foi menor do que o esperado, tendo em alguns casos obtido aumento de acurácia de 0,04%.

Tabela 20 - Ordenação das redes com melhor relação F1/Tempo, considerando otimização

Rede	Tempo (ms)	Acurácia	F1-SCORE	Relação F1/Tempo
02 - Alexnet_cinza	34.07	97.14%	86.966%	2.55%
02 - Alexnet_Otimizado	35.26	97.18%	87.210%	2.47%
02 - Alexnet_Colorido	38.02	97.00%	86.538%	2.28%
04 - Squeeze1_1_Otimizado	50.35	97.12%	87.100%	1.73%
04 - Squeeze1_1_Cinza.pkl	49.34	96.67%	84.323%	1.71%
04 - Squeeze1_1_Colorido.pkl	60.83	96.97%	86.544%	1.42%
05 - VGG19_Otimizado	80.68	97.62%	88.390%	1.10%
05 - VGG19_Cinza.pkl	81.15	97.23%	87.921%	1.08%
05 - VGG19_Colorido.pkl	88.50	97.29%	88.367%	1.00%
01 - Mobilenet_Colorido.pkl	89.77	96.64%	85.729%	0.95%
01 - Mobilenet_Otimizado	96.55	97.71%	89.340%	0.93%
01 - Mobilenet_Cinza.pkl	98.05	96.89%	86.536%	0.88%

Fonte: Próprio autor, 2021

Caso o único parâmetro analisado fosse a acurácia, a rede Mobilenet otimizada e VGG19 otimizada seriam as com melhor desempenho nesse quesito, tendo obtido valores, respectivamente de 97,71% e 97,62%. Uma melhora de cerca de 0,33% em relação ao mais bem colocado sem otimização.

O *F1-Score* obteve resultados similares, com as redes Mobilenet e VGG19 otimizadas tendo o melhor desempenho em relação as demais. Obtendo valores 0,97% melhores em relação ao mais bem colocado sem a utilização da otimização.

A utilização da otimização foi bem-sucedida, melhorando os valores de acurácia e *F1-Score* das redes neurais. Porém, percebeu-se que valores muito altos de *dropout*, entre 0,4 e 0,6 baixaram significativamente a acurácia das redes, para valores de 69% a 75%.

A queda na acurácia pelos altos valores de *dropout* podem ser explicados pela alta porcentagem de neurônios que foram eliminados (40 a 60%), fazendo com que a rede perdesse a capacidade de fazer mais conexões, e assim, performar adequadamente.

Houve também a tendência de queda na acurácia para valores de taxa de aprendizado muito baixas, para valores abaixo de 0,01. Isso se deve ao fato de a rede não conseguir convergir a tempo, necessitando de mais épocas do que o utilizado para alcançar valores razoáveis.

A taxa de decaimento não demonstrou tanta influência quanto os outros dois parâmetros, sendo dependente do *dropout* e taxa de aprendizado. Obtendo bons resultados tanto em valores baixos, de 0,07, como valores mais altos, de 0,20.

Ao levar em consideração a relação *F1-Score*/Tempo, não foi perceptível melhoria de desempenho do uso da otimização, pois as redes otimizadas performavam com tempos de inferência muito próximos as redes sem otimização.

Outras redes, como SqueezeNet e MobileNet obtiveram grande melhora nos valores de *F1-Score*, tendo um aumento, respectivamente, de 2,77% e 3,61%. Mesmo com grande melhora, a relação *F1*/Tempo não foi afetada, pois os tempos de inferência permaneceram os mesmos.

Através dos resultados das inferências sobre o banco de dados, conseguiu-se compreender melhor o comportamento da rede neural, sendo que na maioria dos casos, os erros tornariam os valores do índice do pavimento mais arrojados, ou seja, os erros ocorreram muito mais na detecção de falsos negativos, inserindo maior número de imagens consideradas não-trincas pela rede, mas que verdadeiramente são trincas.

Esse tipo de erro pode influenciar na tomada de decisões na escolha por uma determinada rede neural em detrimento a outra. A consideração entre verdadeiros positivos e

falsos negativos é chamada *recall*, conforme equação 3, e demonstra quão boa a rede é para lidar com valores positivos, neste caso, detecção de trincas verdadeiras.

Por fim, levando em consideração todas as redes analisadas neste trabalho, a AlexNet treinada em escala de cinza foi a que obteve melhores valores de Relação-F1/Tempo. Ligeiramente melhor do que a versão otimizada, por ter valores de inferência de cerca de 1 milissegundo mais rápido.

Os resultados obtidos neste trabalho estão em concordância com os encontrados por Nguyen (2021), o qual propôs um índice para relacionar o custo computacional com a acurácia, de forma a encontrar o melhor método para classificação de trincas. Baseando-se no índice proposto o autor também selecionou a rede AlexNet como a mais eficiente dentre as redes Inception-V3 e ResNet-101.

Jiale (2022) realizou aplicações em tempo real com detecção de trincas com tempos de processamento de 47 milissegundos, o que demonstra possibilidade de aplicação da rede AlexNet, e a importância do tempo de inferência na seleção da rede neural. A escolha da melhor rede neural para a detecção de trincas está condicionada a finalidade a qual a mesma se propõe, podendo ter maior influência do tempo de inferência, ou da acurácia.

5. CONCLUSÃO

Com a abordagem da consideração dos parâmetros de *F1-Score* e tempo de inferência, e ao analisar todas as 16 redes neurais sem otimização, e mais 4 redes otimizadas, pode-se concluir que a rede AlexNet treinada em escala de cinza, com 97,14% de acurácia, 86,96% de *F1-Score* se sobressaiu em relação as demais devido ao seu baixo tempo de inferência, de cerca de 36 milissegundos, valor que possibilita sua utilização em detecções de trincas em pavimentos em tempo real.

Estes resultados estão em consonância com pesquisas recentes sobre a detecção de trincas, como Jiale (2022), que utilizou processamento de imagens em tempo real em uma rede neural com tempo de inferência de 47 milissegundos, obtendo acurácia de 98% na detecção de trincas.

A acurácia da rede AlexNet proposta, em relação com a proposta por Jiale (2022) é cerca de 0,86% menor, porém, a rede proposta neste trabalho performa mais rapidamente, de forma que a relação entre o acerto na classificação das imagens e o tempo permanece sendo mais alto.

Pelo fato da rede Alexnet ter alcançado valores de acurácia e *F1-Score* relativamente altos, fazendo do valor relação *F1-Score* / Tempo o maior de todas as redes testadas. A relação da rede Alexnet performou 47,54% melhor do que a rede SqueezeNet, colocada em segundo lugar.

Recomenda-se para próximos trabalhos testar banco de dados com imagens retiradas de equipamentos com utilização de tecnologia infravermelha para validação das redes propostas, assim como testar a aplicabilidade das redes neurais na utilização em tempo real na detecção de trincas, e testar um maior número de arquiteturas e métodos de otimização.

REFERÊNCIAS BIBLIOGRÁFICAS

ALVARENGA W. **Métodos De Otimização Hiperparamétrica: Um Estudo Comparativo Utilizando Árvores De Decisão E Florestas Aleatórias Na Classificação Binária.** 2018. Dissertação de Mestrado.

BASTOS, G. A. **Comportamento mecânico de misturas asfálticas reforçadas com geogrelhas para pavimentos flexíveis.** Dissertação de mestrado – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Civil, 2010

BERGSTRA, J. e BENGIO, Y. **Random search for hyper-parameter optimization.** Journal of Machine Learning Research, 2012.

CHUN, P.; YAMANE, T.; TSUZUKI, Y. **Automatic Detection of Cracks in Asphalt Pavement Using Deep Learning to Overcome Weaknesses in Images and GIS Visualization.** *Appl. Sci.* **2021**, *11*, 892. <https://doi.org/10.3390/app11030892>

CONDORI, H.; CRUZ, J.; MACHACA W. **ResNet neural network hyperparameter tuning for Rigid Pavement Failure Assessment.** IEEE 15th International Symposium on Applied Computational Intelligence and Informatics. 2021

CONFEDERAÇÃO NACIONAL DO TRANSPORTE (CNT). **Pesquisa CNT de Rodovias 2021.** 234 p. CDU 656.11(81)(047) Brasília: CNT, SEST, SENAT, 2021.

CLOUD GOOGLE. **Visão geral do ajuste de hiperparâmetros.** Disponível em: <<https://cloud.google.com/ai-platform/training/docs/hyperparameter-tuning-overview?hl=pt-br>> Acessado em: 20/11/2020

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTES – DNIT. **005/2003 – TER.** Defeitos nos pavimentos flexíveis e semirrígidos - Terminologia. Diretoria de Planejamento e Pesquisa. Instituto de Pesquisas Rodoviárias. Rio de Janeiro, 2003a.

_____. **008/2003 – PRO.** Levantamento visual contínuo para avaliação da superfície de pavimentos flexíveis e semi-rígidos – Procedimento. Diretoria de Planejamento e Pesquisa. Instituto de Pesquisas Rodoviárias. Rio de Janeiro, 2003b.

FAVRETTO, L. **Análise Do Desempenho De Uma Rede Neural Convolutacional Na Detecção De Trincas Em Pavimentos Flexíveis.** 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Faculdade de Engenharia e Arquitetura, Universidade de Passo Fundo, Passo Fundo, 2019.

FENG C, ZHANG H, WANG H, WANG S, LI Y. Automatic Pixel-Level Crack Detection on Dam Surface Using Deep Convolutional Network. *Sensors (Basel)*. 2020;20(7):2069. Published 2020 Apr 7. doi:10.3390/s20072069

HAYKIN, S. **Redes neurais: princípios e prática.** 2 ed. Porto Alegre: Bookman, 2001.

HE, K.; ZHANG, X.; REN, S.; SUN, J. **Spatial pyramid pooling in deep convolutional networks for visual recognition**. IEEE transactions on pattern analysis and machine intelligence, IEEE, v. 37, n. 9, p. 1904–1916, 2015.

HOANG, N.; NGUYEN, Q.; TRAN, V. Automatic recognition of asphalt pavement cracks using metaheuristic optimized edge detection algorithms and convolution neural network. **Automation in Construction**, v. 94, July 2018

HUANG, Gao. Densely connected convolutional networks. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2017. p. 4700-4708.

HOWARD, A. G.; ZHU, M.; CHEN, B.; KALENICHENKO, D.; WANG, W.; WEYAND, T.; ANDREETTO, M.; ADAM, H. **Mobilenets: Efficient convolutional neural networks for mobile vision applications**. arXiv preprint arXiv:1704.04861, 2017.

JIALE, L., TAO L., XUEFEI W., JANYOU Y. **Automated asphalt pavement damage rate detection based on optimized GA-CNN**, Automation in Construction, Volume 136, 2022.

KIM, B.; CHO, S. **Automated Vision-Based Detection of Cracks on Concrete Surfaces Using a Deep Learning Technique**. Sensors 2018, 18, 3452. <https://doi.org/10.3390/s18103452>

KHAN, S., HAYAT, M., & PORIKLI, F. **Regularization of Deep Neural Networks with Spectral Dropout**. Neural networks: the official journal of the International Neural Network Society, 2019.

KHAN, S., RAHMANI H., SHAH S., BENNAMOUN, M., **A Guide to Convolutional Neural Networks for Computer Vision**, Morgan & Claypool, 2018, doi: 10.2200/S00822ED1V01Y201712COV015, 2018.

LEAL, R. **Métricas Comuns em Machine Learning**. 2017. Disponível em: <<https://medium.com/as-máquinas-que-pensam/métricas-comuns-em-machine-learning-como-analisar-a-qualidade-de-chat-bots-inteligentes-métricas-1ba580d7cc96>> Acessado em: 20/11/2020

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep Learning**. Nature, v. 521, 2015. <https://doi:10.1038/nature14539>

LI, S.; CAO, Y.; CAI, H. Automatic Pavement-Crack Detection and Segmentation Based on Steerable Matched Filtering and an Active Contour Model. Journal of Computing in Civil Engineering, v.31, n.5, sept. 2017. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000695](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000695)

LIMA, J. P.; RAMOS, R. A. R.; FERNANDES JUNIOR, J. L. **A prática de gestão de pavimentos em cidades médias brasileiras**. In: **Congresso Luso-Brasileiro para o Planeamento Urbano, Regional, Integrado e Sustentável**, 2, 2006, Braga, Portugal. Anais do Pluris, Braga, Portugal: Universidade do Minho, 2006.

LIZOTTE, D. **Practical Bayesian Optimization**. PhD thesis, University of Alberta, Edmonton, Alberta, 2008.

MACKAY, D. J. **A practical Bayesian framework for backpropagation networks.** *Neural computation*, 4(3):448–472, 1992.

MIURA, L. 2020. **Modelos de Predição | Otimização de Hiperparâmetros em Python.** Disponível em: <<https://medium.com/turing-talks/modelos-de-predi%C3%A7%C3%A3o-otimiza%C3%A7%C3%A3o-de-hiperpar%C3%A2metros-em-python-3436fc55016e>> Acessado em: 20/11/2020

MOCKUS, J., TIESIS, V., and ZILINSKAS, A. **The application of Bayesian methods for seeking the extremum.** *Towards Global Optimization*, 2, 1978.

NOGUEIRA, F. **Bayesian Optimization: Open source constrained global optimization tool for Python.** Disponível em: <<https://github.com/fmfn/BayesianOptimization>> Acessado em: 03/02/2022

NGUYEN, N. H. T., PERRY, S., BONE, D., LE, H. T., & NGUYEN, T. T.. **Two-stage convolutional neural network for road crack detection and segmentation.** *Expert Systems with Applications*, 186, 115718. doi:10.1016/j.eswa.2021.115718 (2021)

NGUYEN, A., CHIANESE, R. GHAREHBAGHI V. R., ARAVINTHAN T., NOORI M. Influence of image noise on crack detection performance of deep convolutional neural networks. *Proceedings of the 10th International Conference on Structural Health Monitoring of Intelligent Infrastructure, SHMII, 2021*

MCGHEE, K. 2004. **NCHRP Synthesis of Highway Practice 334: Automated Pavement Distress Collection Techniques.** Transportation Research Board of the National Academies, Washington DC.

PAULY, L.; PEEL, H.; LUO, S.; HOGG, D.; FUENTES, R. **Deeper Networks for Pavement Crack Detection.** *In: INTERNATIONAL SYMPOSIUM ON AUTOMATION AND ROBOTICS IN CONSTRUCTION, 2017, Taipei.* Proceedings [...]. IAARC, 2017, p. 479-485.

PIERCE, L. M.; WEITZEL, N. D. **Automated Pavement Condition Surveys.** Washington, DC: The National Academies Press, 2019. 122 p. <https://doi.org/10.17226/25513>

RADOPOULOU, S.; BRILAKIS, I. **Automated Detection of Multiple Pavement Defects.** *Journal of Computing in Civil Engineering*, v.31, n.2, mar. 2017. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000623](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000623)

RAJADURAI, R., KANG S.. **Automated Vision-Based Crack Detection on Concrete Surfaces Using Deep Learning.** *Applied Sciences* 11.112021

REIS C. **Otimização de Hiperparâmetros em Redes Neurais Profundas.** Trabalho de Conclusão de Curso. 2018

RODRIGUES, V. B. **Uso de Redes Neurais para Reconhecimento de Trincas em Pavimentos Flexíveis.** 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Faculdade de Engenharia e Arquitetura, Universidade de Passo Fundo, Passo Fundo, 2019.

RUIZ, P. **Understanding and visualizing DenseNets**. 2018 Disponível em: <<https://towardsdatascience.com/understanding-and-visualizing-densenets-7f688092391a>> Acessado em: 03/02/2022

SAMARASINGHE, S. **Neural Networks por Applied Sciences and Engineering: from fundamentals to complex pattern recognition**. New York: Auerbach Publications, 2006.

SNOEK, J. *et al.* **Scalable bayesian optimization using deep neural networks**. In: International conference on machine learning. PMLR, 2015. p. 2171-2180.

SOUZA, C. **Usando convolução separável em profundidade na otimização da arquitetura squeezeNet**. Dissertação de Mestrado, Recife, 2020

SIMONYAN, K.; ZISSERMAN, A. **Very deep convolutional networks for large-scale image recognition**. arXiv preprint arXiv:1409.1556, 2014.

TRIGGS, B, DALAL, N. **Histograms of oriented gradients for human detection**. In IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005.

XU, H.; SU, X.; WANG, Y.; CAI, H.; CUI, K.; CHEN, X. **Automatic Bridge Crack Detection Using a Convolutional Neural Network**. *Appl. Sci.* 2019, 9, 2867. <https://doi.org/10.3390/app9142867>

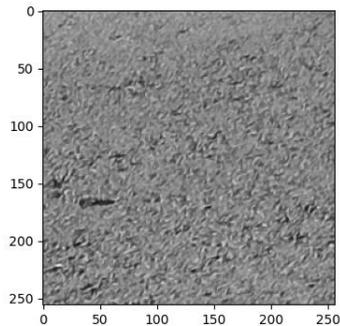
ZHANG, A., WANG, C. P., **Automated Pixel-Level Pavement Crack Detection on 3D Asphalt Surfaces Using a Deep-Learning Network**. *Computer-Aided Civil and Infrastructure Engineering*, 2017.

ZHENG, Y.; YANG, C; MERKULOV, A. **Breast cancer screening using convolutional neural network and follow-up digital mammography**. 4. 10.1117/12.2304564. 2018

ZHOU, S. **Deep learning-based roadway crack classification using laser-scanned range images: A comparative study on hyperparameter selection**. *Automation in Construction*, Elsevier Publications, 2020.

ANEXO

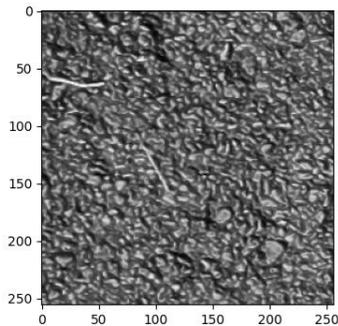
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1109 seg

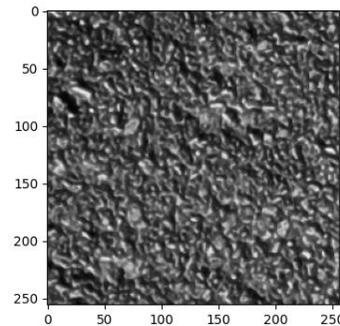
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1158 seg

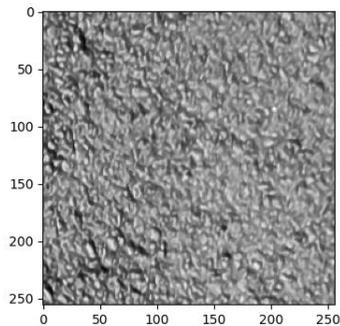
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1085 seg

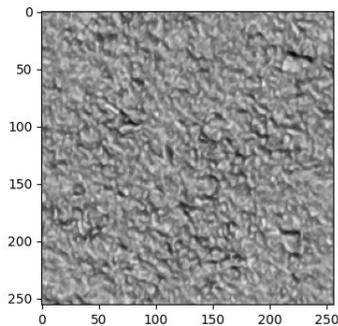
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1173 seg

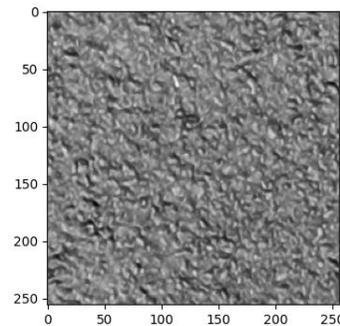
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1238 seg

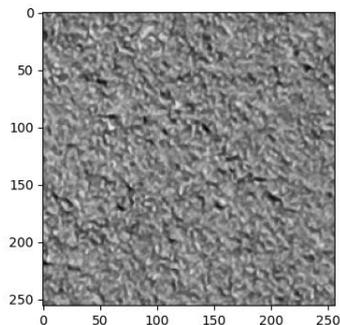
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1092 seg

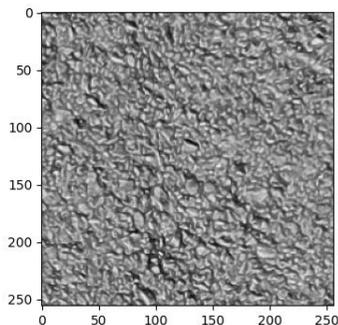
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1307 seg

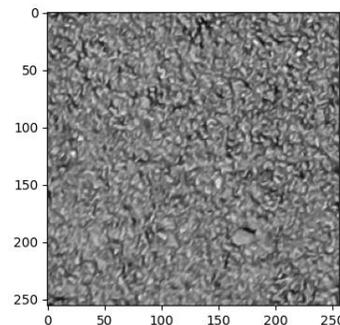
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1127 seg

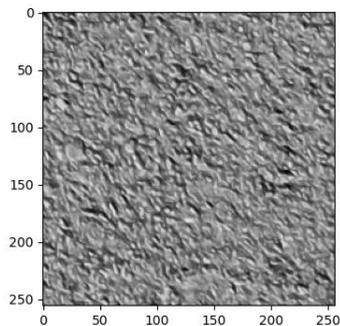
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1119 seg

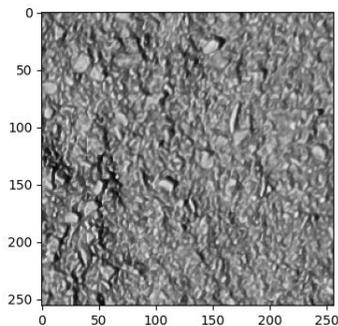
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1097 seg

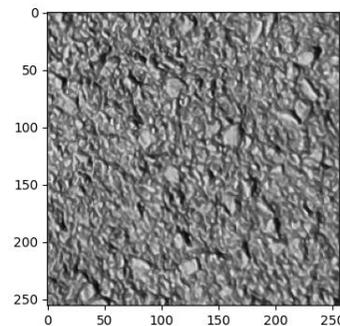
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 1.12%
Não Trinca: 98.88%
Inferência: 0.1079 seg

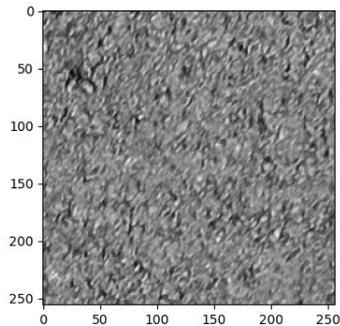
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1104 seg

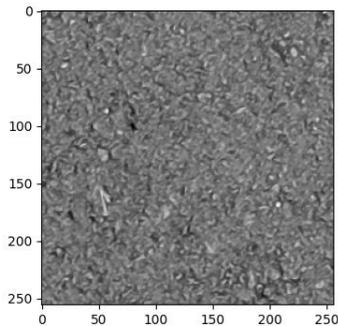
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1256 seg

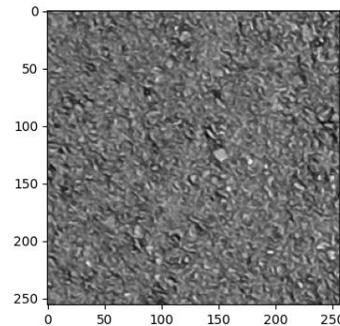
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.109 seg

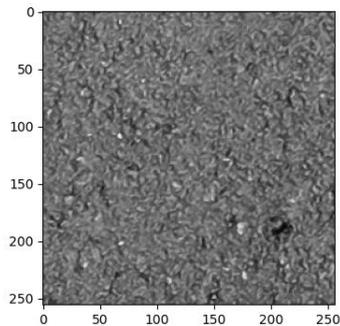
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1186 seg

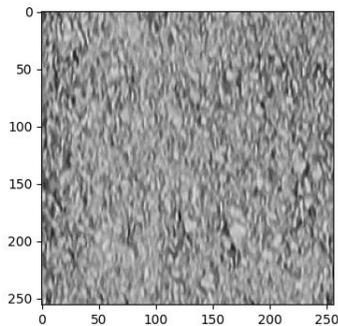
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1037 seg

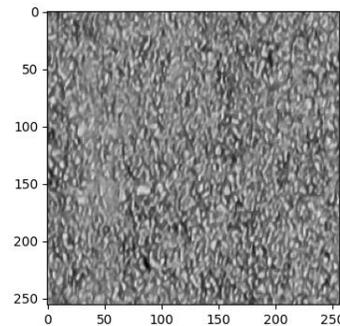
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1093 seg

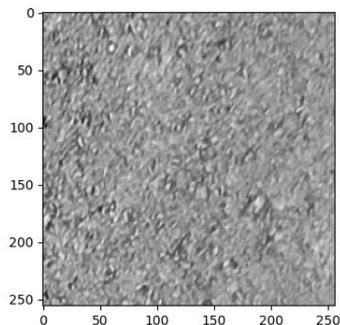
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1073 seg

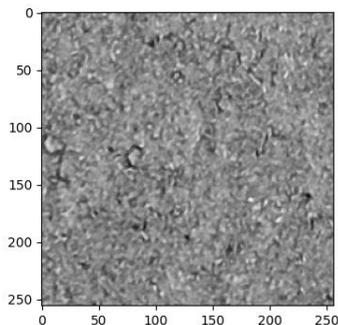
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.1034 seg

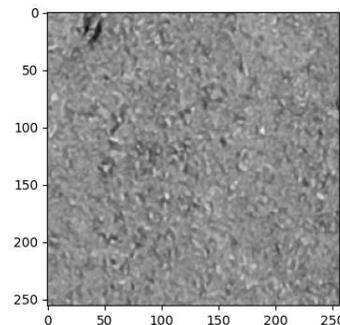
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1063 seg

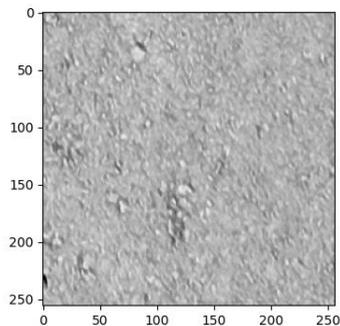
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.1425 seg

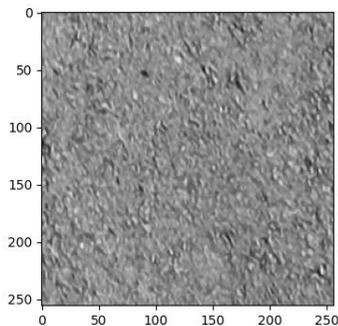
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1045 seg

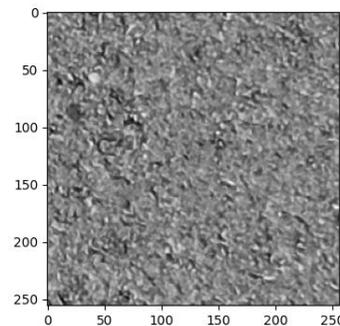
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1067 seg

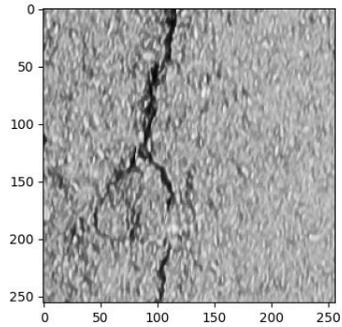
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

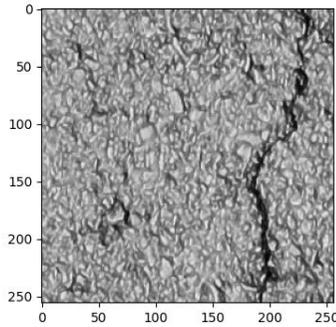
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1037 seg

01 - Mobilenet_Cinza_30092021.pkl



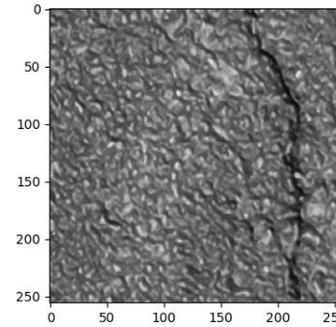
Pred.: Trinca
Trinca: 53.23%
Não Trinca: 46.77%
Inferência: 0.1127 seg

01 - Mobilenet_Cinza_30092021.pkl



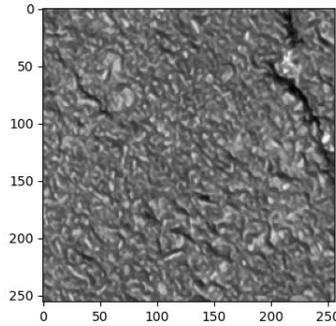
Pred.: Não Trinca
Trinca: 47.25%
Não Trinca: 52.75%
Inferência: 0.1121 seg

01 - Mobilenet_Cinza_30092021.pkl



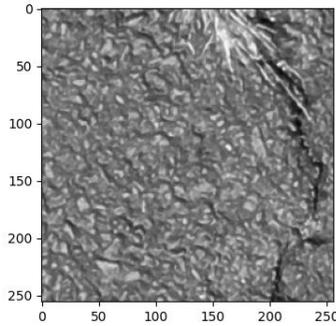
Pred.: Trinca
Trinca: 51.03%
Não Trinca: 48.97%
Inferência: 0.1075 seg

01 - Mobilenet_Cinza_30092021.pkl



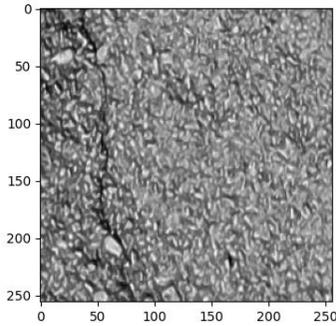
Pred.: Não Trinca
Trinca: 22.64%
Não Trinca: 77.36%
Inferência: 0.1051 seg

01 - Mobilenet_Cinza_30092021.pkl



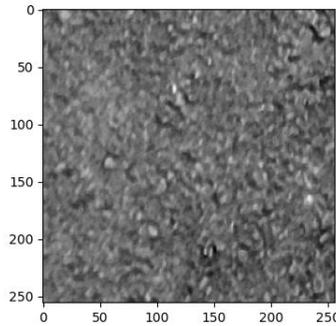
Pred.: Não Trinca
Trinca: 42.96%
Não Trinca: 57.04%
Inferência: 0.1095 seg

01 - Mobilenet_Cinza_30092021.pkl



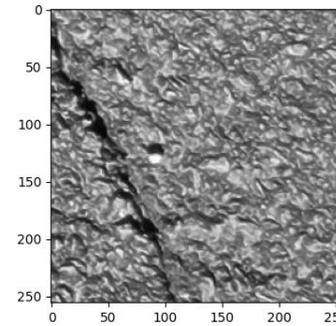
Pred.: Não Trinca
Trinca: 23.73%
Não Trinca: 76.27%
Inferência: 0.1072 seg

01 - Mobilenet_Cinza_30092021.pkl



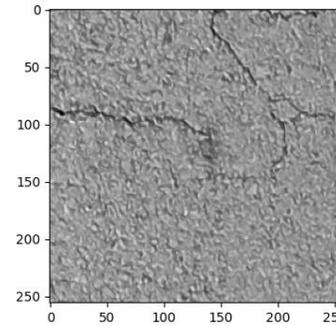
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.115 seg

01 - Mobilenet_Cinza_30092021.pkl



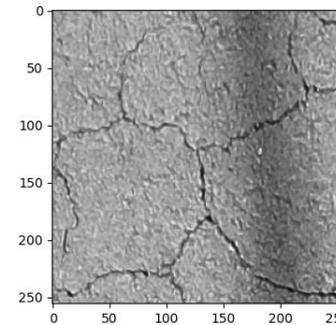
Pred.: Trinca
Trinca: 87.52%
Não Trinca: 12.48%
Inferência: 0.1084 seg

01 - Mobilenet_Cinza_30092021.pkl



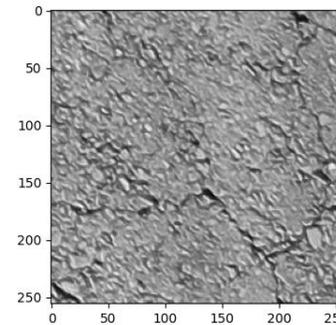
Pred.: Trinca
Trinca: 99.15%
Não Trinca: 0.85%
Inferência: 0.1054 seg

01 - Mobilenet_Cinza_30092021.pkl



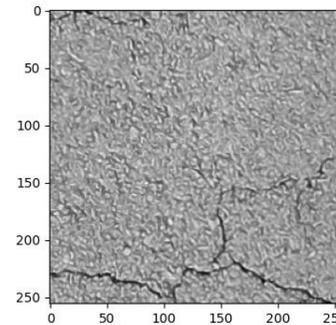
Pred.: Trinca
Trinca: 99.94%
Não Trinca: 0.06%
Inferência: 0.1079 seg

01 - Mobilenet_Cinza_30092021.pkl

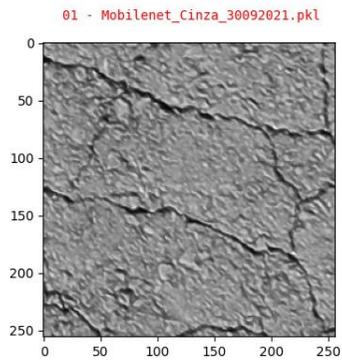


Pred.: Trinca
Trinca: 71.39%
Não Trinca: 28.61%
Inferência: 0.1147 seg

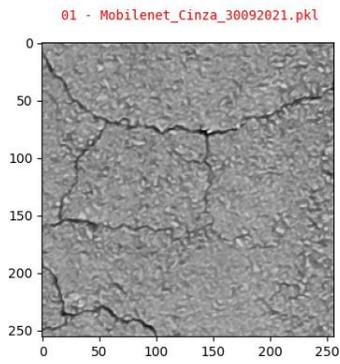
01 - Mobilenet_Cinza_30092021.pkl



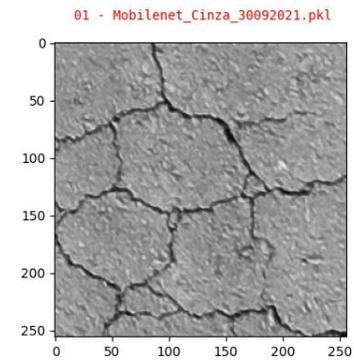
Pred.: Trinca
Trinca: 98.49%
Não Trinca: 1.51%
Inferência: 0.1046 seg



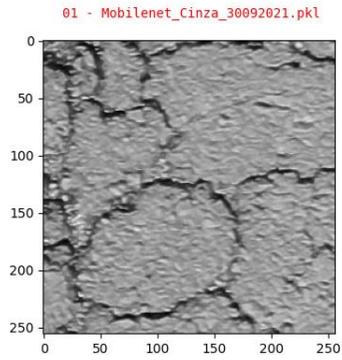
Pred.: Trinca
Trinca: 99.89%
Não Trinca: 0.11%
Inferência: 0.1057 seg



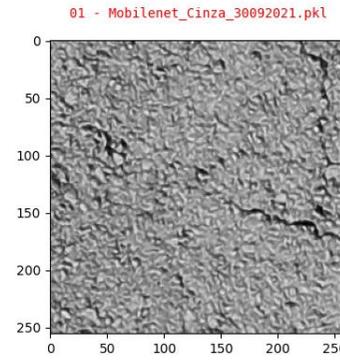
Pred.: Trinca
Trinca: 99.98%
Não Trinca: 0.02%
Inferência: 0.1047 seg



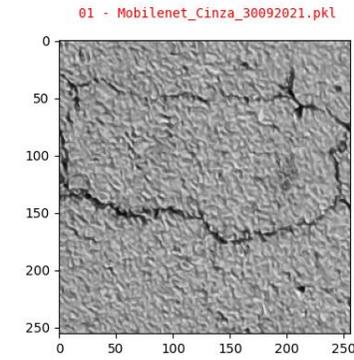
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.0796 seg



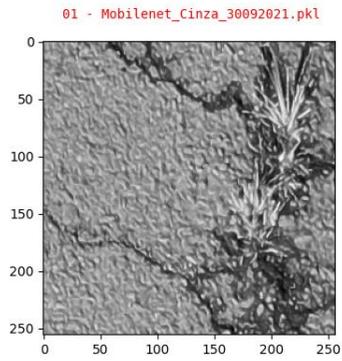
Pred.: Trinca
Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.0904 seg



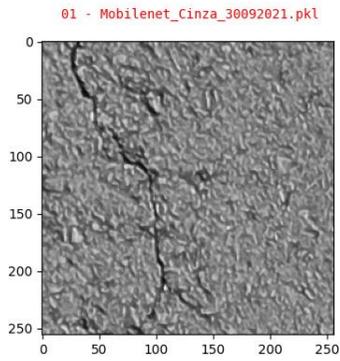
Pred.: Trinca
Trinca: 63.27%
Não Trinca: 36.73%
Inferência: 0.12 seg



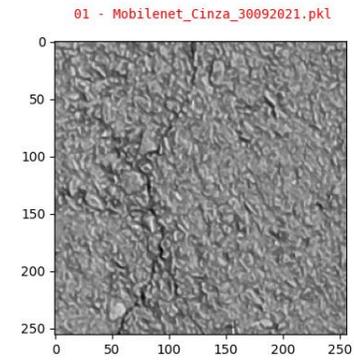
Pred.: Trinca
Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.085 seg



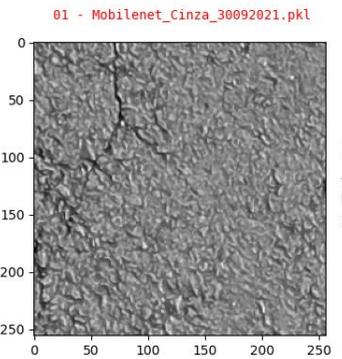
Pred.: Trinca
Trinca: 98.09%
Não Trinca: 1.91%
Inferência: 0.0771 seg



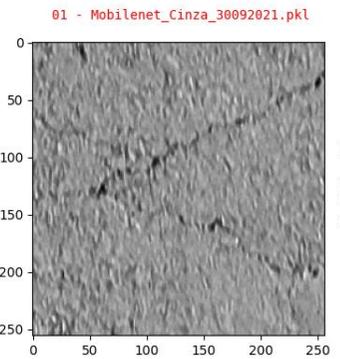
Pred.: Trinca
Trinca: 86.34%
Não Trinca: 13.66%
Inferência: 0.1164 seg



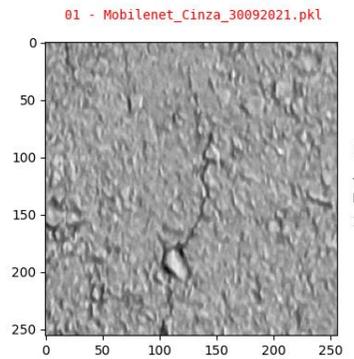
Pred.: Trinca
Trinca: 63.27%
Não Trinca: 36.73%
Inferência: 0.0813 seg



Pred.: Não Trinca
Trinca: 45.26%
Não Trinca: 54.74%
Inferência: 0.0832 seg

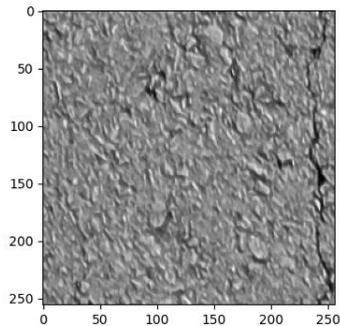


Pred.: Não Trinca
Trinca: 30.09%
Não Trinca: 69.91%
Inferência: 0.1114 seg



Pred.: Não Trinca
Trinca: 0.45%
Não Trinca: 99.55%
Inferência: 0.0813 seg

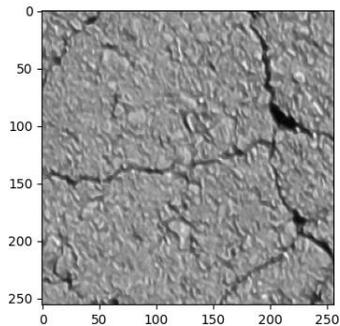
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Não Trinca

Trinca: 42.74%
Não Trinca: 57.26%
Inferência: 0.0772 seg

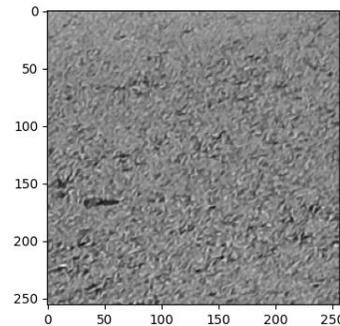
01 - Mobilenet_Cinza_30092021.pkl



Pred.: Trinca

Trinca: 99.95%
Não Trinca: 0.05%
Inferência: 0.1122 seg

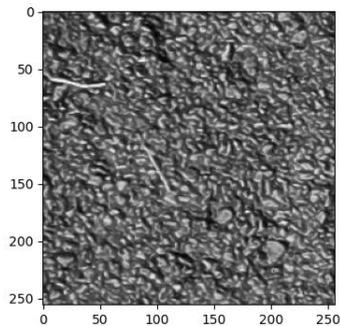
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0799 seg

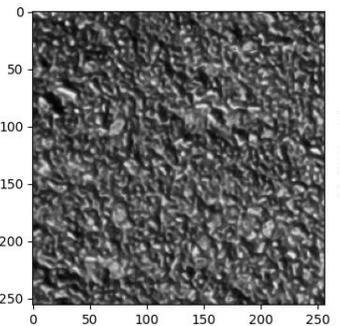
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0756 seg

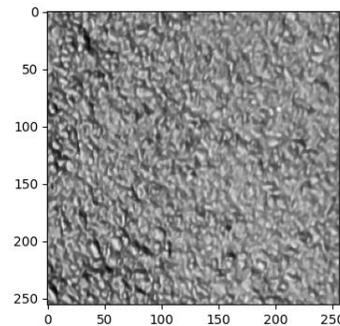
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0886 seg

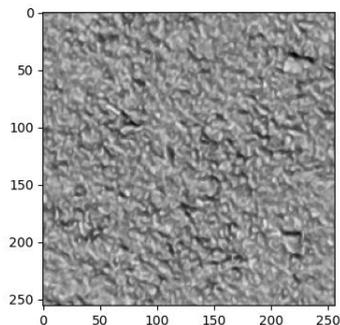
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0827 seg

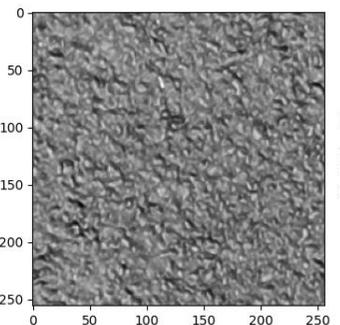
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.079 seg

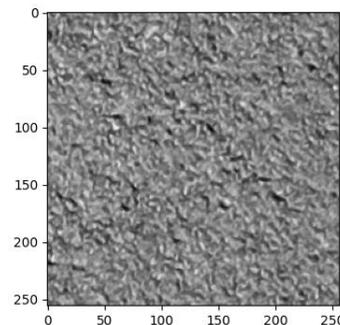
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0822 seg

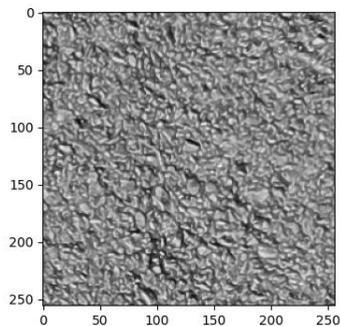
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0769 seg

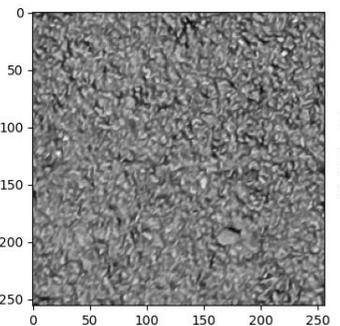
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.14%
Não Trinca: 99.86%
Inferência: 0.0762 seg

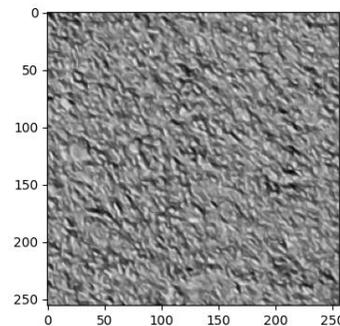
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0889 seg

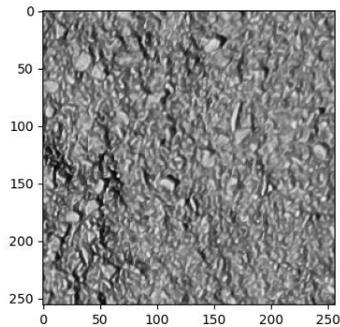
01 - Mobilenet_Colorido_01102021.pkl



Pred.: Não Trinca

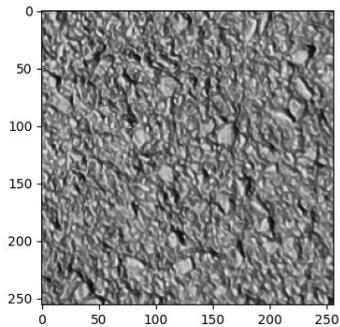
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0831 seg

01 - Mobilenet_Colorido_01102021.pkl



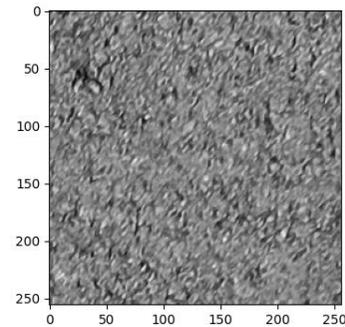
Pred.: Não Trinca
 Trinca: 0.47%
 Não Trinca: 99.53%
 Inferência: 0.0755 seg

01 - Mobilenet_Colorido_01102021.pkl



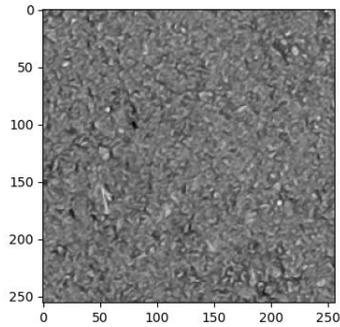
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0746 seg

01 - Mobilenet_Colorido_01102021.pkl



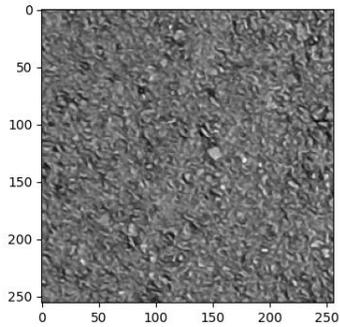
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0765 seg

01 - Mobilenet_Colorido_01102021.pkl



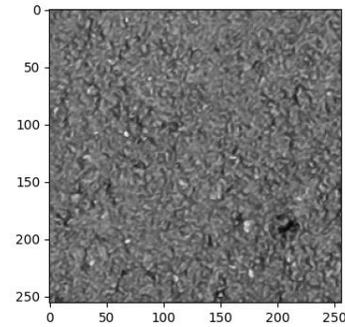
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0799 seg

01 - Mobilenet_Colorido_01102021.pkl



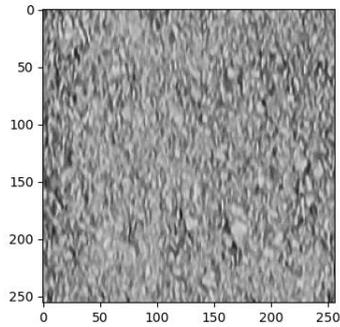
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0829 seg

01 - Mobilenet_Colorido_01102021.pkl



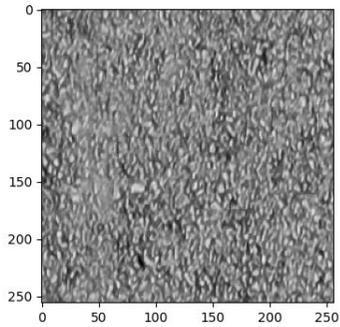
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0813 seg

01 - Mobilenet_Colorido_01102021.pkl



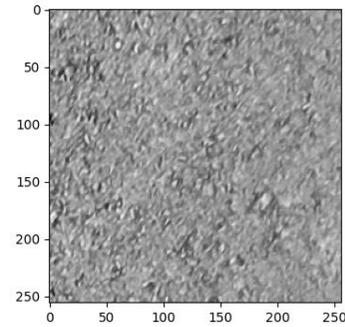
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0876 seg

01 - Mobilenet_Colorido_01102021.pkl



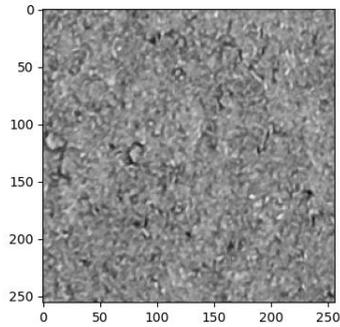
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0779 seg

01 - Mobilenet_Colorido_01102021.pkl



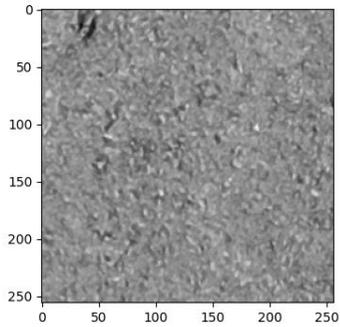
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0774 seg

01 - Mobilenet_Colorido_01102021.pkl



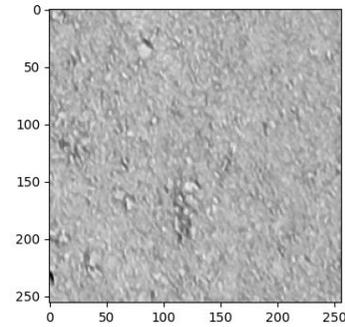
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0806 seg

01 - Mobilenet_Colorido_01102021.pkl



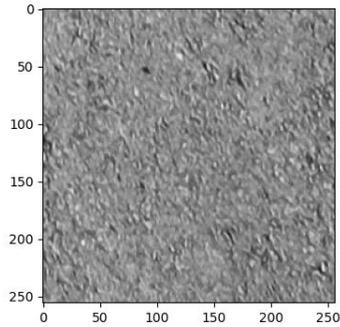
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.08 seg

01 - Mobilenet_Colorido_01102021.pkl



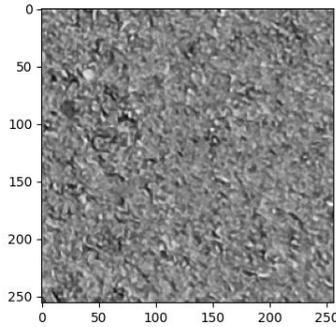
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0872 seg

01 - Mobilenet_Colorido_01102021.pkl



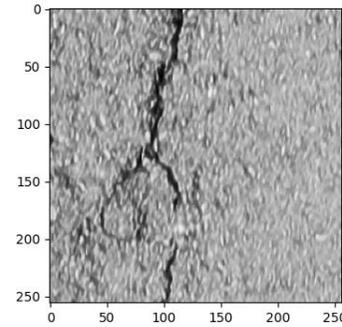
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0795 seg

01 - Mobilenet_Colorido_01102021.pkl



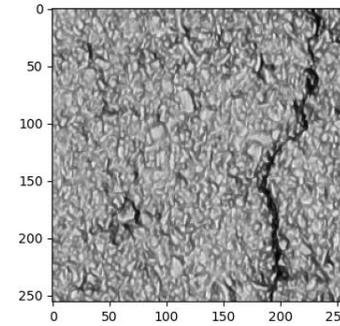
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0949 seg

01 - Mobilenet_Colorido_01102021.pkl



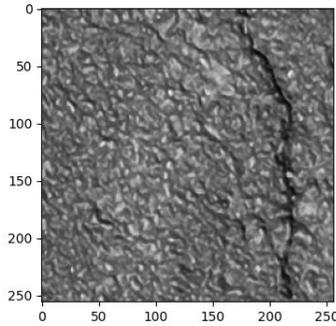
Pred.: Trinca
 Trinca: 84.12%
 Não Trinca: 15.88%
 Inferência: 0.0772 seg

01 - Mobilenet_Colorido_01102021.pkl



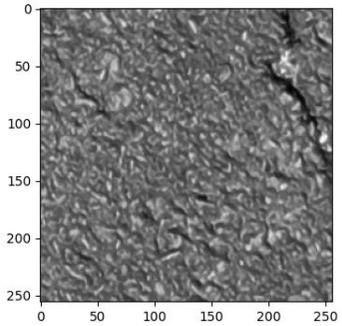
Pred.: Trinca
 Trinca: 77.54%
 Não Trinca: 22.46%
 Inferência: 0.0837 seg

01 - Mobilenet_Colorido_01102021.pkl



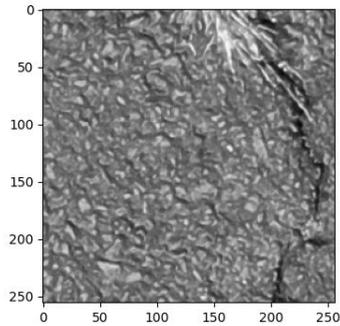
Pred.: Não Trinca
 Trinca: 12.42%
 Não Trinca: 87.58%
 Inferência: 0.0774 seg

01 - Mobilenet_Colorido_01102021.pkl



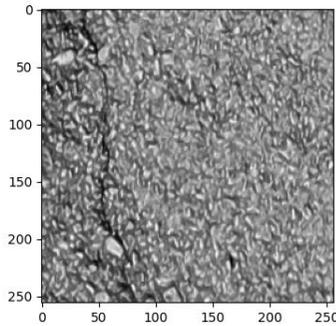
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0869 seg

01 - Mobilenet_Colorido_01102021.pkl



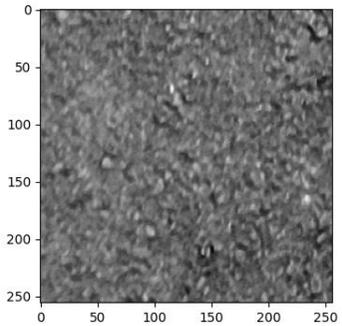
Pred.: Não Trinca
 Trinca: 5.74%
 Não Trinca: 94.26%
 Inferência: 0.0772 seg

01 - Mobilenet_Colorido_01102021.pkl



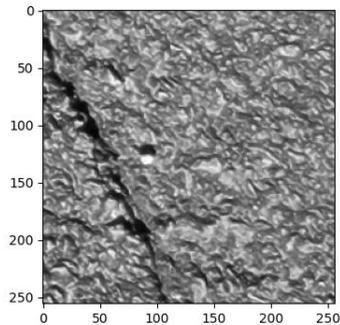
Pred.: Não Trinca
 Trinca: 2.01%
 Não Trinca: 97.99%
 Inferência: 0.0776 seg

01 - Mobilenet_Colorido_01102021.pkl



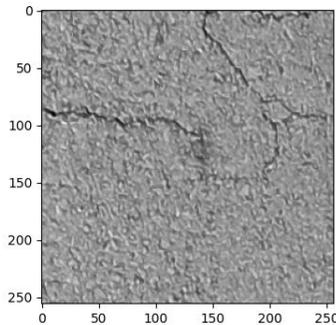
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0767 seg

01 - Mobilenet_Colorido_01102021.pkl



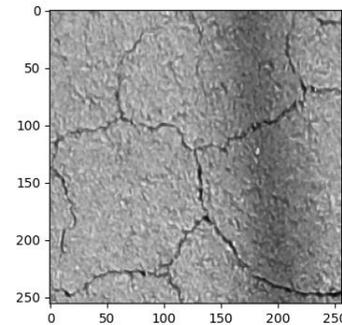
Pred.: Não Trinca
 Trinca: 2.86%
 Não Trinca: 97.14%
 Inferência: 0.075 seg

01 - Mobilenet_Colorido_01102021.pkl



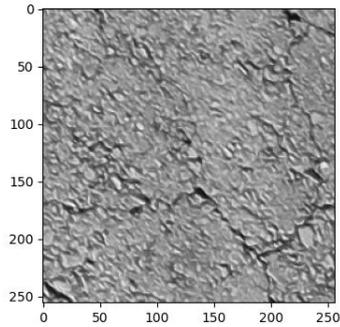
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0774 seg

01 - Mobilenet_Colorido_01102021.pkl



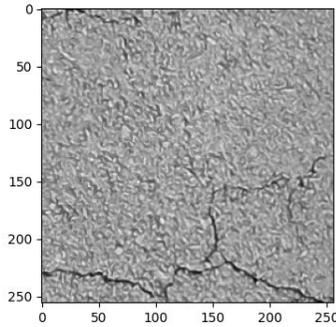
Pred.: Trinca
 Trinca: 77.08%
 Não Trinca: 22.92%
 Inferência: 0.0744 seg

01 - Mobilenet_Colorido_01102021.pkl



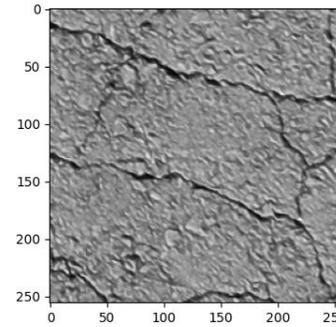
Pred.: Não Trinca
Trinca: 26.21%
Não Trinca: 73.79%
Inferência: 0.0788 seg

01 - Mobilenet_Colorido_01102021.pkl



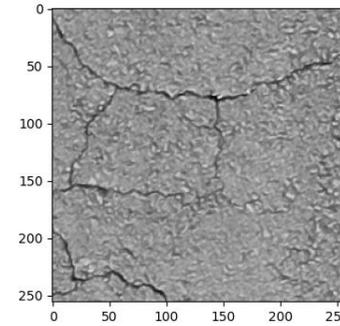
Pred.: Não Trinca
Trinca: 0.19%
Não Trinca: 99.81%
Inferência: 0.0758 seg

01 - Mobilenet_Colorido_01102021.pkl



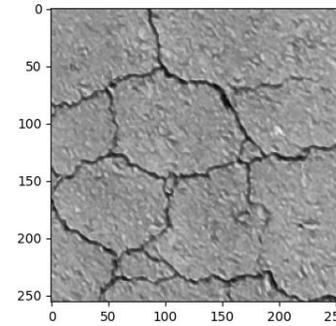
Pred.: Trinca
Trinca: 99.47%
Não Trinca: 0.53%
Inferência: 0.0761 seg

01 - Mobilenet_Colorido_01102021.pkl



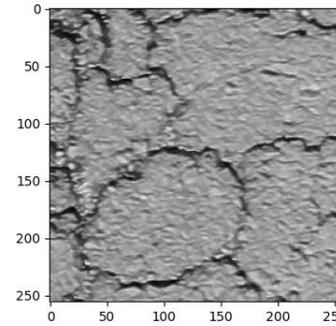
Pred.: Trinca
Trinca: 86.14%
Não Trinca: 13.86%
Inferência: 0.0805 seg

01 - Mobilenet_Colorido_01102021.pkl



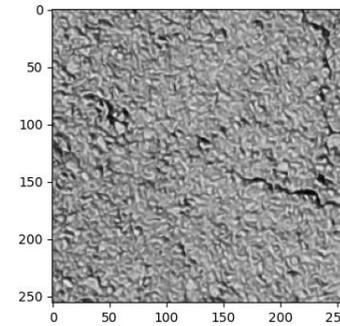
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.0761 seg

01 - Mobilenet_Colorido_01102021.pkl



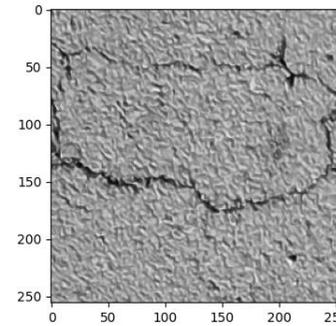
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.0789 seg

01 - Mobilenet_Colorido_01102021.pkl



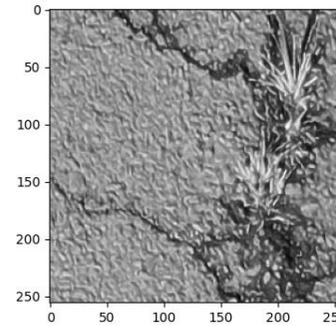
Pred.: Trinca
Trinca: 98.63%
Não Trinca: 1.37%
Inferência: 0.0788 seg

01 - Mobilenet_Colorido_01102021.pkl



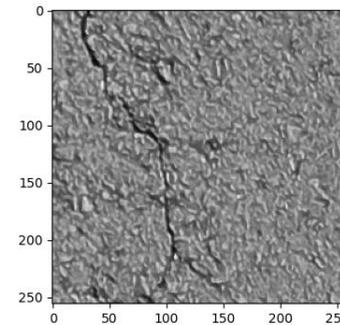
Pred.: Trinca
Trinca: 99.91%
Não Trinca: 0.09%
Inferência: 0.0793 seg

01 - Mobilenet_Colorido_01102021.pkl



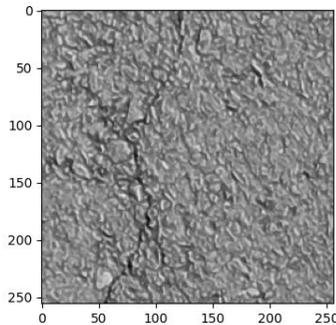
Pred.: Trinca
Trinca: 77.39%
Não Trinca: 22.61%
Inferência: 0.0794 seg

01 - Mobilenet_Colorido_01102021.pkl



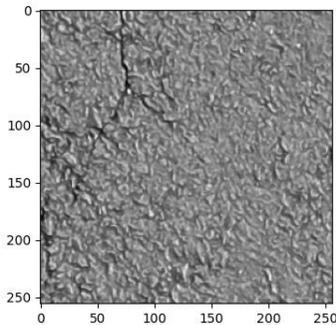
Pred.: Trinca
Trinca: 60.60%
Não Trinca: 39.40%
Inferência: 0.0808 seg

01 - Mobilenet_Colorido_01102021.pkl



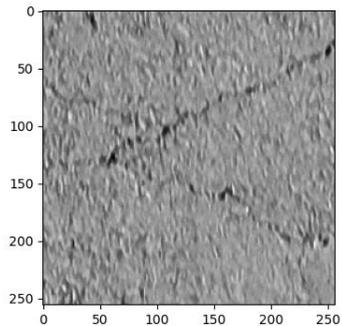
Pred.: Não Trinca
Trinca: 1.05%
Não Trinca: 98.95%
Inferência: 0.079 seg

01 - Mobilenet_Colorido_01102021.pkl



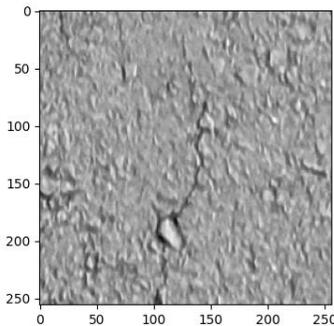
Pred.: Não Trinca
Trinca: 1.56%
Não Trinca: 98.44%
Inferência: 0.0822 seg

01 - Mobilenet_Colorido_01102021.pkl



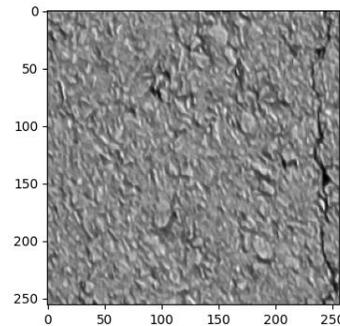
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0883 seg

01 - Mobilenet_Colorido_01102021.pkl



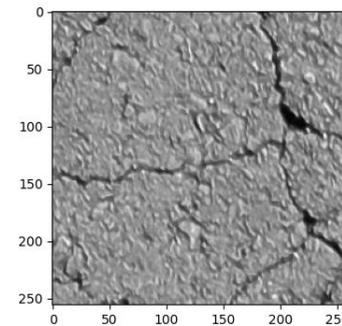
Pred.: Não Trinca
 Trinca: 0.18%
 Não Trinca: 99.82%
 Inferência: 0.0799 seg

01 - Mobilenet_Colorido_01102021.pkl



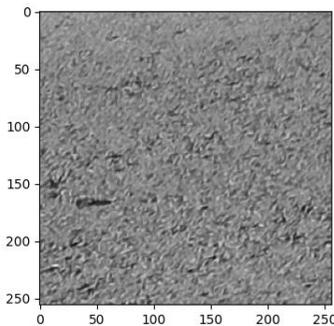
Pred.: Não Trinca
 Trinca: 9.70%
 Não Trinca: 90.30%
 Inferência: 0.0761 seg

01 - Mobilenet_Colorido_01102021.pkl



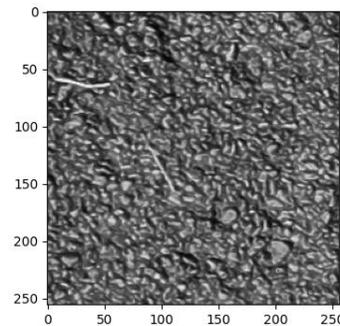
Pred.: Trinca
 Trinca: 99.97%
 Não Trinca: 0.03%
 Inferência: 0.0779 seg

02 - Alexnet_cinza_01102021.pkl



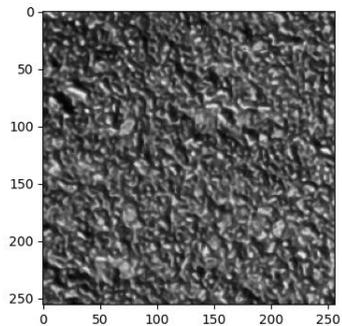
Pred.: Não Trinca
 Trinca: 0.07%
 Não Trinca: 99.93%
 Inferência: 0.031 seg

02 - Alexnet_cinza_01102021.pkl



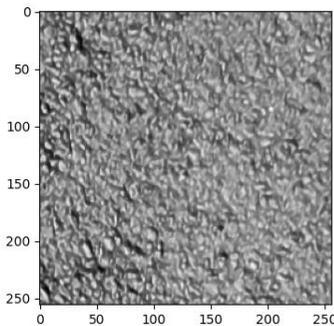
Pred.: Não Trinca
 Trinca: 0.20%
 Não Trinca: 99.80%
 Inferência: 0.0301 seg

02 - Alexnet_cinza_01102021.pkl



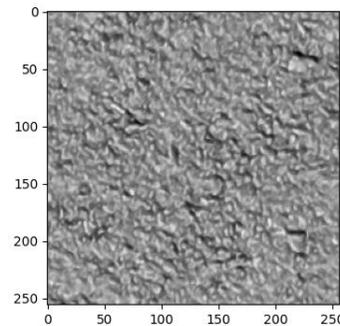
Pred.: Não Trinca
 Trinca: 0.06%
 Não Trinca: 99.94%
 Inferência: 0.0313 seg

02 - Alexnet_cinza_01102021.pkl



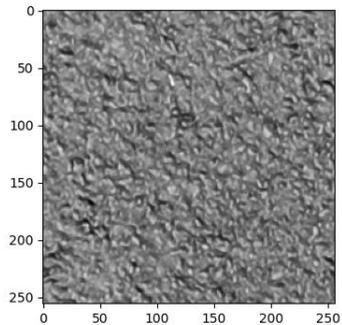
Pred.: Não Trinca
 Trinca: 10.95%
 Não Trinca: 89.05%
 Inferência: 0.0337 seg

02 - Alexnet_cinza_01102021.pkl



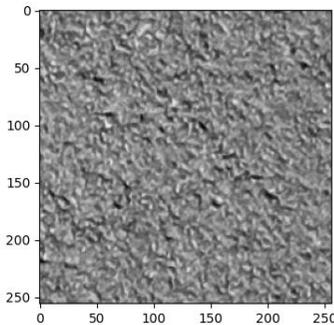
Pred.: Não Trinca
 Trinca: 0.11%
 Não Trinca: 99.89%
 Inferência: 0.037 seg

02 - Alexnet_cinza_01102021.pkl



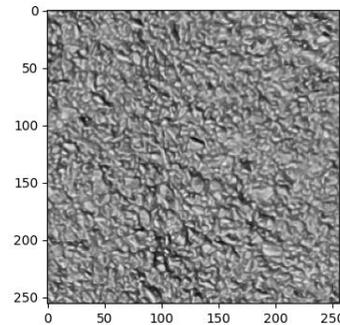
Pred.: Não Trinca
 Trinca: 0.05%
 Não Trinca: 99.95%
 Inferência: 0.031 seg

02 - Alexnet_cinza_01102021.pkl



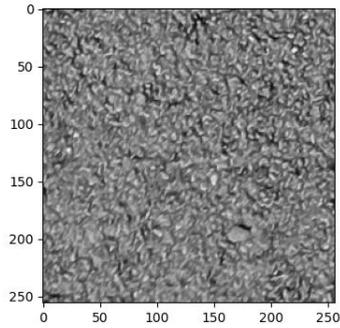
Pred.: Não Trinca
 Trinca: 0.06%
 Não Trinca: 99.94%
 Inferência: 0.031 seg

02 - Alexnet_cinza_01102021.pkl



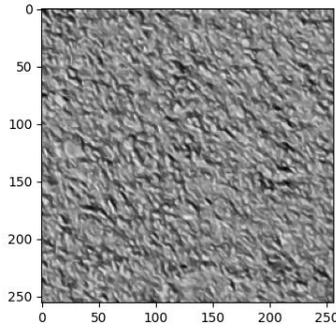
Pred.: Não Trinca
 Trinca: 2.06%
 Não Trinca: 97.94%
 Inferência: 0.031 seg

02 - Alexnet_cinza_01102021.pkl



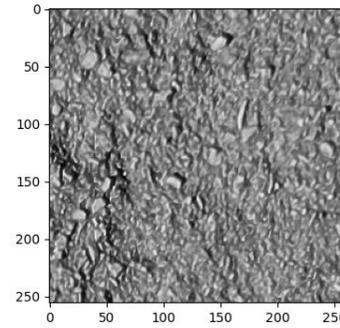
Pred.: Não Trinca
 Trinca: 0.24%
 Não Trinca: 99.76%
 Inferência: 0.0376 seg

02 - Alexnet_cinza_01102021.pkl



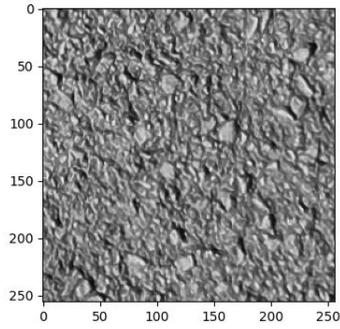
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0384 seg

02 - Alexnet_cinza_01102021.pkl



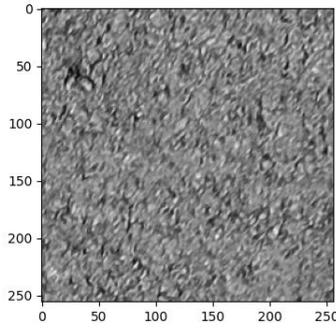
Pred.: Não Trinca
 Trinca: 17.36%
 Não Trinca: 82.64%
 Inferência: 0.0309 seg

02 - Alexnet_cinza_01102021.pkl



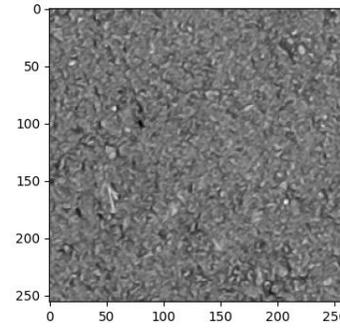
Pred.: Não Trinca
 Trinca: 0.71%
 Não Trinca: 99.29%
 Inferência: 0.0315 seg

02 - Alexnet_cinza_01102021.pkl



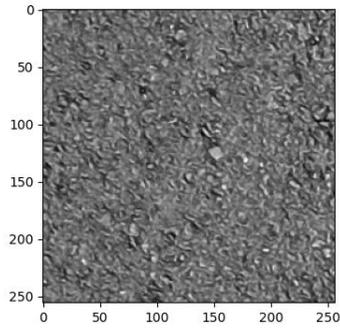
Pred.: Não Trinca
 Trinca: 0.03%
 Não Trinca: 99.97%
 Inferência: 0.0306 seg

02 - Alexnet_cinza_01102021.pkl



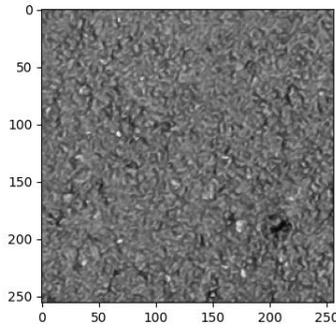
Pred.: Não Trinca
 Trinca: 0.08%
 Não Trinca: 99.92%
 Inferência: 0.0401 seg

02 - Alexnet_cinza_01102021.pkl



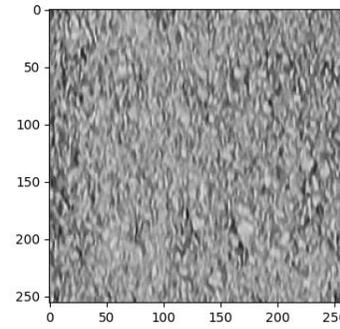
Pred.: Não Trinca
 Trinca: 0.02%
 Não Trinca: 99.98%
 Inferência: 0.0323 seg

02 - Alexnet_cinza_01102021.pkl



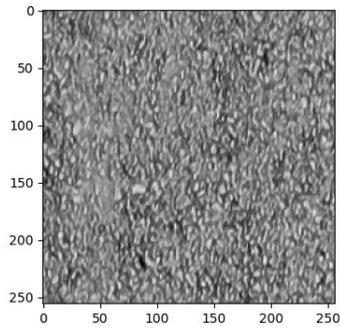
Pred.: Não Trinca
 Trinca: 0.12%
 Não Trinca: 99.88%
 Inferência: 0.0307 seg

02 - Alexnet_cinza_01102021.pkl



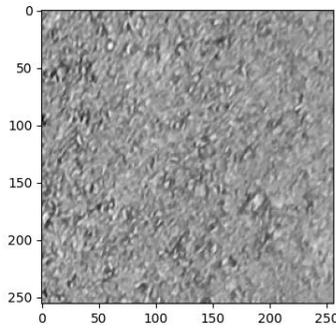
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.0322 seg

02 - Alexnet_cinza_01102021.pkl



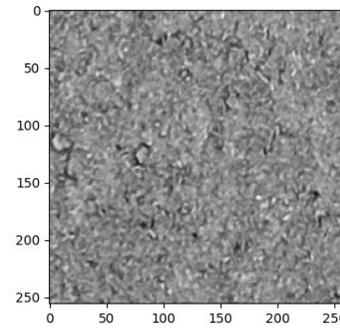
Pred.: Não Trinca
 Trinca: 0.48%
 Não Trinca: 99.52%
 Inferência: 0.031 seg

02 - Alexnet_cinza_01102021.pkl

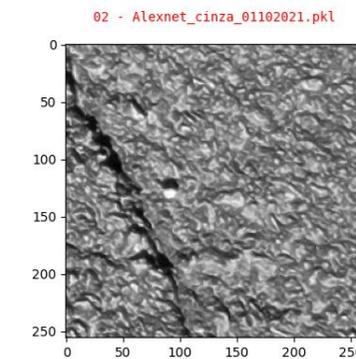
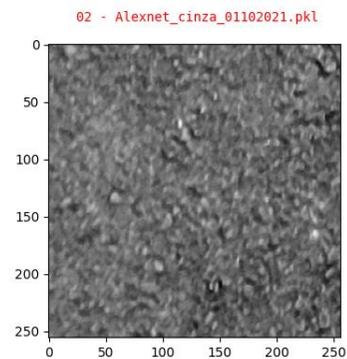
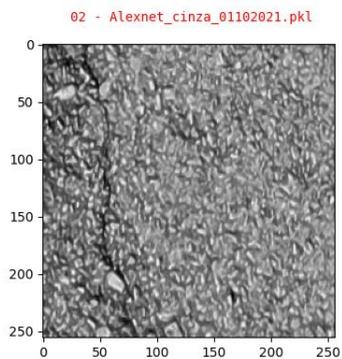
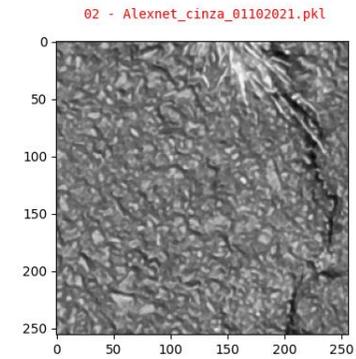
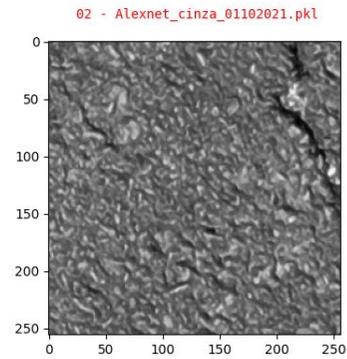
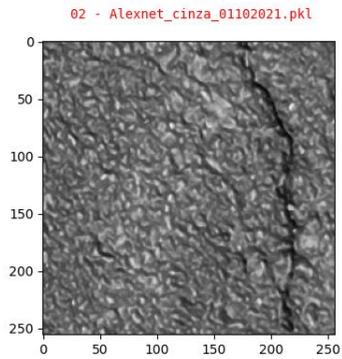
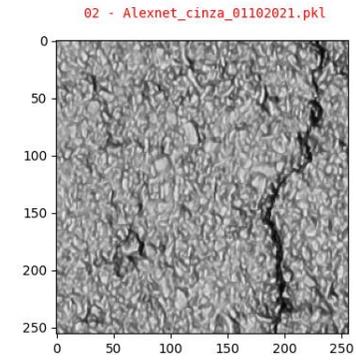
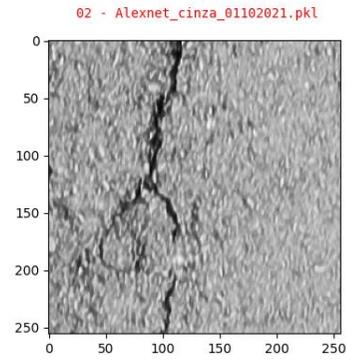
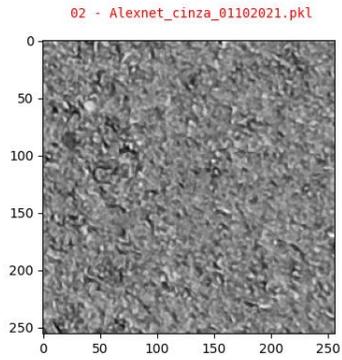
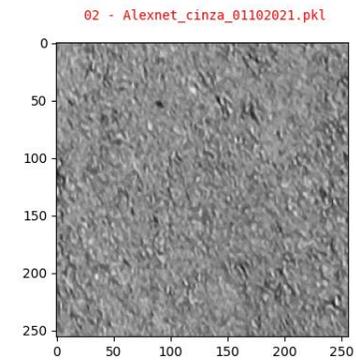
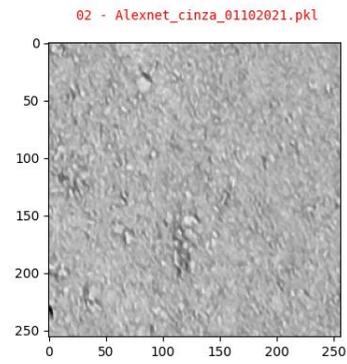
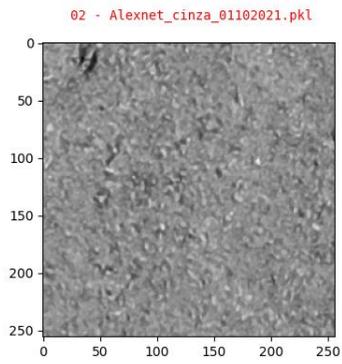


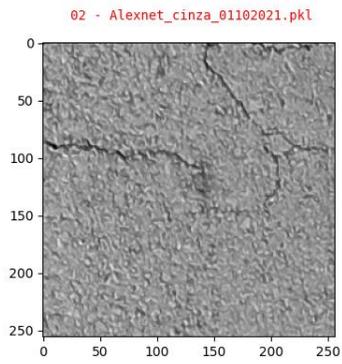
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.037 seg

02 - Alexnet_cinza_01102021.pkl

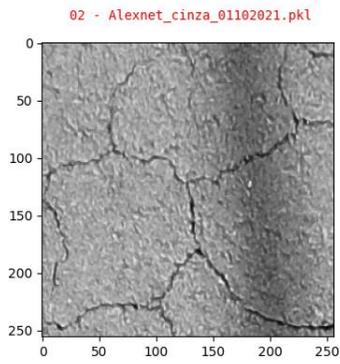


Pred.: Não Trinca
 Trinca: 0.02%
 Não Trinca: 99.98%
 Inferência: 0.0407 seg

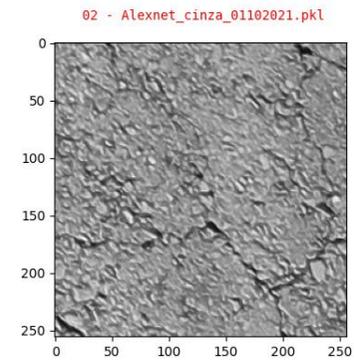




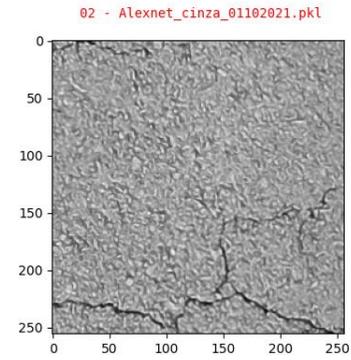
Pred.: Não Trinca
Trinca: 6.86%
Não Trinca: 93.14%
Inferência: 0.0298 seg



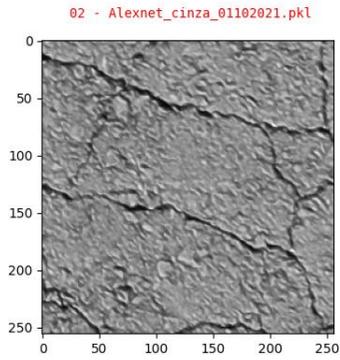
Pred.: Trinca
Trinca: 99.98%
Não Trinca: 0.02%
Inferência: 0.0313 seg



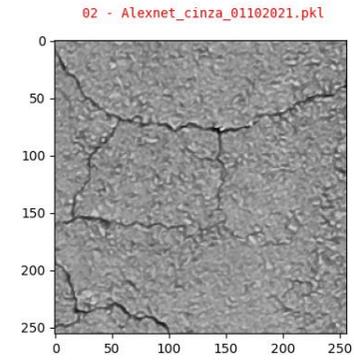
Pred.: Trinca
Trinca: 95.81%
Não Trinca: 4.19%
Inferência: 0.0312 seg



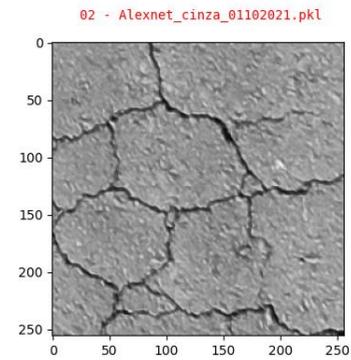
Pred.: Trinca
Trinca: 96.20%
Não Trinca: 3.80%
Inferência: 0.0309 seg



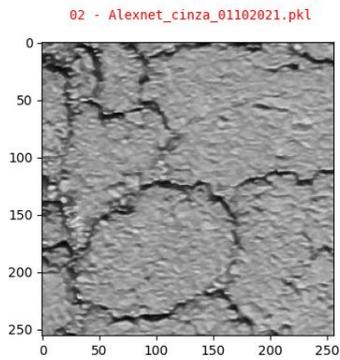
Pred.: Trinca
Trinca: 99.93%
Não Trinca: 0.07%
Inferência: 0.0302 seg



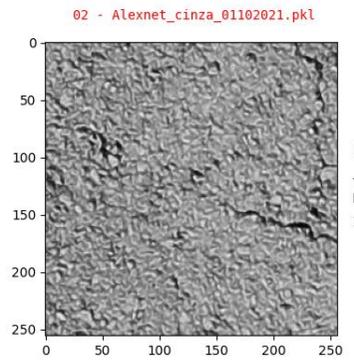
Pred.: Trinca
Trinca: 99.80%
Não Trinca: 0.20%
Inferência: 0.0314 seg



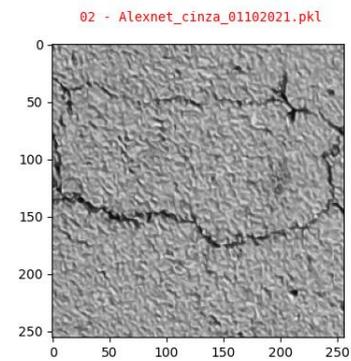
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.0314 seg



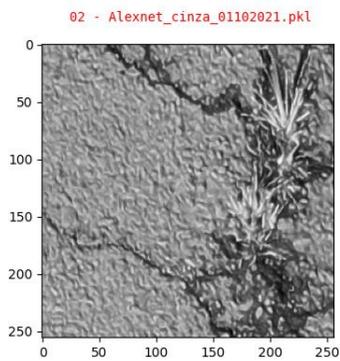
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.0359 seg



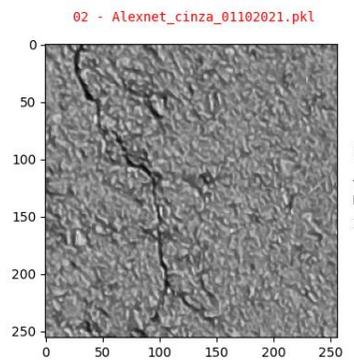
Pred.: Não Trinca
Trinca: 48.87%
Não Trinca: 51.13%
Inferência: 0.0308 seg



Pred.: Trinca
Trinca: 84.66%
Não Trinca: 15.40%
Inferência: 0.0306 seg

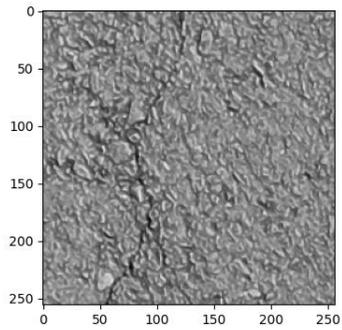


Pred.: Trinca
Trinca: 94.84%
Não Trinca: 5.16%
Inferência: 0.0305 seg



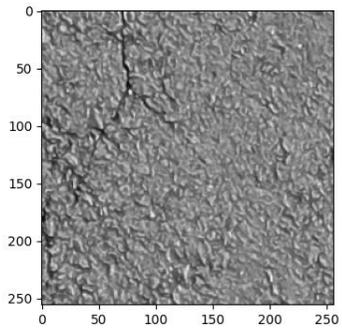
Pred.: Não Trinca
Trinca: 19.70%
Não Trinca: 80.30%
Inferência: 0.0321 seg

02 - Alexnet_cinza_01102021.pkl



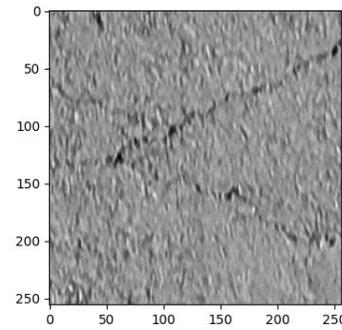
Pred.: Não Trinca
 Trinca: 3.20%
 Não Trinca: 96.80%
 Inferência: 0.0309 seg

02 - Alexnet_cinza_01102021.pkl



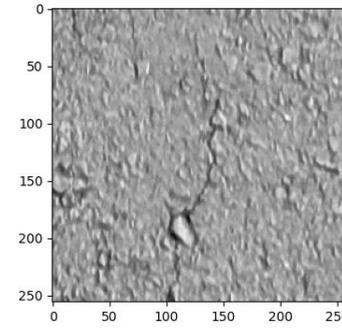
Pred.: Não Trinca
 Trinca: 2.57%
 Não Trinca: 97.43%
 Inferência: 0.0323 seg

02 - Alexnet_cinza_01102021.pkl



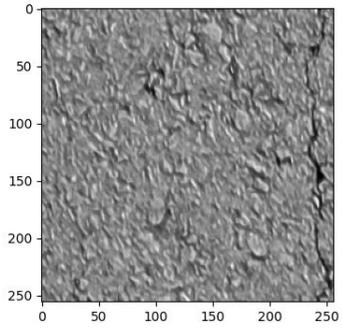
Pred.: Não Trinca
 Trinca: 0.39%
 Não Trinca: 99.61%
 Inferência: 0.0329 seg

02 - Alexnet_cinza_01102021.pkl



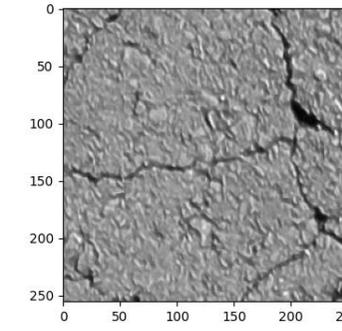
Pred.: Trinca
 Trinca: 50.67%
 Não Trinca: 49.33%
 Inferência: 0.0314 seg

02 - Alexnet_cinza_01102021.pkl



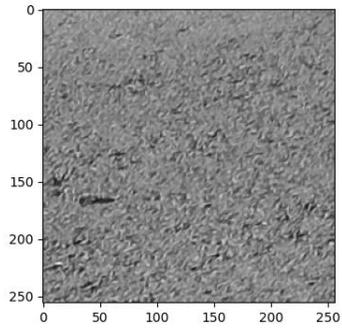
Pred.: Não Trinca
 Trinca: 9.33%
 Não Trinca: 90.67%
 Inferência: 0.0348 seg

02 - Alexnet_cinza_01102021.pkl



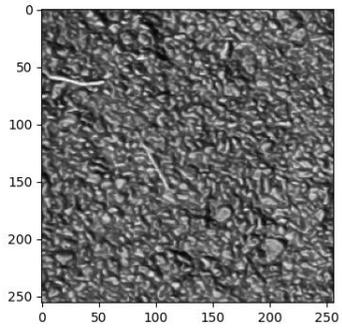
Pred.: Trinca
 Trinca: 98.19%
 Não Trinca: 1.81%
 Inferência: 0.032 seg

02 - Alexnet_Colorido_01102021.pkl



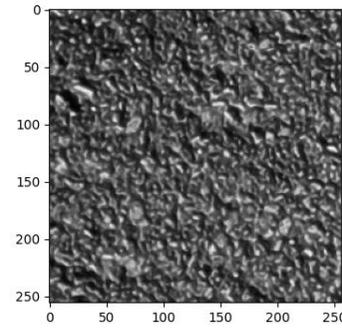
Pred.: Não Trinca
 Trinca: 0.24%
 Não Trinca: 99.76%
 Inferência: 0.043 seg

02 - Alexnet_Colorido_01102021.pkl



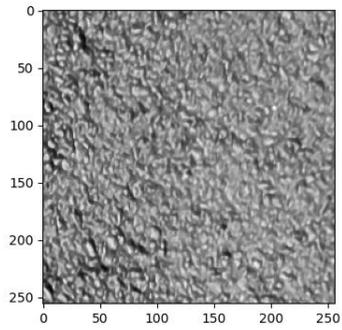
Pred.: Não Trinca
 Trinca: 2.33%
 Não Trinca: 97.67%
 Inferência: 0.0365 seg

02 - Alexnet_Colorido_01102021.pkl



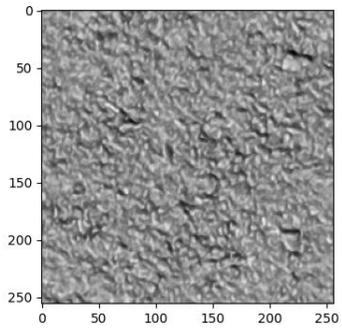
Pred.: Não Trinca
 Trinca: 0.02%
 Não Trinca: 99.98%
 Inferência: 0.0395 seg

02 - Alexnet_Colorido_01102021.pkl



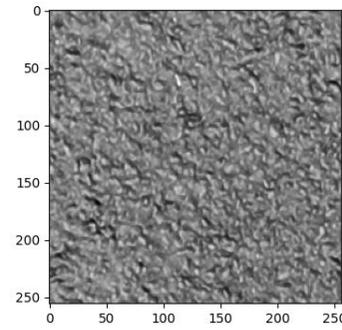
Pred.: Não Trinca
 Trinca: 14.17%
 Não Trinca: 85.83%
 Inferência: 0.0365 seg

02 - Alexnet_Colorido_01102021.pkl



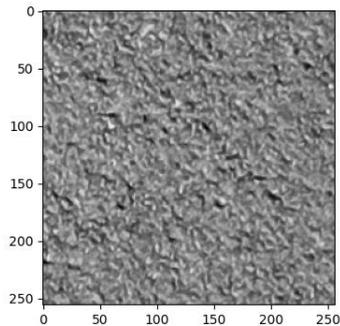
Pred.: Não Trinca
 Trinca: 0.99%
 Não Trinca: 99.01%
 Inferência: 0.0314 seg

02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca
 Trinca: 1.15%
 Não Trinca: 98.85%
 Inferência: 0.0383 seg

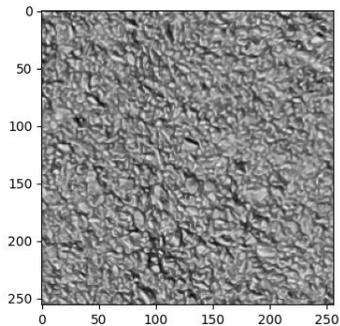
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.08%
Não Trinca: 99.92%
Inferência: 0.0399 seg

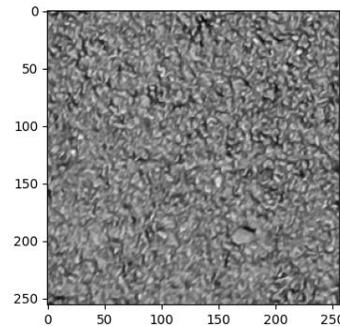
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 38.07%
Não Trinca: 61.93%
Inferência: 0.0399 seg

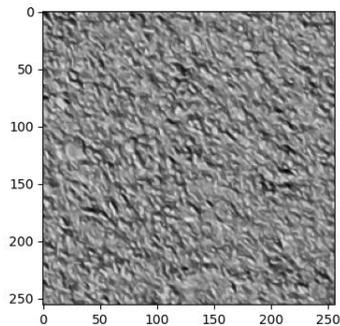
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.06%
Não Trinca: 99.94%
Inferência: 0.0448 seg

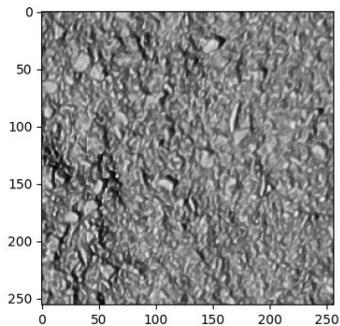
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.51%
Não Trinca: 99.49%
Inferência: 0.0374 seg

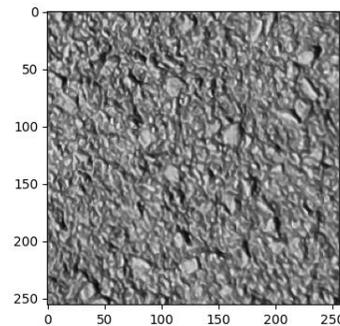
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 30.53%
Não Trinca: 69.47%
Inferência: 0.0396 seg

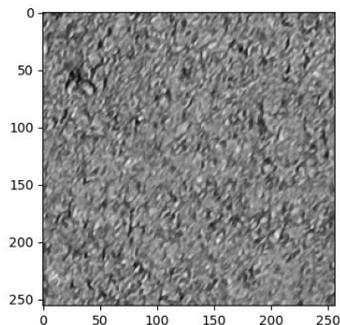
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 2.64%
Não Trinca: 97.36%
Inferência: 0.044 seg

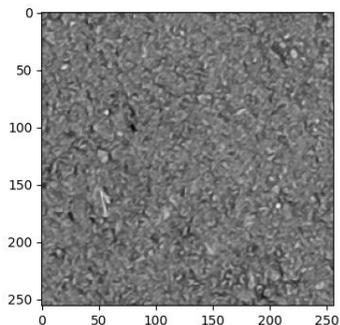
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.09%
Não Trinca: 99.91%
Inferência: 0.0353 seg

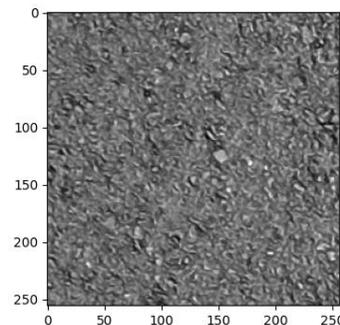
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.04%
Não Trinca: 99.96%
Inferência: 0.0377 seg

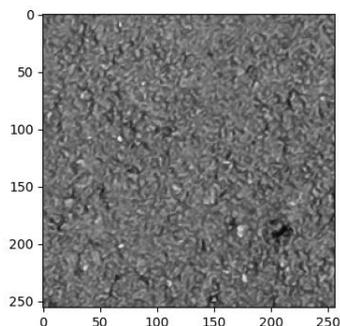
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0371 seg

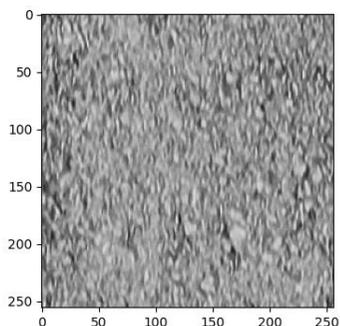
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.10%
Não Trinca: 99.90%
Inferência: 0.0375 seg

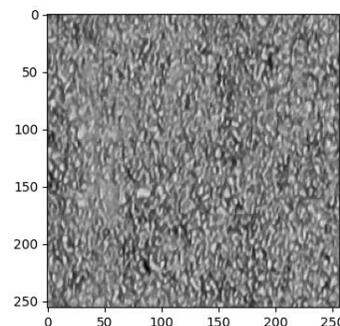
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.20%
Não Trinca: 99.80%
Inferência: 0.0479 seg

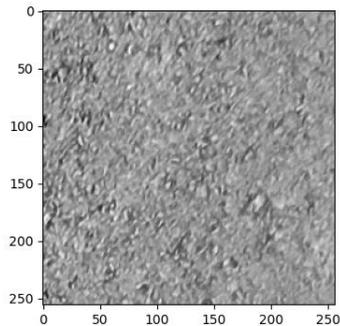
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

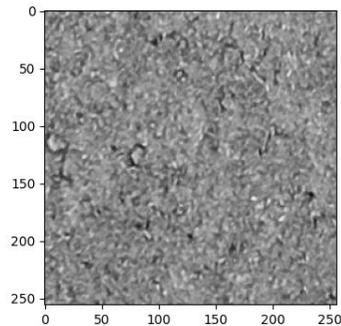
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0377 seg

02 - Alexnet_Colorido_01102021.pkl



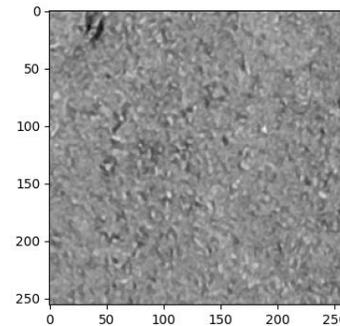
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0426 seg

02 - Alexnet_Colorido_01102021.pkl



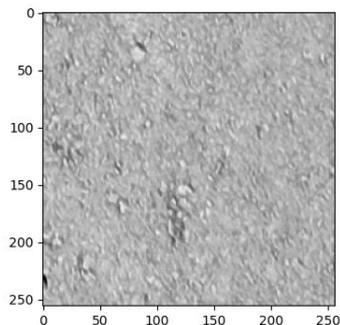
Pred.: Não Trincado
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.0343 seg

02 - Alexnet_Colorido_01102021.pkl



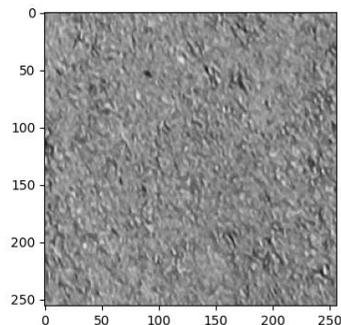
Pred.: Não Trincado
 Trinca: 0.05%
 Não Trinca: 99.95%
 Inferência: 0.0357 seg

02 - Alexnet_Colorido_01102021.pkl



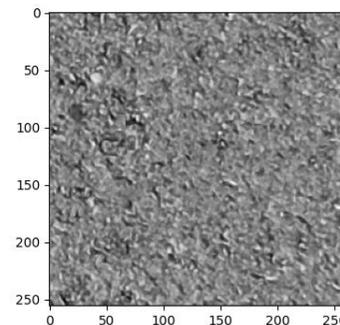
Pred.: Não Trincado
 Trinca: 0.20%
 Não Trinca: 99.80%
 Inferência: 0.0399 seg

02 - Alexnet_Colorido_01102021.pkl



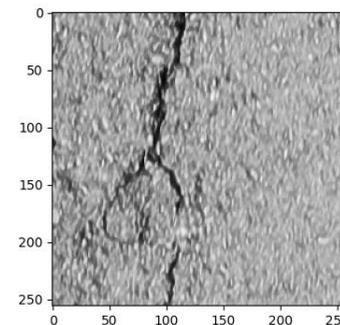
Pred.: Não Trincado
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.0413 seg

02 - Alexnet_Colorido_01102021.pkl



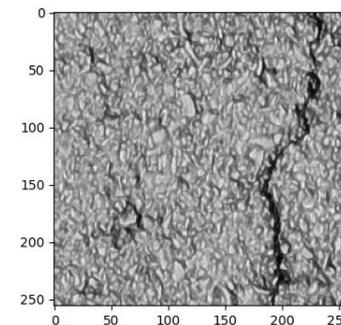
Pred.: Não Trincado
 Trinca: 0.35%
 Não Trinca: 99.65%
 Inferência: 0.0449 seg

02 - Alexnet_Colorido_01102021.pkl



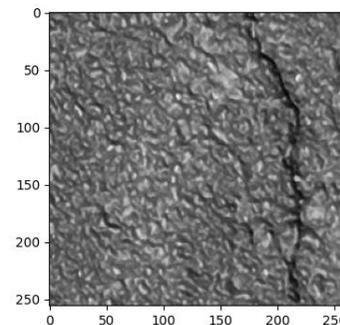
Pred.: Trincado
 Trinca: 97.92%
 Não Trinca: 2.08%
 Inferência: 0.0394 seg

02 - Alexnet_Colorido_01102021.pkl



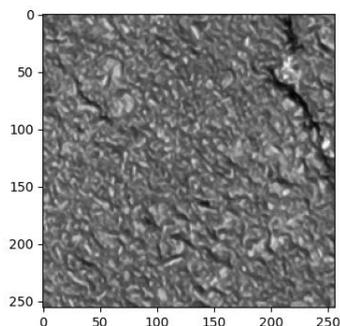
Pred.: Trincado
 Trinca: 92.31%
 Não Trinca: 7.69%
 Inferência: 0.0364 seg

02 - Alexnet_Colorido_01102021.pkl



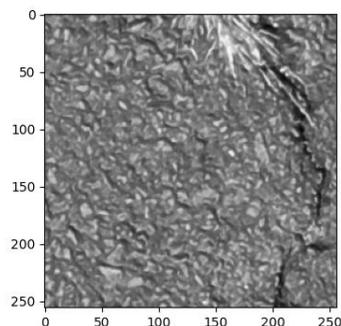
Pred.: Não Trincado
 Trinca: 26.70%
 Não Trinca: 73.30%
 Inferência: 0.0383 seg

02 - Alexnet_Colorido_01102021.pkl



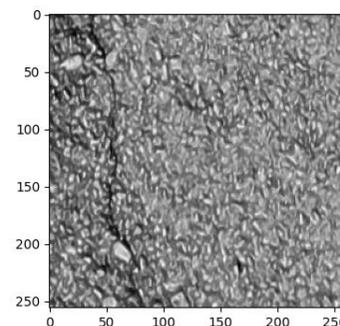
Pred.: Não Trincado
 Trinca: 11.74%
 Não Trinca: 88.26%
 Inferência: 0.0405 seg

02 - Alexnet_Colorido_01102021.pkl



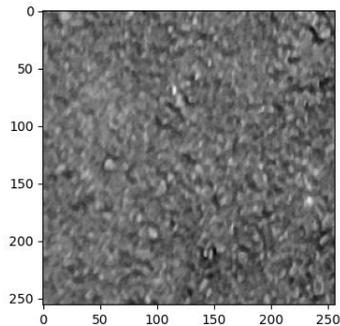
Pred.: Não Trincado
 Trinca: 48.41%
 Não Trinca: 51.59%
 Inferência: 0.0458 seg

02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trincado
 Trinca: 11.83%
 Não Trinca: 88.17%
 Inferência: 0.0409 seg

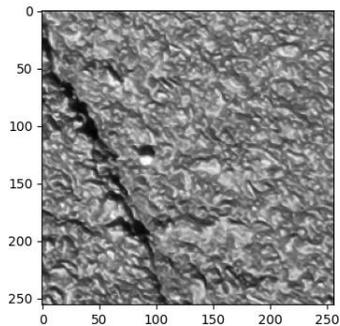
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0377 seg

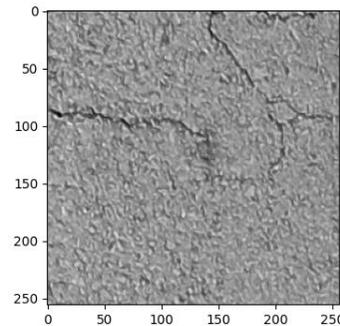
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

Trinca: 52.09%
Não Trinca: 47.91%
Inferência: 0.0369 seg

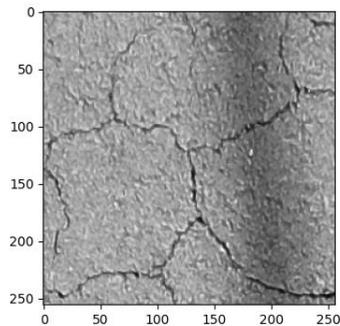
02 - Alexnet_Colorido_01102021.pkl



Pred.: Não Trinca

Trinca: 39.93%
Não Trinca: 60.07%
Inferência: 0.031 seg

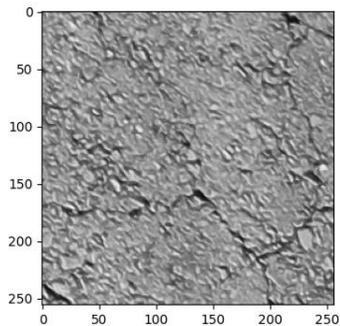
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.0387 seg

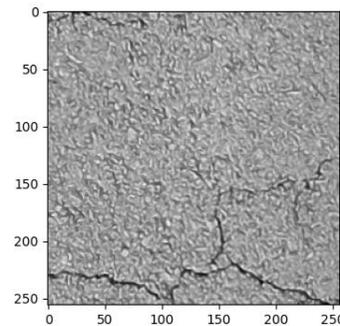
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

Trinca: 99.21%
Não Trinca: 0.79%
Inferência: 0.0397 seg

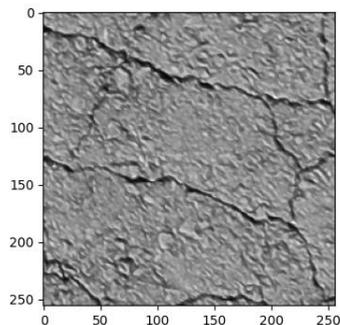
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

Trinca: 98.35%
Não Trinca: 1.65%
Inferência: 0.0397 seg

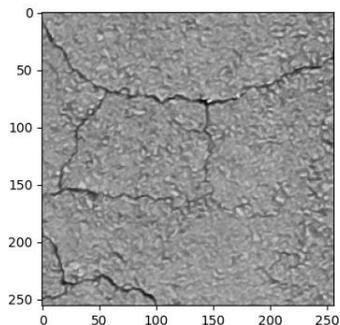
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.0377 seg

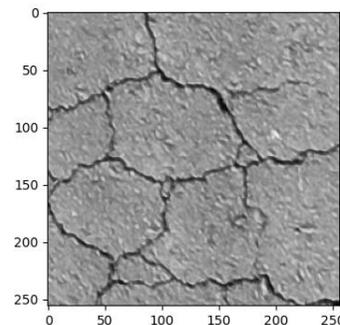
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

Trinca: 99.97%
Não Trinca: 0.03%
Inferência: 0.0391 seg

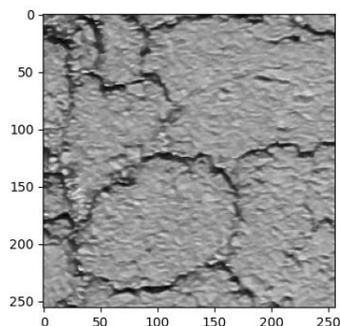
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.0394 seg

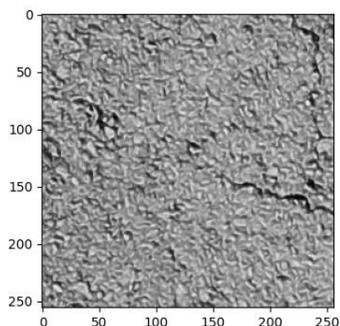
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.0387 seg

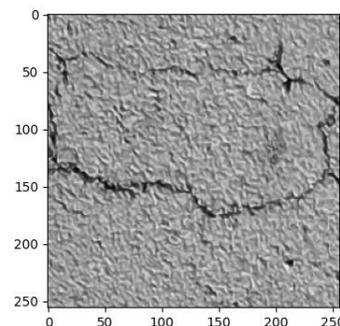
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

Trinca: 88.33%
Não Trinca: 11.67%
Inferência: 0.0374 seg

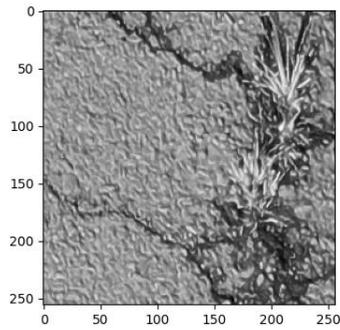
02 - Alexnet_Colorido_01102021.pkl



Pred.: Trinca

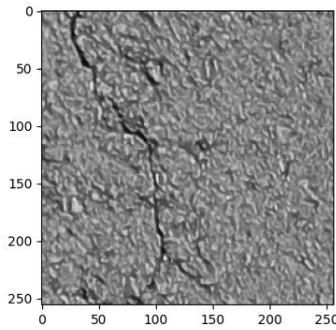
Trinca: 97.02%
Não Trinca: 2.98%
Inferência: 0.0435 seg

02 - Alexnet_Colorido_01102021.pkl



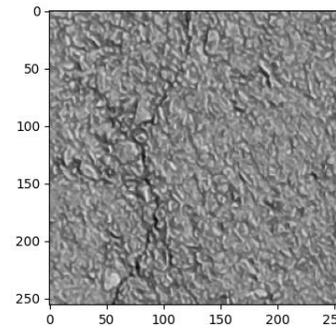
Pred.: Trinca
 Trinca: 96.05%
 Não Trinca: 3.95%
 Inferência: 0.0355 seg

02 - Alexnet_Colorido_01102021.pkl



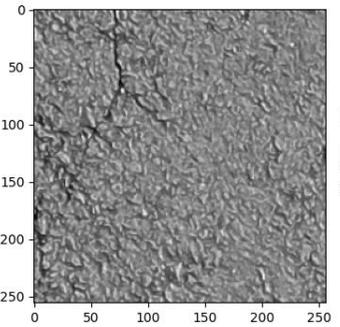
Pred.: Não Trinca
 Trinca: 41.80%
 Não Trinca: 58.20%
 Inferência: 0.0378 seg

02 - Alexnet_Colorido_01102021.pkl



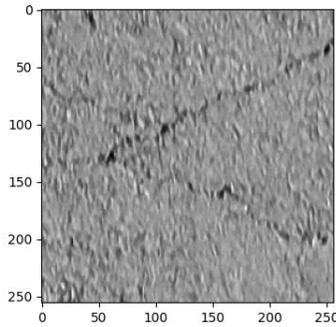
Pred.: Não Trinca
 Trinca: 22.37%
 Não Trinca: 77.63%
 Inferência: 0.0386 seg

02 - Alexnet_Colorido_01102021.pkl



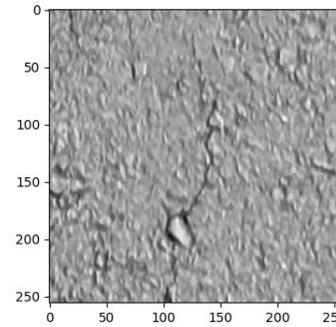
Pred.: Não Trinca
 Trinca: 16.96%
 Não Trinca: 83.04%
 Inferência: 0.046 seg

02 - Alexnet_Colorido_01102021.pkl



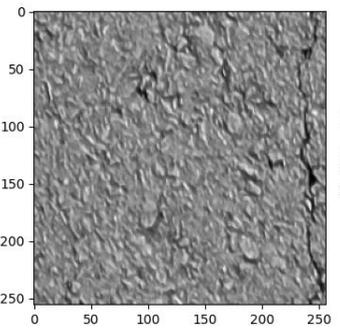
Pred.: Não Trinca
 Trinca: 16.45%
 Não Trinca: 83.55%
 Inferência: 0.0383 seg

02 - Alexnet_Colorido_01102021.pkl



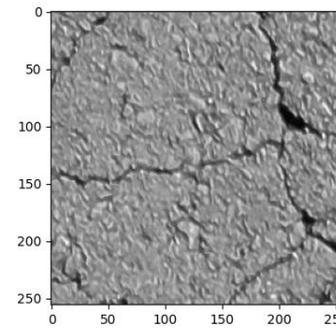
Pred.: Não Trinca
 Trinca: 38.73%
 Não Trinca: 61.27%
 Inferência: 0.0383 seg

02 - Alexnet_Colorido_01102021.pkl



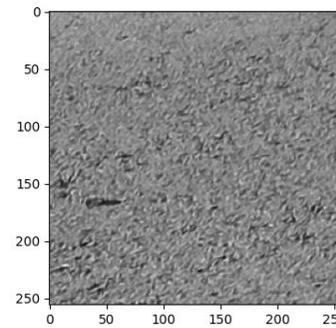
Pred.: Não Trinca
 Trinca: 30.95%
 Não Trinca: 69.05%
 Inferência: 0.0438 seg

02 - Alexnet_Colorido_01102021.pkl



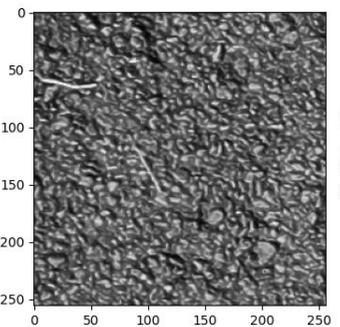
Pred.: Trinca
 Trinca: 99.58%
 Não Trinca: 0.42%
 Inferência: 0.0302 seg

03 - Densenet_Cinza_06102021.pkl



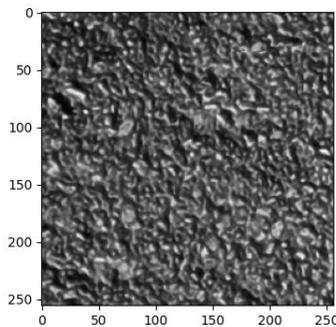
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2027 seg

03 - Densenet_Cinza_06102021.pkl



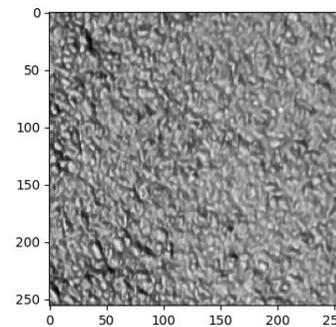
Pred.: Não Trinca
 Trinca: 0.03%
 Não Trinca: 99.97%
 Inferência: 0.2008 seg

03 - Densenet_Cinza_06102021.pkl



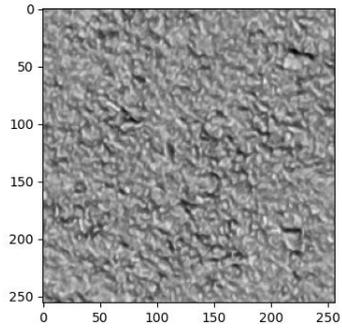
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.2005 seg

03 - Densenet_Cinza_06102021.pkl



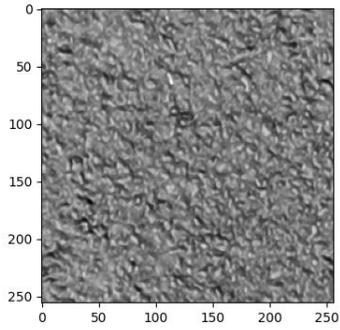
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2107 seg

03 - Densenet_Cinza_06102021.pkl



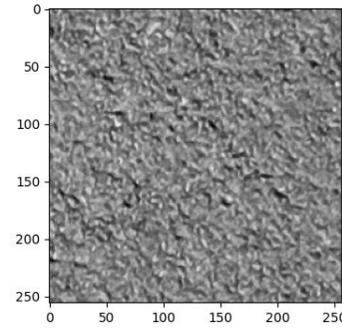
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1873 seg

03 - Densenet_Cinza_06102021.pkl



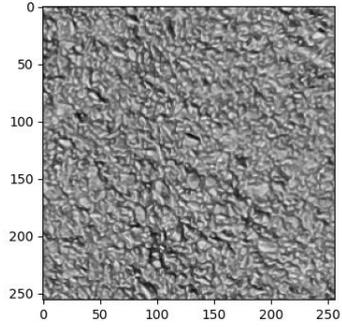
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2121 seg

03 - Densenet_Cinza_06102021.pkl



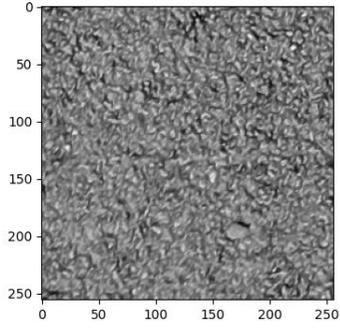
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.192 seg

03 - Densenet_Cinza_06102021.pkl



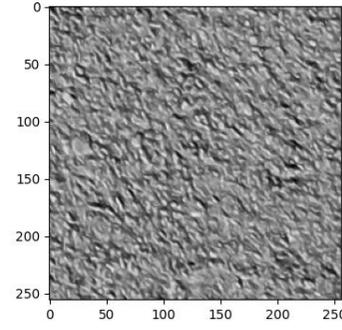
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.1911 seg

03 - Densenet_Cinza_06102021.pkl



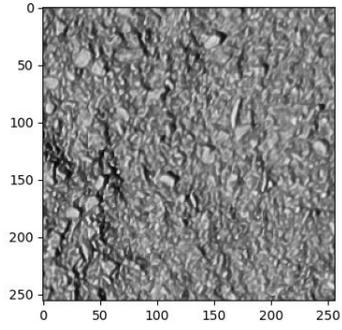
Pred.: Não Trinca
 Trinca: 0.11%
 Não Trinca: 99.89%
 Inferência: 0.1956 seg

03 - Densenet_Cinza_06102021.pkl



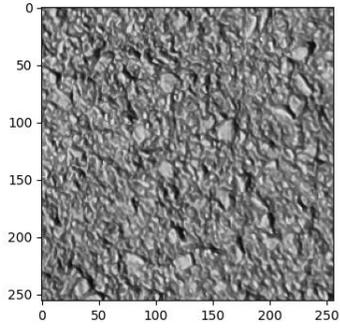
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2077 seg

03 - Densenet_Cinza_06102021.pkl



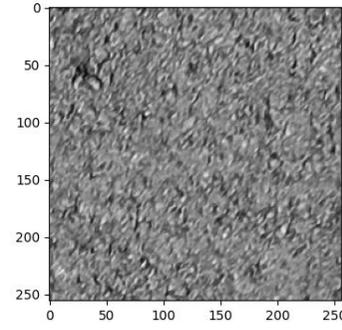
Pred.: Não Trinca
 Trinca: 10.30%
 Não Trinca: 89.70%
 Inferência: 0.1941 seg

03 - Densenet_Cinza_06102021.pkl



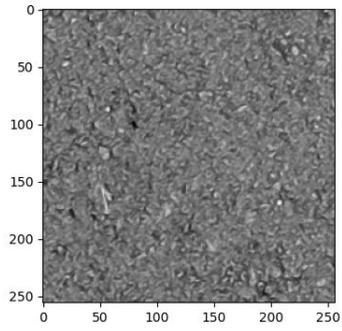
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.1971 seg

03 - Densenet_Cinza_06102021.pkl



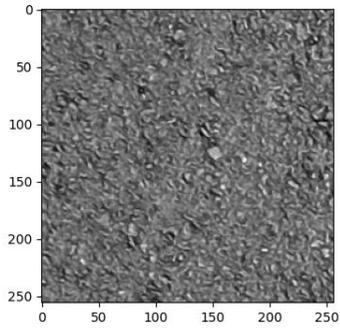
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2082 seg

03 - Densenet_Cinza_06102021.pkl



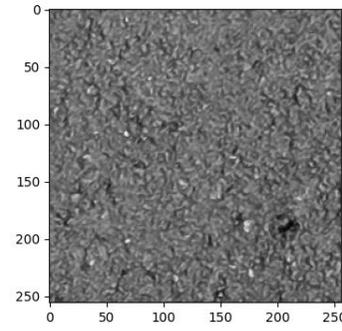
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2015 seg

03 - Densenet_Cinza_06102021.pkl



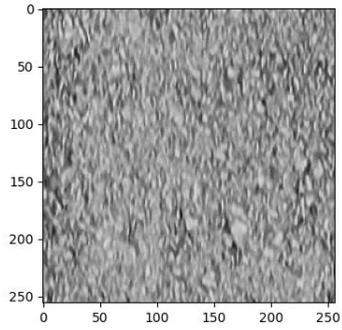
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1982 seg

03 - Densenet_Cinza_06102021.pkl



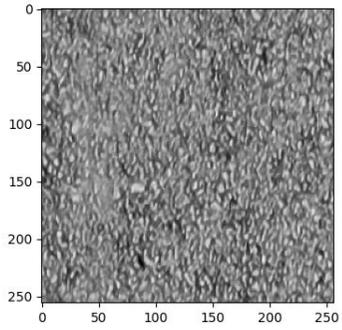
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2056 seg

03 - Densenet_Cinza_06102021.pkl



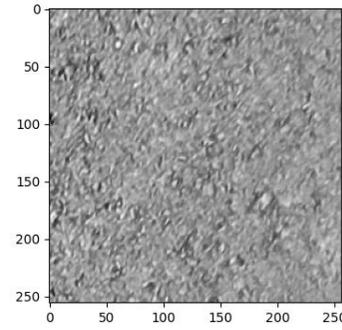
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2012 seg

03 - Densenet_Cinza_06102021.pkl



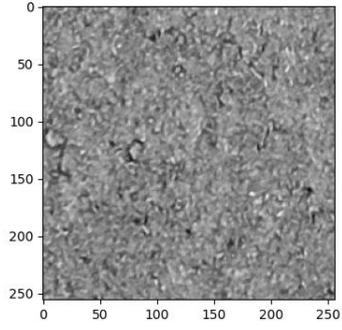
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1993 seg

03 - Densenet_Cinza_06102021.pkl



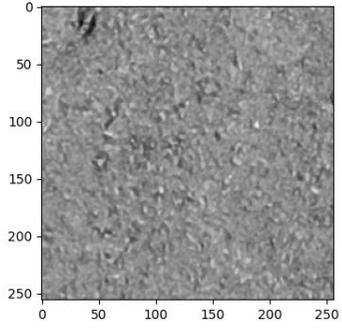
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2002 seg

03 - Densenet_Cinza_06102021.pkl



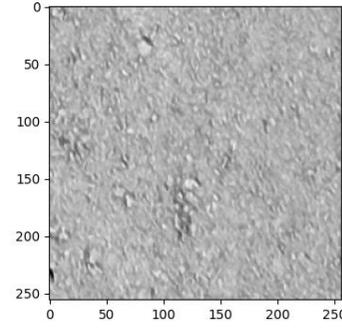
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2009 seg

03 - Densenet_Cinza_06102021.pkl



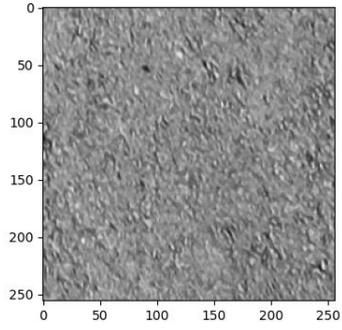
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2002 seg

03 - Densenet_Cinza_06102021.pkl



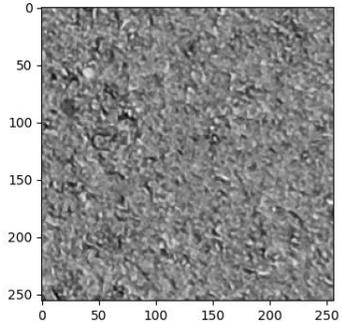
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1929 seg

03 - Densenet_Cinza_06102021.pkl



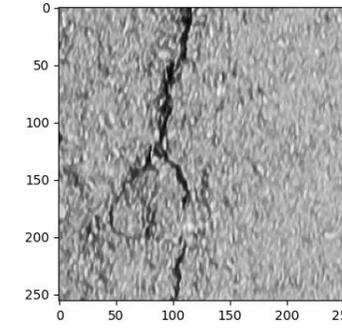
Pred.: Não Trincado
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.1928 seg

03 - Densenet_Cinza_06102021.pkl



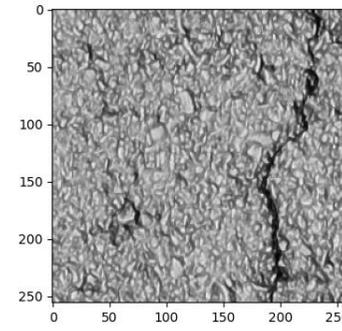
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1972 seg

03 - Densenet_Cinza_06102021.pkl



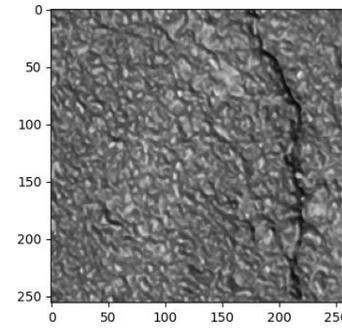
Pred.: Trincado
 Trinca: 59.66%
 Não Trinca: 40.34%
 Inferência: 0.1962 seg

03 - Densenet_Cinza_06102021.pkl



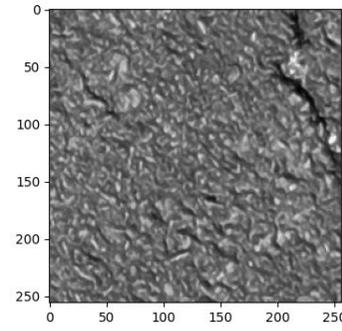
Pred.: Trincado
 Trinca: 86.50%
 Não Trinca: 13.50%
 Inferência: 0.1999 seg

03 - Densenet_Cinza_06102021.pkl



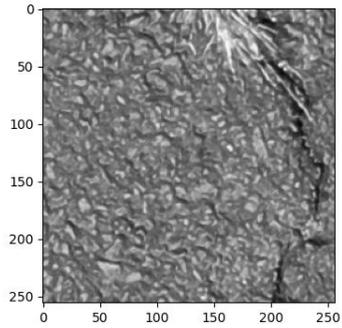
Pred.: Trincado
 Trinca: 50.11%
 Não Trinca: 49.89%
 Inferência: 0.1977 seg

03 - Densenet_Cinza_06102021.pkl



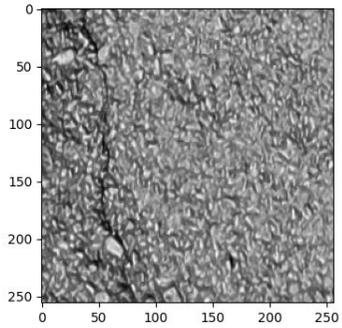
Pred.: Não Trincado
 Trinca: 30.93%
 Não Trinca: 69.07%
 Inferência: 0.2043 seg

03 - Densenet_Cinza_06102021.pkl



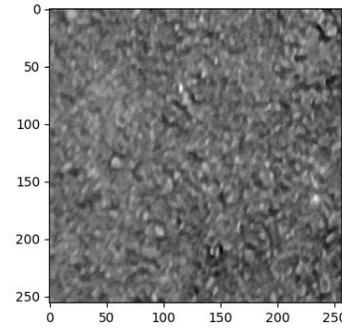
Pred.: Não Trinca
 Trinca: 40.36%
 Não Trinca: 59.64%
 Inferência: 0.2007 seg

03 - Densenet_Cinza_06102021.pkl



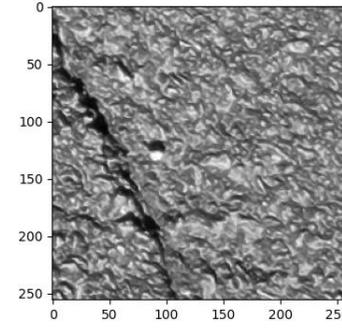
Pred.: Não Trinca
 Trinca: 33.77%
 Não Trinca: 66.23%
 Inferência: 0.1963 seg

03 - Densenet_Cinza_06102021.pkl



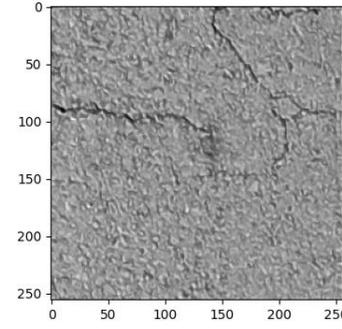
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1921 seg

03 - Densenet_Cinza_06102021.pkl



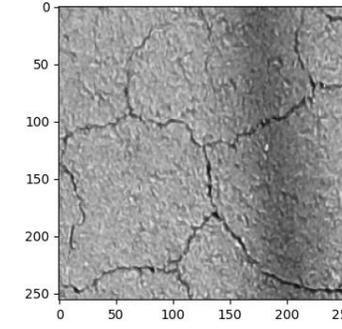
Pred.: Trinca
 Trinca: 84.90%
 Não Trinca: 15.10%
 Inferência: 0.1889 seg

03 - Densenet_Cinza_06102021.pkl



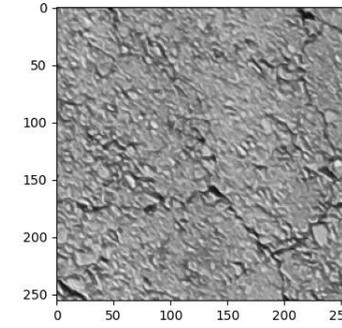
Pred.: Trinca
 Trinca: 97.82%
 Não Trinca: 2.18%
 Inferência: 0.2198 seg

03 - Densenet_Cinza_06102021.pkl



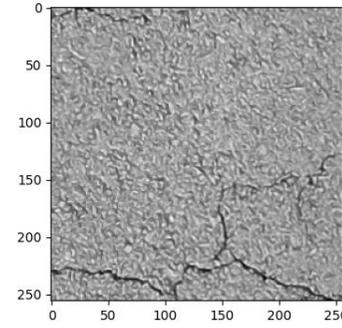
Pred.: Trinca
 Trinca: 99.98%
 Não Trinca: 0.02%
 Inferência: 0.1998 seg

03 - Densenet_Cinza_06102021.pkl



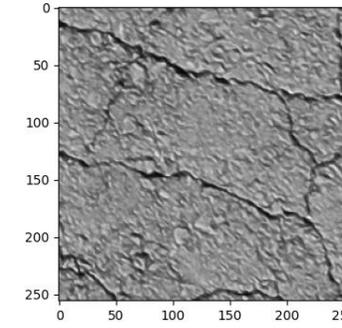
Pred.: Trinca
 Trinca: 88.61%
 Não Trinca: 11.39%
 Inferência: 0.192 seg

03 - Densenet_Cinza_06102021.pkl



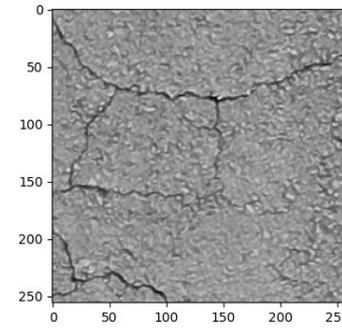
Pred.: Trinca
 Trinca: 95.01%
 Não Trinca: 4.99%
 Inferência: 0.1908 seg

03 - Densenet_Cinza_06102021.pkl



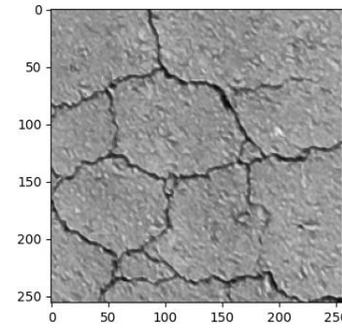
Pred.: Trinca
 Trinca: 99.99%
 Não Trinca: 0.01%
 Inferência: 0.1936 seg

03 - Densenet_Cinza_06102021.pkl



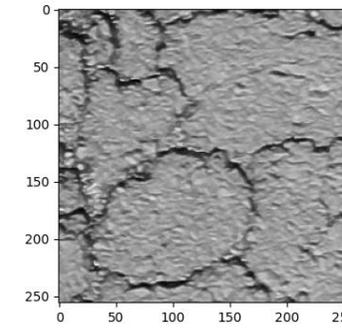
Pred.: Trinca
 Trinca: 99.89%
 Não Trinca: 0.11%
 Inferência: 0.1982 seg

03 - Densenet_Cinza_06102021.pkl

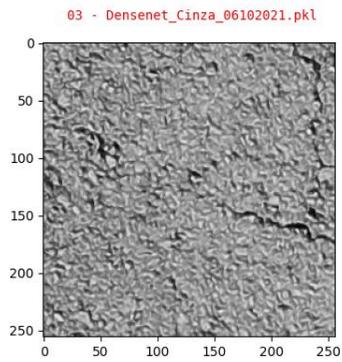


Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.1901 seg

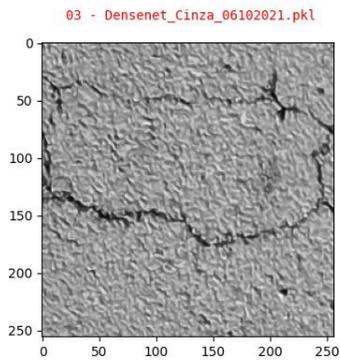
03 - Densenet_Cinza_06102021.pkl



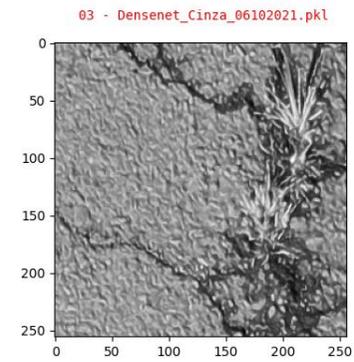
Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.1959 seg



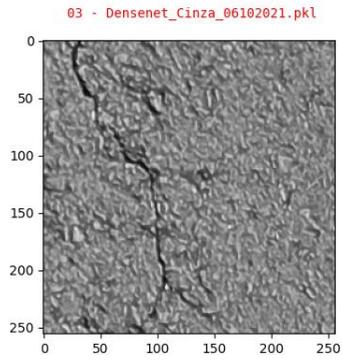
Pred.: Trinca
Trinca: 97.01%
Não Trinca: 2.99%
Inferência: 0.1965 seg



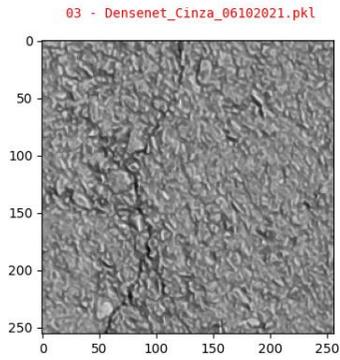
Pred.: Trinca
Trinca: 99.97%
Não Trinca: 0.03%
Inferência: 0.1948 seg



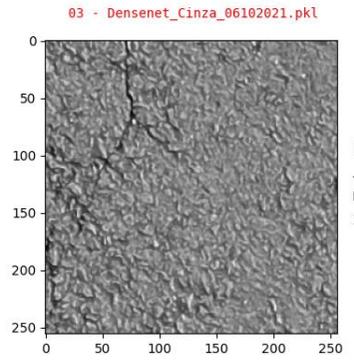
Pred.: Trinca
Trinca: 98.23%
Não Trinca: 1.77%
Inferência: 0.2021 seg



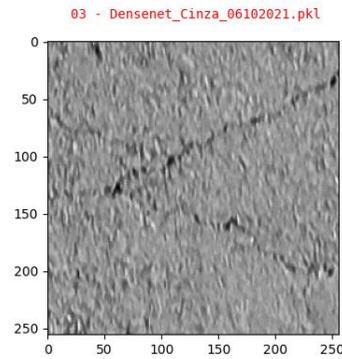
Pred.: Trinca
Trinca: 90.65%
Não Trinca: 9.35%
Inferência: 0.1883 seg



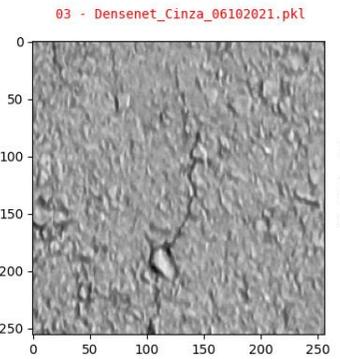
Pred.: Trinca
Trinca: 77.69%
Não Trinca: 22.31%
Inferência: 0.2032 seg



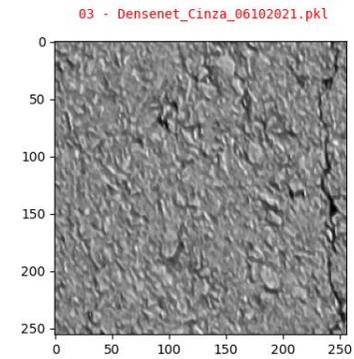
Pred.: Não Trinca
Trinca: 49.60%
Não Trinca: 50.40%
Inferência: 0.1871 seg



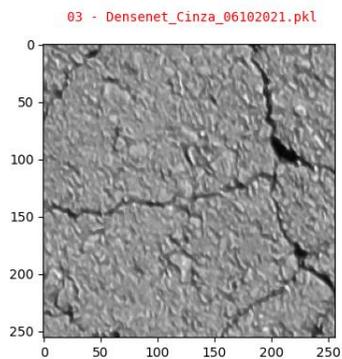
Pred.: Trinca
Trinca: 53.51%
Não Trinca: 46.49%
Inferência: 0.204 seg



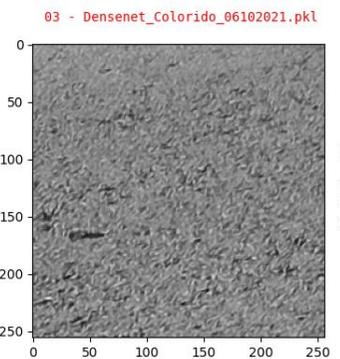
Pred.: Não Trinca
Trinca: 40.46%
Não Trinca: 59.54%
Inferência: 0.1965 seg



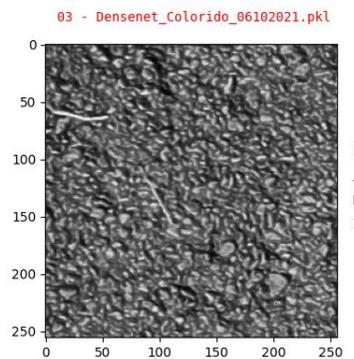
Pred.: Trinca
Trinca: 80.83%
Não Trinca: 19.17%
Inferência: 0.2018 seg



Pred.: Trinca
Trinca: 98.97%
Não Trinca: 1.03%
Inferência: 0.2001 seg

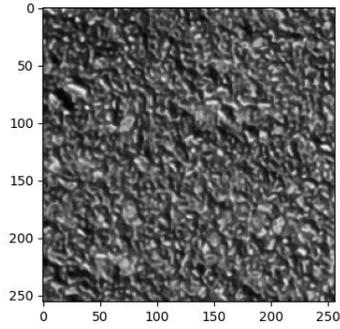


Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2116 seg



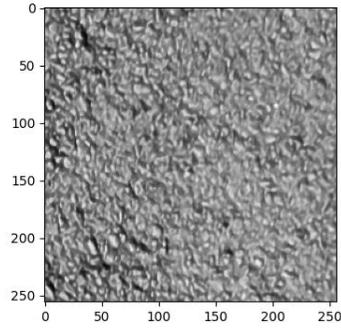
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1928 seg

03 - Densenet_Colorido_06102021.pkl



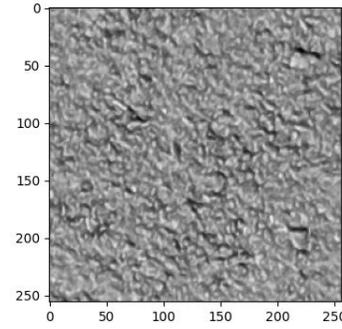
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1942 seg

03 - Densenet_Colorido_06102021.pkl



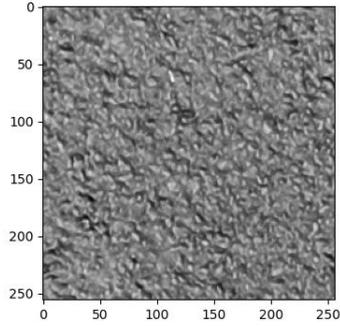
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2007 seg

03 - Densenet_Colorido_06102021.pkl



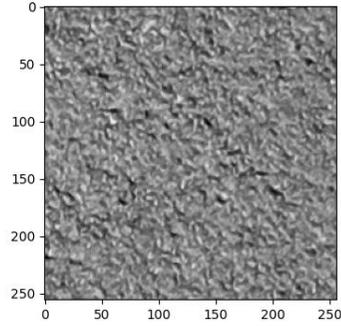
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2065 seg

03 - Densenet_Colorido_06102021.pkl



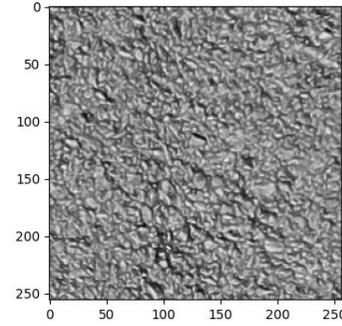
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1942 seg

03 - Densenet_Colorido_06102021.pkl



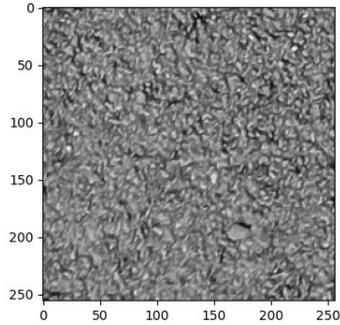
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2012 seg

03 - Densenet_Colorido_06102021.pkl



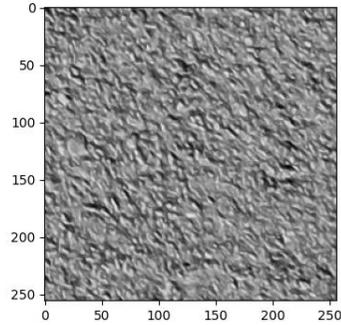
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2107 seg

03 - Densenet_Colorido_06102021.pkl



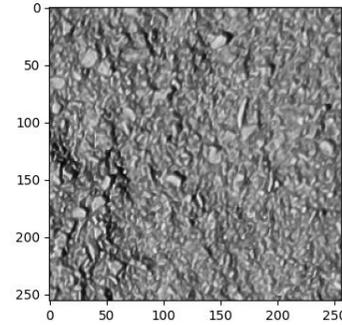
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2027 seg

03 - Densenet_Colorido_06102021.pkl



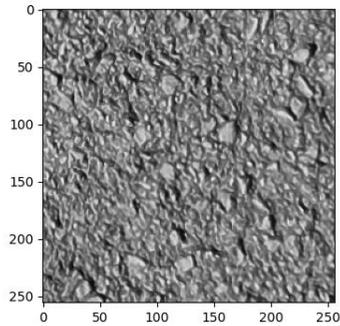
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2 seg

03 - Densenet_Colorido_06102021.pkl



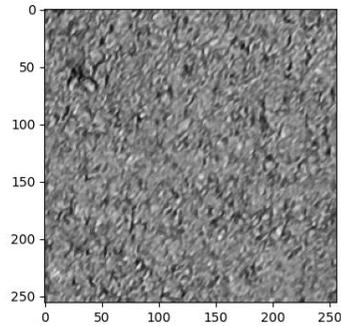
Pred.: Não Trinca
 Trinca: 1.05%
 Não Trinca: 98.95%
 Inferência: 0.1889 seg

03 - Densenet_Colorido_06102021.pkl



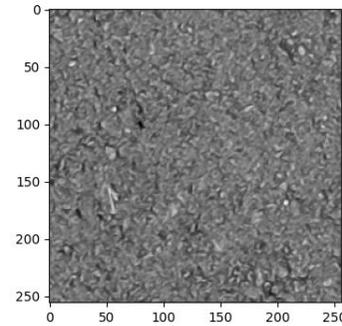
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2006 seg

03 - Densenet_Colorido_06102021.pkl



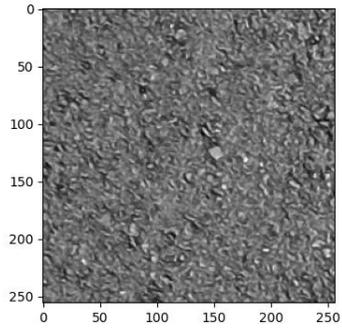
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2026 seg

03 - Densenet_Colorido_06102021.pkl



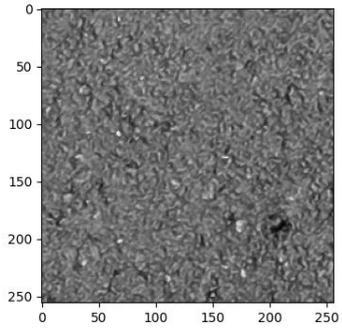
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2003 seg

03 - Densenet_Colorido_06102021.pkl



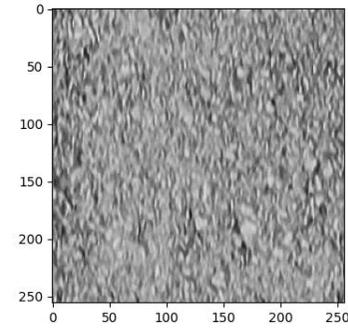
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2081 seg

03 - Densenet_Colorido_06102021.pkl



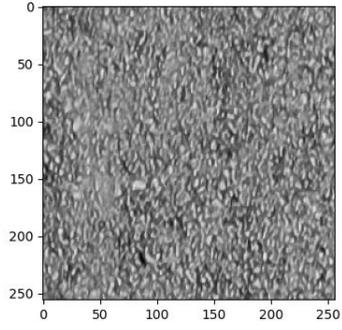
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1982 seg

03 - Densenet_Colorido_06102021.pkl



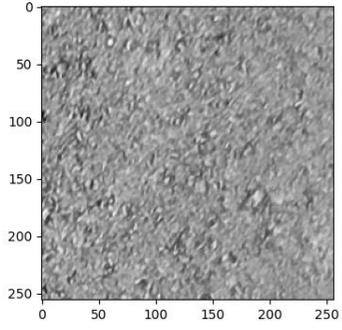
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1982 seg

03 - Densenet_Colorido_06102021.pkl



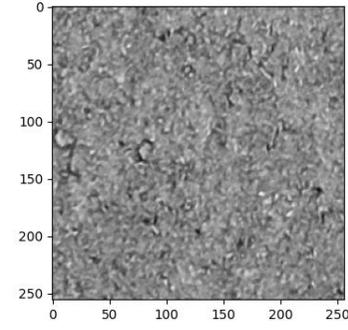
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2109 seg

03 - Densenet_Colorido_06102021.pkl



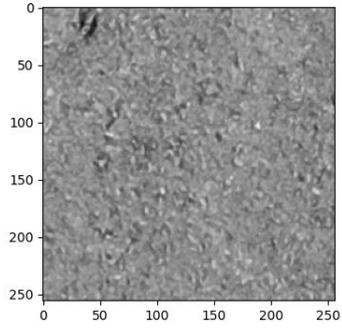
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2024 seg

03 - Densenet_Colorido_06102021.pkl



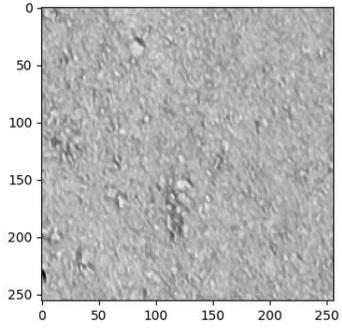
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2066 seg

03 - Densenet_Colorido_06102021.pkl



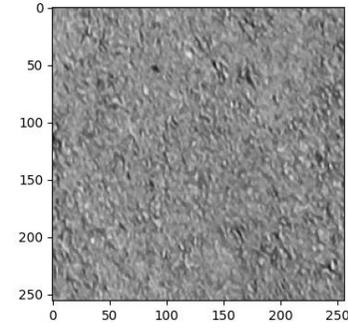
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1978 seg

03 - Densenet_Colorido_06102021.pkl



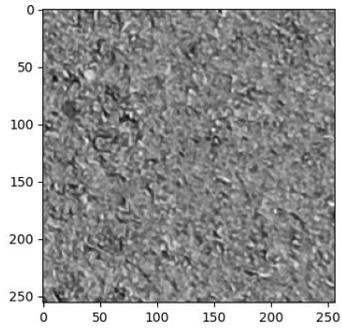
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2174 seg

03 - Densenet_Colorido_06102021.pkl



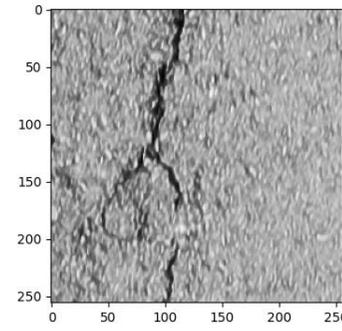
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2088 seg

03 - Densenet_Colorido_06102021.pkl



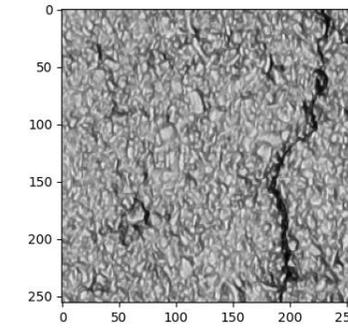
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.1981 seg

03 - Densenet_Colorido_06102021.pkl



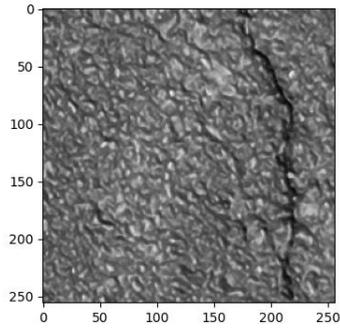
Pred.: Trinca
 Trinca: 92.47%
 Não Trinca: 7.53%
 Inferência: 0.1955 seg

03 - Densenet_Colorido_06102021.pkl



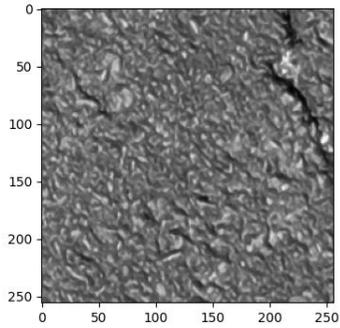
Pred.: Trinca
 Trinca: 68.44%
 Não Trinca: 31.56%
 Inferência: 0.1972 seg

03 - Densenet_Colorido_06102021.pkl



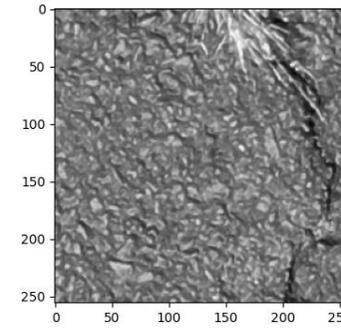
Pred.: Não Trinca
 Trinca: 32.31%
 Não Trinca: 67.69%
 Inferência: 0.2012 seg

03 - Densenet_Colorido_06102021.pkl



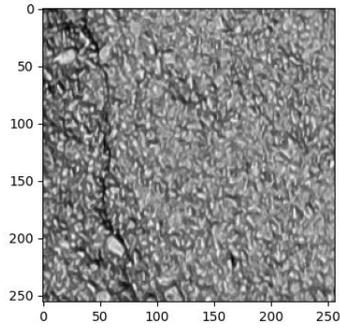
Pred.: Não Trinca
 Trinca: 0.18%
 Não Trinca: 99.82%
 Inferência: 0.2109 seg

03 - Densenet_Colorido_06102021.pkl



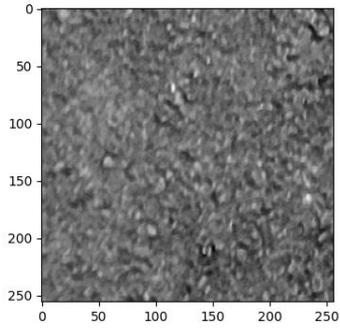
Pred.: Trinca
 Trinca: 72.12%
 Não Trinca: 27.88%
 Inferência: 0.2027 seg

03 - Densenet_Colorido_06102021.pkl



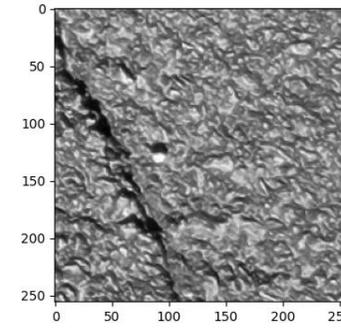
Pred.: Não Trinca
 Trinca: 5.93%
 Não Trinca: 94.07%
 Inferência: 0.1995 seg

03 - Densenet_Colorido_06102021.pkl



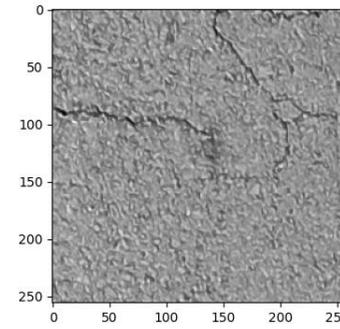
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.2057 seg

03 - Densenet_Colorido_06102021.pkl



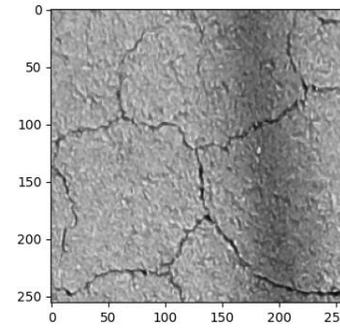
Pred.: Trinca
 Trinca: 94.18%
 Não Trinca: 5.82%
 Inferência: 0.2091 seg

03 - Densenet_Colorido_06102021.pkl



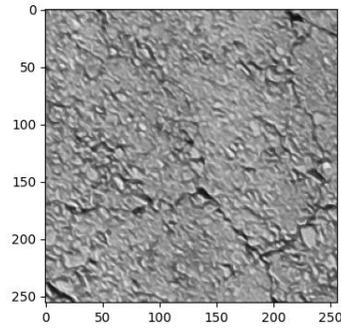
Pred.: Trinca
 Trinca: 65.68%
 Não Trinca: 34.32%
 Inferência: 0.2095 seg

03 - Densenet_Colorido_06102021.pkl



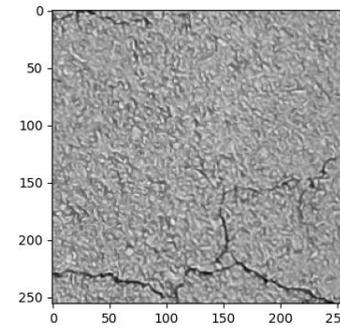
Pred.: Trinca
 Trinca: 99.92%
 Não Trinca: 0.08%
 Inferência: 0.1911 seg

03 - Densenet_Colorido_06102021.pkl



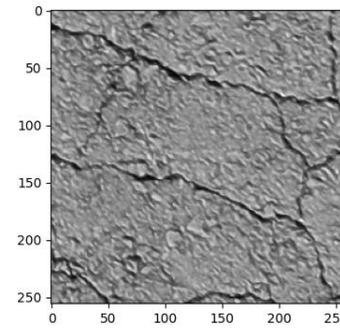
Pred.: Não Trinca
 Trinca: 47.42%
 Não Trinca: 52.58%
 Inferência: 0.1954 seg

03 - Densenet_Colorido_06102021.pkl



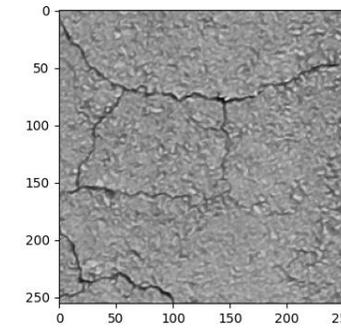
Pred.: Trinca
 Trinca: 94.48%
 Não Trinca: 5.52%
 Inferência: 0.1892 seg

03 - Densenet_Colorido_06102021.pkl



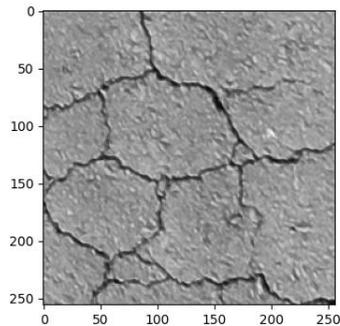
Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.2045 seg

03 - Densenet_Colorido_06102021.pkl



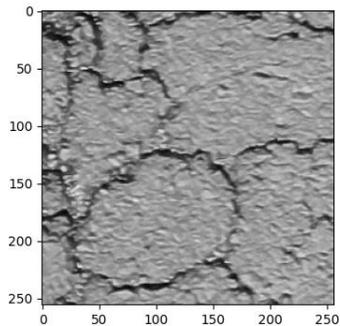
Pred.: Trinca
 Trinca: 99.99%
 Não Trinca: 0.01%
 Inferência: 0.207 seg

03 - Densenet_Colorido_06102021.pkl



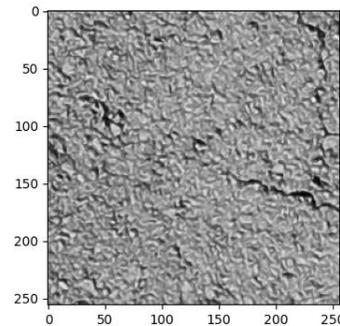
Pred.: Trinca
Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.1965 seg

03 - Densenet_Colorido_06102021.pkl



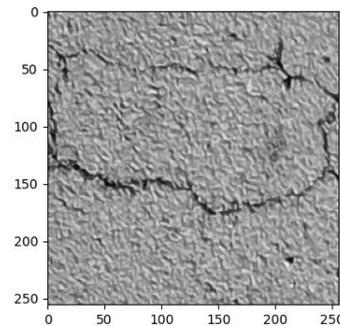
Pred.: Trinca
Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.2204 seg

03 - Densenet_Colorido_06102021.pkl



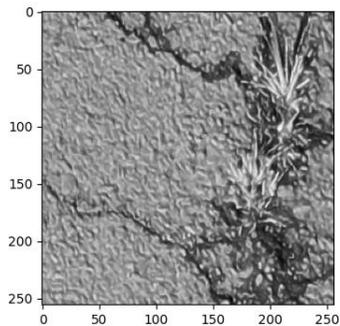
Pred.: Trinca
Trinca: 73.26%
Não Trinca: 26.74%
Inferência: 0.1909 seg

03 - Densenet_Colorido_06102021.pkl



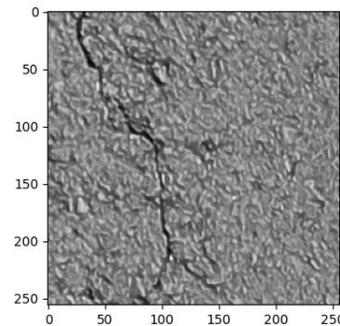
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.203 seg

03 - Densenet_Colorido_06102021.pkl



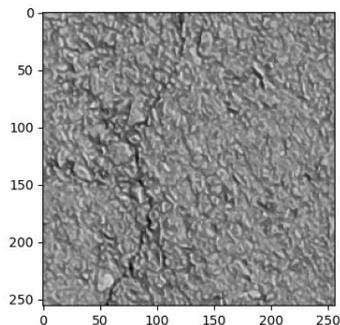
Pred.: Trinca
Trinca: 80.46%
Não Trinca: 19.54%
Inferência: 0.2024 seg

03 - Densenet_Colorido_06102021.pkl



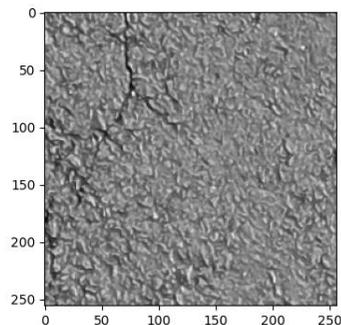
Pred.: Trinca
Trinca: 98.82%
Não Trinca: 1.18%
Inferência: 0.1994 seg

03 - Densenet_Colorido_06102021.pkl



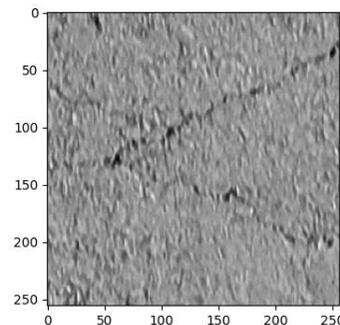
Pred.: Não Trinca
Trinca: 14.07%
Não Trinca: 85.93%
Inferência: 0.2043 seg

03 - Densenet_Colorido_06102021.pkl



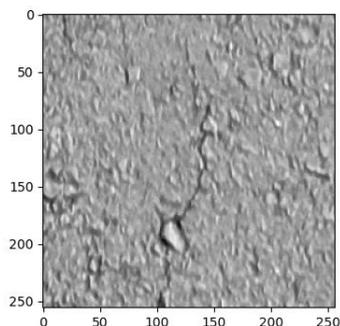
Pred.: Não Trinca
Trinca: 24.28%
Não Trinca: 75.72%
Inferência: 0.214 seg

03 - Densenet_Colorido_06102021.pkl



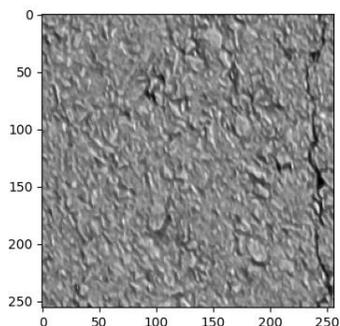
Pred.: Não Trinca
Trinca: 37.28%
Não Trinca: 62.72%
Inferência: 0.2243 seg

03 - Densenet_Colorido_06102021.pkl



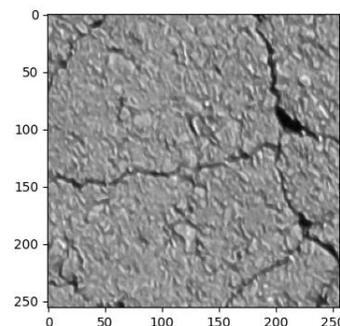
Pred.: Não Trinca
Trinca: 5.25%
Não Trinca: 94.75%
Inferência: 0.203 seg

03 - Densenet_Colorido_06102021.pkl



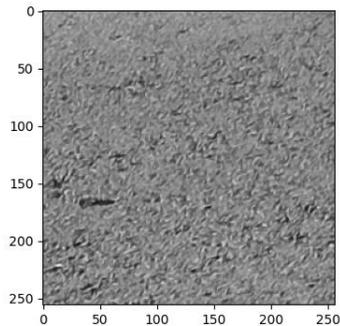
Pred.: Trinca
Trinca: 94.89%
Não Trinca: 5.11%
Inferência: 0.2009 seg

03 - Densenet_Colorido_06102021.pkl



Pred.: Trinca
Trinca: 99.94%
Não Trinca: 0.06%
Inferência: 0.1924 seg

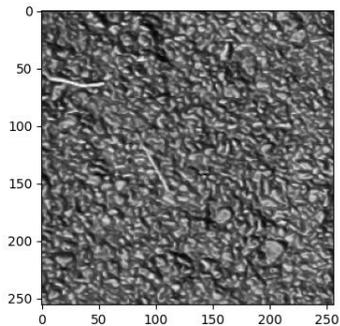
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.04%
Não Trinca: 99.96%
Inferência: 0.0449 seg

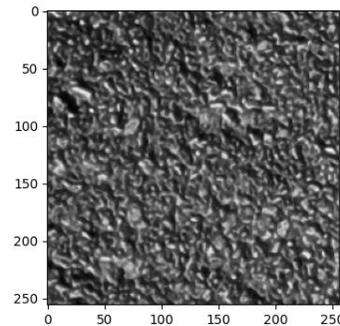
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.60%
Não Trinca: 99.40%
Inferência: 0.0466 seg

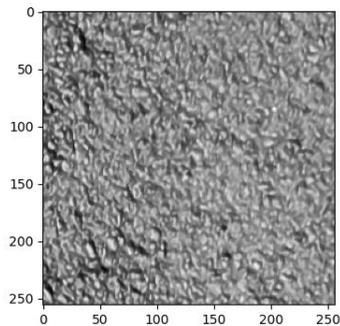
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.41%
Não Trinca: 99.59%
Inferência: 0.057 seg

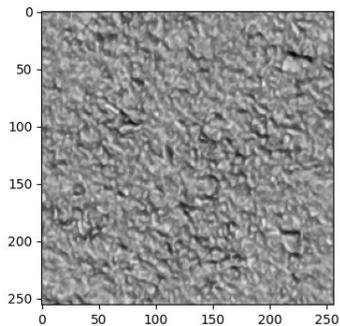
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.17%
Não Trinca: 99.83%
Inferência: 0.0446 seg

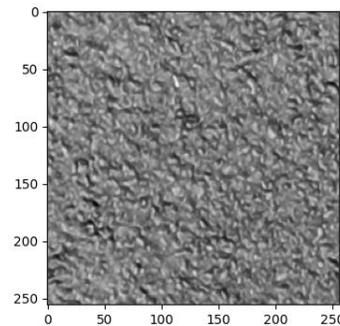
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0453 seg

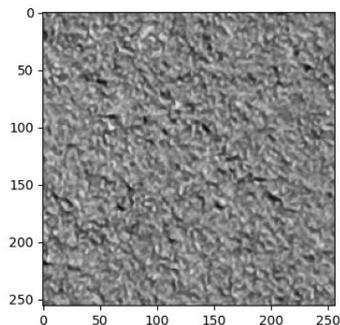
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.0481 seg

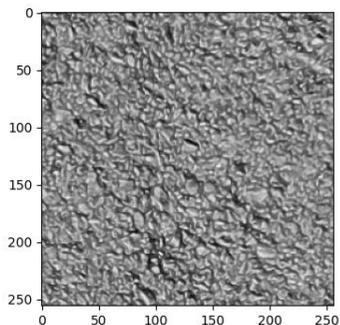
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0483 seg

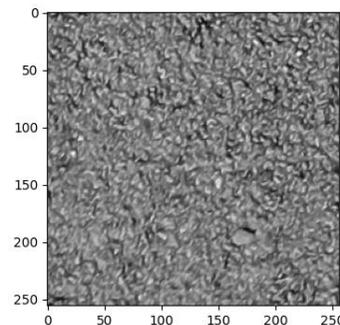
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 1.91%
Não Trinca: 98.09%
Inferência: 0.0509 seg

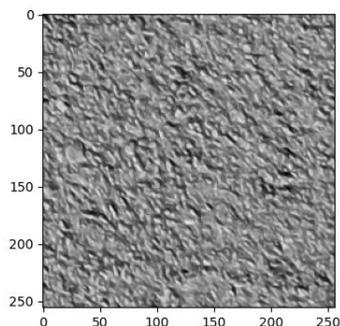
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0445 seg

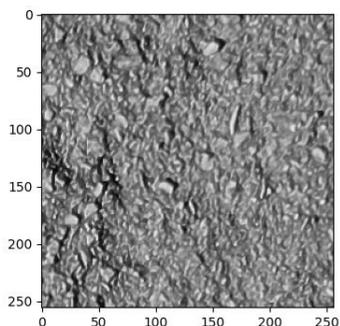
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0474 seg

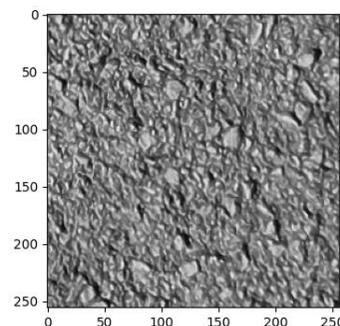
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 8.07%
Não Trinca: 91.93%
Inferência: 0.0443 seg

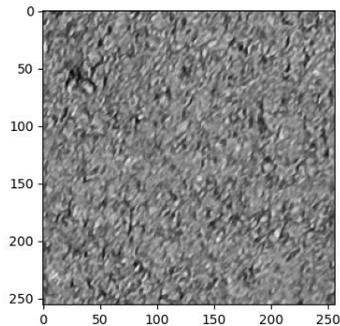
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 1.97%
Não Trinca: 98.03%
Inferência: 0.0442 seg

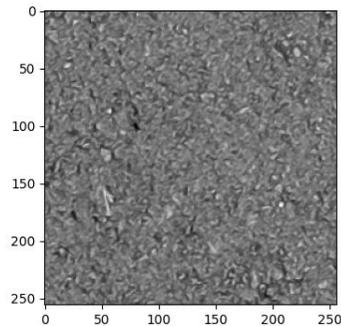
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.06%
Não Trinca: 99.94%
Inferência: 0.0444 seg

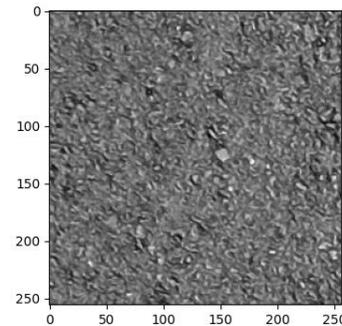
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.04%
Não Trinca: 99.96%
Inferência: 0.0472 seg

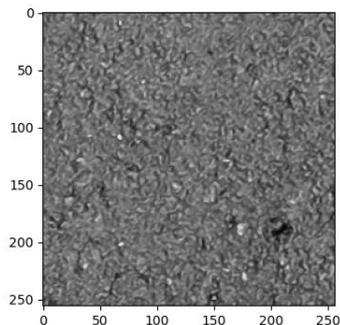
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.0474 seg

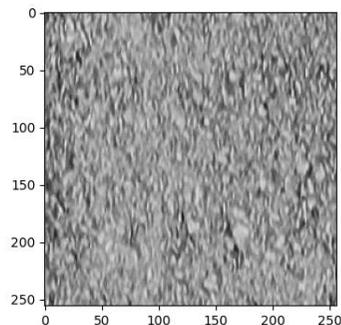
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.0463 seg

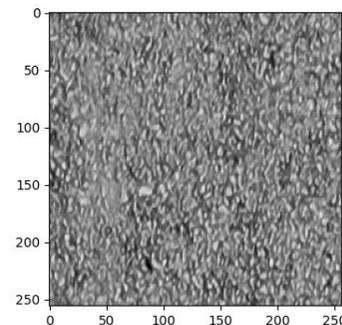
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.0438 seg

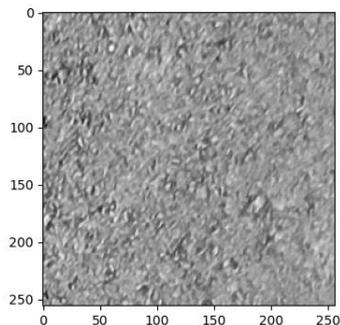
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.08%
Não Trinca: 99.92%
Inferência: 0.0449 seg

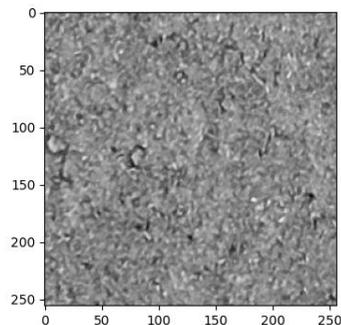
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0429 seg

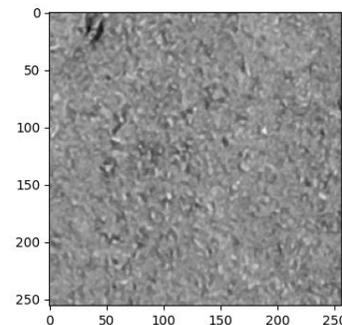
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0456 seg

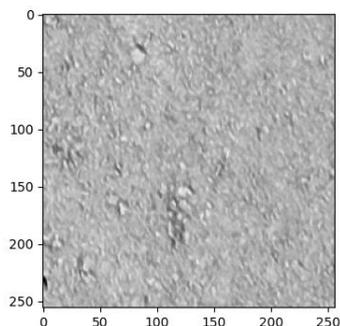
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0443 seg

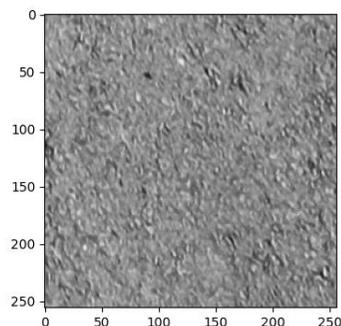
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.05%
Não Trinca: 99.95%
Inferência: 0.0459 seg

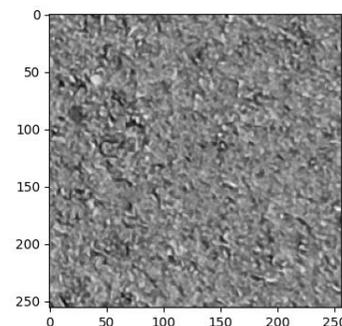
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0466 seg

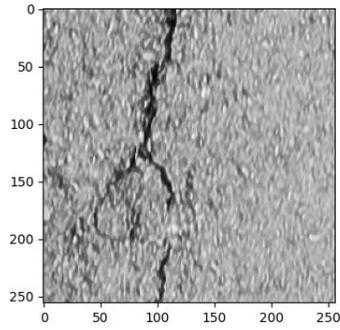
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.19%
Não Trinca: 99.81%
Inferência: 0.0455 seg

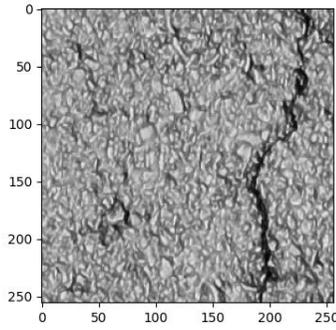
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Trinca

Trinca: 54.91%
Não Trinca: 45.09%
Inferência: 0.0518 seg

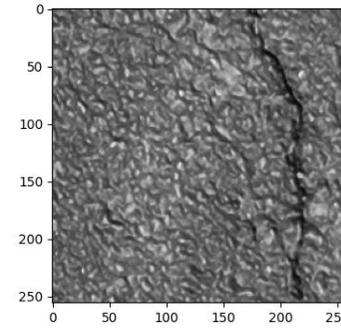
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 27.14%
Não Trinca: 72.86%
Inferência: 0.0455 seg

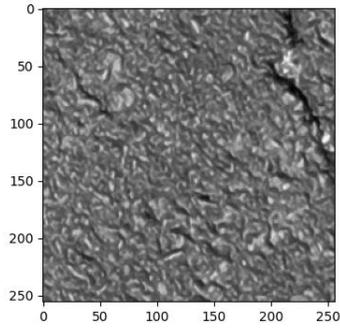
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 14.12%
Não Trinca: 85.88%
Inferência: 0.0435 seg

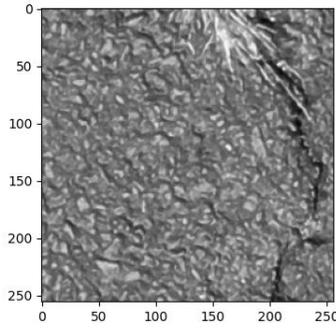
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 15.04%
Não Trinca: 84.96%
Inferência: 0.0447 seg

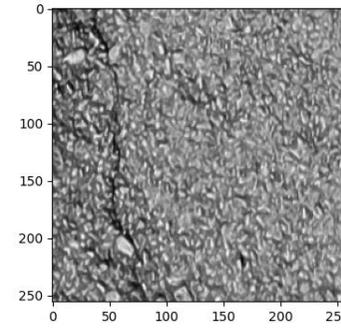
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 4.11%
Não Trinca: 95.89%
Inferência: 0.045 seg

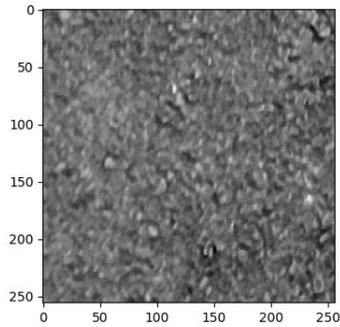
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 5.78%
Não Trinca: 94.22%
Inferência: 0.0462 seg

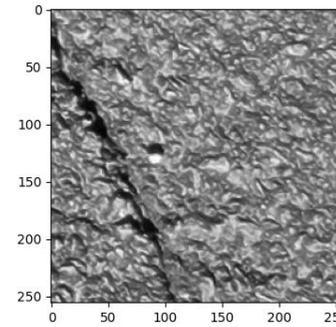
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0536 seg

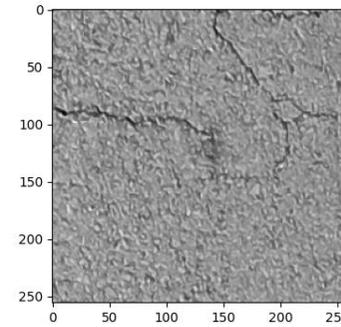
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Trinca

Trinca: 82.02%
Não Trinca: 17.98%
Inferência: 0.0547 seg

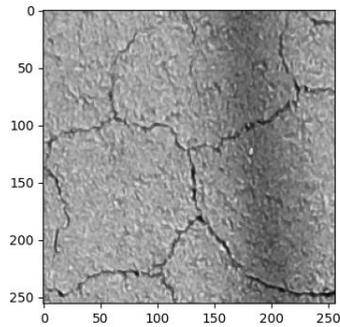
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 6.50%
Não Trinca: 93.50%
Inferência: 0.0446 seg

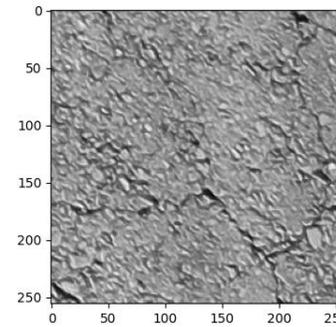
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Trinca

Trinca: 99.75%
Não Trinca: 0.25%
Inferência: 0.0456 seg

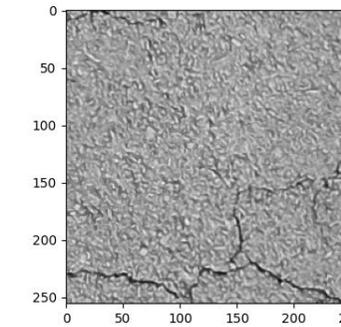
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Trinca

Trinca: 51.30%
Não Trinca: 48.70%
Inferência: 0.0446 seg

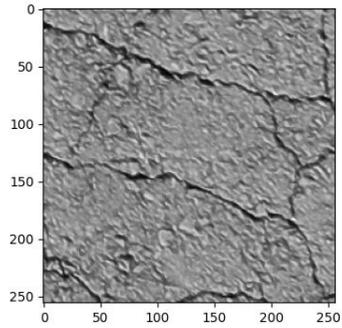
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Trinca

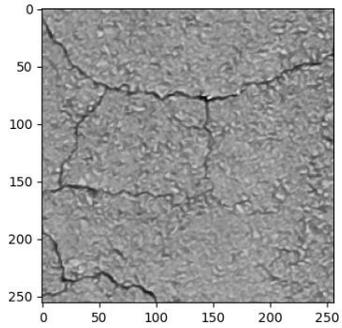
Trinca: 99.17%
Não Trinca: 0.83%
Inferência: 0.054 seg

04 - Squeeze1_1_Cinza_06102021.pkl



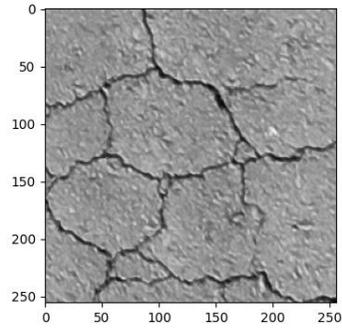
Pred.: Trinca
 Trinca: 99.96%
 Não Trinca: 0.04%
 Inferência: 0.0476 seg

04 - Squeeze1_1_Cinza_06102021.pkl



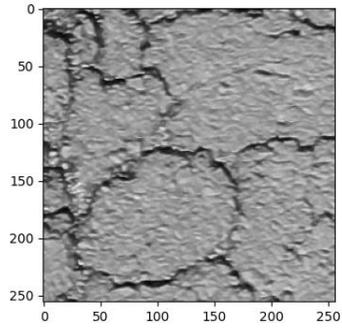
Pred.: Trinca
 Trinca: 99.93%
 Não Trinca: 0.07%
 Inferência: 0.0577 seg

04 - Squeeze1_1_Cinza_06102021.pkl



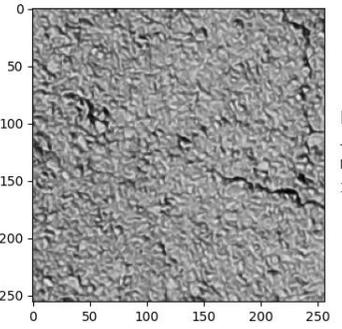
Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.044 seg

04 - Squeeze1_1_Cinza_06102021.pkl



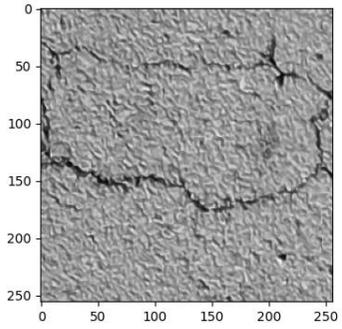
Pred.: Trinca
 Trinca: 99.97%
 Não Trinca: 0.03%
 Inferência: 0.0504 seg

04 - Squeeze1_1_Cinza_06102021.pkl



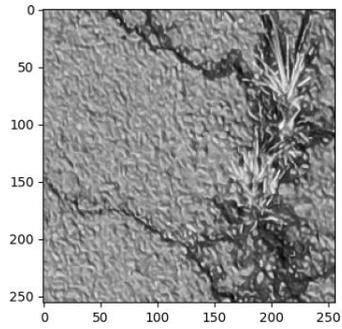
Pred.: Não Trinca
 Trinca: 8.50%
 Não Trinca: 91.50%
 Inferência: 0.0449 seg

04 - Squeeze1_1_Cinza_06102021.pkl



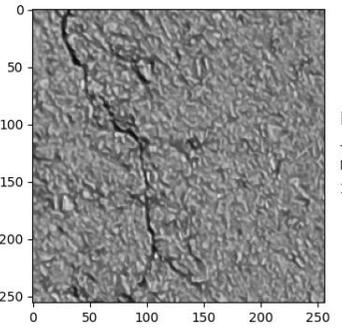
Pred.: Trinca
 Trinca: 92.37%
 Não Trinca: 7.63%
 Inferência: 0.0457 seg

04 - Squeeze1_1_Cinza_06102021.pkl



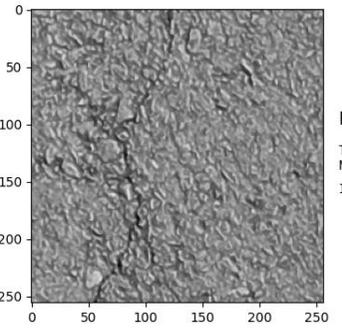
Pred.: Trinca
 Trinca: 96.35%
 Não Trinca: 3.65%
 Inferência: 0.0462 seg

04 - Squeeze1_1_Cinza_06102021.pkl



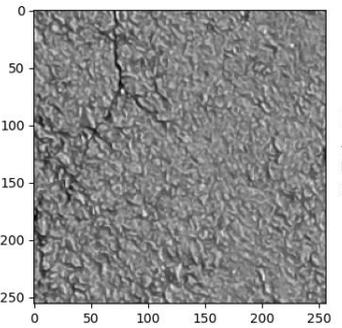
Pred.: Não Trinca
 Trinca: 39.36%
 Não Trinca: 60.64%
 Inferência: 0.0444 seg

04 - Squeeze1_1_Cinza_06102021.pkl



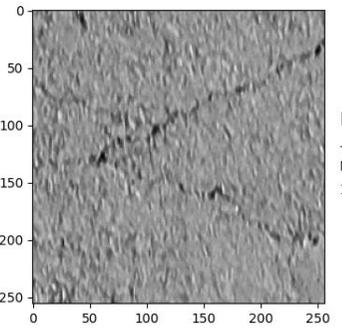
Pred.: Não Trinca
 Trinca: 0.07%
 Não Trinca: 99.93%
 Inferência: 0.0502 seg

04 - Squeeze1_1_Cinza_06102021.pkl



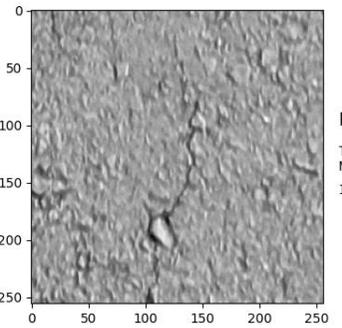
Pred.: Não Trinca
 Trinca: 35.69%
 Não Trinca: 64.31%
 Inferência: 0.0465 seg

04 - Squeeze1_1_Cinza_06102021.pkl



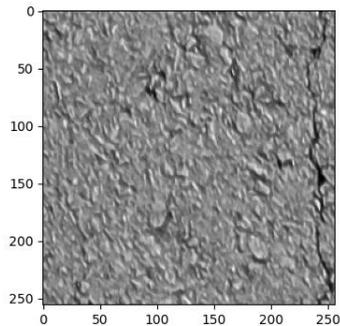
Pred.: Não Trinca
 Trinca: 2.74%
 Não Trinca: 97.26%
 Inferência: 0.0454 seg

04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca
 Trinca: 7.35%
 Não Trinca: 92.65%
 Inferência: 0.0449 seg

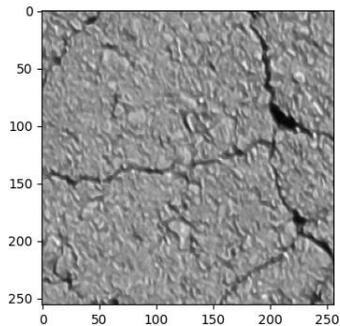
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Não Trinca

Trinca: 8.48%
Não Trinca: 91.52%
Inferência: 0.049 seg

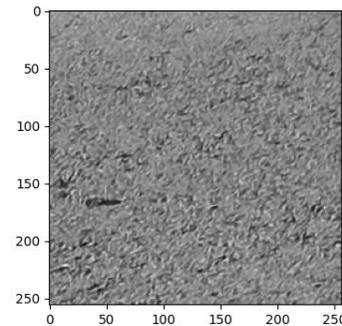
04 - Squeeze1_1_Cinza_06102021.pkl



Pred.: Trinca

Trinca: 68.97%
Não Trinca: 31.03%
Inferência: 0.0445 seg

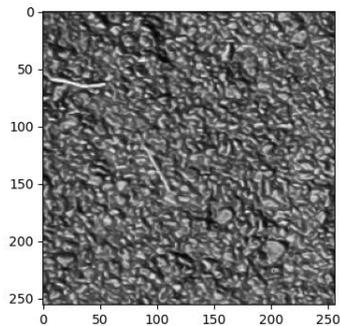
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.065 seg

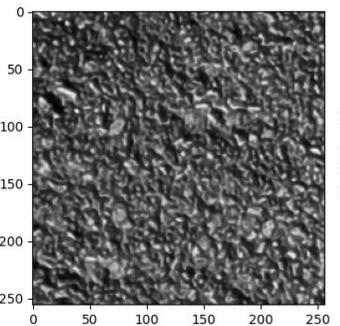
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 7.03%
Não Trinca: 92.97%
Inferência: 0.0635 seg

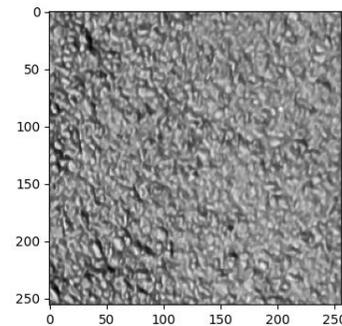
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.10%
Não Trinca: 99.90%
Inferência: 0.0679 seg

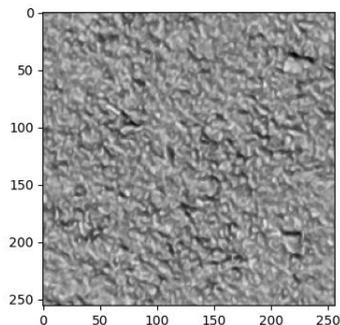
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 4.79%
Não Trinca: 95.21%
Inferência: 0.064 seg

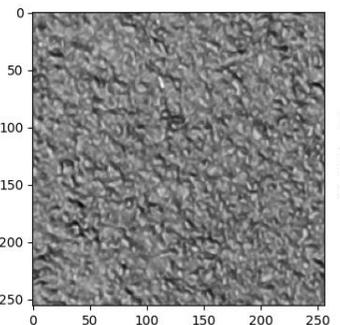
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 2.01%
Não Trinca: 97.99%
Inferência: 0.0556 seg

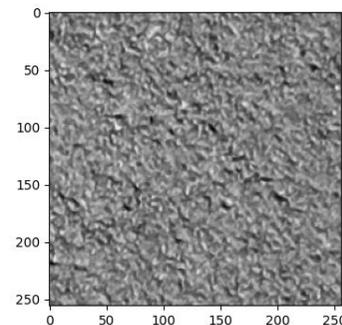
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.20%
Não Trinca: 99.80%
Inferência: 0.0643 seg

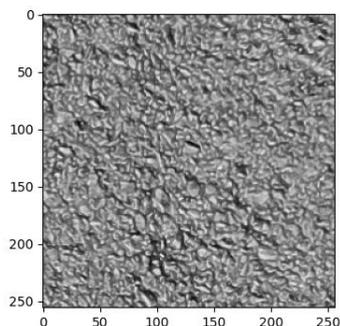
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.063 seg

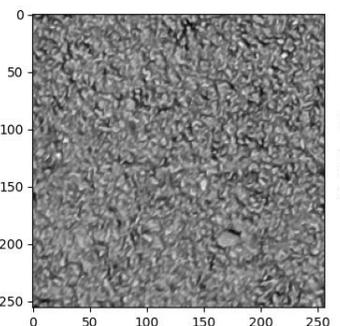
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 14.53%
Não Trinca: 85.47%
Inferência: 0.0627 seg

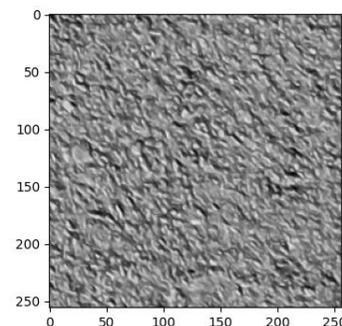
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0638 seg

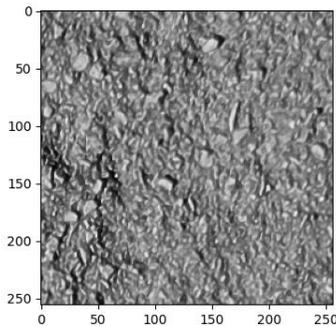
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

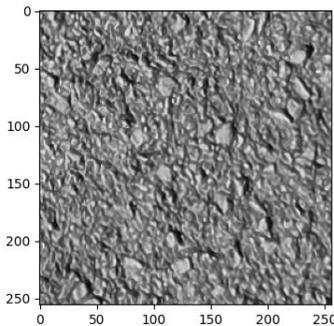
Trinca: 0.04%
Não Trinca: 99.96%
Inferência: 0.0627 seg

04 - Squeeze1_1_Colorido_06102021.pkl



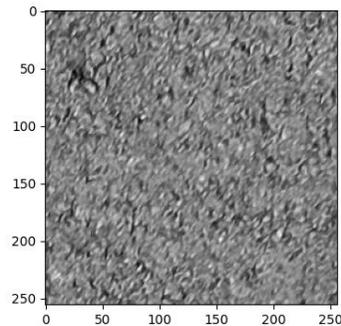
Pred.: Não Trinca
Trinca: 10.76%
Não Trinca: 89.24%
Inferência: 0.0696 seg

04 - Squeeze1_1_Colorido_06102021.pkl



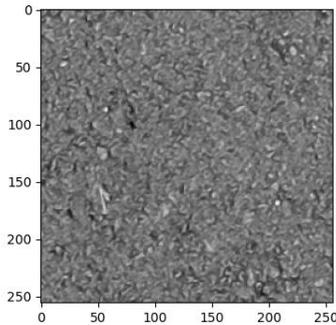
Pred.: Não Trinca
Trinca: 1.22%
Não Trinca: 98.78%
Inferência: 0.0637 seg

04 - Squeeze1_1_Colorido_06102021.pkl



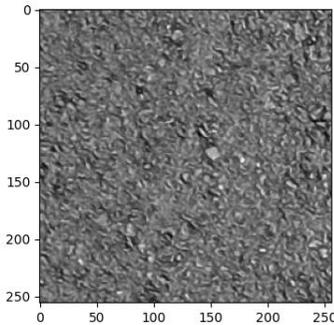
Pred.: Não Trinca
Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.07 seg

04 - Squeeze1_1_Colorido_06102021.pkl



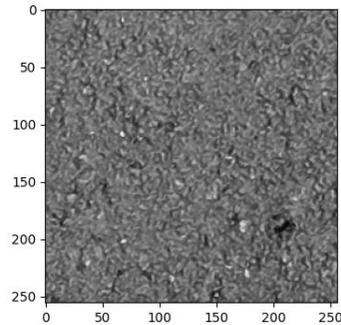
Pred.: Não Trinca
Trinca: 0.06%
Não Trinca: 99.94%
Inferência: 0.0688 seg

04 - Squeeze1_1_Colorido_06102021.pkl



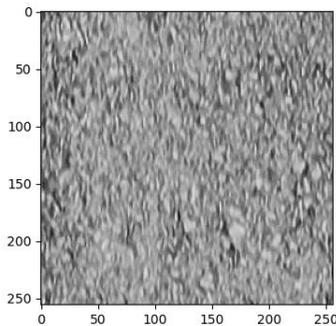
Pred.: Não Trinca
Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.0691 seg

04 - Squeeze1_1_Colorido_06102021.pkl



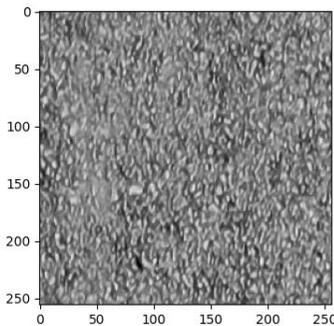
Pred.: Não Trinca
Trinca: 0.08%
Não Trinca: 99.92%
Inferência: 0.0651 seg

04 - Squeeze1_1_Colorido_06102021.pkl



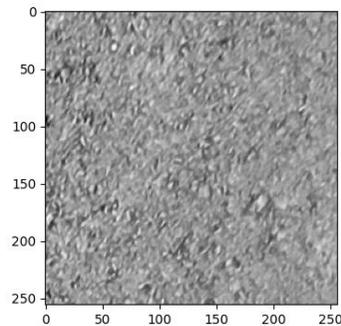
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0653 seg

04 - Squeeze1_1_Colorido_06102021.pkl



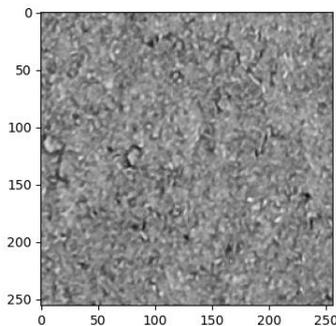
Pred.: Não Trinca
Trinca: 0.42%
Não Trinca: 99.58%
Inferência: 0.0955 seg

04 - Squeeze1_1_Colorido_06102021.pkl



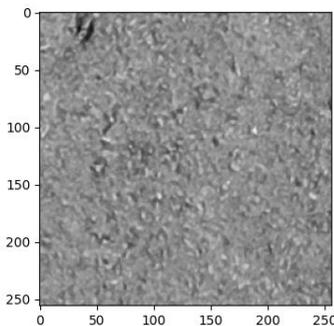
Pred.: Não Trinca
Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0741 seg

04 - Squeeze1_1_Colorido_06102021.pkl



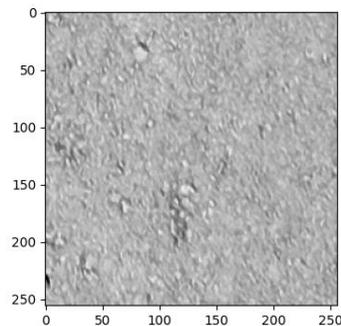
Pred.: Não Trinca
Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0658 seg

04 - Squeeze1_1_Colorido_06102021.pkl



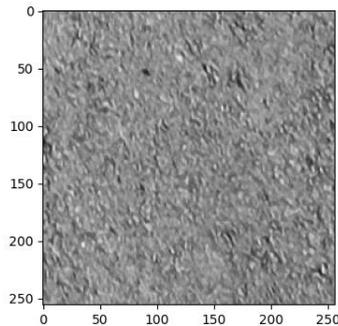
Pred.: Não Trinca
Trinca: 0.12%
Não Trinca: 99.88%
Inferência: 0.0681 seg

04 - Squeeze1_1_Colorido_06102021.pkl



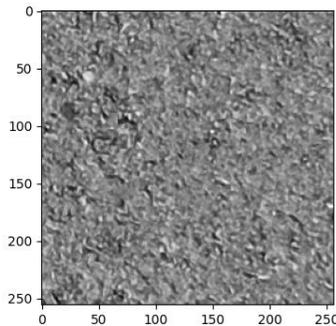
Pred.: Não Trinca
Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.0677 seg

04 - Squeeze1_1_Colorido_06102021.pkl



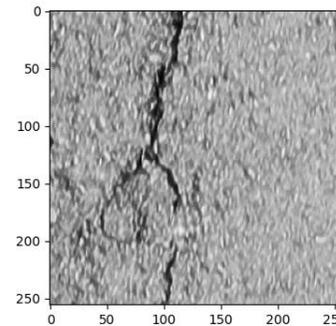
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.066 seg

04 - Squeeze1_1_Colorido_06102021.pkl



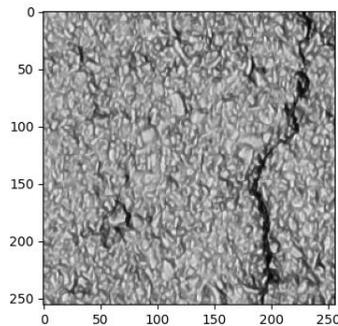
Pred.: Não Trinca
Trinca: 2.67%
Não Trinca: 97.33%
Inferência: 0.0757 seg

04 - Squeeze1_1_Colorido_06102021.pkl



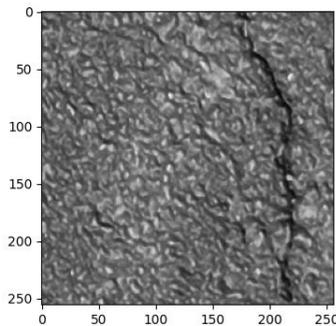
Pred.: Trinca
Trinca: 65.89%
Não Trinca: 34.11%
Inferência: 0.0681 seg

04 - Squeeze1_1_Colorido_06102021.pkl



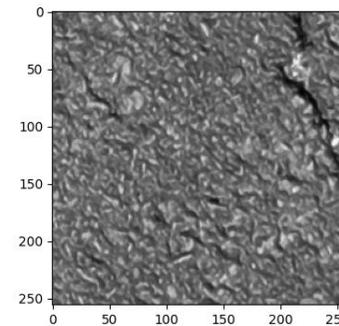
Pred.: Trinca
Trinca: 60.98%
Não Trinca: 39.02%
Inferência: 0.0632 seg

04 - Squeeze1_1_Colorido_06102021.pkl



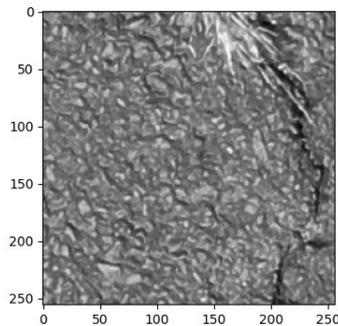
Pred.: Não Trinca
Trinca: 5.98%
Não Trinca: 94.02%
Inferência: 0.0616 seg

04 - Squeeze1_1_Colorido_06102021.pkl



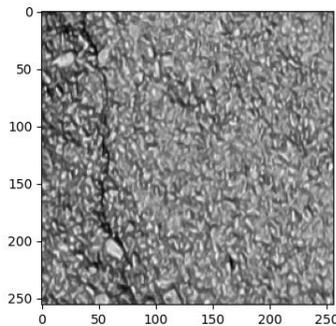
Pred.: Não Trinca
Trinca: 4.79%
Não Trinca: 95.21%
Inferência: 0.0678 seg

04 - Squeeze1_1_Colorido_06102021.pkl



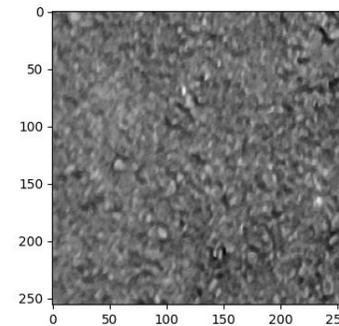
Pred.: Não Trinca
Trinca: 24.51%
Não Trinca: 75.49%
Inferência: 0.0675 seg

04 - Squeeze1_1_Colorido_06102021.pkl



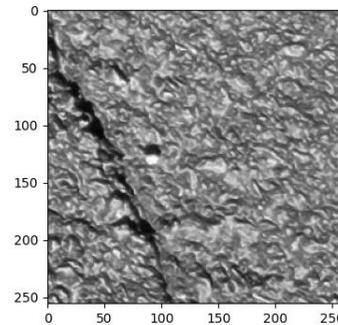
Pred.: Não Trinca
Trinca: 12.17%
Não Trinca: 87.83%
Inferência: 0.0642 seg

04 - Squeeze1_1_Colorido_06102021.pkl



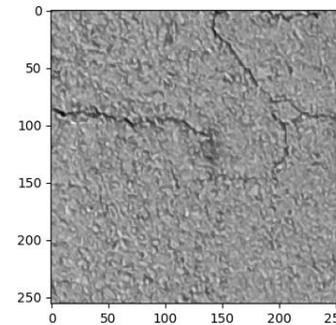
Pred.: Não Trinca
Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.07 seg

04 - Squeeze1_1_Colorido_06102021.pkl



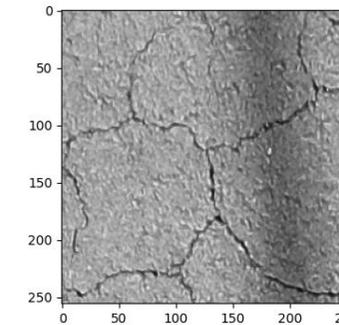
Pred.: Trinca
Trinca: 82.07%
Não Trinca: 17.93%
Inferência: 0.065 seg

04 - Squeeze1_1_Colorido_06102021.pkl



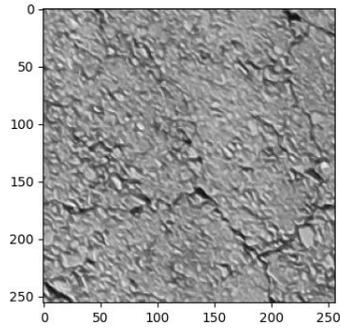
Pred.: Trinca
Trinca: 84.39%
Não Trinca: 15.61%
Inferência: 0.0732 seg

04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca
Trinca: 99.96%
Não Trinca: 0.04%
Inferência: 0.0732 seg

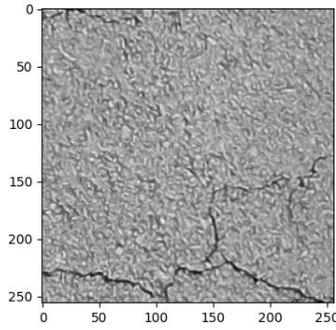
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 82.13%
Não Trinca: 17.87%
Inferência: 0.0624 seg

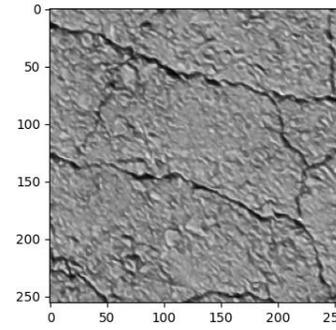
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 96.86%
Não Trinca: 3.14%
Inferência: 0.0638 seg

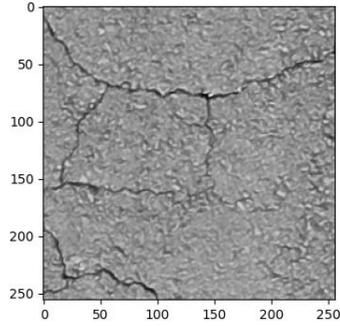
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.0821 seg

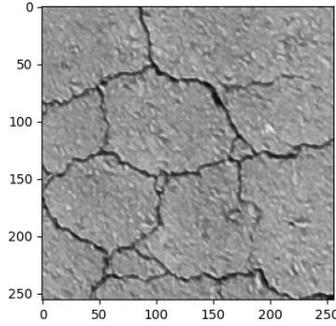
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 97.20%
Não Trinca: 2.80%
Inferência: 0.0634 seg

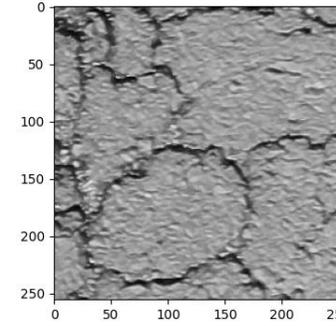
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.0761 seg

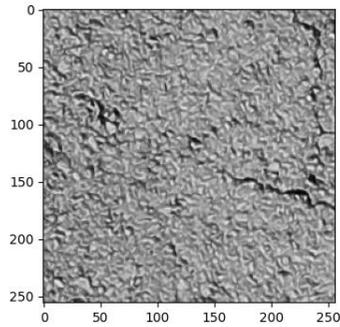
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.062 seg

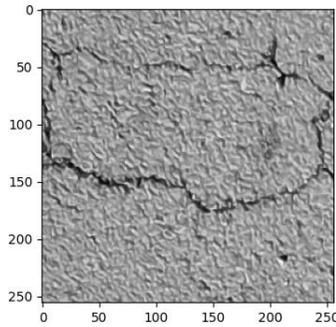
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 93.67%
Não Trinca: 6.33%
Inferência: 0.0758 seg

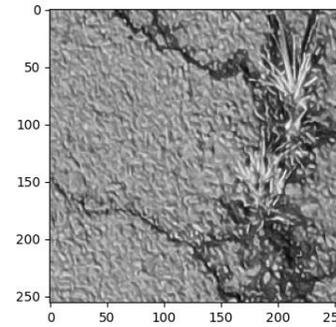
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.0736 seg

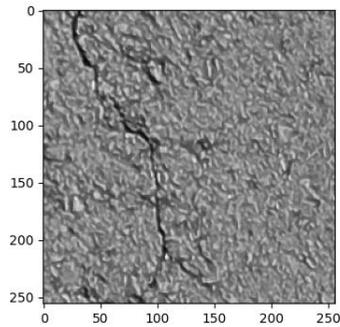
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 85.28%
Não Trinca: 14.72%
Inferência: 0.0627 seg

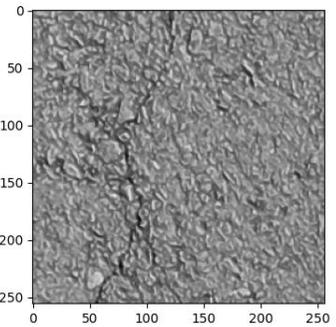
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 82.12%
Não Trinca: 17.88%
Inferência: 0.0663 seg

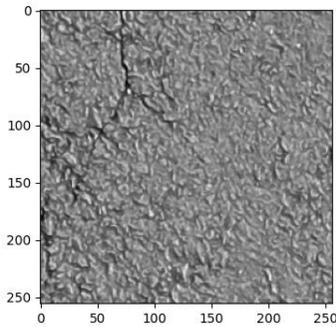
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 3.16%
Não Trinca: 96.84%
Inferência: 0.0792 seg

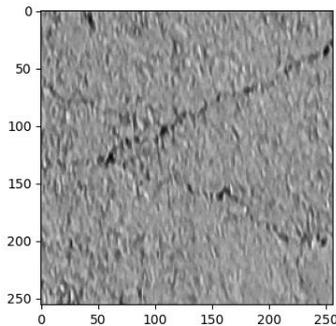
04 - Squeeze1_1_Colorido_06102021.pkl



Pred.: Não Trinca

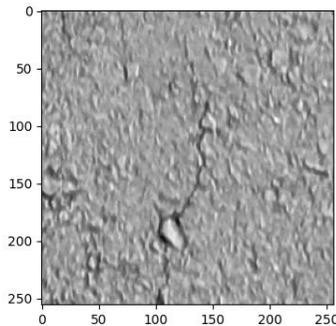
Trinca: 12.91%
Não Trinca: 87.09%
Inferência: 0.0626 seg

04 - Squeeze1_1_Colorido_06102021.pkl



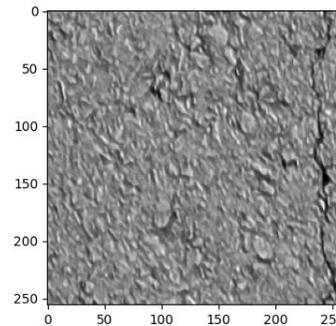
Pred.: Não Trinca
Trinca: 46.22%
Não Trinca: 53.78%
Inferência: 0.0764 seg

04 - Squeeze1_1_Colorido_06102021.pkl



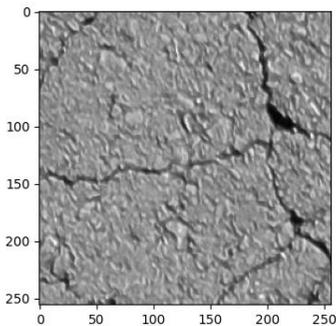
Pred.: Não Trinca
Trinca: 25.06%
Não Trinca: 74.94%
Inferência: 0.065 seg

04 - Squeeze1_1_Colorido_06102021.pkl



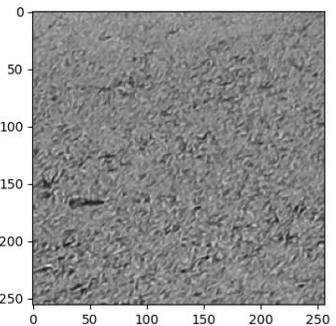
Pred.: Não Trinca
Trinca: 44.42%
Não Trinca: 55.58%
Inferência: 0.066 seg

04 - Squeeze1_1_Colorido_06102021.pkl



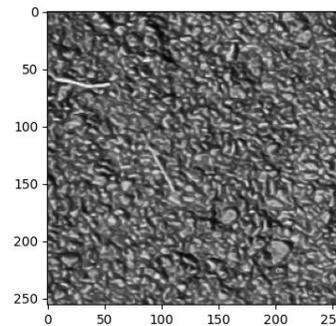
Pred.: Trinca
Trinca: 98.22%
Não Trinca: 1.78%
Inferência: 0.0623 seg

05 - VGG19_Cinza_05102021.pkl



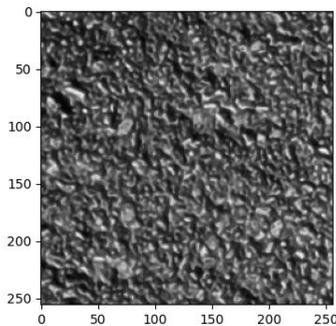
Pred.: Não Trinca
Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.0842 seg

05 - VGG19_Cinza_05102021.pkl



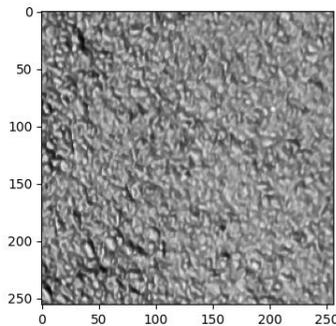
Pred.: Não Trinca
Trinca: 0.67%
Não Trinca: 99.33%
Inferência: 0.0797 seg

05 - VGG19_Cinza_05102021.pkl



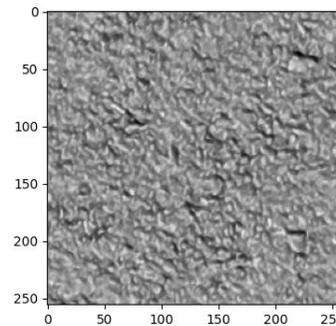
Pred.: Não Trinca
Trinca: 1.10%
Não Trinca: 98.90%
Inferência: 0.0785 seg

05 - VGG19_Cinza_05102021.pkl



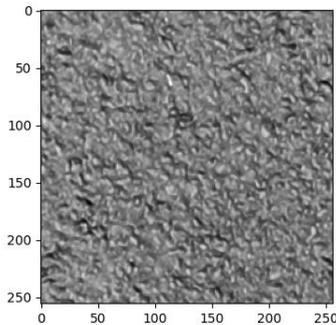
Pred.: Não Trinca
Trinca: 0.15%
Não Trinca: 99.85%
Inferência: 0.0801 seg

05 - VGG19_Cinza_05102021.pkl



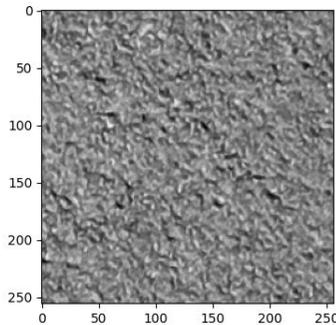
Pred.: Não Trinca
Trinca: 0.13%
Não Trinca: 99.87%
Inferência: 0.08 seg

05 - VGG19_Cinza_05102021.pkl



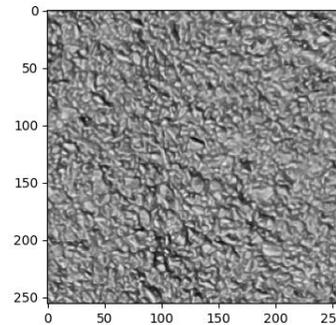
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0866 seg

05 - VGG19_Cinza_05102021.pkl

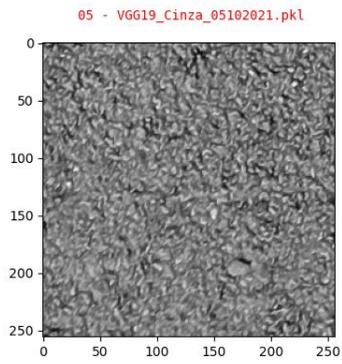


Pred.: Não Trinca
Trinca: 0.04%
Não Trinca: 99.96%
Inferência: 0.0785 seg

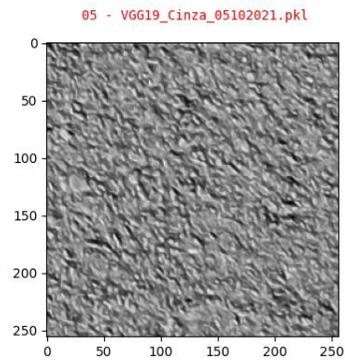
05 - VGG19_Cinza_05102021.pkl



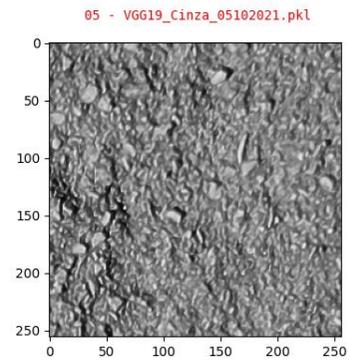
Pred.: Não Trinca
Trinca: 1.34%
Não Trinca: 98.66%
Inferência: 0.0789 seg



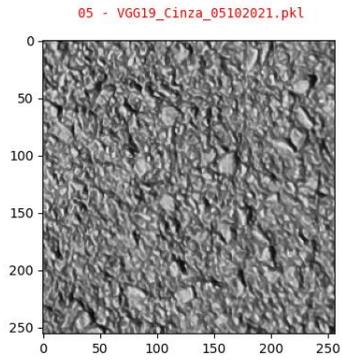
Pred.: Não Trinca
Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0798 seg



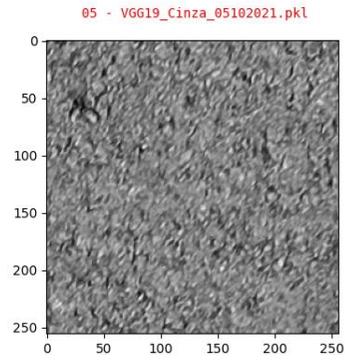
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0791 seg



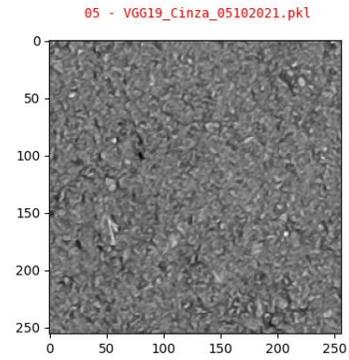
Pred.: Não Trinca
Trinca: 27.28%
Não Trinca: 72.72%
Inferência: 0.0788 seg



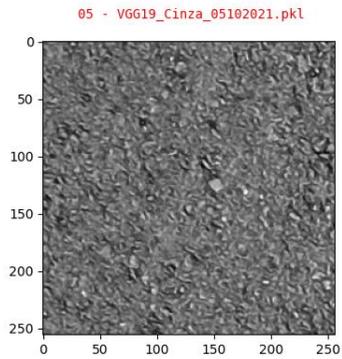
Pred.: Não Trinca
Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0822 seg



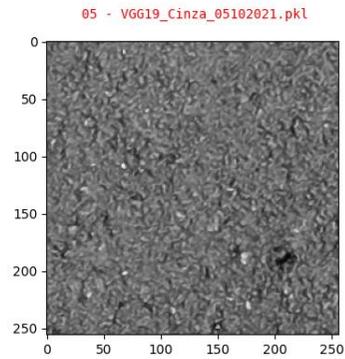
Pred.: Não Trinca
Trinca: 0.06%
Não Trinca: 99.94%
Inferência: 0.079 seg



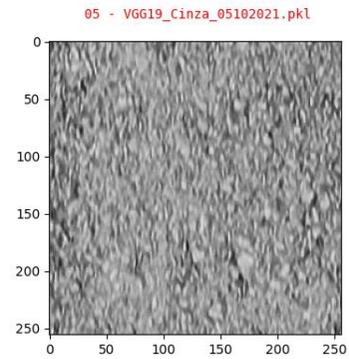
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0827 seg



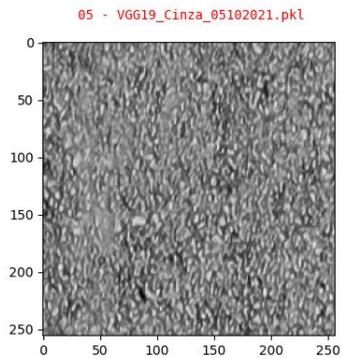
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0786 seg



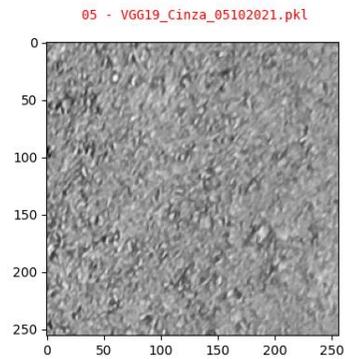
Pred.: Não Trinca
Trinca: 0.06%
Não Trinca: 99.94%
Inferência: 0.0791 seg



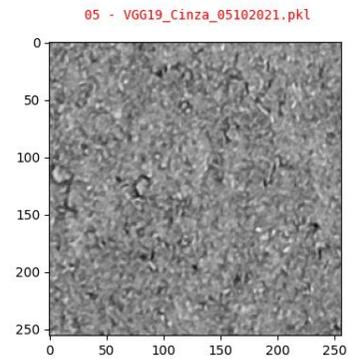
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0808 seg



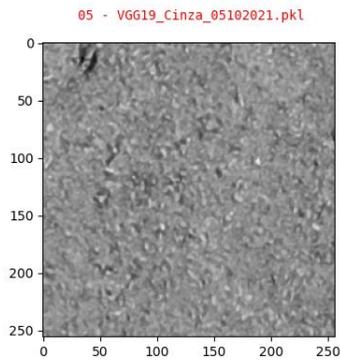
Pred.: Não Trinca
Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.0827 seg



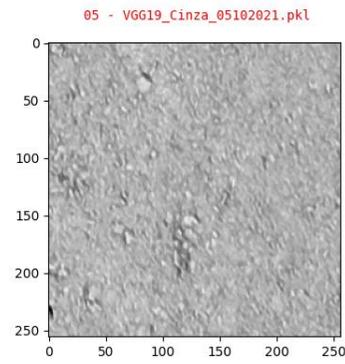
Pred.: Não Trinca
Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.079 seg



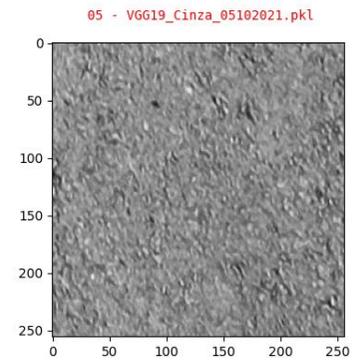
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0785 seg



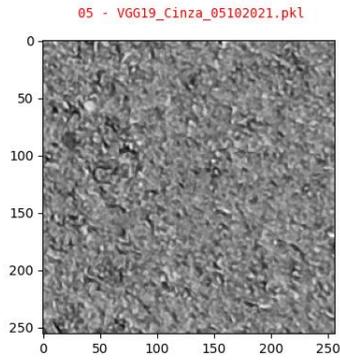
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0789 seg



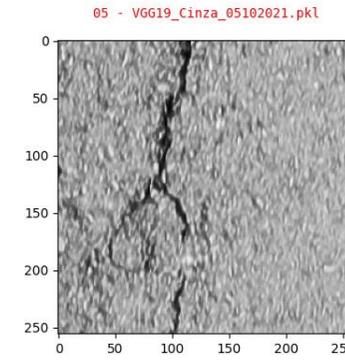
Pred.: Não Trinca
Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.08 seg



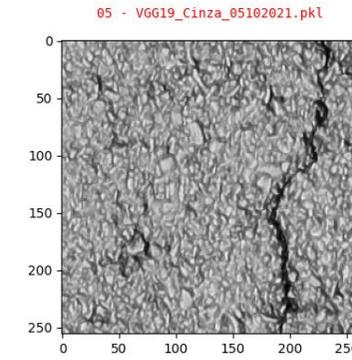
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0819 seg



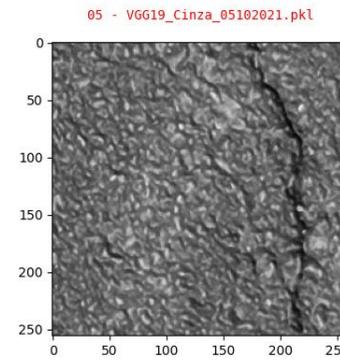
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0825 seg



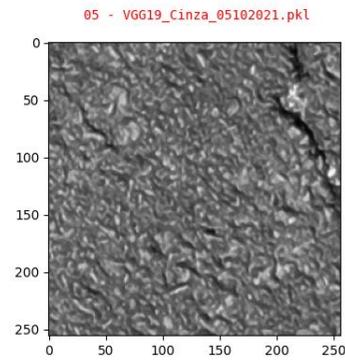
Pred.: Trinca
Trinca: 56.26%
Não Trinca: 43.74%
Inferência: 0.0803 seg



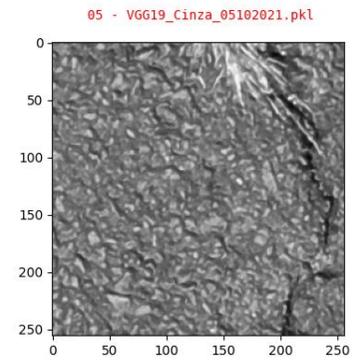
Pred.: Trinca
Trinca: 52.72%
Não Trinca: 47.28%
Inferência: 0.0805 seg



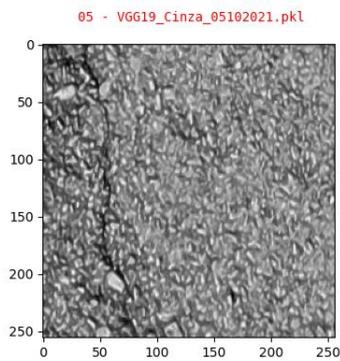
Pred.: Trinca
Trinca: 61.03%
Não Trinca: 38.97%
Inferência: 0.0794 seg



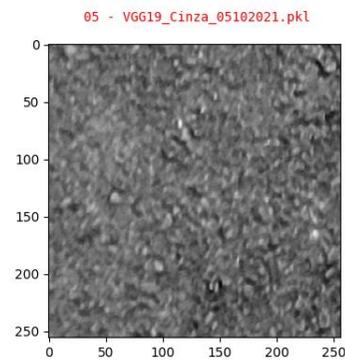
Pred.: Não Trinca
Trinca: 25.07%
Não Trinca: 74.93%
Inferência: 0.0817 seg



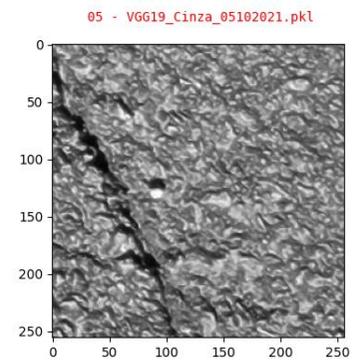
Pred.: Não Trinca
Trinca: 36.58%
Não Trinca: 63.42%
Inferência: 0.0813 seg



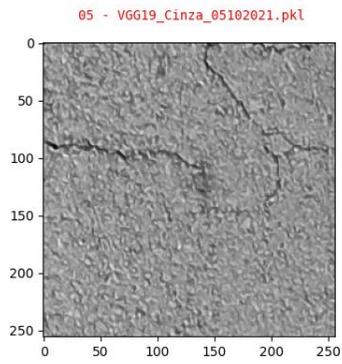
Pred.: Não Trinca
Trinca: 42.25%
Não Trinca: 57.75%
Inferência: 0.0857 seg



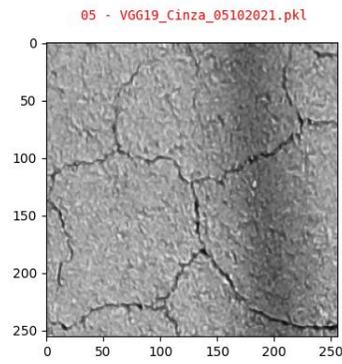
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0791 seg



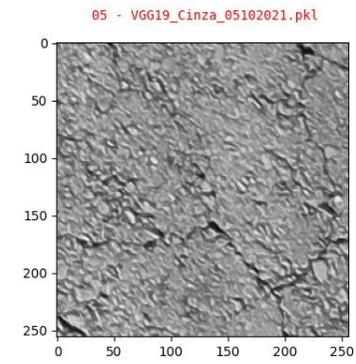
Pred.: Não Trinca
Trinca: 38.18%
Não Trinca: 61.82%
Inferência: 0.0795 seg



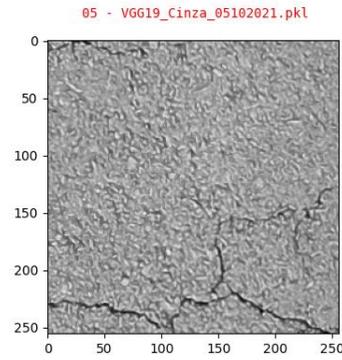
Pred.: Trinca
Trinca: 90.67%
Não Trinca: 9.33%
Inferência: 0.0802 seg



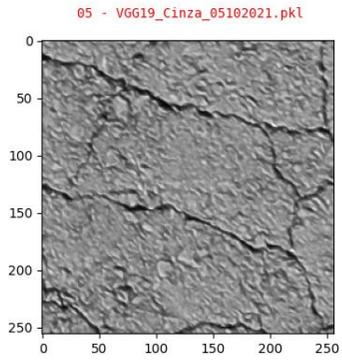
Pred.: Trinca
Trinca: 99.96%
Não Trinca: 0.04%
Inferência: 0.079 seg



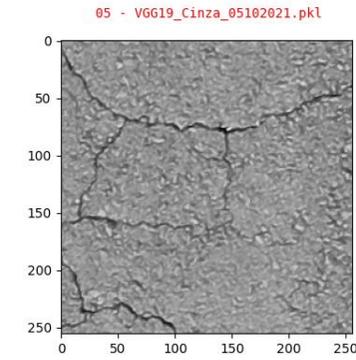
Pred.: Trinca
Trinca: 95.98%
Não Trinca: 4.02%
Inferência: 0.0801 seg



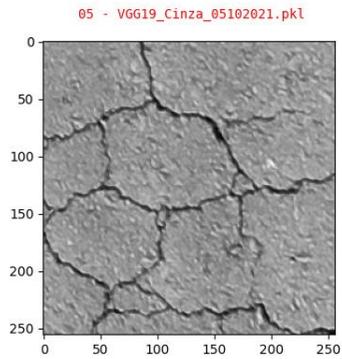
Pred.: Trinca
Trinca: 84.50%
Não Trinca: 15.50%
Inferência: 0.079 seg



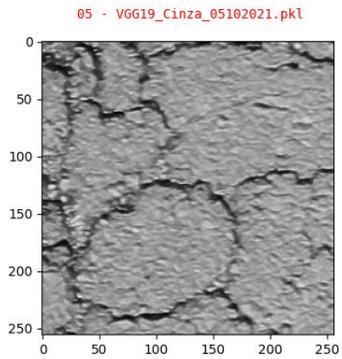
Pred.: Trinca
Trinca: 99.98%
Não Trinca: 0.02%
Inferência: 0.0791 seg



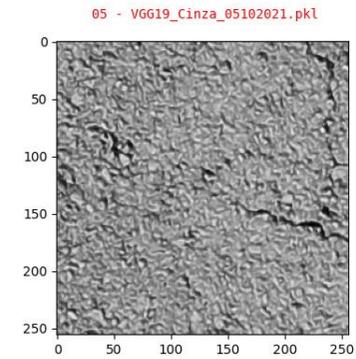
Pred.: Trinca
Trinca: 99.91%
Não Trinca: 0.09%
Inferência: 0.079 seg



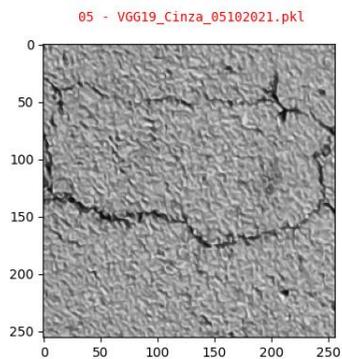
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.0806 seg



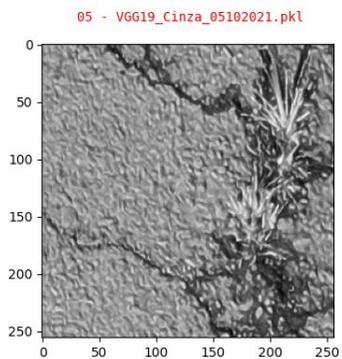
Pred.: Trinca
Trinca: 99.98%
Não Trinca: 0.02%
Inferência: 0.0811 seg



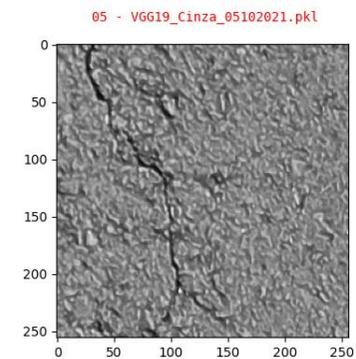
Pred.: Trinca
Trinca: 78.22%
Não Trinca: 21.78%
Inferência: 0.0792 seg



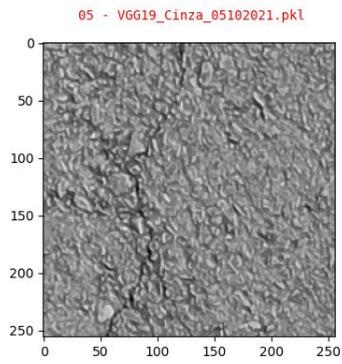
Pred.: Trinca
Trinca: 99.88%
Não Trinca: 0.12%
Inferência: 0.0792 seg



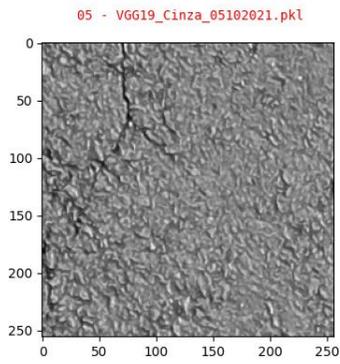
Pred.: Trinca
Trinca: 97.33%
Não Trinca: 2.67%
Inferência: 0.0788 seg



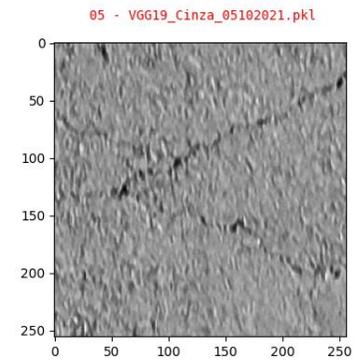
Pred.: Trinca
Trinca: 94.25%
Não Trinca: 5.75%
Inferência: 0.0796 seg



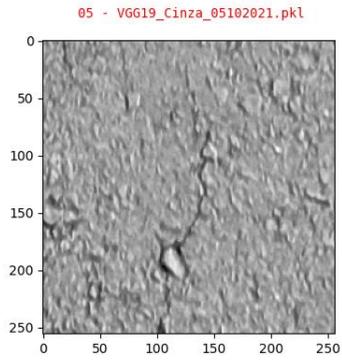
Pred.: Trinca
Trinca: 81.38%
Não Trinca: 18.62%
Inferência: 0.0817 seg



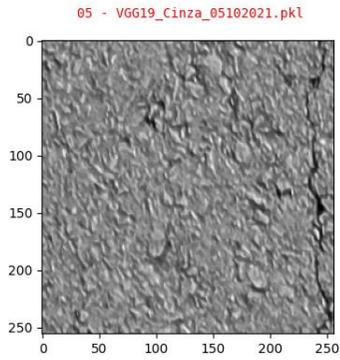
Pred.: Trinca
Trinca: 62.43%
Não Trinca: 37.57%
Inferência: 0.0787 seg



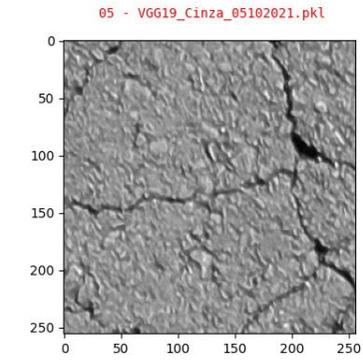
Pred.: Não Trinca
Trinca: 20.33%
Não Trinca: 79.67%
Inferência: 0.0801 seg



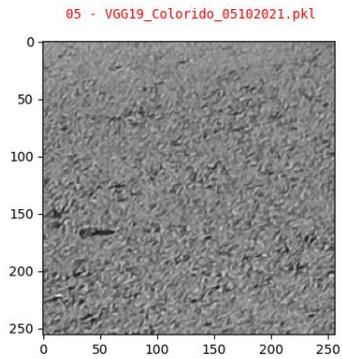
Pred.: Não Trinca
Trinca: 17.07%
Não Trinca: 82.93%
Inferência: 0.0799 seg



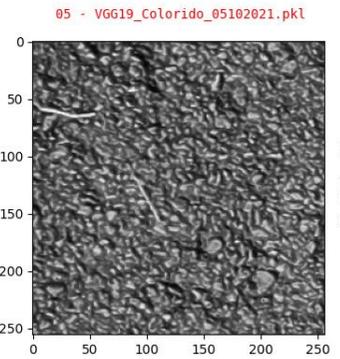
Pred.: Trinca
Trinca: 53.79%
Não Trinca: 46.21%
Inferência: 0.0795 seg



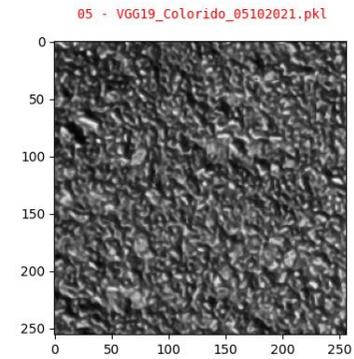
Pred.: Trinca
Trinca: 99.47%
Não Trinca: 0.53%
Inferência: 0.0792 seg



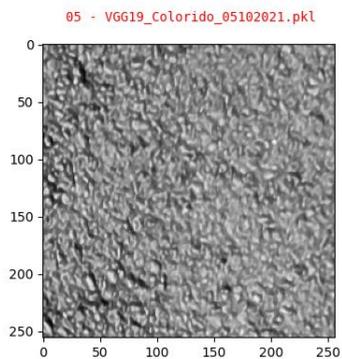
Pred.: Não Trinca
Trinca: 0.63%
Não Trinca: 99.37%
Inferência: 0.099 seg



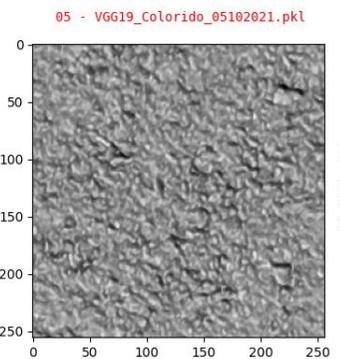
Pred.: Não Trinca
Trinca: 0.45%
Não Trinca: 99.55%
Inferência: 0.0912 seg



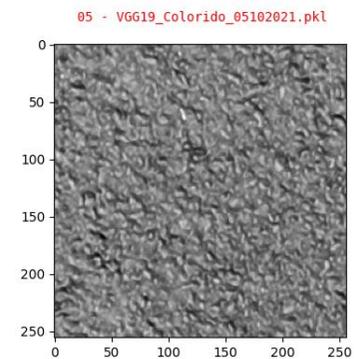
Pred.: Não Trinca
Trinca: 7.51%
Não Trinca: 92.49%
Inferência: 0.0865 seg



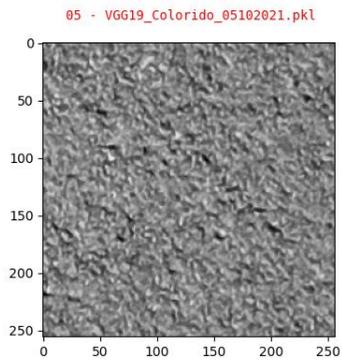
Pred.: Não Trinca
Trinca: 0.82%
Não Trinca: 99.18%
Inferência: 0.0946 seg



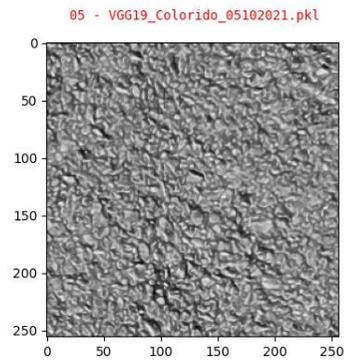
Pred.: Não Trinca
Trinca: 0.18%
Não Trinca: 99.82%
Inferência: 0.0923 seg



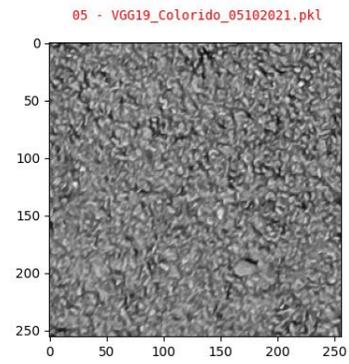
Pred.: Não Trinca
Trinca: 0.05%
Não Trinca: 99.95%
Inferência: 0.093 seg



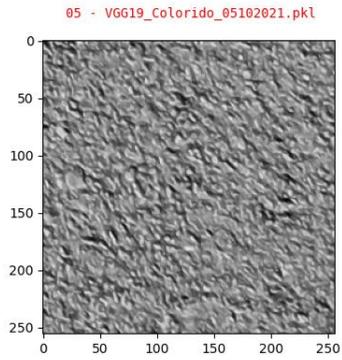
Pred.: Não Trinca
Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.0926 seg



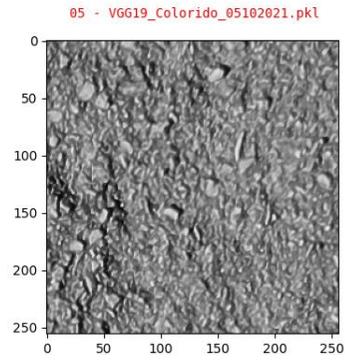
Pred.: Não Trinca
Trinca: 1.71%
Não Trinca: 98.29%
Inferência: 0.0868 seg



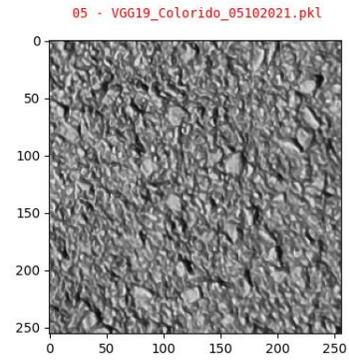
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0922 seg



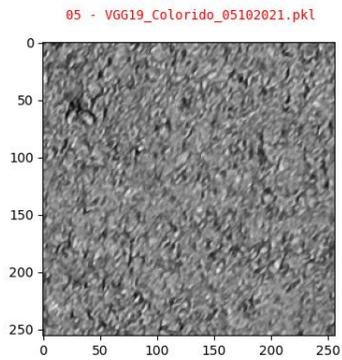
Pred.: Não Trinca
Trinca: 0.23%
Não Trinca: 99.77%
Inferência: 0.0897 seg



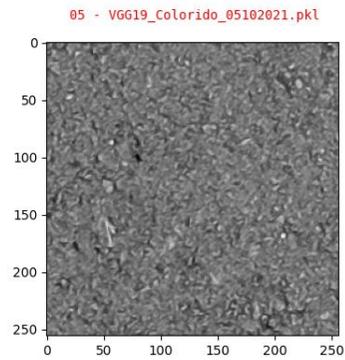
Pred.: Não Trinca
Trinca: 25.66%
Não Trinca: 74.34%
Inferência: 0.0896 seg



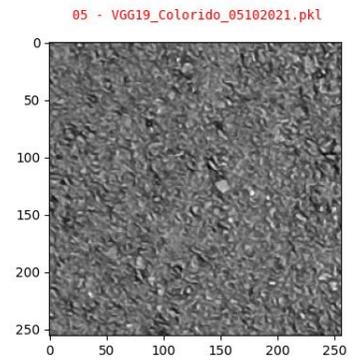
Pred.: Não Trinca
Trinca: 0.51%
Não Trinca: 99.49%
Inferência: 0.0924 seg



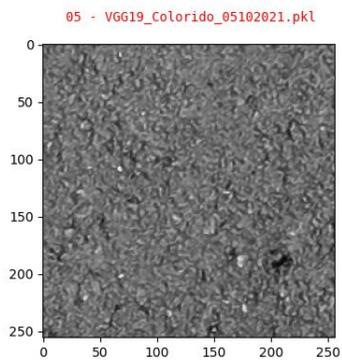
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0901 seg



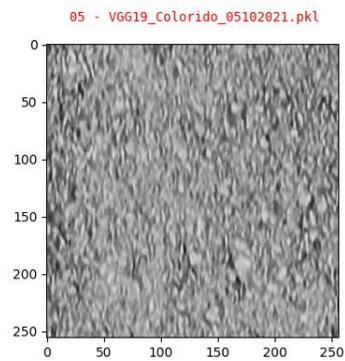
Pred.: Não Trinca
Trinca: 0.07%
Não Trinca: 99.93%
Inferência: 0.0882 seg



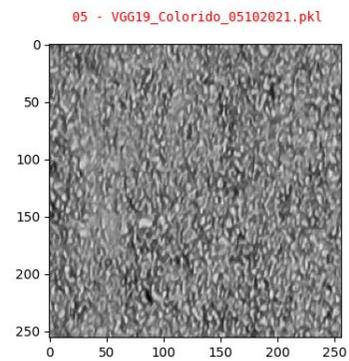
Pred.: Não Trinca
Trinca: 0.06%
Não Trinca: 99.94%
Inferência: 0.0877 seg



Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0884 seg

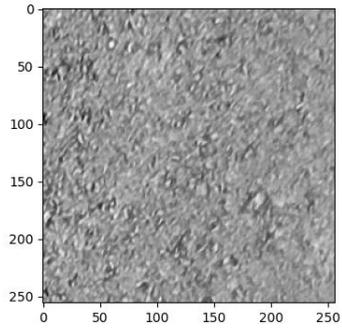


Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.0849 seg



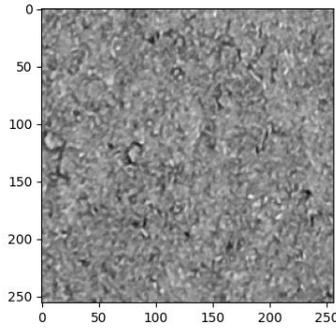
Pred.: Não Trinca
Trinca: 0.04%
Não Trinca: 99.96%
Inferência: 0.089 seg

05 - VGG19_Colorido_05102021.pkl



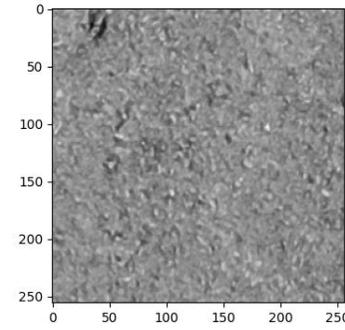
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.0869 seg

05 - VGG19_Colorido_05102021.pkl



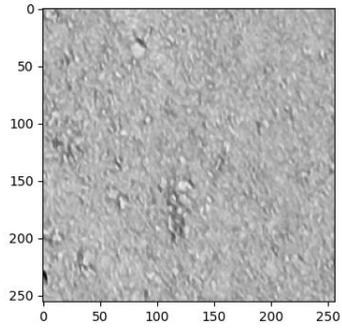
Pred.: Não Trinca
 Trinca: 0.22%
 Não Trinca: 99.78%
 Inferência: 0.0843 seg

05 - VGG19_Colorido_05102021.pkl



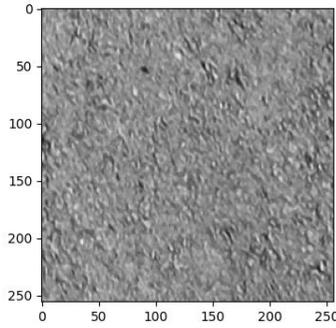
Pred.: Não Trinca
 Trinca: 0.13%
 Não Trinca: 99.87%
 Inferência: 0.0947 seg

05 - VGG19_Colorido_05102021.pkl



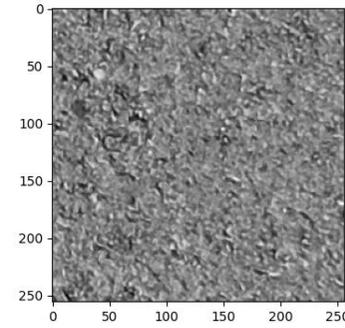
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.0891 seg

05 - VGG19_Colorido_05102021.pkl



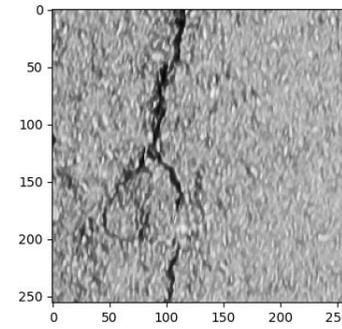
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.091 seg

05 - VGG19_Colorido_05102021.pkl



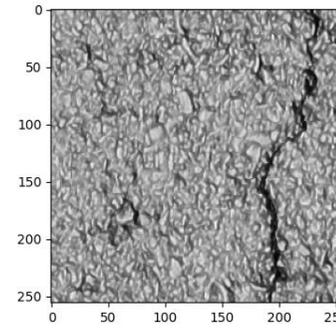
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.0898 seg

05 - VGG19_Colorido_05102021.pkl



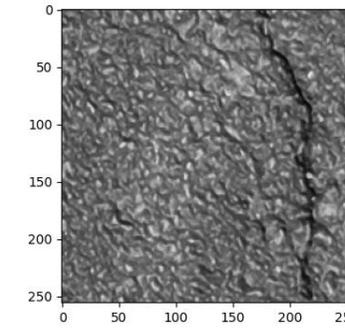
Pred.: Trinca
 Trinca: 94.98%
 Não Trinca: 5.02%
 Inferência: 0.0877 seg

05 - VGG19_Colorido_05102021.pkl



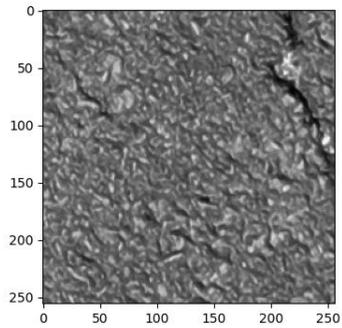
Pred.: Trinca
 Trinca: 80.54%
 Não Trinca: 19.46%
 Inferência: 0.0879 seg

05 - VGG19_Colorido_05102021.pkl



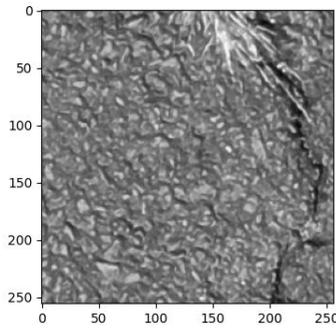
Pred.: Trinca
 Trinca: 62.11%
 Não Trinca: 37.89%
 Inferência: 0.0917 seg

05 - VGG19_Colorido_05102021.pkl



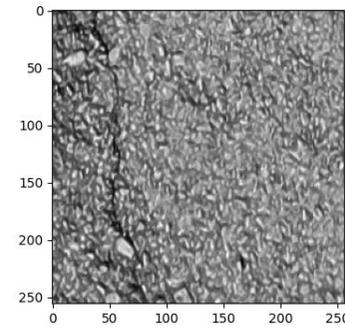
Pred.: Não Trinca
 Trinca: 30.98%
 Não Trinca: 69.02%
 Inferência: 0.0891 seg

05 - VGG19_Colorido_05102021.pkl



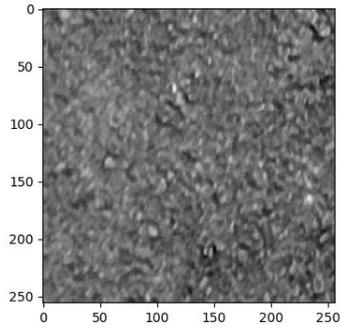
Pred.: Não Trinca
 Trinca: 35.58%
 Não Trinca: 64.42%
 Inferência: 0.086 seg

05 - VGG19_Colorido_05102021.pkl



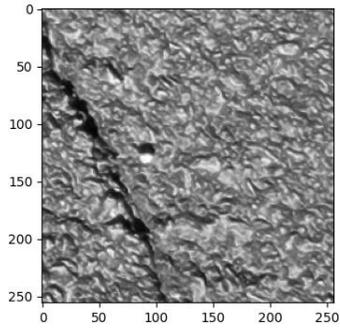
Pred.: Não Trinca
 Trinca: 44.09%
 Não Trinca: 55.91%
 Inferência: 0.0881 seg

05 - VGG19_Colorido_05102021.pkl



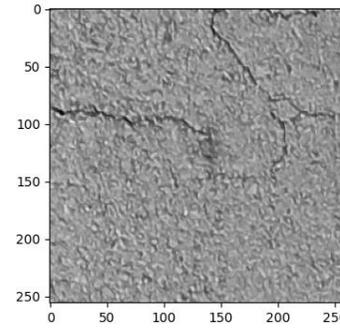
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.0977 seg

05 - VGG19_Colorido_05102021.pkl



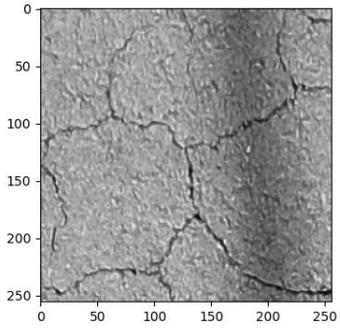
Pred.: Trinca
 Trinca: 87.51%
 Não Trinca: 12.49%
 Inferência: 0.0852 seg

05 - VGG19_Colorido_05102021.pkl



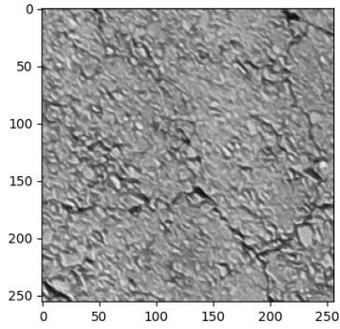
Pred.: Trinca
 Trinca: 65.15%
 Não Trinca: 34.85%
 Inferência: 0.0895 seg

05 - VGG19_Colorido_05102021.pkl



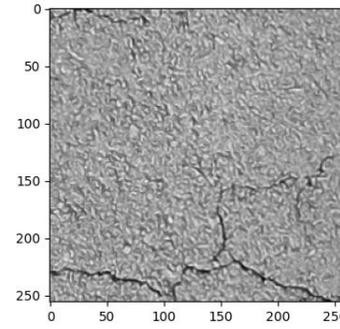
Pred.: Trinca
 Trinca: 99.93%
 Não Trinca: 0.07%
 Inferência: 0.09 seg

05 - VGG19_Colorido_05102021.pkl



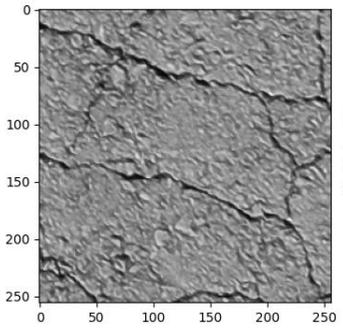
Pred.: Trinca
 Trinca: 99.13%
 Não Trinca: 0.87%
 Inferência: 0.0904 seg

05 - VGG19_Colorido_05102021.pkl



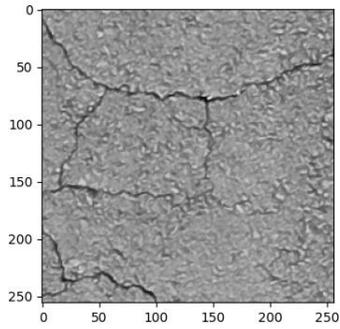
Pred.: Trinca
 Trinca: 84.37%
 Não Trinca: 15.63%
 Inferência: 0.0949 seg

05 - VGG19_Colorido_05102021.pkl



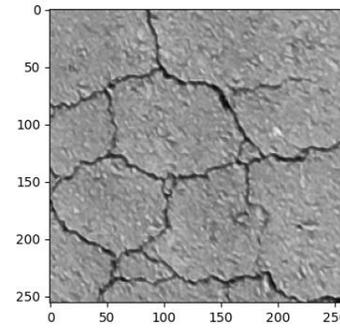
Pred.: Trinca
 Trinca: 99.98%
 Não Trinca: 0.02%
 Inferência: 0.0895 seg

05 - VGG19_Colorido_05102021.pkl



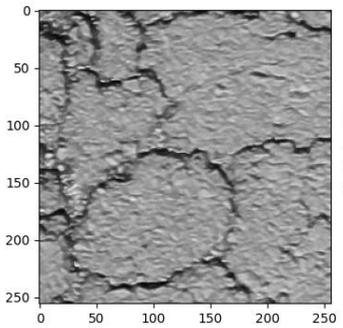
Pred.: Trinca
 Trinca: 99.26%
 Não Trinca: 0.74%
 Inferência: 0.1161 seg

05 - VGG19_Colorido_05102021.pkl



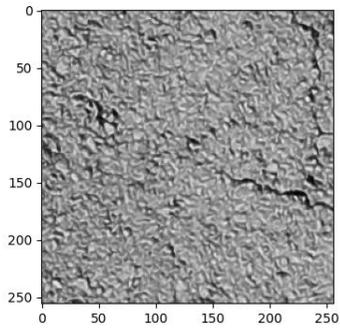
Pred.: Trinca
 Trinca: 99.99%
 Não Trinca: 0.01%
 Inferência: 0.0895 seg

05 - VGG19_Colorido_05102021.pkl



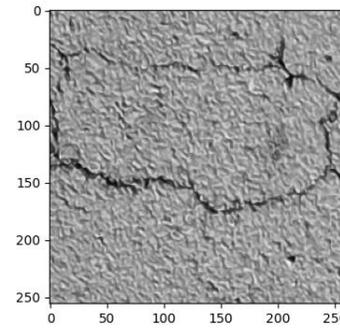
Pred.: Trinca
 Trinca: 99.98%
 Não Trinca: 0.02%
 Inferência: 0.1015 seg

05 - VGG19_Colorido_05102021.pkl

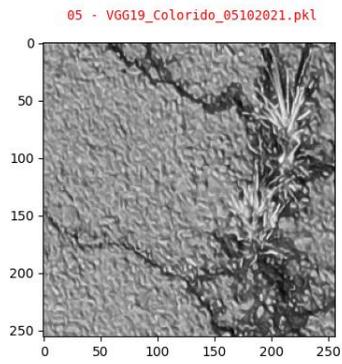


Pred.: Não Trinca
 Trinca: 47.48%
 Não Trinca: 52.52%
 Inferência: 0.0933 seg

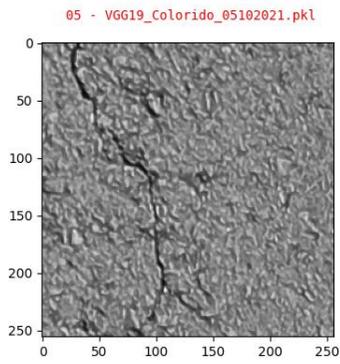
05 - VGG19_Colorido_05102021.pkl



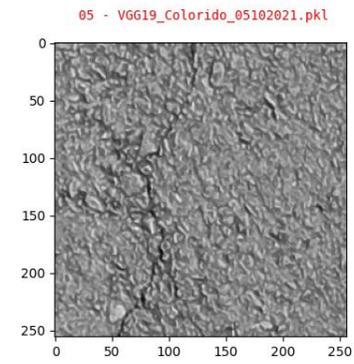
Pred.: Trinca
 Trinca: 99.97%
 Não Trinca: 0.03%
 Inferência: 0.0897 seg



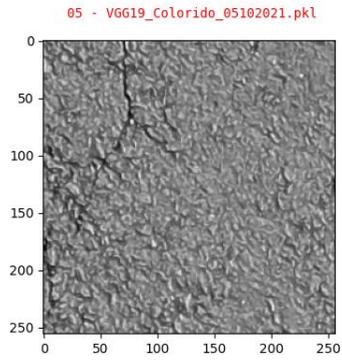
Pred.: Trinca
Trinca: 99.28%
Não Trinca: 0.72%
Inferência: 0.0904 seg



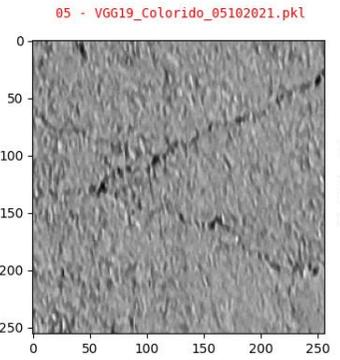
Pred.: Trinca
Trinca: 85.55%
Não Trinca: 14.45%
Inferência: 0.0885 seg



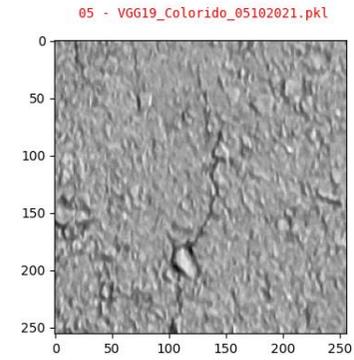
Pred.: Trinca
Trinca: 80.23%
Não Trinca: 19.77%
Inferência: 0.0893 seg



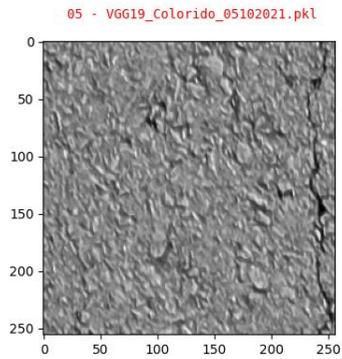
Pred.: Trinca
Trinca: 80.04%
Não Trinca: 19.96%
Inferência: 0.0968 seg



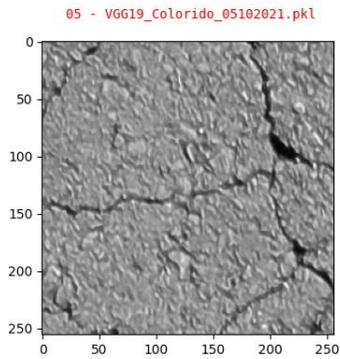
Pred.: Não Trinca
Trinca: 5.77%
Não Trinca: 94.23%
Inferência: 0.0981 seg



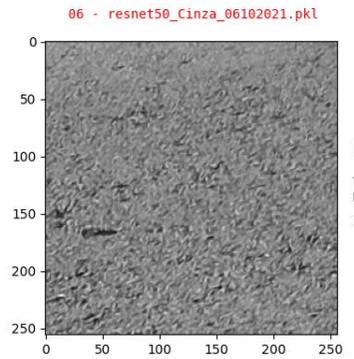
Pred.: Trinca
Trinca: 58.93%
Não Trinca: 41.07%
Inferência: 0.0892 seg



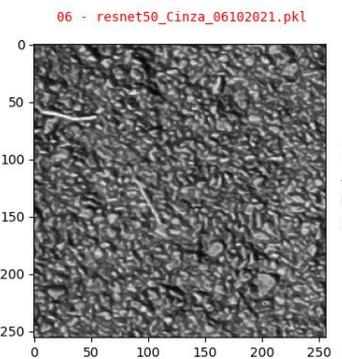
Pred.: Trinca
Trinca: 84.40%
Não Trinca: 15.60%
Inferência: 0.0835 seg



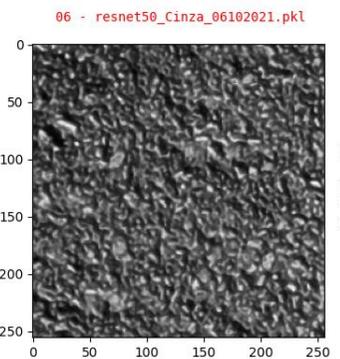
Pred.: Trinca
Trinca: 99.98%
Não Trinca: 0.02%
Inferência: 0.0826 seg



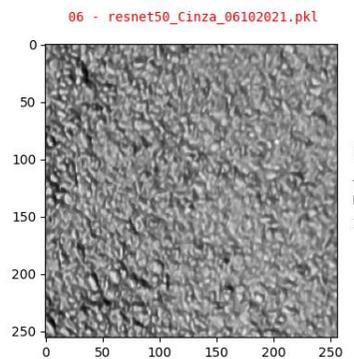
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1653 seg



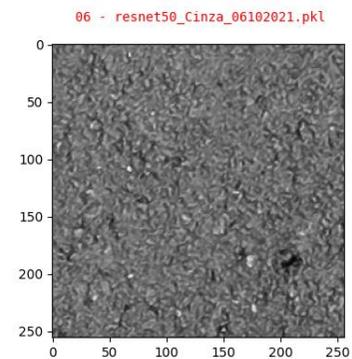
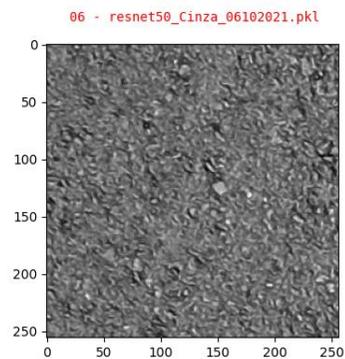
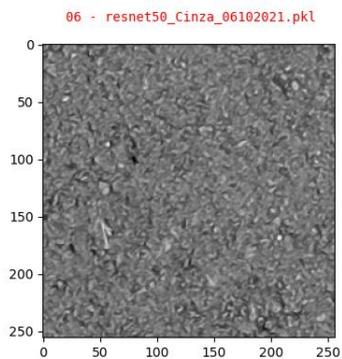
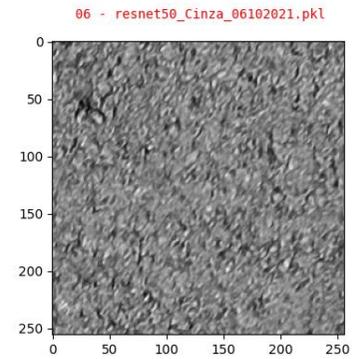
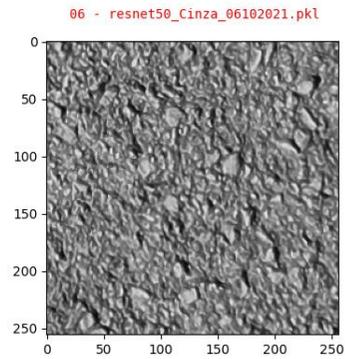
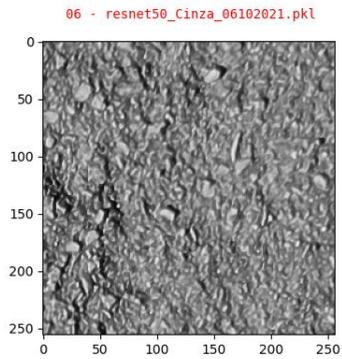
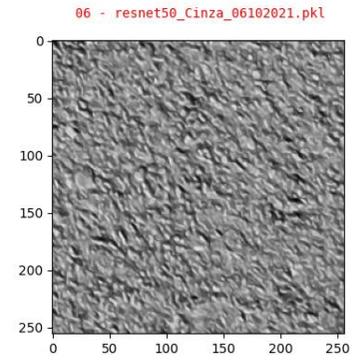
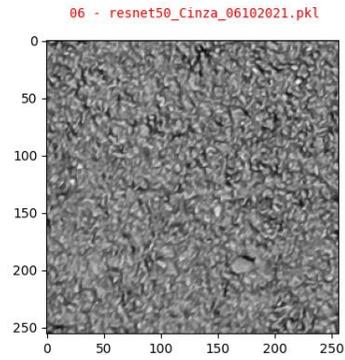
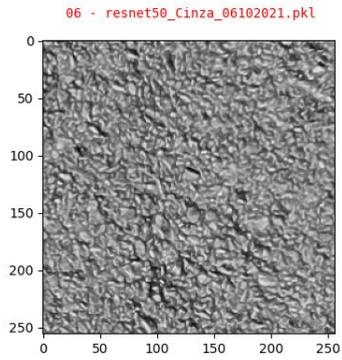
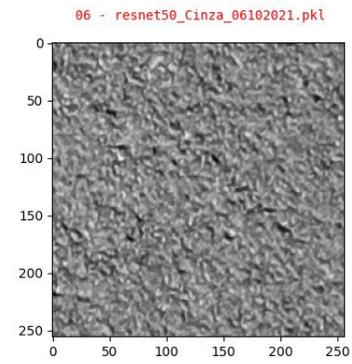
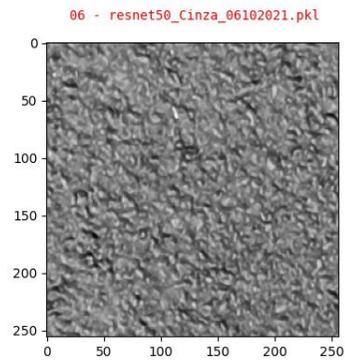
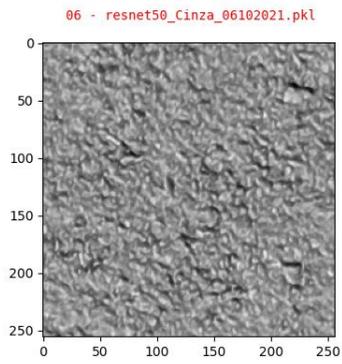
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1633 seg



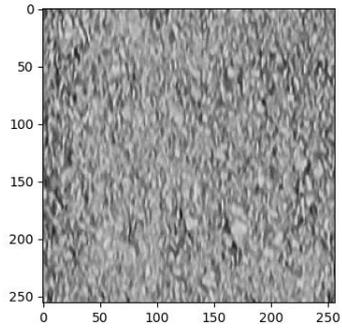
Pred.: Não Trinca
Trinca: 0.09%
Não Trinca: 99.91%
Inferência: 0.1671 seg



Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1653 seg

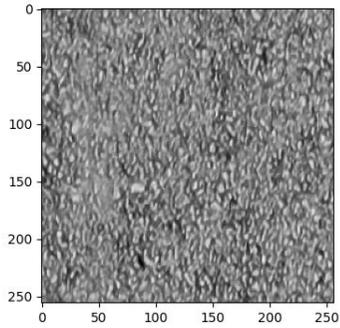


06 - resnet50_Cinza_06102021.pkl



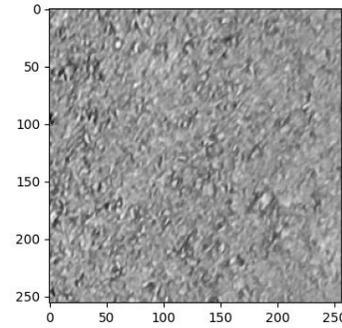
Pred.: Não Trincado
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1693 seg

06 - resnet50_Cinza_06102021.pkl



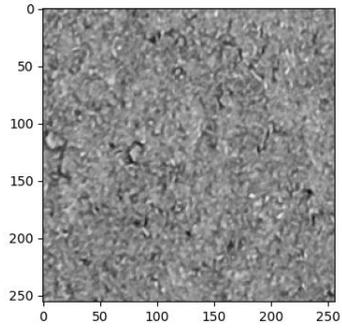
Pred.: Não Trincado
Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.1653 seg

06 - resnet50_Cinza_06102021.pkl



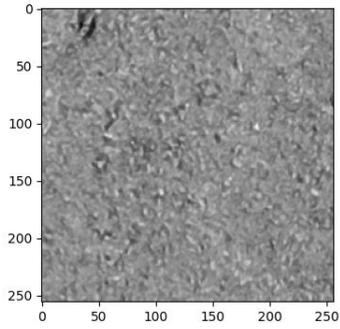
Pred.: Não Trincado
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1664 seg

06 - resnet50_Cinza_06102021.pkl



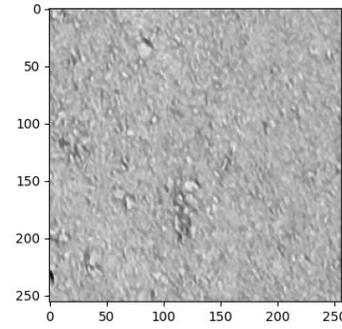
Pred.: Não Trincado
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1677 seg

06 - resnet50_Cinza_06102021.pkl



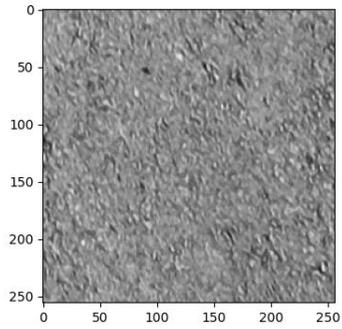
Pred.: Não Trincado
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1638 seg

06 - resnet50_Cinza_06102021.pkl



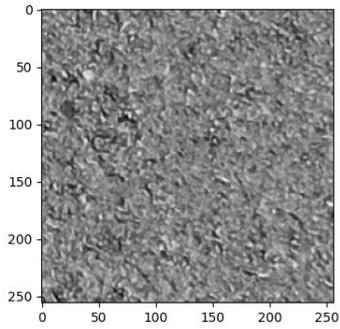
Pred.: Não Trincado
Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.1704 seg

06 - resnet50_Cinza_06102021.pkl



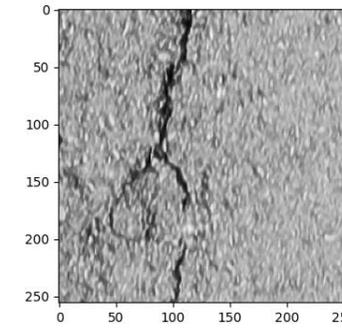
Pred.: Não Trincado
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1653 seg

06 - resnet50_Cinza_06102021.pkl



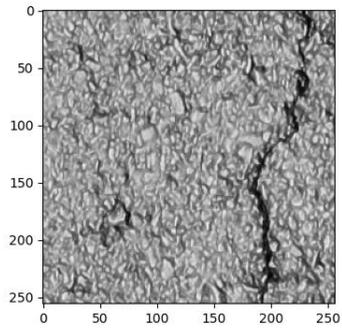
Pred.: Não Trincado
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1667 seg

06 - resnet50_Cinza_06102021.pkl



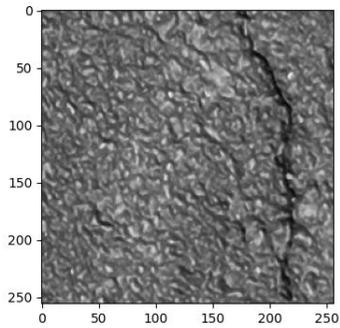
Pred.: Trincado
Trinca: 52.32%
Não Trinca: 47.68%
Inferência: 0.1661 seg

06 - resnet50_Cinza_06102021.pkl



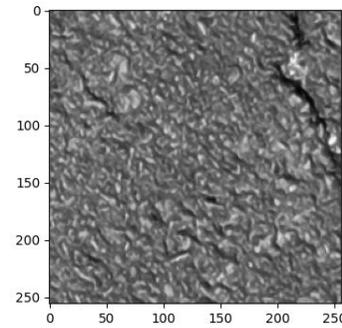
Pred.: Não Trincado
Trinca: 44.29%
Não Trinca: 55.71%
Inferência: 0.1668 seg

06 - resnet50_Cinza_06102021.pkl

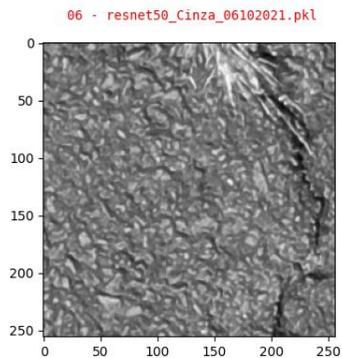


Pred.: Não Trincado
Trinca: 38.48%
Não Trinca: 61.52%
Inferência: 0.1667 seg

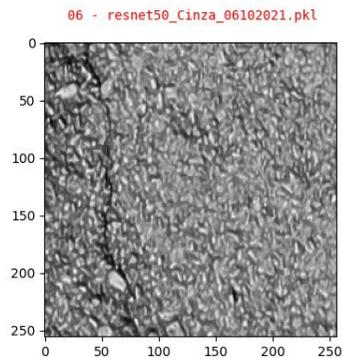
06 - resnet50_Cinza_06102021.pkl



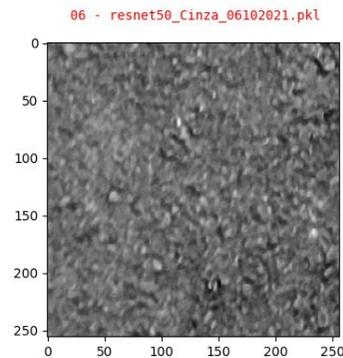
Pred.: Não Trincado
Trinca: 31.26%
Não Trinca: 68.74%
Inferência: 0.1685 seg



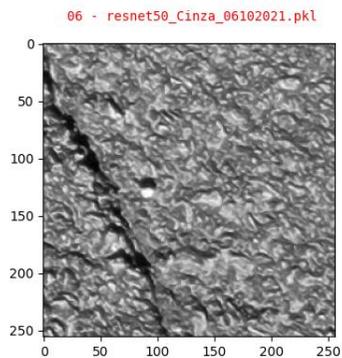
Pred.: Trinca
Trinca: 52.36%
Não Trinca: 47.64%
Inferência: 0.1664 seg



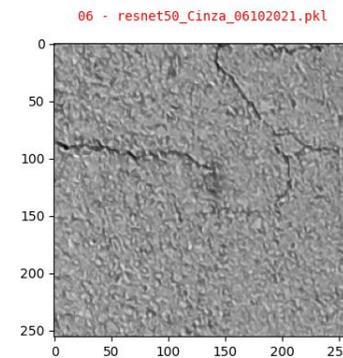
Pred.: Não Trinca
Trinca: 12.39%
Não Trinca: 87.61%
Inferência: 0.1666 seg



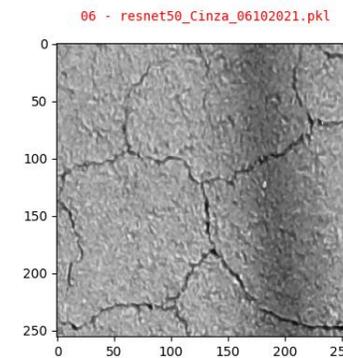
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1676 seg



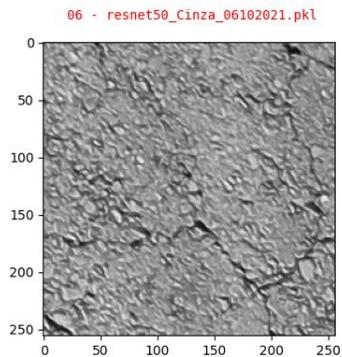
Pred.: Trinca
Trinca: 83.58%
Não Trinca: 16.42%
Inferência: 0.1627 seg



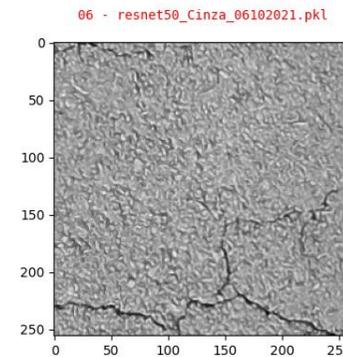
Pred.: Trinca
Trinca: 97.78%
Não Trinca: 2.22%
Inferência: 0.1681 seg



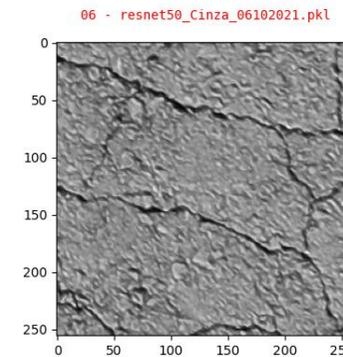
Pred.: Trinca
Trinca: 99.88%
Não Trinca: 0.12%
Inferência: 0.1653 seg



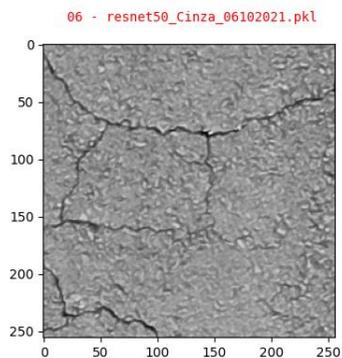
Pred.: Trinca
Trinca: 77.36%
Não Trinca: 22.64%
Inferência: 0.1657 seg



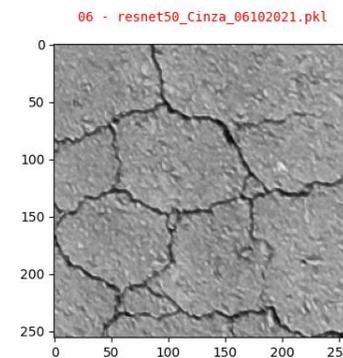
Pred.: Trinca
Trinca: 99.69%
Não Trinca: 0.31%
Inferência: 0.1662 seg



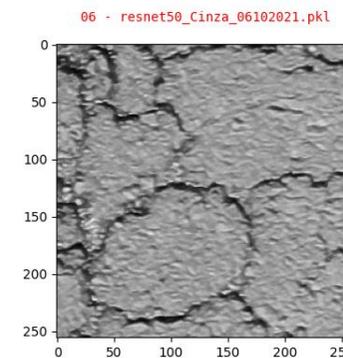
Pred.: Trinca
Trinca: 99.96%
Não Trinca: 0.04%
Inferência: 0.1702 seg



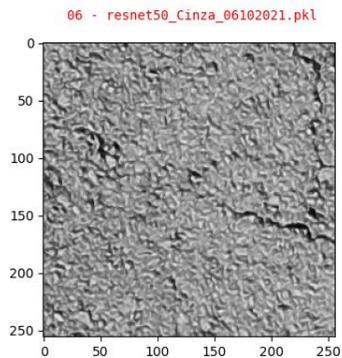
Pred.: Trinca
Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.1676 seg



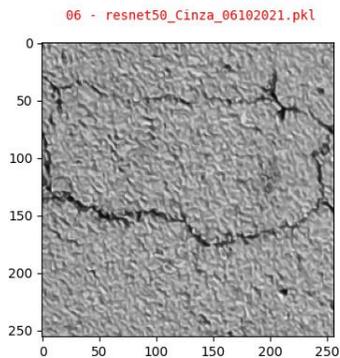
Pred.: Trinca
Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.1665 seg



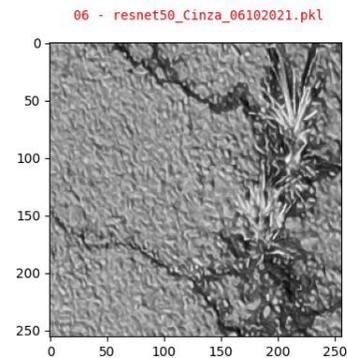
Pred.: Trinca
Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.1665 seg



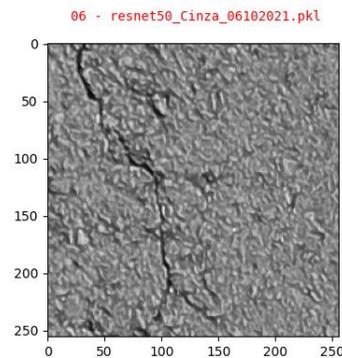
Pred.: Trinca
Trinca: 77.90%
Não Trinca: 22.10%
Inferência: 0.1669 seg



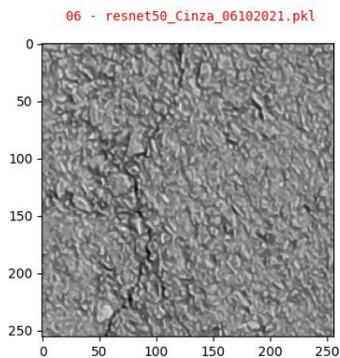
Pred.: Trinca
Trinca: 99.96%
Não Trinca: 0.04%
Inferência: 0.1651 seg



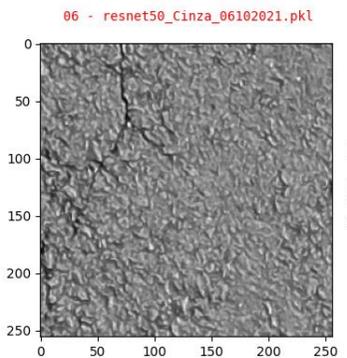
Pred.: Trinca
Trinca: 96.96%
Não Trinca: 3.04%
Inferência: 0.1745 seg



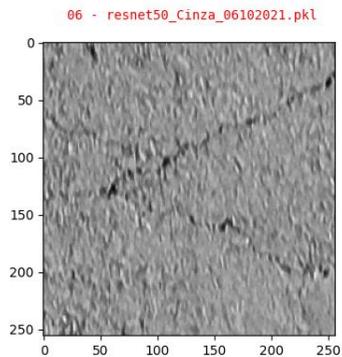
Pred.: Trinca
Trinca: 83.05%
Não Trinca: 16.95%
Inferência: 0.164 seg



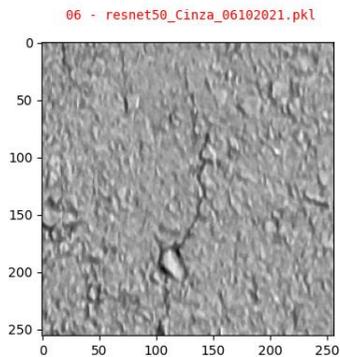
Pred.: Trinca
Trinca: 53.60%
Não Trinca: 46.40%
Inferência: 0.1682 seg



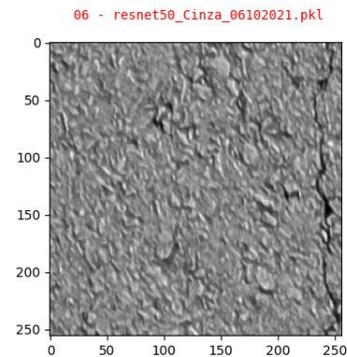
Pred.: Não Trinca
Trinca: 24.66%
Não Trinca: 75.34%
Inferência: 0.1694 seg



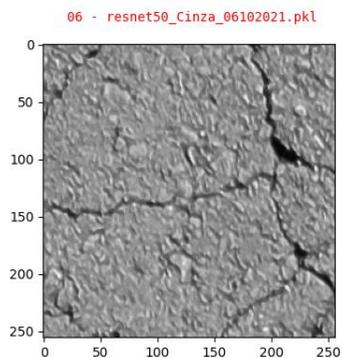
Pred.: Trinca
Trinca: 82.09%
Não Trinca: 17.91%
Inferência: 0.1642 seg



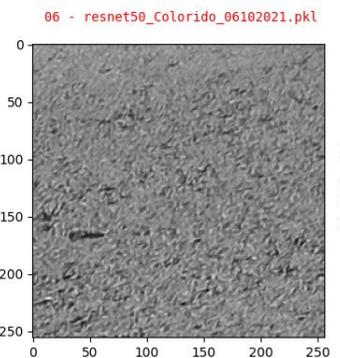
Pred.: Trinca
Trinca: 84.17%
Não Trinca: 15.83%
Inferência: 0.1659 seg



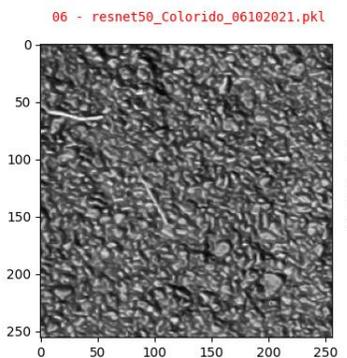
Pred.: Trinca
Trinca: 51.87%
Não Trinca: 48.13%
Inferência: 0.1648 seg



Pred.: Trinca
Trinca: 99.78%
Não Trinca: 0.22%
Inferência: 0.1672 seg

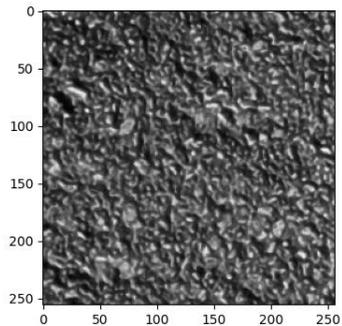


Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1777 seg



Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1712 seg

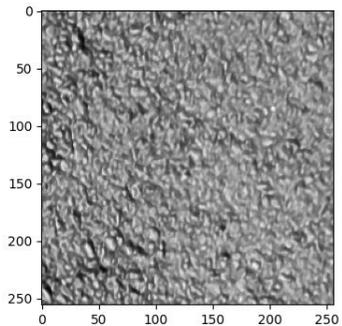
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.1749 seg

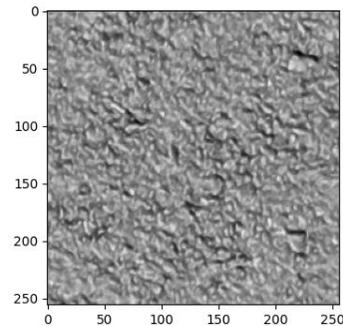
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1707 seg

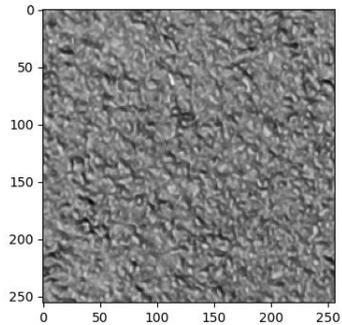
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1685 seg

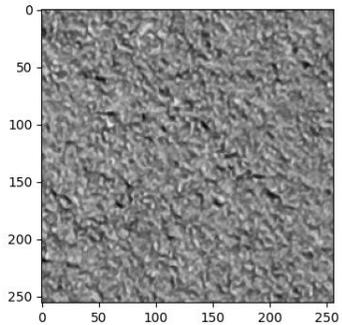
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1819 seg

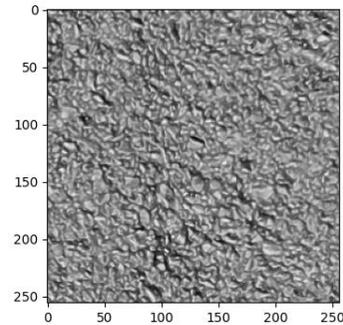
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1702 seg

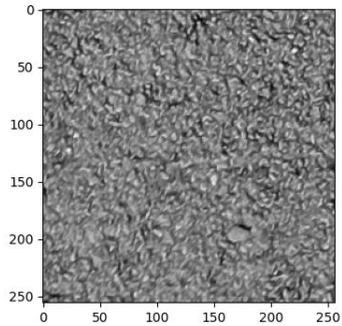
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.11%
Não Trinca: 99.89%
Inferência: 0.1754 seg

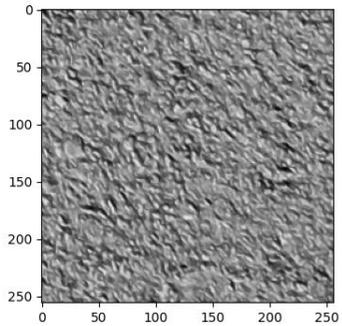
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1715 seg

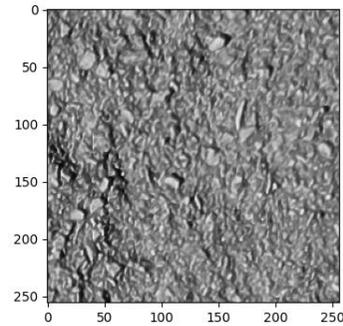
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1811 seg

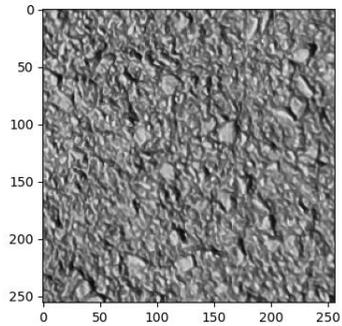
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 6.96%
Não Trinca: 93.04%
Inferência: 0.1752 seg

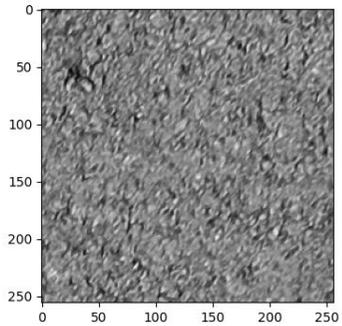
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.1795 seg

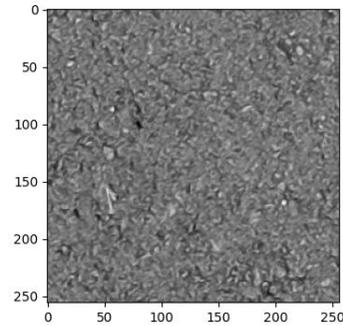
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.174 seg

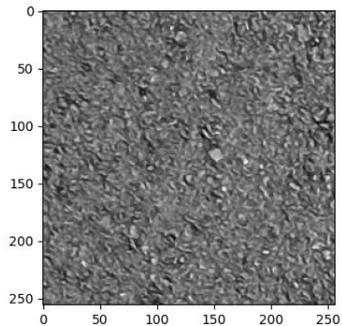
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.17 seg

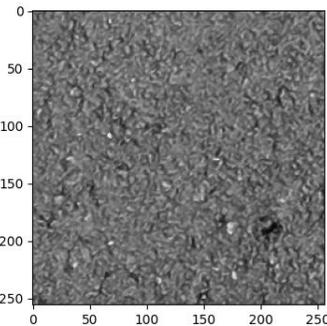
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1747 seg

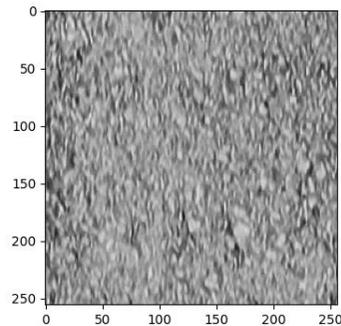
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.1798 seg

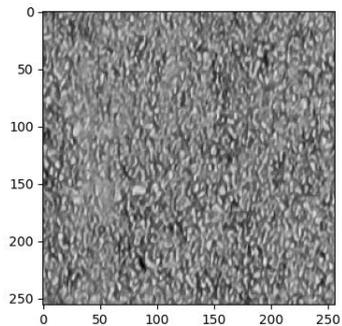
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1735 seg

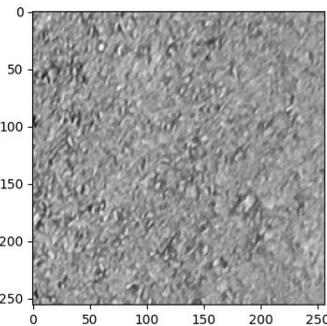
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1733 seg

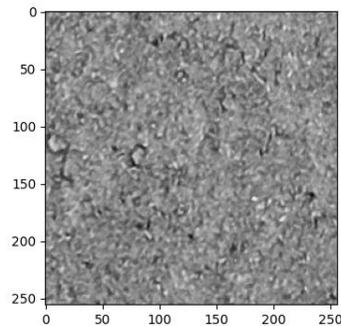
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1725 seg

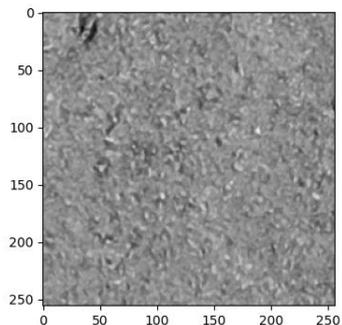
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1769 seg

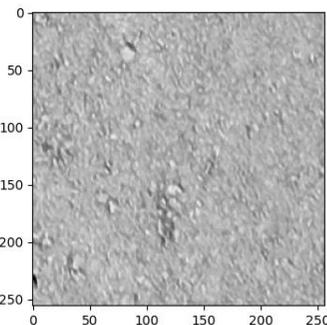
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1735 seg

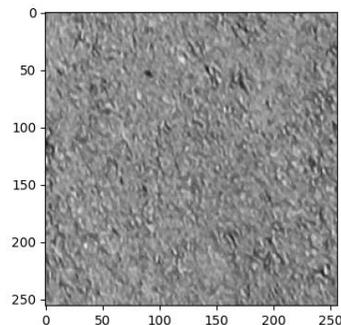
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1735 seg

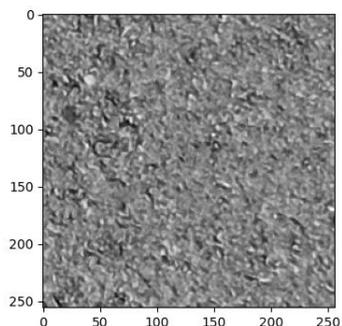
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.1742 seg

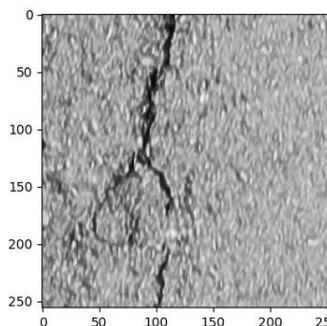
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1732 seg

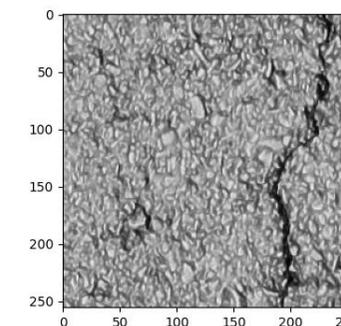
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 83.68%
Não Trinca: 16.32%
Inferência: 0.1771 seg

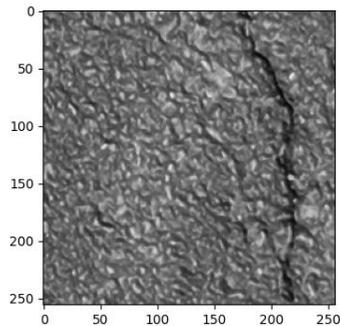
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

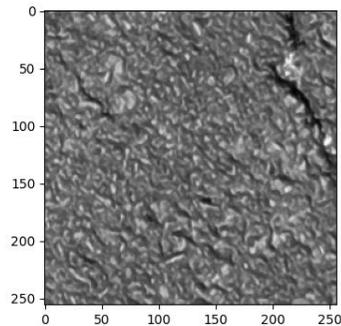
Trinca: 89.52%
Não Trinca: 10.48%
Inferência: 0.18 seg

06 - resnet50_Colorido_06102021.pkl



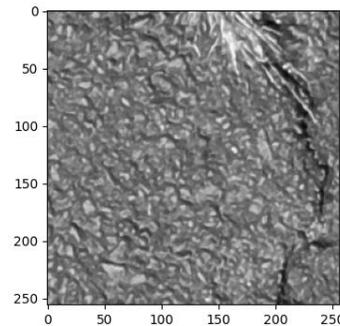
Pred.: Trinca
Trinca: 84.70%
Não Trinca: 15.30%
Inferência: 0.1726 seg

06 - resnet50_Colorido_06102021.pkl



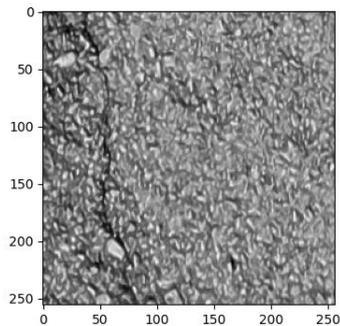
Pred.: Não Trinca
Trinca: 33.55%
Não Trinca: 66.45%
Inferência: 0.1869 seg

06 - resnet50_Colorido_06102021.pkl



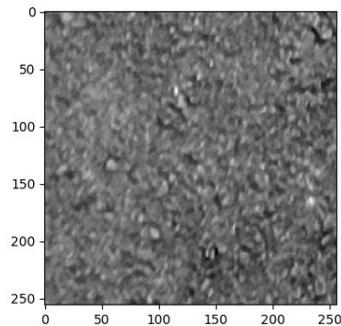
Pred.: Não Trinca
Trinca: 49.09%
Não Trinca: 50.91%
Inferência: 0.1797 seg

06 - resnet50_Colorido_06102021.pkl



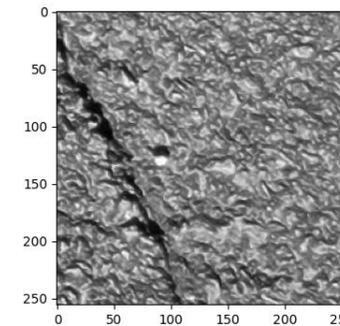
Pred.: Não Trinca
Trinca: 4.02%
Não Trinca: 95.98%
Inferência: 0.1788 seg

06 - resnet50_Colorido_06102021.pkl



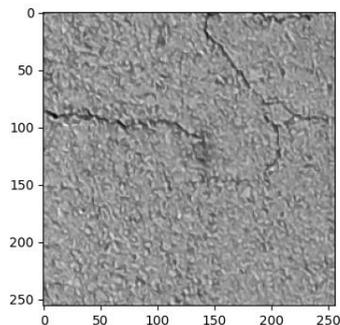
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.1715 seg

06 - resnet50_Colorido_06102021.pkl



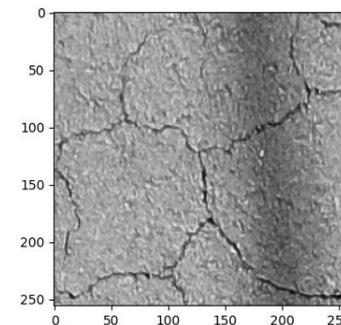
Pred.: Trinca
Trinca: 98.34%
Não Trinca: 1.66%
Inferência: 0.1739 seg

06 - resnet50_Colorido_06102021.pkl



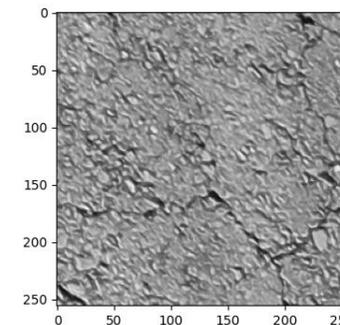
Pred.: Trinca
Trinca: 71.71%
Não Trinca: 28.29%
Inferência: 0.1746 seg

06 - resnet50_Colorido_06102021.pkl



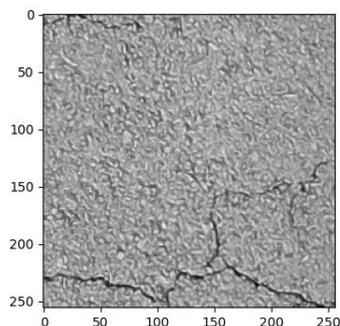
Pred.: Trinca
Trinca: 99.02%
Não Trinca: 0.98%
Inferência: 0.1856 seg

06 - resnet50_Colorido_06102021.pkl



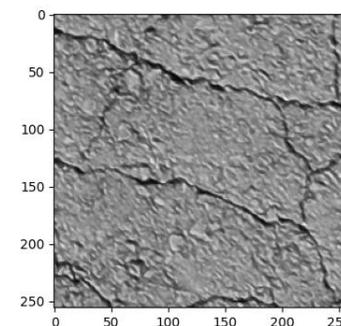
Pred.: Trinca
Trinca: 99.91%
Não Trinca: 0.09%
Inferência: 0.1755 seg

06 - resnet50_Colorido_06102021.pkl



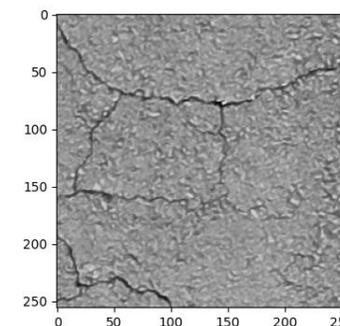
Pred.: Trinca
Trinca: 99.37%
Não Trinca: 0.63%
Inferência: 0.1797 seg

06 - resnet50_Colorido_06102021.pkl



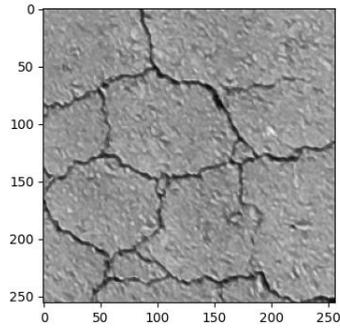
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.1712 seg

06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca
Trinca: 99.65%
Não Trinca: 0.35%
Inferência: 0.1811 seg

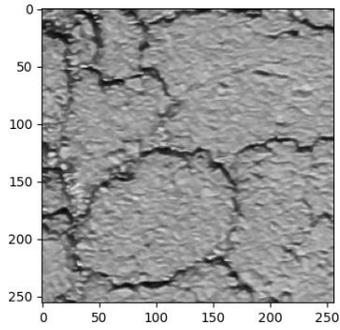
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.1749 seg

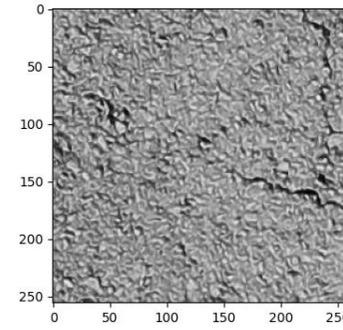
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.1793 seg

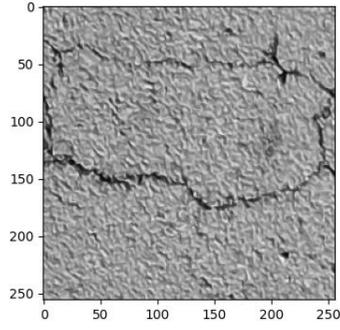
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 93.66%
Não Trinca: 6.34%
Inferência: 0.1749 seg

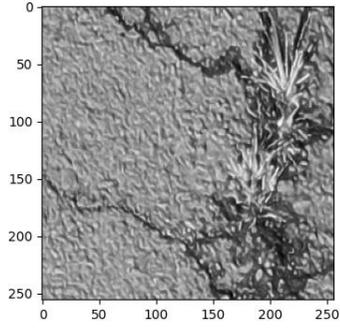
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 99.75%
Não Trinca: 0.25%
Inferência: 0.1782 seg

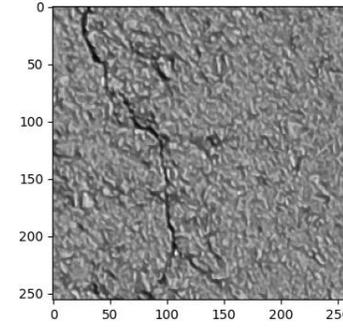
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 75.86%
Não Trinca: 24.14%
Inferência: 0.1739 seg

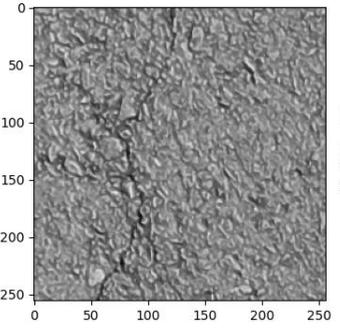
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 99.01%
Não Trinca: 0.99%
Inferência: 0.1802 seg

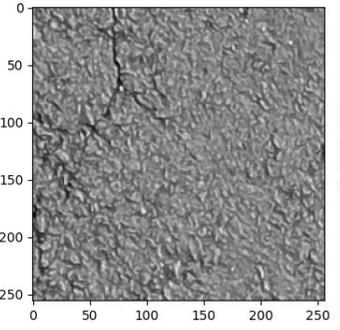
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 4.27%
Não Trinca: 95.73%
Inferência: 0.167 seg

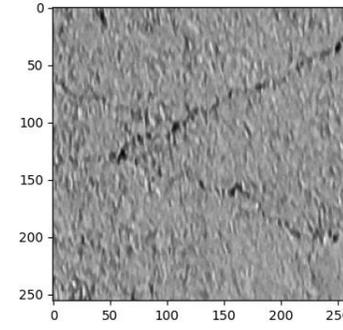
06 - resnet50_Colorido_06102021.pkl



Pred.: Não Trinca

Trinca: 38.64%
Não Trinca: 61.36%
Inferência: 0.1755 seg

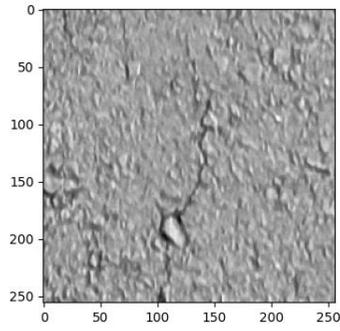
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 50.65%
Não Trinca: 49.35%
Inferência: 0.1766 seg

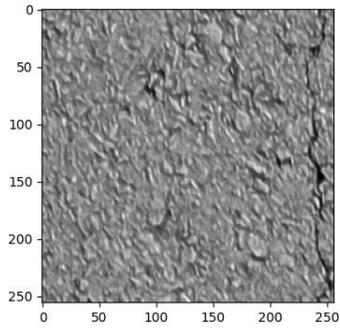
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 90.13%
Não Trinca: 9.87%
Inferência: 0.1814 seg

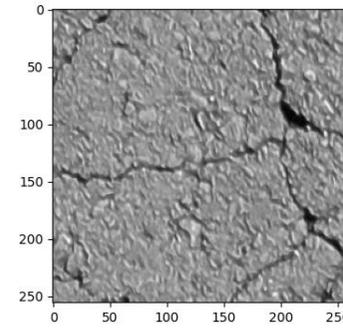
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 84.19%
Não Trinca: 15.81%
Inferência: 0.1781 seg

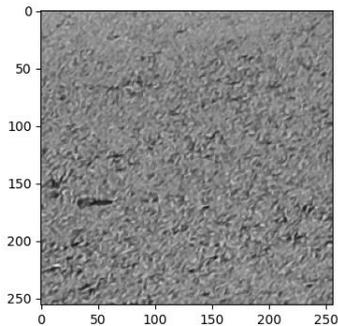
06 - resnet50_Colorido_06102021.pkl



Pred.: Trinca

Trinca: 99.90%
Não Trinca: 0.10%
Inferência: 0.1763 seg

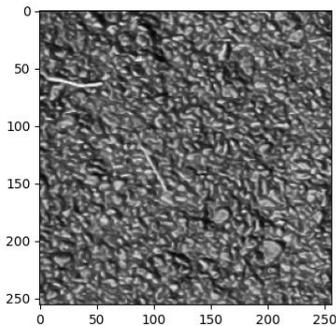
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2154 seg

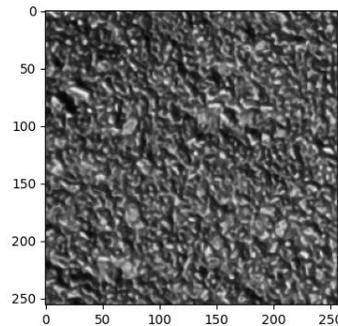
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.16%
Não Trinca: 99.84%
Inferência: 0.2148 seg

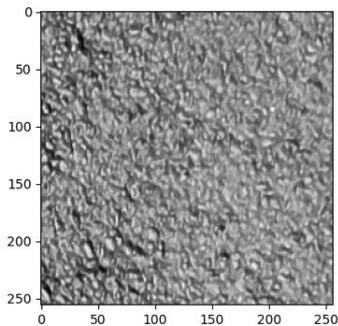
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.19%
Não Trinca: 99.81%
Inferência: 0.2157 seg

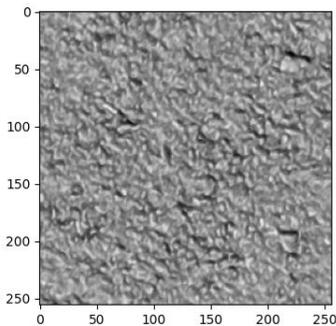
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.44%
Não Trinca: 99.56%
Inferência: 0.2147 seg

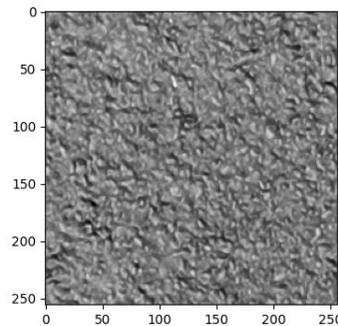
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.06%
Não Trinca: 99.94%
Inferência: 0.2189 seg

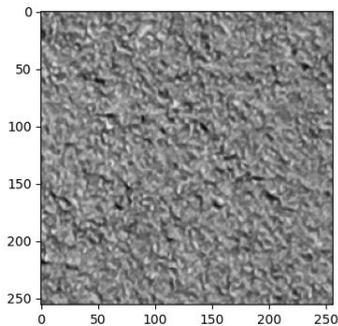
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2201 seg

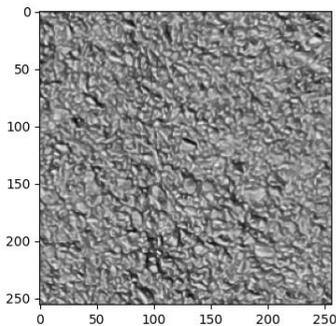
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.2175 seg

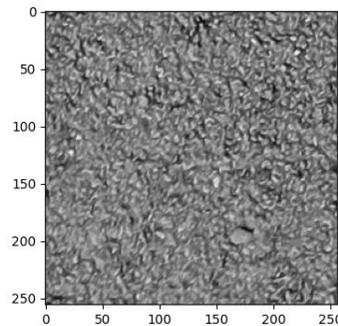
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.05%
Não Trinca: 99.95%
Inferência: 0.219 seg

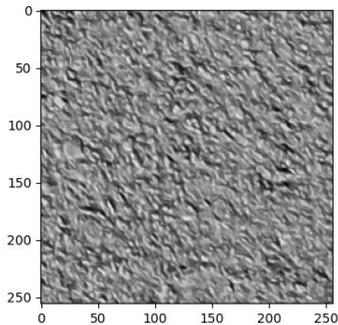
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.04%
Não Trinca: 99.96%
Inferência: 0.2233 seg

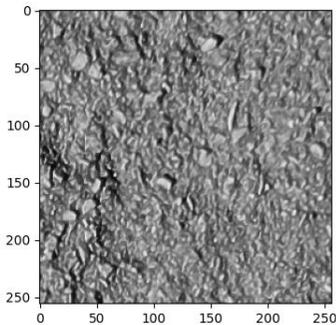
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.2126 seg

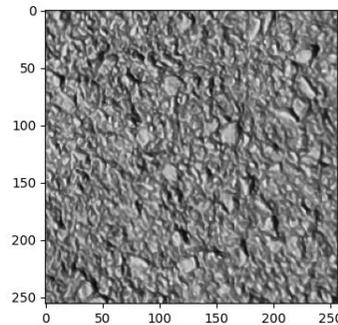
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 1.71%
Não Trinca: 98.29%
Inferência: 0.2141 seg

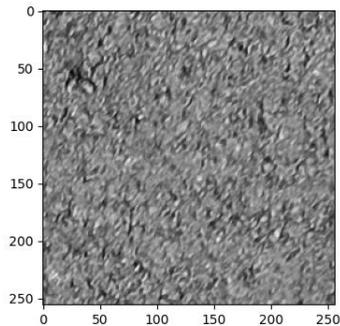
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.2135 seg

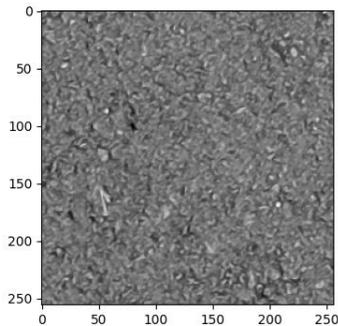
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.04%
Não Trinca: 99.96%
Inferência: 0.2135 seg

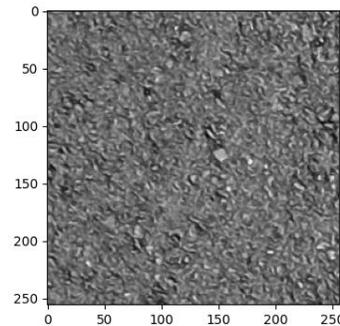
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.214 seg

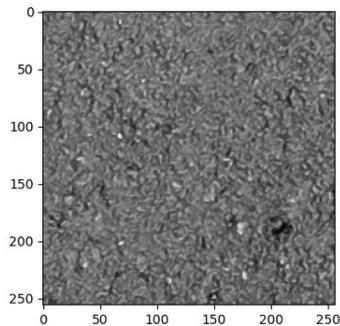
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2195 seg

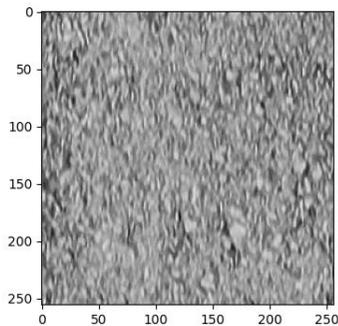
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.2171 seg

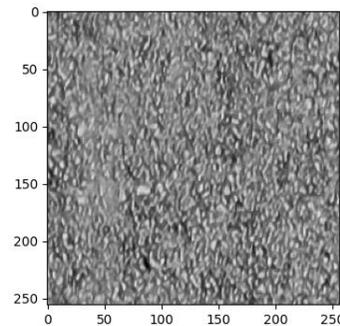
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.2161 seg

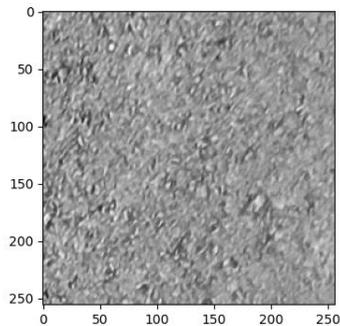
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.07%
Não Trinca: 99.93%
Inferência: 0.2173 seg

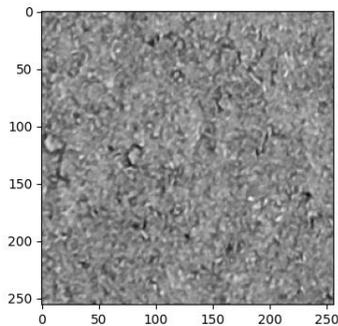
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.09%
Não Trinca: 99.91%
Inferência: 0.218 seg

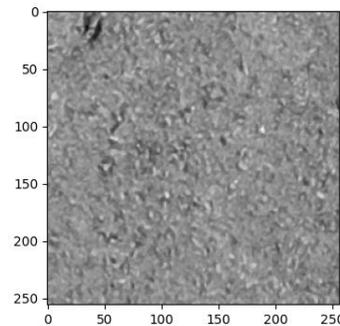
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2204 seg

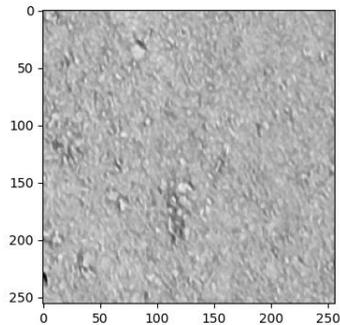
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2145 seg

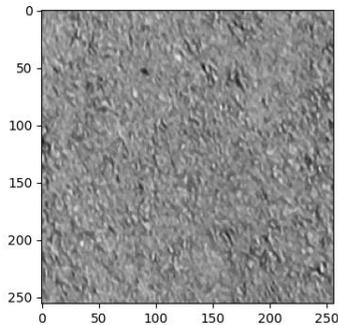
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.05%
Não Trinca: 99.95%
Inferência: 0.2208 seg

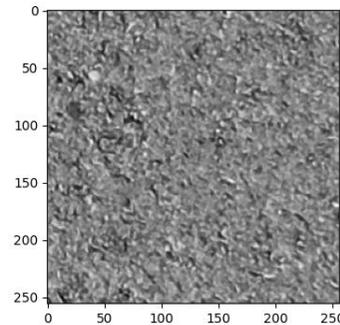
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.2159 seg

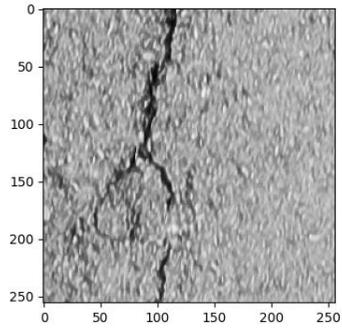
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

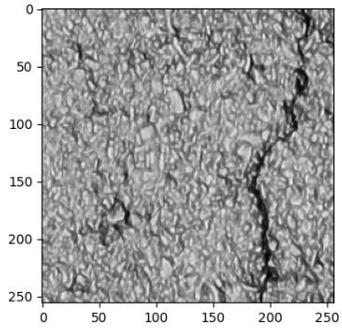
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2207 seg

07 - resnet101_Cinza_23102021.pkl



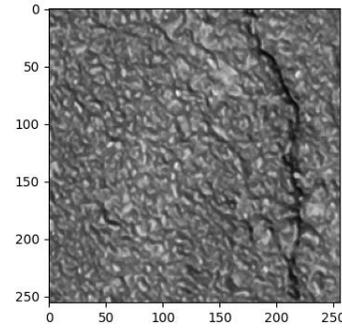
Pred.: Trinca
 Trinca: 61.60%
 Não Trinca: 38.40%
 Inferência: 0.2137 seg

07 - resnet101_Cinza_23102021.pkl



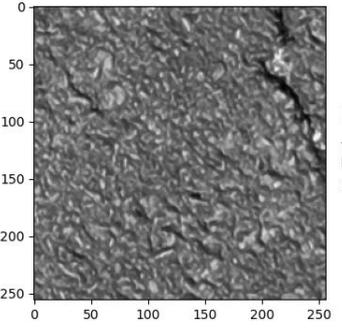
Pred.: Trinca
 Trinca: 57.76%
 Não Trinca: 42.24%
 Inferência: 0.2185 seg

07 - resnet101_Cinza_23102021.pkl



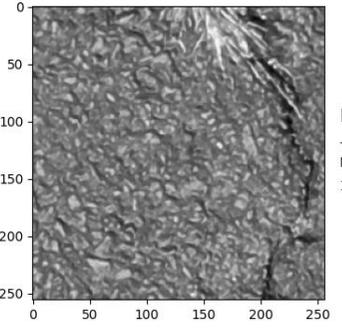
Pred.: Trinca
 Trinca: 58.72%
 Não Trinca: 41.28%
 Inferência: 0.22 seg

07 - resnet101_Cinza_23102021.pkl



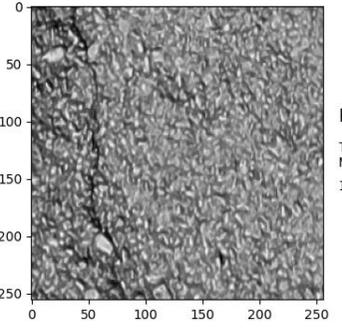
Pred.: Não Trinca
 Trinca: 26.51%
 Não Trinca: 73.49%
 Inferência: 0.2185 seg

07 - resnet101_Cinza_23102021.pkl



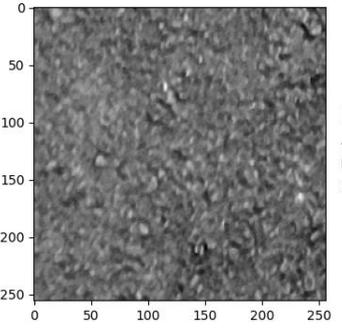
Pred.: Não Trinca
 Trinca: 28.58%
 Não Trinca: 71.42%
 Inferência: 0.2214 seg

07 - resnet101_Cinza_23102021.pkl



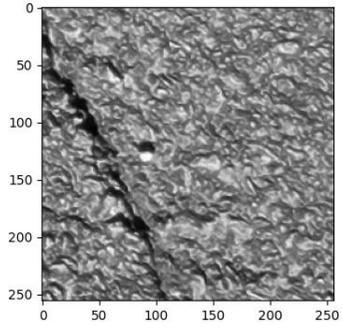
Pred.: Não Trinca
 Trinca: 28.20%
 Não Trinca: 71.80%
 Inferência: 0.2164 seg

07 - resnet101_Cinza_23102021.pkl



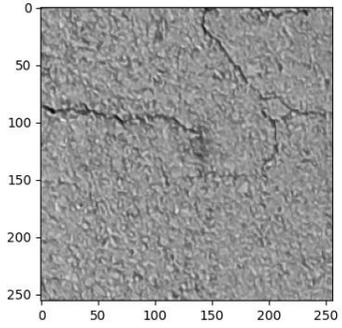
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.219 seg

07 - resnet101_Cinza_23102021.pkl



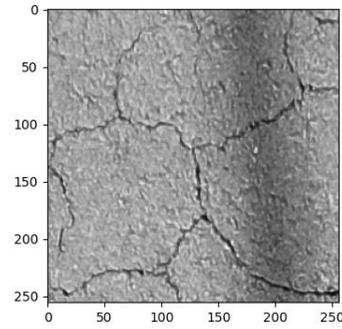
Pred.: Trinca
 Trinca: 85.58%
 Não Trinca: 14.42%
 Inferência: 0.2141 seg

07 - resnet101_Cinza_23102021.pkl



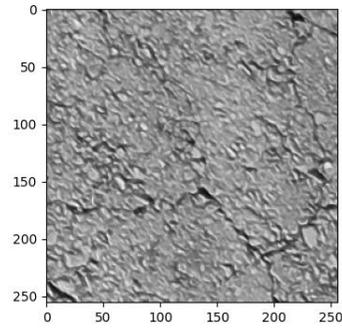
Pred.: Trinca
 Trinca: 94.00%
 Não Trinca: 6.00%
 Inferência: 0.2174 seg

07 - resnet101_Cinza_23102021.pkl



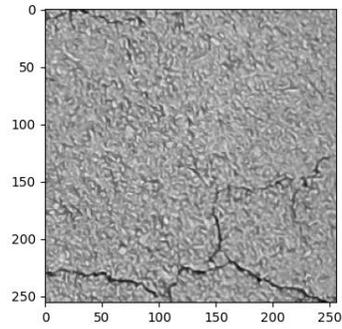
Pred.: Trinca
 Trinca: 99.98%
 Não Trinca: 0.02%
 Inferência: 0.221 seg

07 - resnet101_Cinza_23102021.pkl



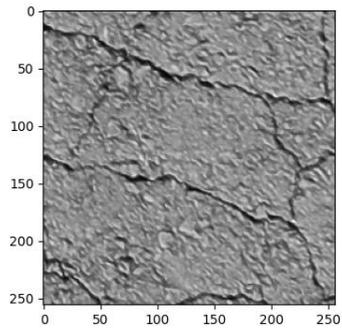
Pred.: Trinca
 Trinca: 73.54%
 Não Trinca: 26.46%
 Inferência: 0.214 seg

07 - resnet101_Cinza_23102021.pkl



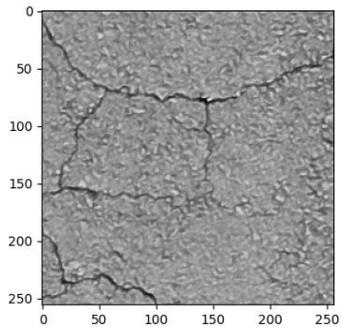
Pred.: Trinca
 Trinca: 90.77%
 Não Trinca: 9.23%
 Inferência: 0.216 seg

07 - resnet101_Cinza_23102021.pkl



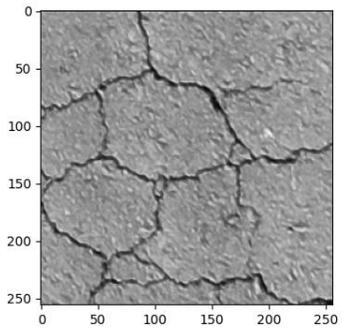
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.2169 seg

07 - resnet101_Cinza_23102021.pkl



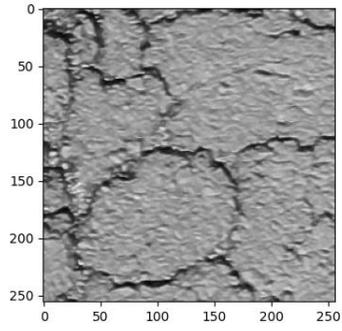
Pred.: Trinca
Trinca: 99.98%
Não Trinca: 0.02%
Inferência: 0.2234 seg

07 - resnet101_Cinza_23102021.pkl



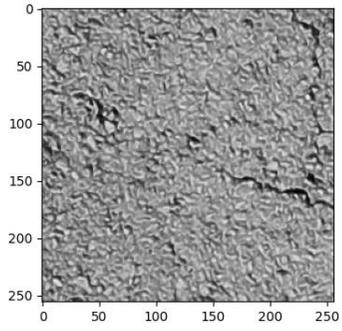
Pred.: Trinca
Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.2149 seg

07 - resnet101_Cinza_23102021.pkl



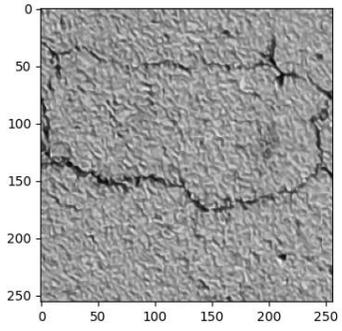
Pred.: Trinca
Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.2144 seg

07 - resnet101_Cinza_23102021.pkl



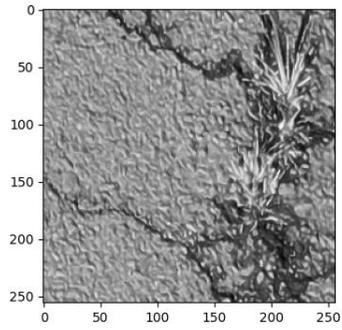
Pred.: Trinca
Trinca: 83.22%
Não Trinca: 16.78%
Inferência: 0.2257 seg

07 - resnet101_Cinza_23102021.pkl



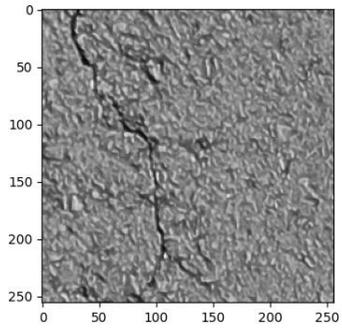
Pred.: Trinca
Trinca: 99.98%
Não Trinca: 0.02%
Inferência: 0.2265 seg

07 - resnet101_Cinza_23102021.pkl



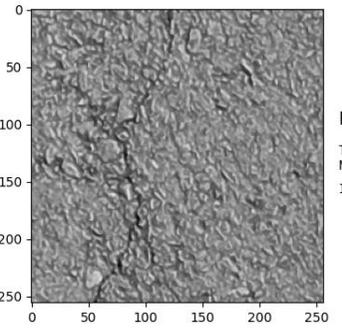
Pred.: Trinca
Trinca: 97.45%
Não Trinca: 2.55%
Inferência: 0.2179 seg

07 - resnet101_Cinza_23102021.pkl



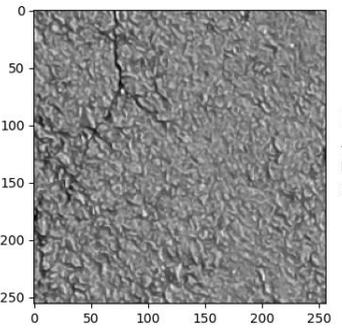
Pred.: Trinca
Trinca: 84.46%
Não Trinca: 15.54%
Inferência: 0.2167 seg

07 - resnet101_Cinza_23102021.pkl



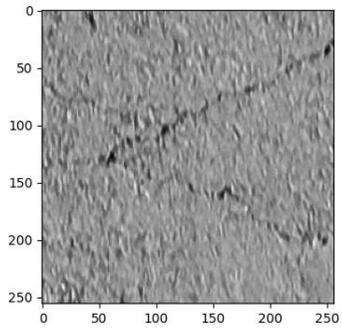
Pred.: Não Trinca
Trinca: 44.53%
Não Trinca: 55.47%
Inferência: 0.2171 seg

07 - resnet101_Cinza_23102021.pkl



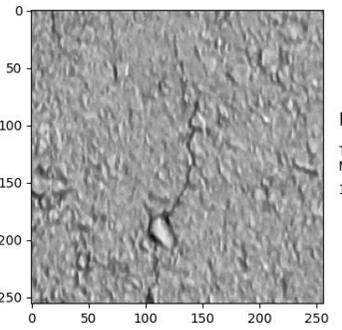
Pred.: Não Trinca
Trinca: 34.49%
Não Trinca: 65.51%
Inferência: 0.2198 seg

07 - resnet101_Cinza_23102021.pkl



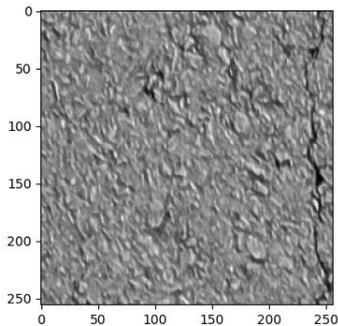
Pred.: Trinca
Trinca: 71.74%
Não Trinca: 28.26%
Inferência: 0.2157 seg

07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca
Trinca: 3.71%
Não Trinca: 96.29%
Inferência: 0.2157 seg

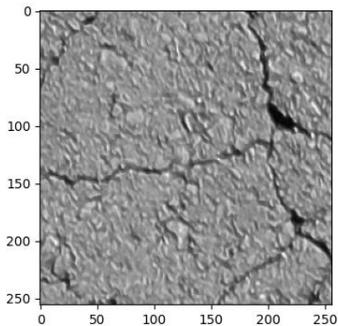
07 - resnet101_Cinza_23102021.pkl



Pred.: Não Trinca

Trinca: 21.11%
Não Trinca: 78.89%
Inferência: 0.214 seg

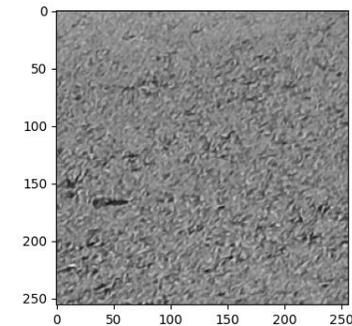
07 - resnet101_Cinza_23102021.pkl



Pred.: Trinca

Trinca: 99.09%
Não Trinca: 0.91%
Inferência: 0.2153 seg

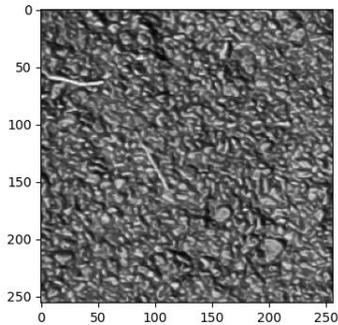
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2162 seg

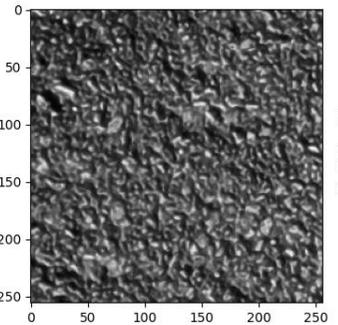
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.57%
Não Trinca: 99.43%
Inferência: 0.2222 seg

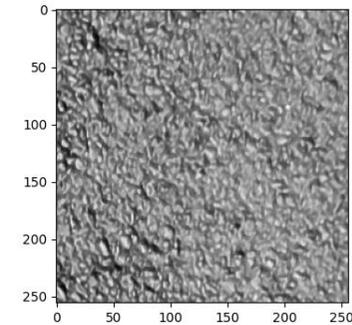
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.05%
Não Trinca: 99.95%
Inferência: 0.2256 seg

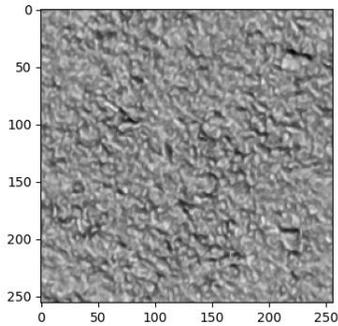
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 1.25%
Não Trinca: 98.75%
Inferência: 0.2184 seg

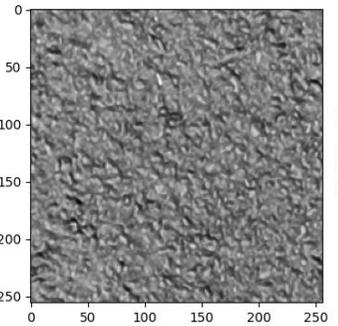
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.40%
Não Trinca: 99.60%
Inferência: 0.2177 seg

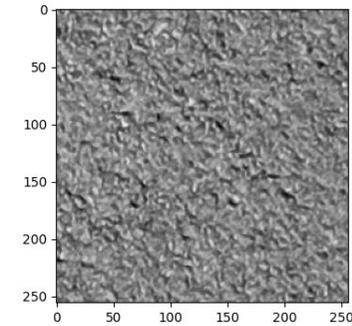
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2168 seg

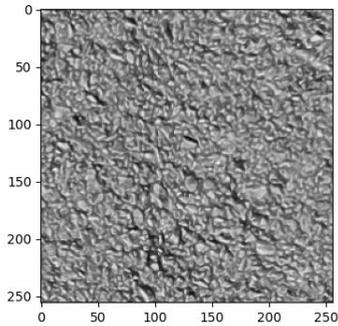
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2237 seg

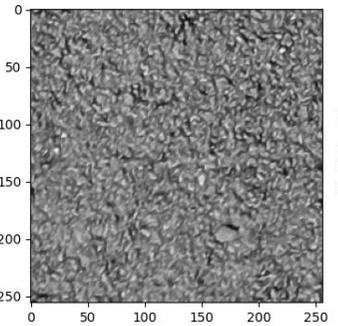
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.49%
Não Trinca: 99.51%
Inferência: 0.2248 seg

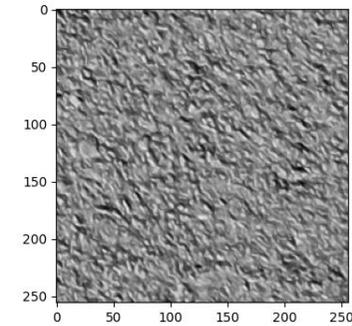
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2168 seg

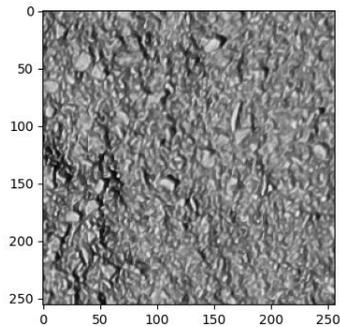
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.68%
Não Trinca: 99.32%
Inferência: 0.2177 seg

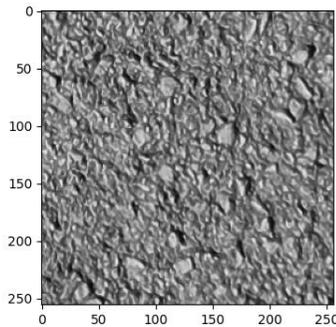
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 5.73%
Não Trinca: 94.27%
Inferência: 0.2216 seg

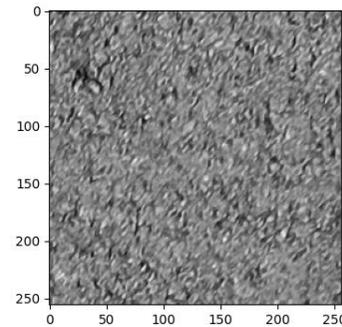
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.05%
Não Trinca: 99.95%
Inferência: 0.2259 seg

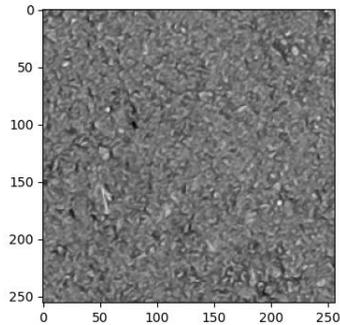
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.2182 seg

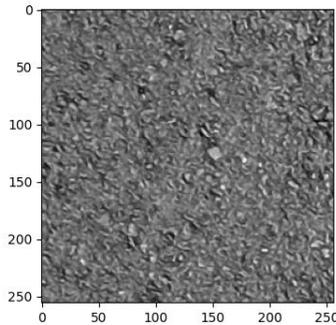
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2189 seg

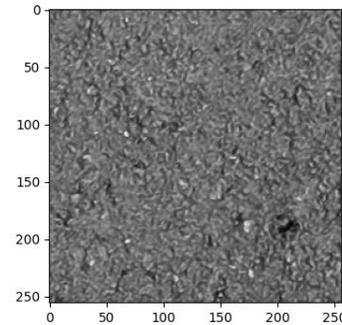
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.219 seg

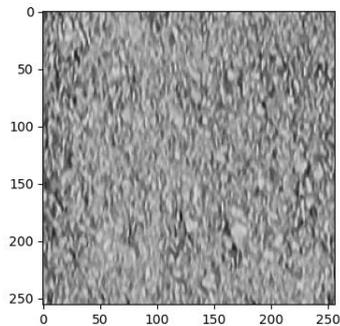
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.223 seg

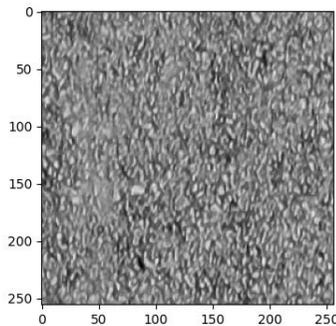
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.19%
Não Trinca: 99.81%
Inferência: 0.2251 seg

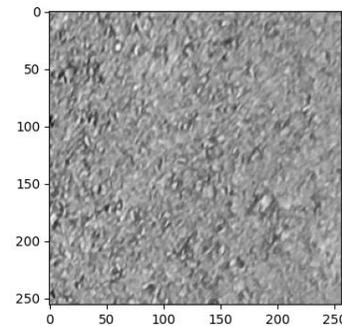
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.2179 seg

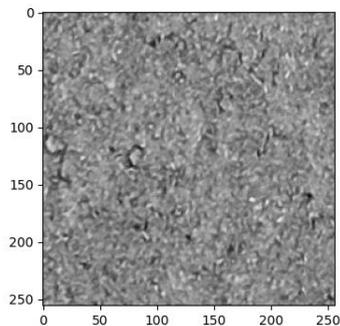
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2213 seg

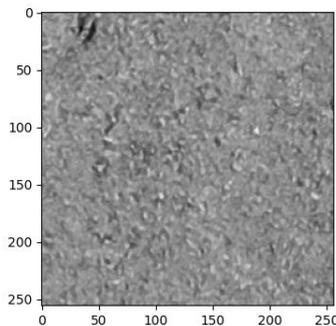
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2212 seg

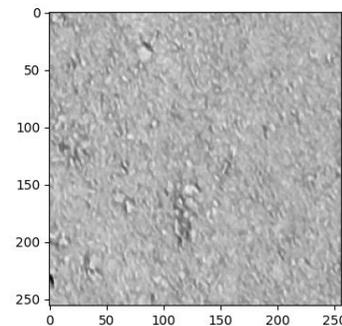
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2285 seg

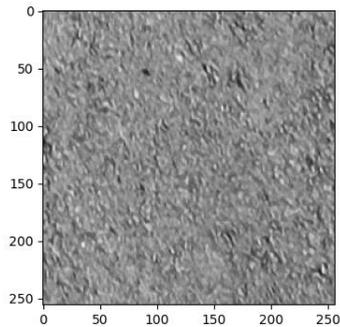
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

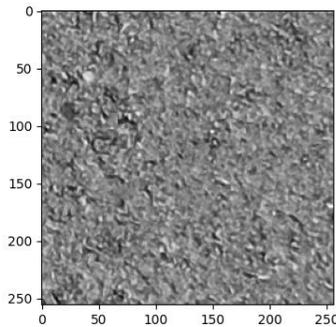
Trinca: 0.05%
Não Trinca: 99.95%
Inferência: 0.2254 seg

07 - resnet101_Colorido_23102021.pkl



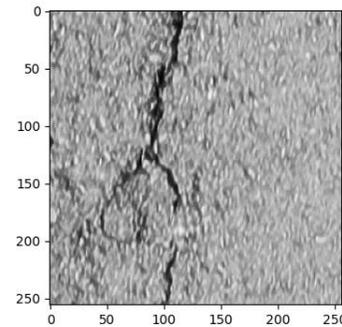
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2206 seg

07 - resnet101_Colorido_23102021.pkl



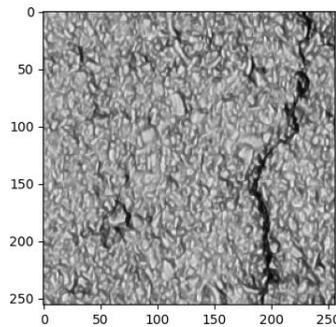
Pred.: Não Trinca
Trinca: 0.01%
Não Trinca: 99.99%
Inferência: 0.2248 seg

07 - resnet101_Colorido_23102021.pkl



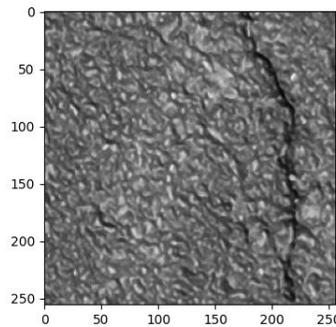
Pred.: Trinca
Trinca: 90.74%
Não Trinca: 9.26%
Inferência: 0.2226 seg

07 - resnet101_Colorido_23102021.pkl



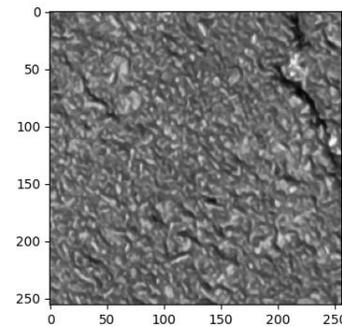
Pred.: Trinca
Trinca: 85.73%
Não Trinca: 14.27%
Inferência: 0.2182 seg

07 - resnet101_Colorido_23102021.pkl



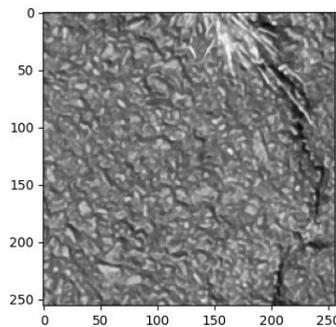
Pred.: Trinca
Trinca: 61.55%
Não Trinca: 38.45%
Inferência: 0.221 seg

07 - resnet101_Colorido_23102021.pkl



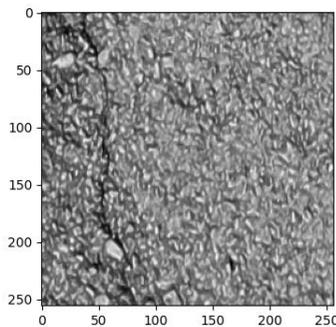
Pred.: Trinca
Trinca: 81.10%
Não Trinca: 18.90%
Inferência: 0.2272 seg

07 - resnet101_Colorido_23102021.pkl



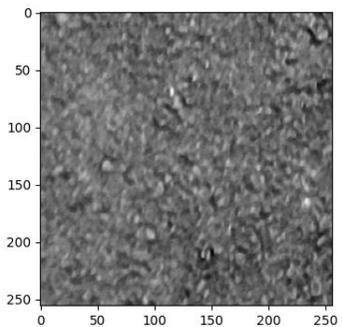
Pred.: Trinca
Trinca: 59.51%
Não Trinca: 40.49%
Inferência: 0.2243 seg

07 - resnet101_Colorido_23102021.pkl



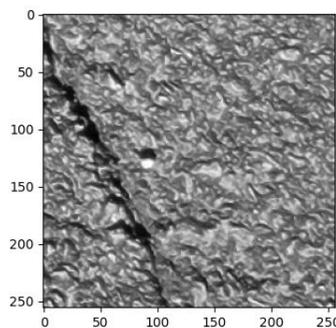
Pred.: Não Trinca
Trinca: 14.98%
Não Trinca: 85.02%
Inferência: 0.2248 seg

07 - resnet101_Colorido_23102021.pkl



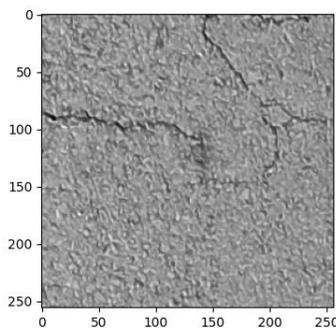
Pred.: Não Trinca
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.2182 seg

07 - resnet101_Colorido_23102021.pkl



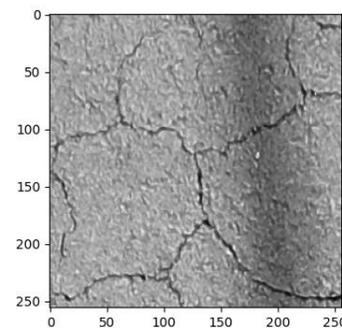
Pred.: Trinca
Trinca: 95.33%
Não Trinca: 4.67%
Inferência: 0.2209 seg

07 - resnet101_Colorido_23102021.pkl



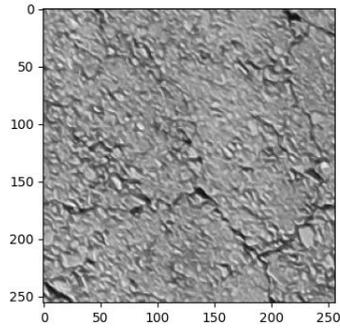
Pred.: Não Trinca
Trinca: 22.77%
Não Trinca: 77.23%
Inferência: 0.2236 seg

07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca
Trinca: 90.33%
Não Trinca: 9.67%
Inferência: 0.2218 seg

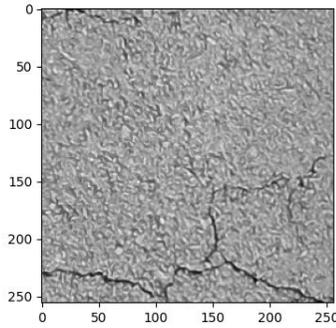
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 91.57%
Não Trinca: 8.43%
Inferência: 0.2181 seg

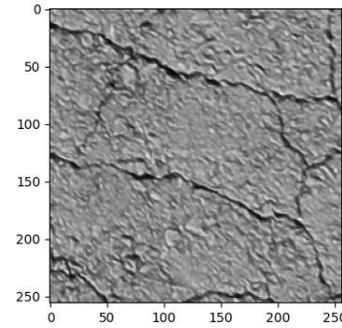
07 - resnet101_Colorido_23102021.pkl



Pred.: Não Trinca

Trinca: 17.51%
Não Trinca: 82.49%
Inferência: 0.2201 seg

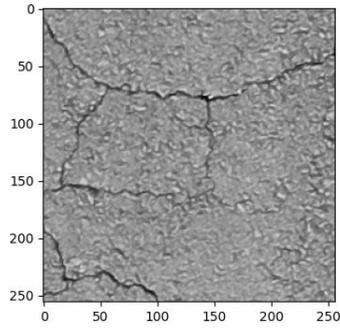
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 99.99%
Não Trinca: 0.01%
Inferência: 0.2178 seg

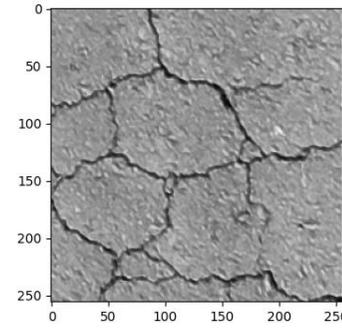
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 99.69%
Não Trinca: 0.31%
Inferência: 0.2195 seg

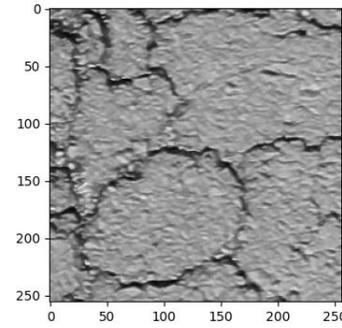
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 99.98%
Não Trinca: 0.02%
Inferência: 0.2226 seg

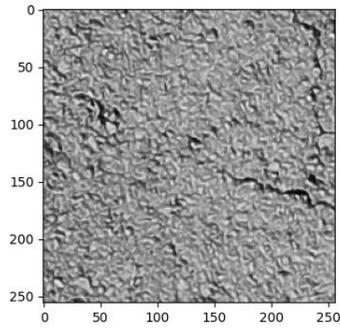
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 99.96%
Não Trinca: 0.04%
Inferência: 0.2154 seg

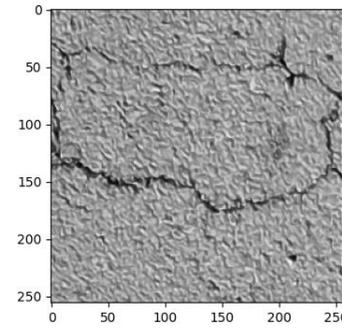
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 91.81%
Não Trinca: 8.19%
Inferência: 0.2185 seg

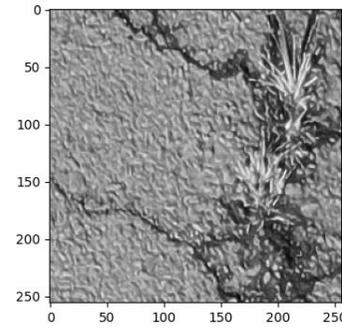
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 99.42%
Não Trinca: 0.58%
Inferência: 0.2199 seg

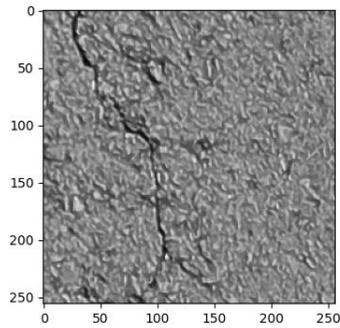
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 90.51%
Não Trinca: 9.49%
Inferência: 0.2153 seg

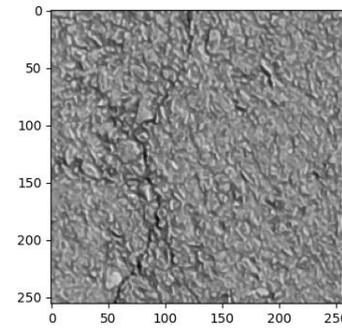
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 92.90%
Não Trinca: 7.10%
Inferência: 0.2178 seg

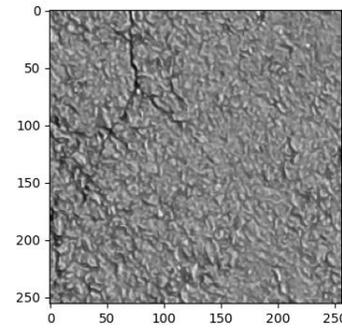
07 - resnet101_Colorido_23102021.pkl



Pred.: Trinca

Trinca: 61.44%
Não Trinca: 38.56%
Inferência: 0.2199 seg

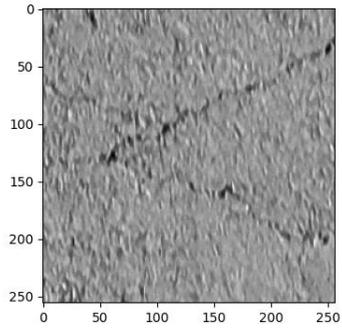
07 - resnet101_Colorido_23102021.pkl



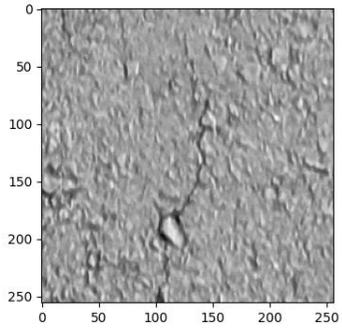
Pred.: Trinca

Trinca: 80.26%
Não Trinca: 19.74%
Inferência: 0.2243 seg

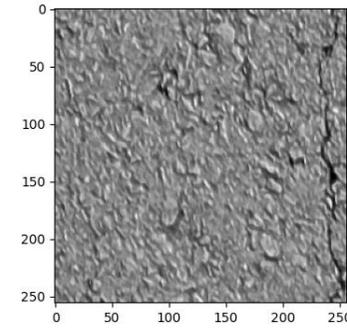
07 - resnet101_Colorido_23102021.pkl



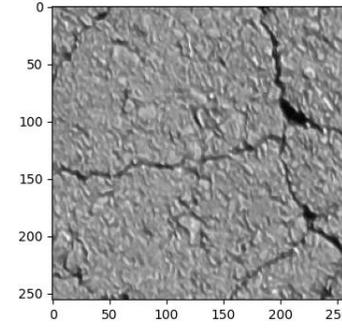
07 - resnet101_Colorido_23102021.pkl



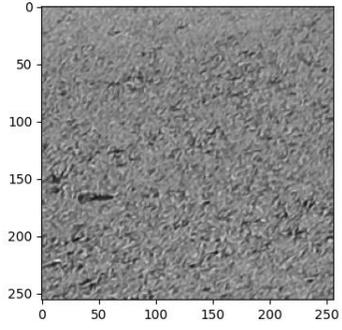
07 - resnet101_Colorido_23102021.pkl



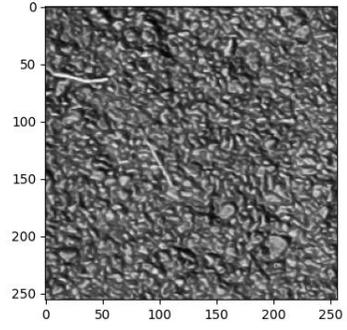
07 - resnet101_Colorido_23102021.pkl



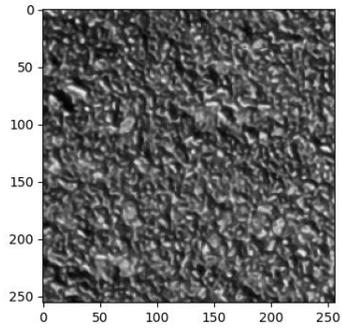
08 - resnet152_Cinza_15102021.pkl



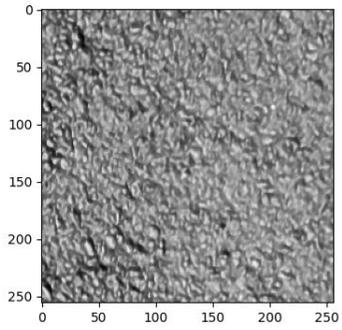
08 - resnet152_Cinza_15102021.pkl



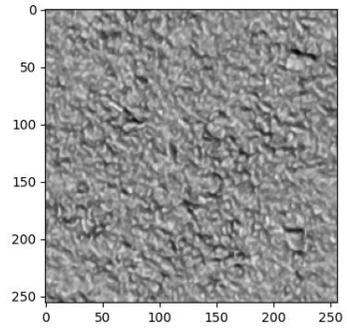
08 - resnet152_Cinza_15102021.pkl



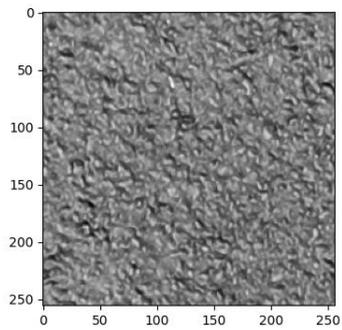
08 - resnet152_Cinza_15102021.pkl



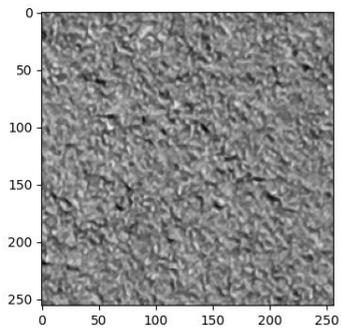
08 - resnet152_Cinza_15102021.pkl



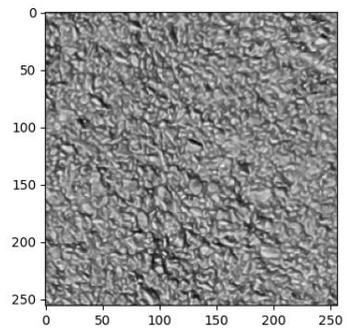
08 - resnet152_Cinza_15102021.pkl



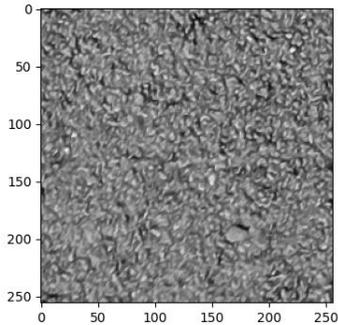
08 - resnet152_Cinza_15102021.pkl



08 - resnet152_Cinza_15102021.pkl



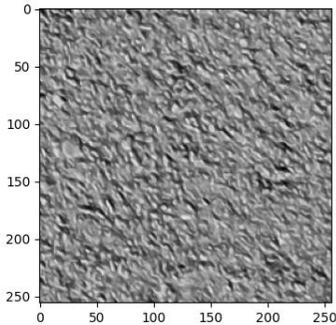
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.3651 seg

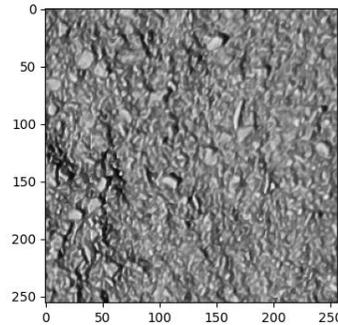
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.3662 seg

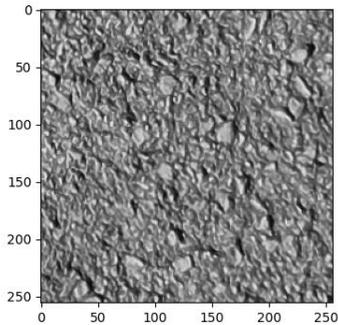
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 5.18%
Não Trinca: 94.82%
Inferência: 0.373 seg

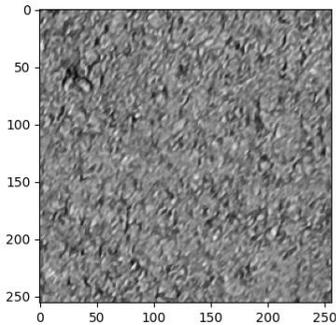
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.09%
Não Trinca: 99.91%
Inferência: 0.3599 seg

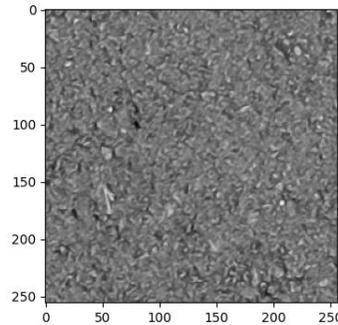
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.07%
Não Trinca: 99.93%
Inferência: 0.3683 seg

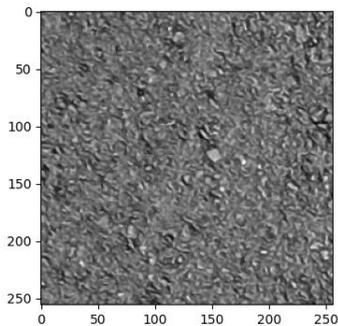
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.3657 seg

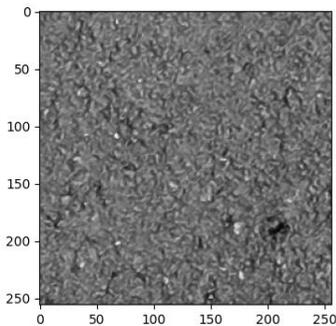
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.02%
Não Trinca: 99.98%
Inferência: 0.3685 seg

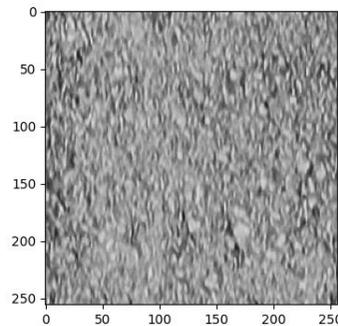
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.25%
Não Trinca: 99.75%
Inferência: 0.3622 seg

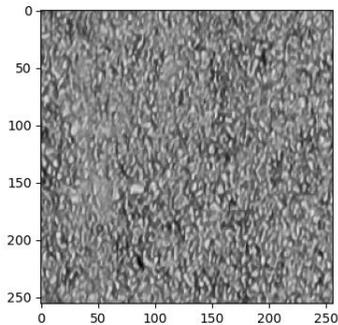
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.03%
Não Trinca: 99.97%
Inferência: 0.3629 seg

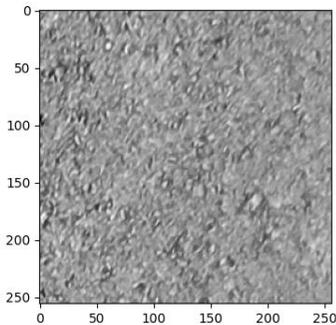
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.21%
Não Trinca: 99.79%
Inferência: 0.3599 seg

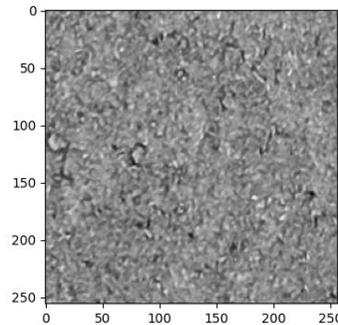
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.3611 seg

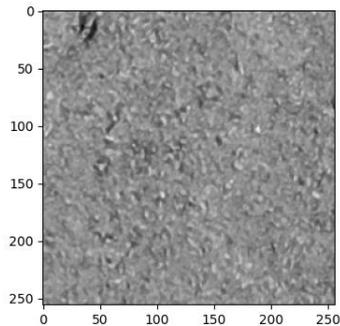
08 - resnet152_Cinza_15102021.pkl



Pred.: Não Trinca

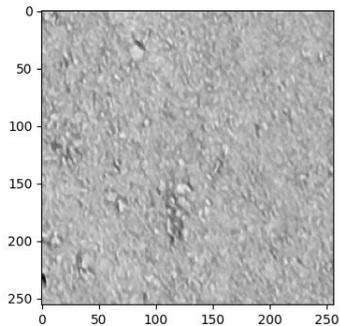
Trinca: 0.00%
Não Trinca: 100.00%
Inferência: 0.3645 seg

08 - resnet152_Cinza_15102021.pkl



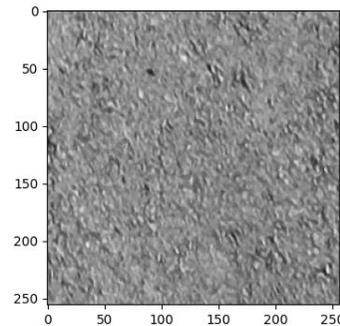
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3659 seg

08 - resnet152_Cinza_15102021.pkl



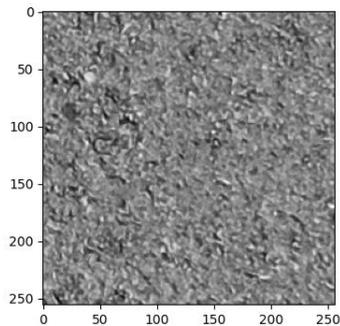
Pred.: Não Trinca
 Trinca: 0.03%
 Não Trinca: 99.97%
 Inferência: 0.3682 seg

08 - resnet152_Cinza_15102021.pkl



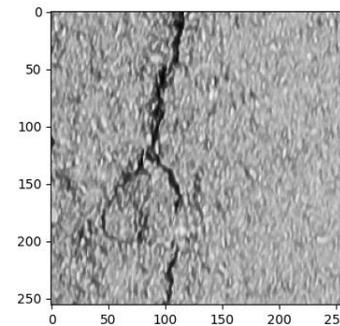
Pred.: Não Trinca
 Trinca: 0.03%
 Não Trinca: 99.97%
 Inferência: 0.3603 seg

08 - resnet152_Cinza_15102021.pkl



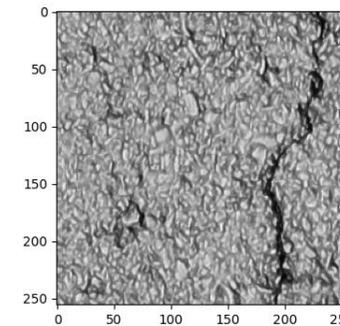
Pred.: Não Trinca
 Trinca: 0.03%
 Não Trinca: 99.97%
 Inferência: 0.3605 seg

08 - resnet152_Cinza_15102021.pkl



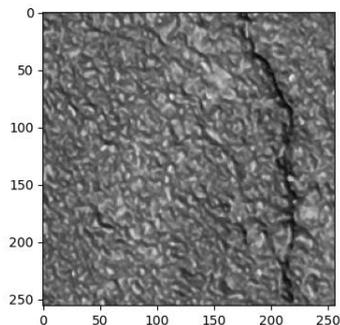
Pred.: Trinca
 Trinca: 80.03%
 Não Trinca: 19.97%
 Inferência: 0.3616 seg

08 - resnet152_Cinza_15102021.pkl



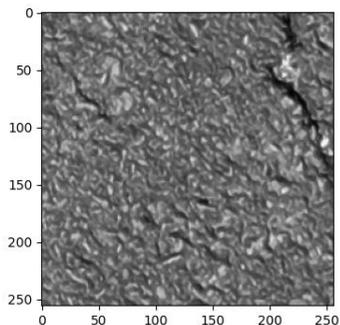
Pred.: Trinca
 Trinca: 67.53%
 Não Trinca: 32.47%
 Inferência: 0.3619 seg

08 - resnet152_Cinza_15102021.pkl



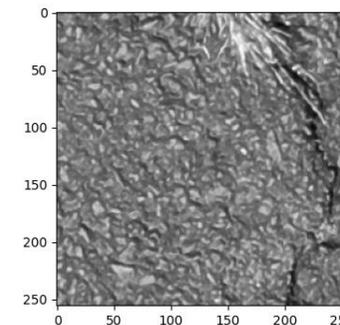
Pred.: Não Trinca
 Trinca: 44.00%
 Não Trinca: 56.00%
 Inferência: 0.3613 seg

08 - resnet152_Cinza_15102021.pkl



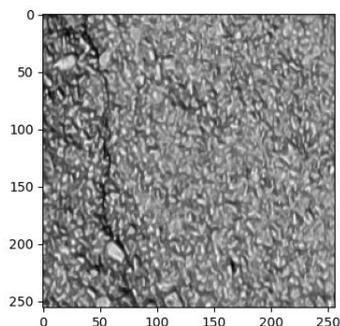
Pred.: Não Trinca
 Trinca: 45.06%
 Não Trinca: 54.94%
 Inferência: 0.3694 seg

08 - resnet152_Cinza_15102021.pkl



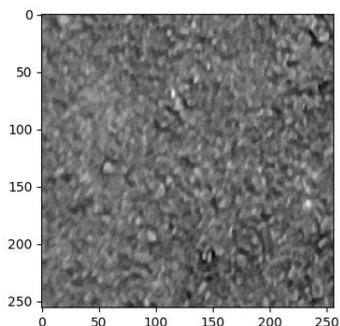
Pred.: Trinca
 Trinca: 66.51%
 Não Trinca: 33.49%
 Inferência: 0.3708 seg

08 - resnet152_Cinza_15102021.pkl



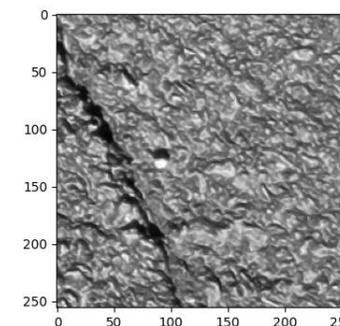
Pred.: Não Trinca
 Trinca: 26.08%
 Não Trinca: 73.92%
 Inferência: 0.3602 seg

08 - resnet152_Cinza_15102021.pkl



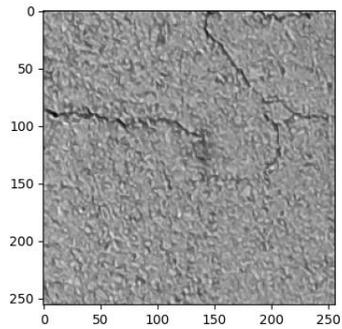
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3731 seg

08 - resnet152_Cinza_15102021.pkl



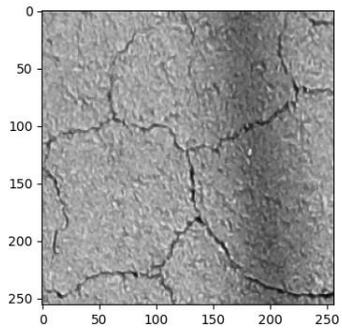
Pred.: Trinca
 Trinca: 95.15%
 Não Trinca: 4.85%
 Inferência: 0.3628 seg

08 - resnet152_Cinza_15102021.pkl



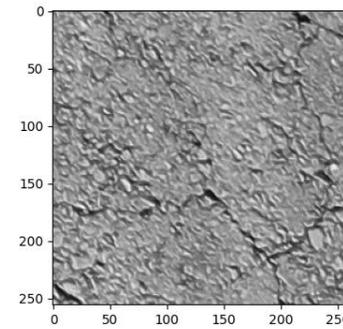
Pred.: Trinca
 Trinca: 99.60%
 Não Trinca: 0.40%
 Inferência: 0.3688 seg

08 - resnet152_Cinza_15102021.pkl



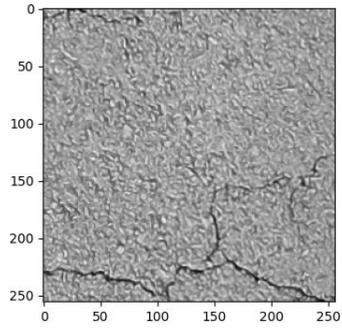
Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.3719 seg

08 - resnet152_Cinza_15102021.pkl



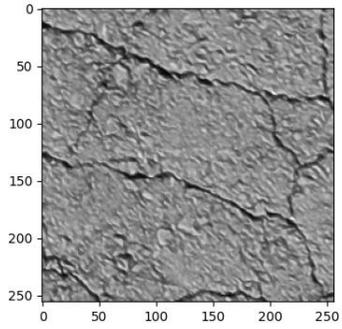
Pred.: Trinca
 Trinca: 95.35%
 Não Trinca: 4.65%
 Inferência: 0.3628 seg

08 - resnet152_Cinza_15102021.pkl



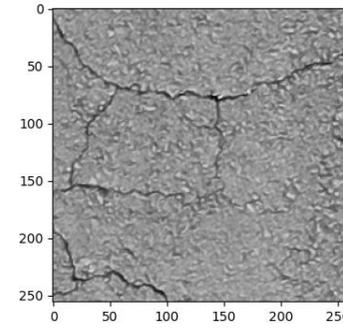
Pred.: Trinca
 Trinca: 91.38%
 Não Trinca: 8.62%
 Inferência: 0.3634 seg

08 - resnet152_Cinza_15102021.pkl



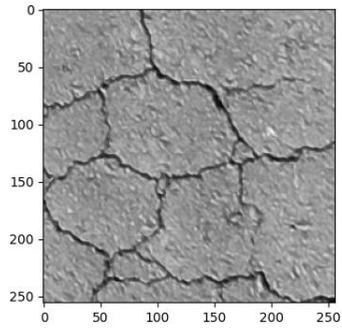
Pred.: Trinca
 Trinca: 99.98%
 Não Trinca: 0.02%
 Inferência: 0.3612 seg

08 - resnet152_Cinza_15102021.pkl



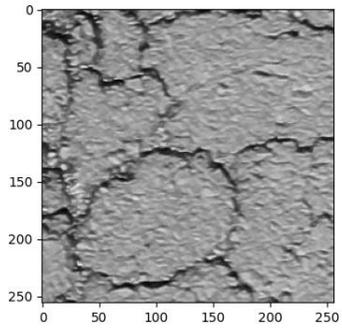
Pred.: Trinca
 Trinca: 99.98%
 Não Trinca: 0.02%
 Inferência: 0.3691 seg

08 - resnet152_Cinza_15102021.pkl



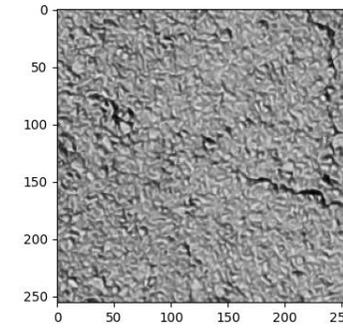
Pred.: Trinca
 Trinca: 99.99%
 Não Trinca: 0.01%
 Inferência: 0.3679 seg

08 - resnet152_Cinza_15102021.pkl



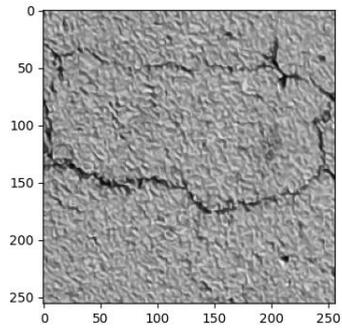
Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.3619 seg

08 - resnet152_Cinza_15102021.pkl



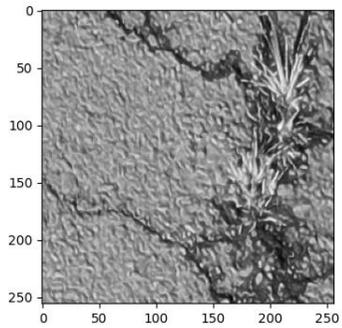
Pred.: Trinca
 Trinca: 77.55%
 Não Trinca: 22.45%
 Inferência: 0.359 seg

08 - resnet152_Cinza_15102021.pkl



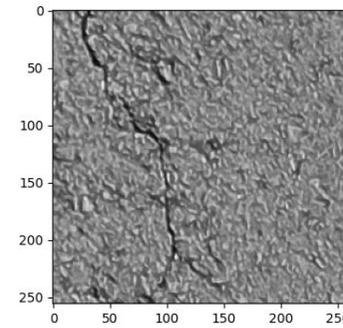
Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.3638 seg

08 - resnet152_Cinza_15102021.pkl



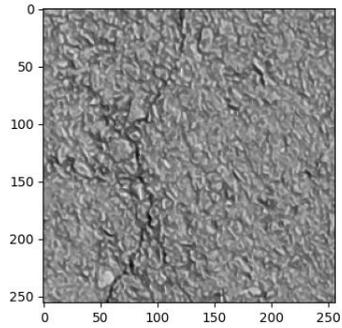
Pred.: Trinca
 Trinca: 96.52%
 Não Trinca: 3.48%
 Inferência: 0.3627 seg

08 - resnet152_Cinza_15102021.pkl



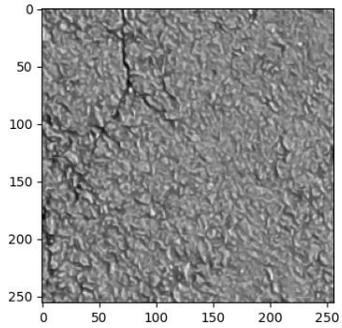
Pred.: Trinca
 Trinca: 82.33%
 Não Trinca: 17.67%
 Inferência: 0.3576 seg

08 - resnet152_Cinza_15102021.pkl



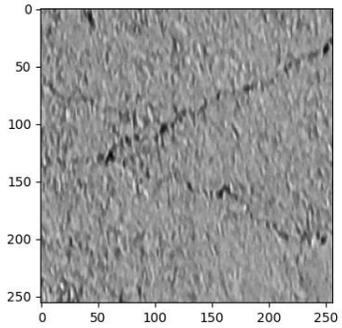
Pred.: Trinca
 Trinca: 79.08%
 Não Trinca: 20.92%
 Inferência: 0.3622 seg

08 - resnet152_Cinza_15102021.pkl



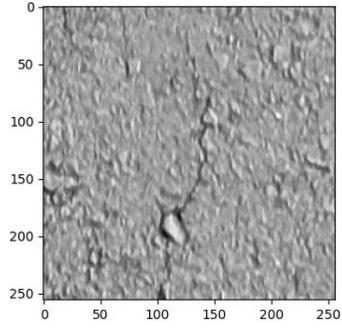
Pred.: Trinca
 Trinca: 52.76%
 Não Trinca: 47.24%
 Inferência: 0.3627 seg

08 - resnet152_Cinza_15102021.pkl



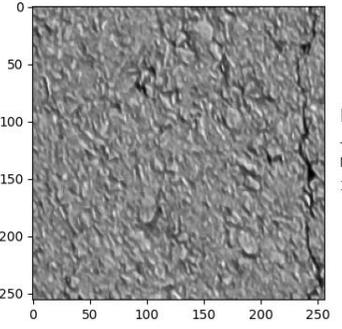
Pred.: Trinca
 Trinca: 76.23%
 Não Trinca: 23.77%
 Inferência: 0.3613 seg

08 - resnet152_Cinza_15102021.pkl



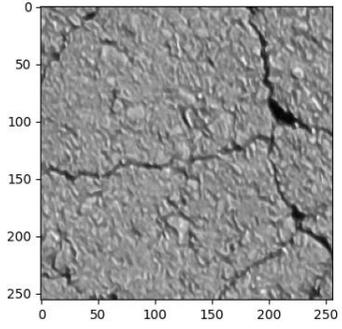
Pred.: Trinca
 Trinca: 76.27%
 Não Trinca: 23.73%
 Inferência: 0.3607 seg

08 - resnet152_Cinza_15102021.pkl



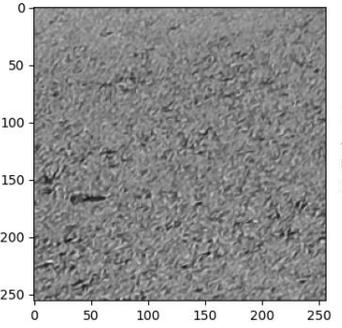
Pred.: Não Trinca
 Trinca: 7.38%
 Não Trinca: 92.62%
 Inferência: 0.3702 seg

08 - resnet152_Cinza_15102021.pkl



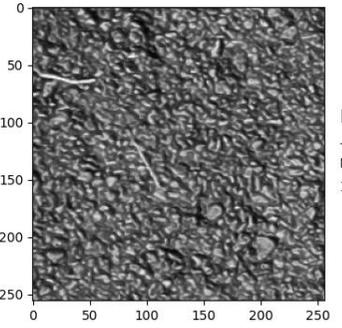
Pred.: Trinca
 Trinca: 99.65%
 Não Trinca: 0.35%
 Inferência: 0.3608 seg

08 - resnet152_Colorido_15102021.pkl



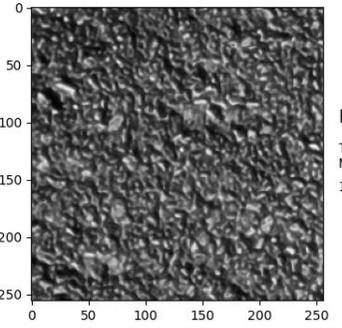
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3655 seg

08 - resnet152_Colorido_15102021.pkl



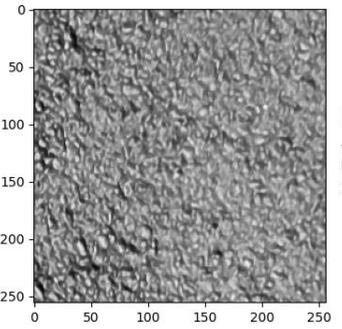
Pred.: Não Trinca
 Trinca: 1.28%
 Não Trinca: 98.72%
 Inferência: 0.3687 seg

08 - resnet152_Colorido_15102021.pkl



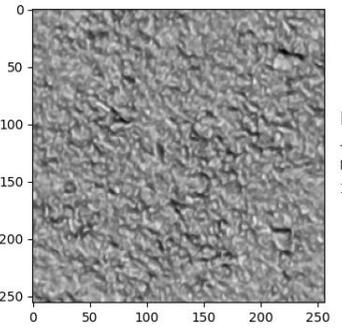
Pred.: Não Trinca
 Trinca: 0.78%
 Não Trinca: 99.22%
 Inferência: 0.3676 seg

08 - resnet152_Colorido_15102021.pkl



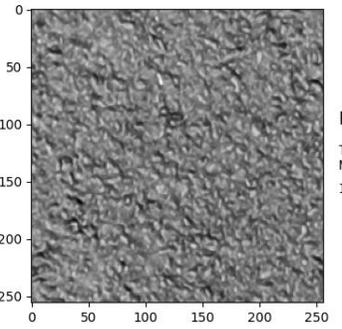
Pred.: Não Trinca
 Trinca: 43.10%
 Não Trinca: 56.90%
 Inferência: 0.3747 seg

08 - resnet152_Colorido_15102021.pkl



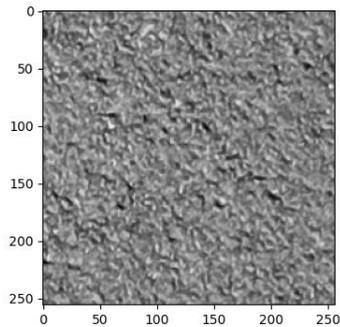
Pred.: Não Trinca
 Trinca: 1.38%
 Não Trinca: 98.62%
 Inferência: 0.3697 seg

08 - resnet152_Colorido_15102021.pkl



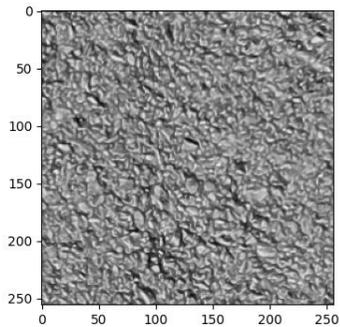
Pred.: Não Trinca
 Trinca: 0.24%
 Não Trinca: 99.76%
 Inferência: 0.367 seg

08 - resnet152_Colorido_15102021.pkl



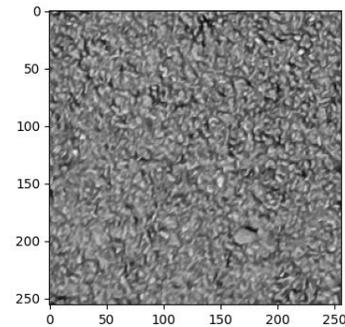
Pred.: Não Trinca
 Trinca: 0.02%
 Não Trinca: 99.98%
 Inferência: 0.3709 seg

08 - resnet152_Colorido_15102021.pkl



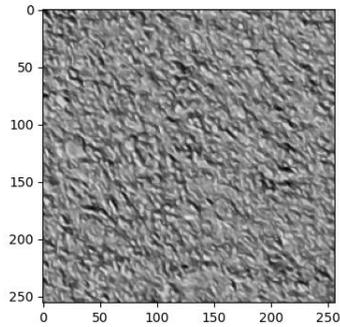
Pred.: Não Trinca
 Trinca: 0.24%
 Não Trinca: 99.76%
 Inferência: 0.3668 seg

08 - resnet152_Colorido_15102021.pkl



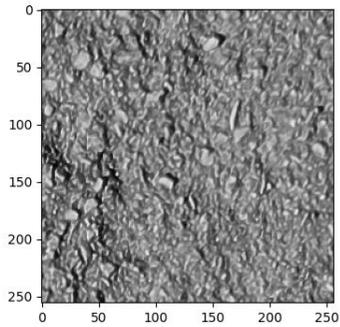
Pred.: Não Trinca
 Trinca: 0.06%
 Não Trinca: 99.94%
 Inferência: 0.3723 seg

08 - resnet152_Colorido_15102021.pkl



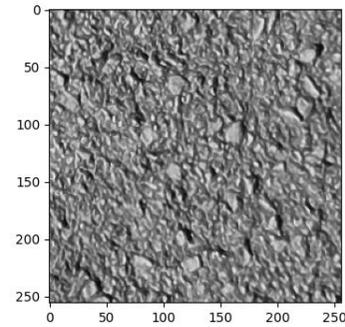
Pred.: Não Trinca
 Trinca: 0.09%
 Não Trinca: 99.91%
 Inferência: 0.3689 seg

08 - resnet152_Colorido_15102021.pkl



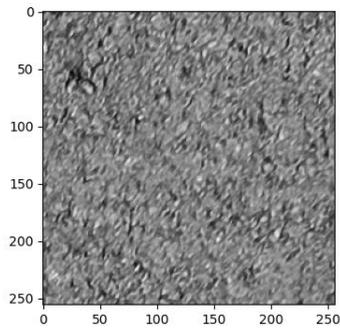
Pred.: Não Trinca
 Trinca: 40.07%
 Não Trinca: 59.93%
 Inferência: 0.3642 seg

08 - resnet152_Colorido_15102021.pkl



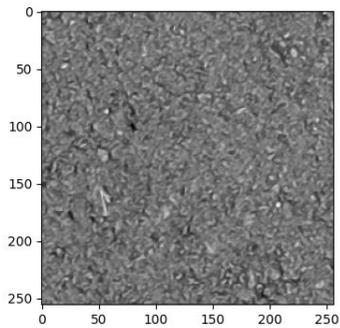
Pred.: Não Trinca
 Trinca: 0.17%
 Não Trinca: 99.83%
 Inferência: 0.3708 seg

08 - resnet152_Colorido_15102021.pkl



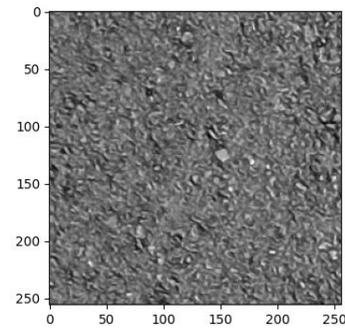
Pred.: Não Trinca
 Trinca: 0.02%
 Não Trinca: 99.98%
 Inferência: 0.3665 seg

08 - resnet152_Colorido_15102021.pkl



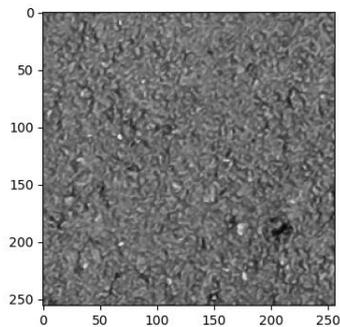
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3702 seg

08 - resnet152_Colorido_15102021.pkl



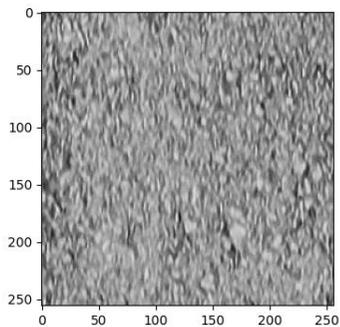
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.3675 seg

08 - resnet152_Colorido_15102021.pkl



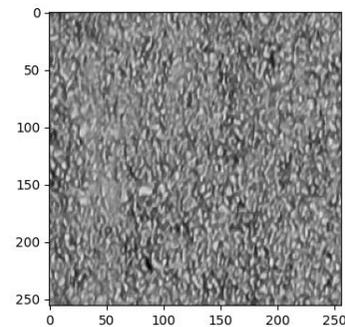
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3672 seg

08 - resnet152_Colorido_15102021.pkl



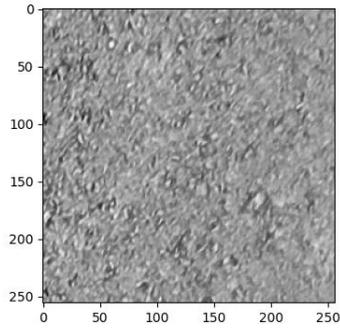
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3681 seg

08 - resnet152_Colorido_15102021.pkl



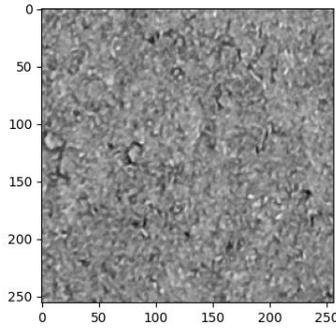
Pred.: Não Trinca
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.3715 seg

08 - resnet152_Colorido_15102021.pkl



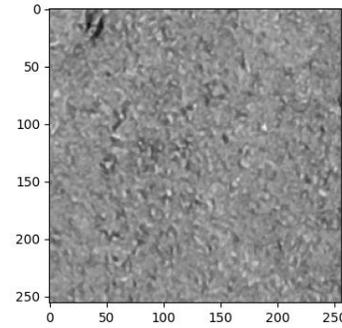
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3695 seg

08 - resnet152_Colorido_15102021.pkl



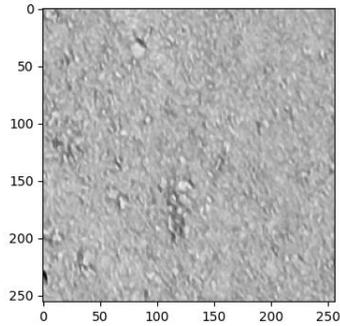
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.373 seg

08 - resnet152_Colorido_15102021.pkl



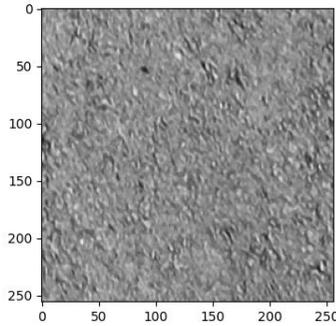
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3733 seg

08 - resnet152_Colorido_15102021.pkl



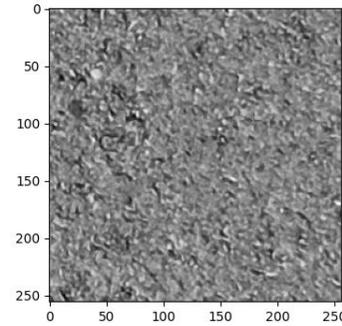
Pred.: Não Trincado
 Trinca: 0.02%
 Não Trinca: 99.98%
 Inferência: 0.3674 seg

08 - resnet152_Colorido_15102021.pkl



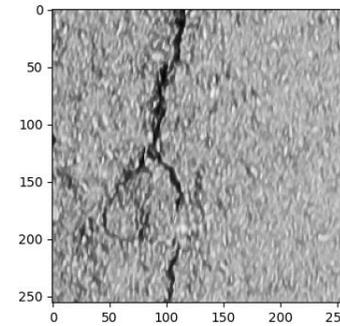
Pred.: Não Trincado
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3658 seg

08 - resnet152_Colorido_15102021.pkl



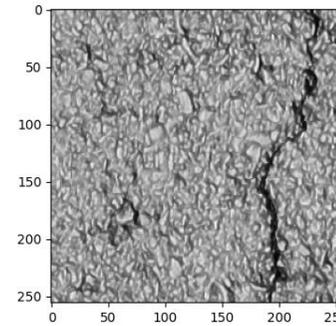
Pred.: Não Trincado
 Trinca: 0.01%
 Não Trinca: 99.99%
 Inferência: 0.3668 seg

08 - resnet152_Colorido_15102021.pkl



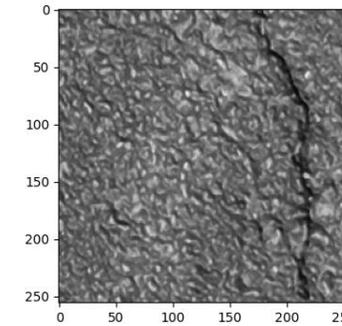
Pred.: Trincado
 Trinca: 95.52%
 Não Trinca: 4.48%
 Inferência: 0.3644 seg

08 - resnet152_Colorido_15102021.pkl



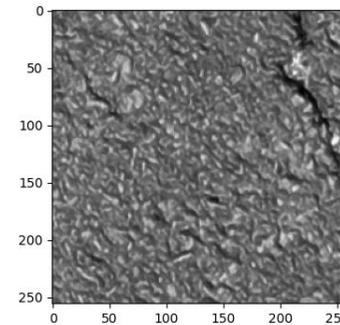
Pred.: Trincado
 Trinca: 97.51%
 Não Trinca: 2.49%
 Inferência: 0.3664 seg

08 - resnet152_Colorido_15102021.pkl



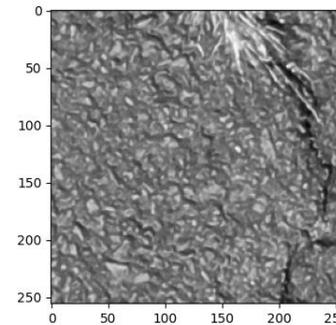
Pred.: Trincado
 Trinca: 91.52%
 Não Trinca: 8.48%
 Inferência: 0.3686 seg

08 - resnet152_Colorido_15102021.pkl



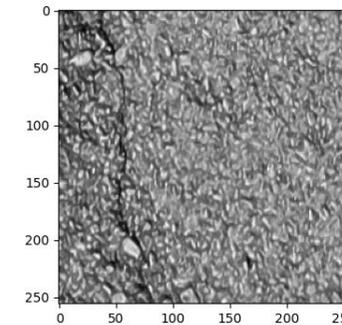
Pred.: Trincado
 Trinca: 74.27%
 Não Trinca: 25.73%
 Inferência: 0.3661 seg

08 - resnet152_Colorido_15102021.pkl



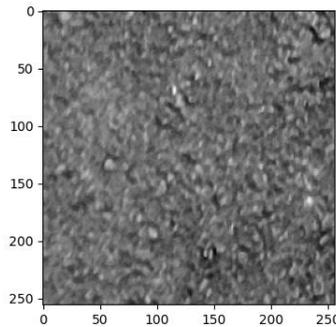
Pred.: Trincado
 Trinca: 94.65%
 Não Trinca: 5.35%
 Inferência: 0.3731 seg

08 - resnet152_Colorido_15102021.pkl



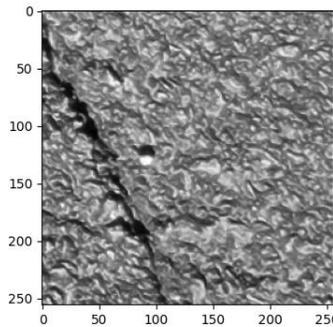
Pred.: Trincado
 Trinca: 69.90%
 Não Trinca: 30.10%
 Inferência: 0.3685 seg

08 - resnet152_Colorido_15102021.pkl



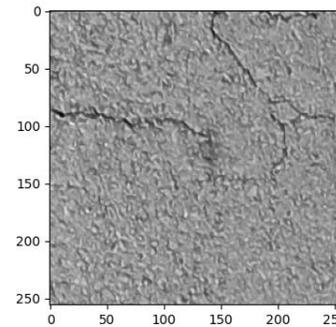
Pred.: Não Trinca
 Trinca: 0.00%
 Não Trinca: 100.00%
 Inferência: 0.3666 seg

08 - resnet152_Colorido_15102021.pkl



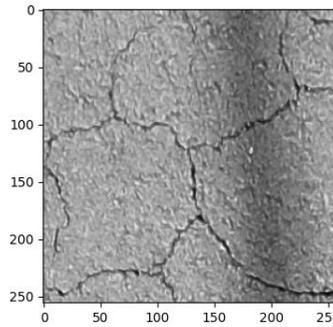
Pred.: Trinca
 Trinca: 97.98%
 Não Trinca: 2.02%
 Inferência: 0.3737 seg

08 - resnet152_Colorido_15102021.pkl



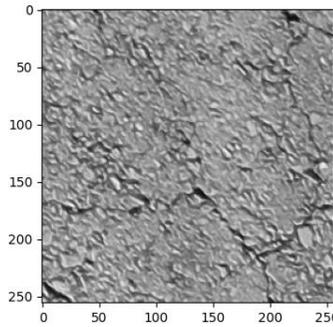
Pred.: Trinca
 Trinca: 75.03%
 Não Trinca: 24.97%
 Inferência: 0.3681 seg

08 - resnet152_Colorido_15102021.pkl



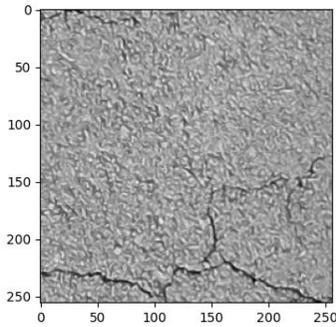
Pred.: Trinca
 Trinca: 96.30%
 Não Trinca: 3.70%
 Inferência: 0.3755 seg

08 - resnet152_Colorido_15102021.pkl



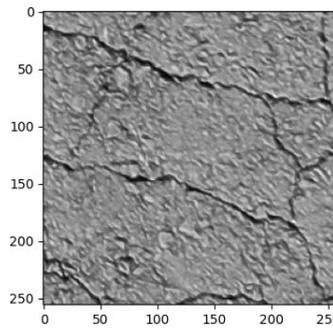
Pred.: Trinca
 Trinca: 99.64%
 Não Trinca: 0.36%
 Inferência: 0.3656 seg

08 - resnet152_Colorido_15102021.pkl



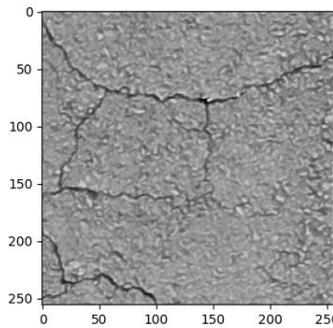
Pred.: Não Trinca
 Trinca: 28.16%
 Não Trinca: 71.84%
 Inferência: 0.3696 seg

08 - resnet152_Colorido_15102021.pkl



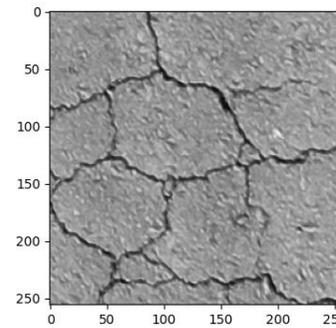
Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.3737 seg

08 - resnet152_Colorido_15102021.pkl



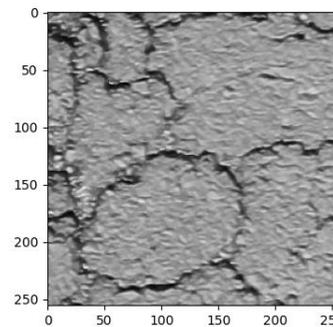
Pred.: Trinca
 Trinca: 99.90%
 Não Trinca: 0.10%
 Inferência: 0.3646 seg

08 - resnet152_Colorido_15102021.pkl



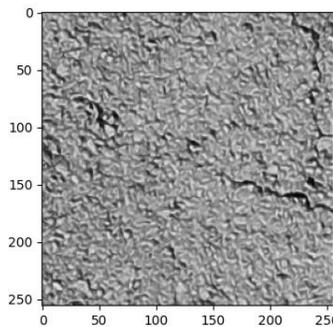
Pred.: Trinca
 Trinca: 99.84%
 Não Trinca: 0.16%
 Inferência: 0.3815 seg

08 - resnet152_Colorido_15102021.pkl



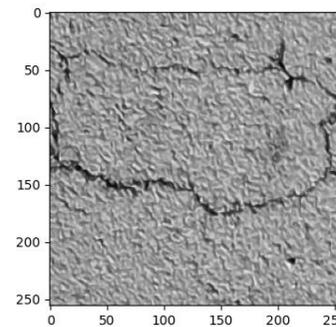
Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.365 seg

08 - resnet152_Colorido_15102021.pkl



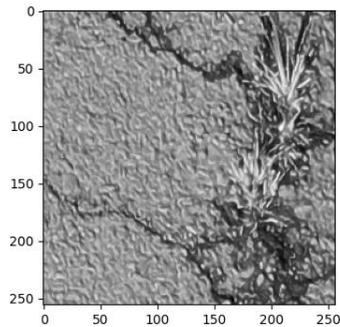
Pred.: Trinca
 Trinca: 98.92%
 Não Trinca: 1.08%
 Inferência: 0.3665 seg

08 - resnet152_Colorido_15102021.pkl



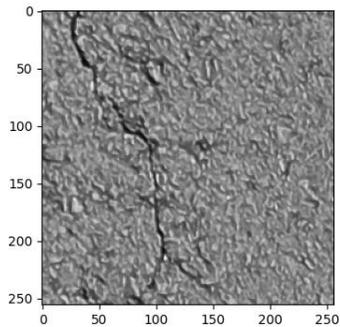
Pred.: Trinca
 Trinca: 100.00%
 Não Trinca: 0.00%
 Inferência: 0.3736 seg

08 - resnet152_Colorido_15102021.pkl



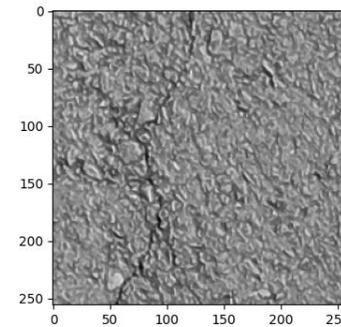
Pred.: Trinca
Trinca: 99.45%
Não Trinca: 0.55%
Inferência: 0.3624 seg

08 - resnet152_Colorido_15102021.pkl



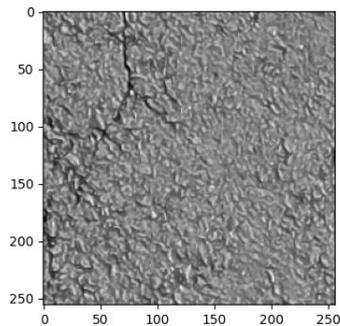
Pred.: Trinca
Trinca: 99.97%
Não Trinca: 0.03%
Inferência: 0.3657 seg

08 - resnet152_Colorido_15102021.pkl



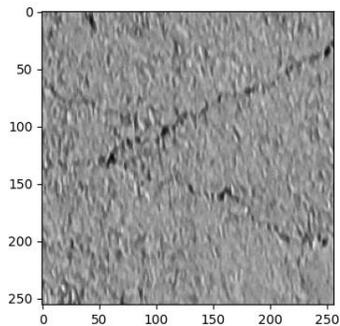
Pred.: Trinca
Trinca: 96.19%
Não Trinca: 3.81%
Inferência: 0.3672 seg

08 - resnet152_Colorido_15102021.pkl



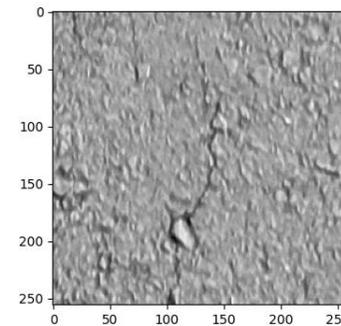
Pred.: Trinca
Trinca: 98.55%
Não Trinca: 1.45%
Inferência: 0.3729 seg

08 - resnet152_Colorido_15102021.pkl



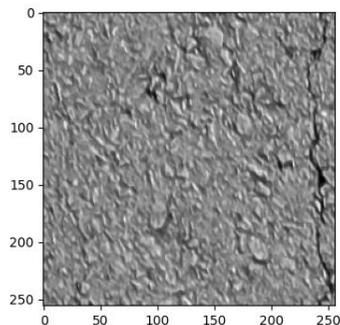
Pred.: Trinca
Trinca: 69.29%
Não Trinca: 30.71%
Inferência: 0.3653 seg

08 - resnet152_Colorido_15102021.pkl



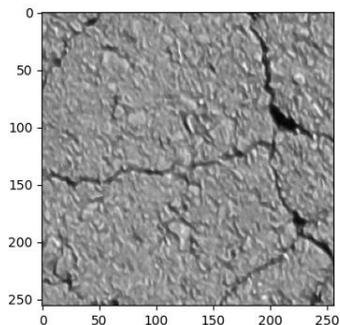
Pred.: Trinca
Trinca: 89.27%
Não Trinca: 10.73%
Inferência: 0.3699 seg

08 - resnet152_Colorido_15102021.pkl



Pred.: Trinca
Trinca: 95.87%
Não Trinca: 4.13%
Inferência: 0.3658 seg

08 - resnet152_Colorido_15102021.pkl



Pred.: Trinca
Trinca: 100.00%
Não Trinca: 0.00%
Inferência: 0.3635 seg



UPF

UNIVERSIDADE
DE PASSO FUNDO

UPF Campus I - BR 285, São José
Passo Fundo - RS - CEP: 99052-900
(54) 3316 7000 - www.upf.br