

Treinamento de Inteligência Artificial para remoção de fundo de fotos de chapas polidas capturadas em ambiente de produção industrial



Data: 23/01/2023

Projeto: HyperStone (centelha)

Introdução

Um dos principais desafios enfrentados por programas de edição de imagens é isolar um “elemento-alvo” para que este possa ser recortado do cenário e utilizado em outros contextos. Tradicionalmente, a detecção dos limites (*Edge Detection*) de um objeto em uma imagem depende de técnicas como “*Chromakey*”, que consiste em gerar o contraste entre um fundo neutro (geralmente verde) e o elemento-alvo.

Na indústria de Natural Stone, a fotografia das chapas polidas é realizada ao final do processo de polimento, portanto, além do elemento-alvo (chapa polida), temos diversos “elementos de cenário” (fundo), tais como a própria politriz e o ambiente de produção. Portanto, os elementos de fundo não constituem um cenário homogêneo que pudesse ser facilmente manipulado por editores tradicionais.

Por outro lado, a visualização das chapas polidas fica prejudicada, pois o cenário interfere na experiência do comprador. Levando estes fatos em consideração, utilizamos o treinamento de Inteligência Artificial (IA) para fazer a distinção entre a chapa polida e os demais elementos presentes na fotografia. Neste documento, apresentamos os resultados alcançados após cerca de 06 meses de pesquisas e aperfeiçoamento do modelo de treinamento.

Metodologia

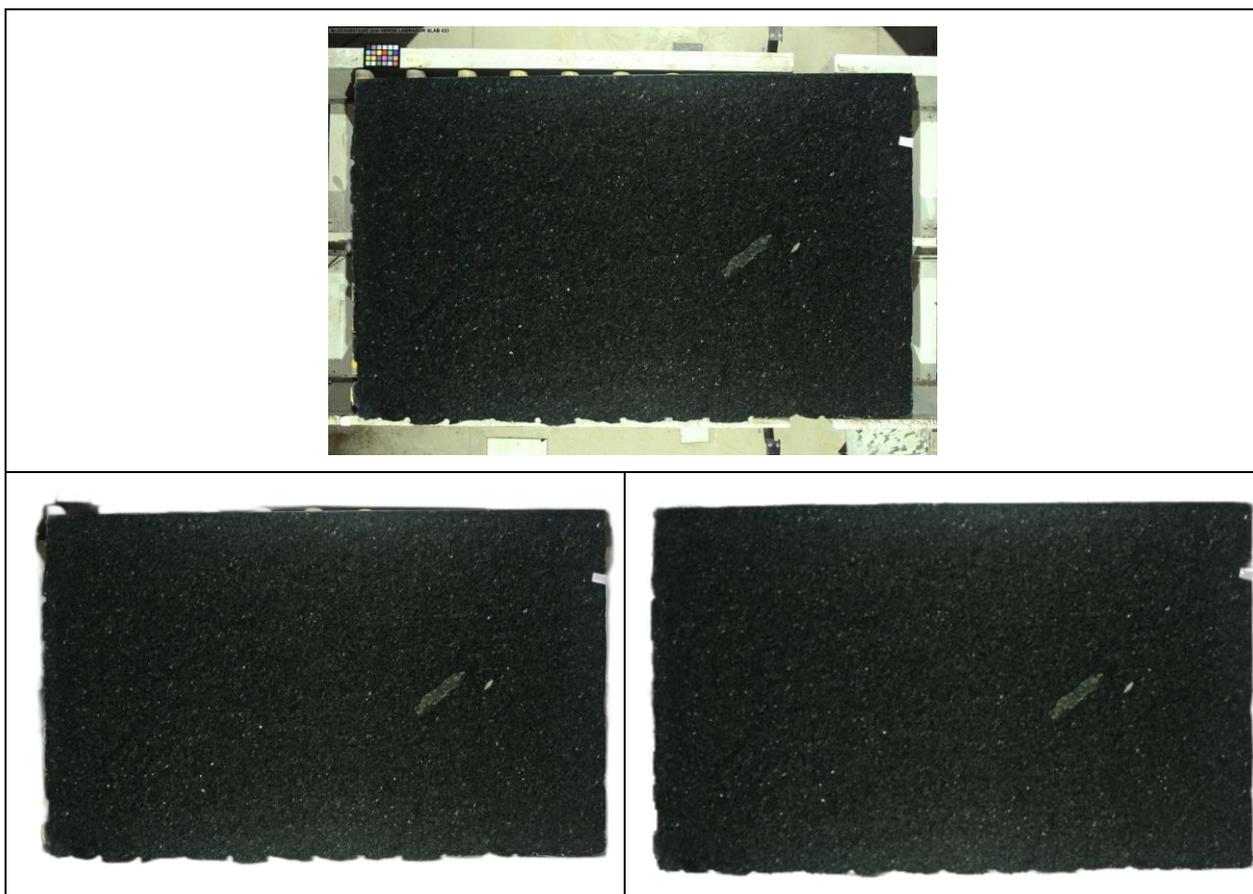
Para o treinamento do modelo de Inteligência Artificial, utilizamos um Dataset com imagens de diferentes chapas, em variedade de tipos, cores, cortes, texturas, formatos e posições, e suas

respectivas máscaras. Definimos um número de mínimo e iterações (*epochs*) de modo a não sobrecarregar os recursos do computador que processaria o treinamento.

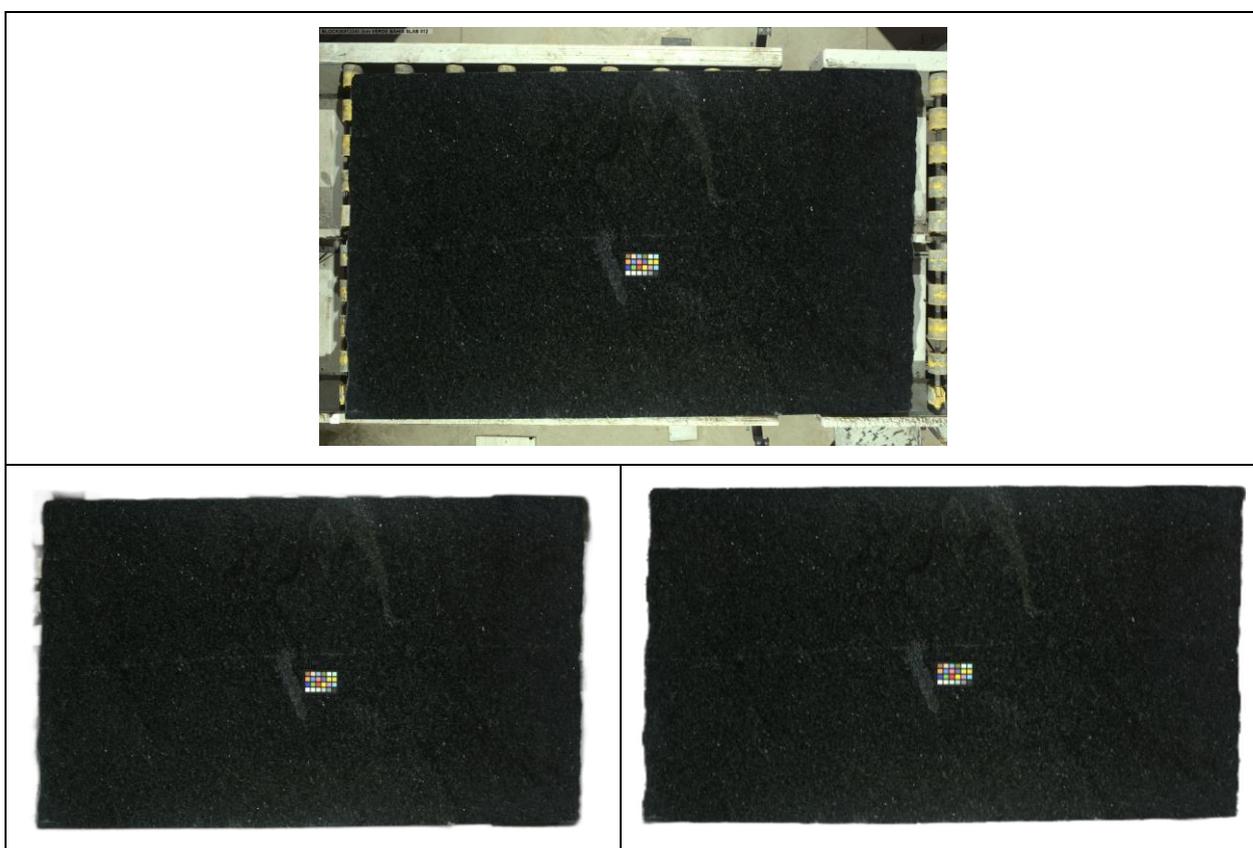
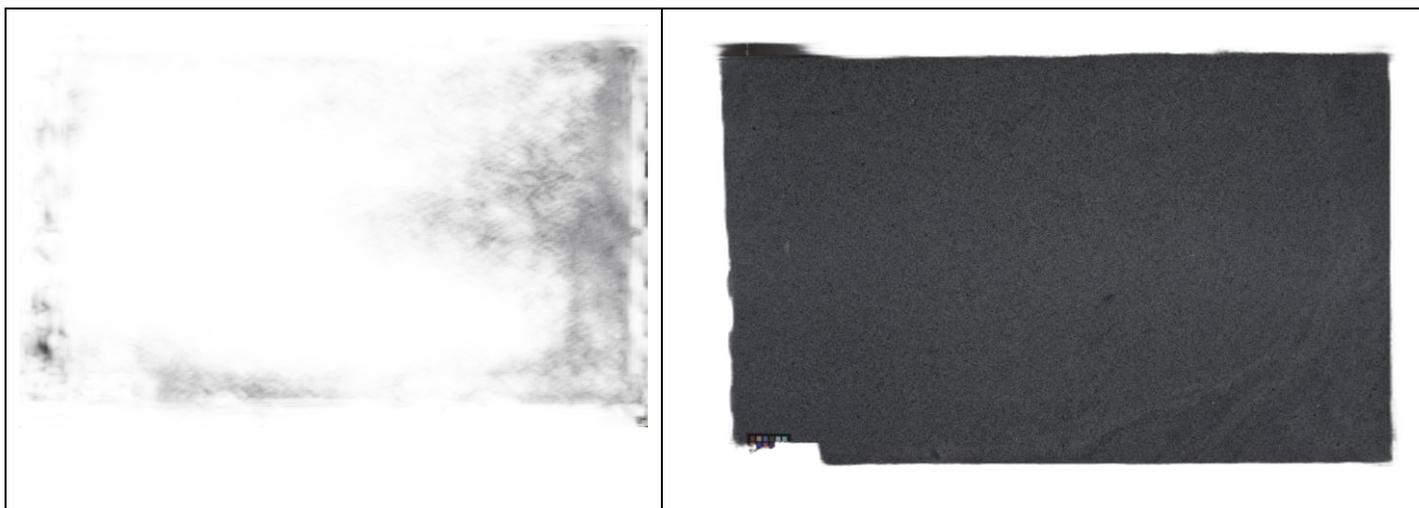
Analisando os resultados com o Dataset de testes, verificamos a necessidade de ampliar a base de imagens. Utilizamos técnicas de “*data augmentation*”, ou seja, ampliamos a base a partir de variações das imagens já existentes, de modo a otimizar, ao máximo possível o treinamento. Os resultados obtidos abaixo utilizaram 206 imagens com as respectivas máscaras e cerca de 500 *epochs*.

Resultados obtidos

Em síntese, obtivemos resultados melhores e mais alinhados às expectativas em comparação ao modelo com treinamento genérico de IA. Os resultados podem ser observados a seguir a partir da comparação entre a imagem original, o uso da biblioteca com o treinamento genérico e o treinamento específico que realizamos:







Conclusão

Os resultados apresentados demonstraram a viabilidade do modelo de treinamento, porém, pretendemos ampliar os testes com materiais e ambientes diferentes para garantir que o modelo seja capaz de fazer uma diferenciação precisa em qualquer situação. Além disso, observamos que as imagens que apresentam um contraste maior entre a poltriz e a chapa alcançaram um resultado melhor.

Como trabalho futuro, pretendemos fazer a identificação do tipo de material e a correção de cor para aumentar a fidedignidade da foto em relação ao objeto real. Estas etapas prepararão o nosso projeto para o desenvolvimento de um modelo de recomendação de materiais e, por fim, o da identificação (individualização) de cada chapa.