

DOI: 10.5748/20CONTECSI/PSE/AIT/7276

eLocator: e207276

**DIGITAL PROCESSING SYSTEM FOR ORNAMENTAL ROCK IMAGES:
INNOVATION WITH ARTIFICIAL INTELLIGENCE FOR PRODUCT CATALOG
TRATAMENTO DIGITAL DE IMAGENS DE ROCHAS ORNAMENTAIS: INOVAÇÃO
COM INTELIGÊNCIA ARTIFICIAL PARA O CATÁLOGO DE PRODUTOS**

Gabriel De Lemos Gomes – <https://orcid.org/0009-0000-3117-5514>

Universidade De Vila Velha

Caio Schmidt França Fonseca – <https://orcid.org/0009-0000-4008-0445>

Universidade De Vila Velha

Saulo Pereira Ribeiro – <https://orcid.org/0000-0003-4301-1538>

Universidade De Vila Velha

Taciana De Lemos Dias – <https://orcid.org/0000-0002-7172-1230>

Universidade Federal Do Espirito Santo

Victor Gianordoli – <https://orcid.org/0000-0001-5905-0641>

Instituto Federal Do Espirito Santo

DIGITAL PROCESSING SYSTEM FOR ORNAMENTAL ROCK IMAGES: INNOVATION WITH ARTIFICIAL INTELLIGENCE FOR PRODUCT CATALOG

ABSTRACT

It is essential to improve the quality of company processes and services considering economic, innovation and Industry 4.0 aspects. This is the case with the product catalog process of a rock processing company. Images captured at the end of the ornamental stone processing process show distinct backgrounds of the piece. The challenges in image processing and segmentation are multiple and varied. This research develops a digital transformation system for images of ornamental rocks, marble or granite sheets, for a product catalog. Topics of artificial intelligence, digital image processing and its technologies, process improvement, innovation and rock processing processes are covered. The proposed system uses artificial intelligence, convolutional neural networks and the libraries U²-Net and OpenCV. Named the "ICT Rochas System," this technological product generates specific images of rock sheets. The findings aid in the innovation and optimization of analyzed processes. A version of the system be developed in the future that produces batch image processing for the catalog, minimizing human intervention.

Keywords: Image processing; Innovation; Artificial Intelligence; Information System; Dimensional Rock Catalog.

SISTEMA DE TRATAMENTO DIGITAL DE IMAGENS DE ROCHAS ORNAMENTAIS: INOVAÇÃO COM INTELIGÊNCIA ARTIFICIAL PARA O CATÁLOGO DE PRODUTOS

RESUMO

É fundamental melhorar a qualidade dos processos e serviços de empresas considerando aspectos econômicos, de inovação e de Indústria 4.0. É o caso do processo de catálogos de produtos de uma empresa beneficiadora de rochas. Imagens capturadas no final do processo de beneficiamento de rochas ornamentais apresentam fundos distintos da peça. Os desafios no tratamento e segmentação de imagens são múltiplos e variados. Esta pesquisa desenvolve um sistema de transformação digital de imagens de rochas ornamentais, de chapa de mármore ou granito, para catálogo de produtos. São abordados temas de inteligência artificial, tratamento digital de imagens e suas tecnologias, melhoria de processos, inovação e processo de beneficiamento de rochas. O sistema proposto utiliza inteligência artificial, redes neurais convolucionais e as bibliotecas U²-Net e OpenCV. O produto tecnológico desenvolvido é o "Sistema TIC Rochas", que produz imagens delimitadas das chapas de rochas. Os resultados contribuem para inovação e otimização de processos analisados. Sugere-se desenvolvimento futuro de uma versão do sistema que produza tratamento de imagens em lote para catálogo, minimizando intervenção humana.

Palavras-chave: Tratamento de imagem; Inovação; Inteligência Artificial; Sistema de Informação; Catálogo de Rochas Ornamentais.

1 INTRODUÇÃO

Com base na Indústria 4.0, inovação, qualidade, eficácia e eficiência, as empresas procuram automatizar e melhorar os seus processos com a adoção de tecnologia da informação e sistemas de informação voltados para os seus negócios.

Sistemas para tratamento de imagens utilizando as técnicas, métodos e variáveis adequados a uma realidade são demandas de empresas de beneficiamento de rochas. Esse é o caso dos processos de tratamento de imagens para composição do Catálogo de Produtos de um Portfólio de chapas de rochas ornamentais para exportação, um problema para uma empresa de beneficiamento de rochas no Espírito Santo, diante da necessidade de melhorar a qualidade dos processos de produção.

Existem alguns obstáculos associados à automatização desses processos de tratamento de imagem, como:

- a variação na qualidade da imagem: a qualidade das imagens obtidas pode variar significativamente dependendo de fatores, como a iluminação do local de captura, a qualidade da câmera utilizada pela empresa e as condições do objeto fotografado. Essas variações na qualidade da imagem podem impactar a eficácia do processo de tratamento de imagem;
- a necessidade de recursos computacionais: o processamento de imagens pode exigir muito recurso computacional, hardware de alto desempenho e muito tempo de processamento;
- as imagens das peças de rochas são obtidas no final do processo de beneficiamento, quando estas ainda se encontram na esteira em condições inadequadas para compor um catálogo de produtos, sendo necessária uma imagem que apresente exclusivamente a peça de rocha real, com suas delimitações e/ou recortes reais.

A implementação bem-sucedida de um sistema de tratamento de imagem automatizado requer um entendimento desses aspectos e requer uma seleção de métodos e técnicas apropriados para lidar com eles.

Com base neste contexto, se estabeleceu a seguinte questão de pesquisa: como automatizar, com um sistema de informação, o processo de tratamento digital de imagem para prover uma imagem de qualidade, que melhor demonstre a chapa de rocha real para a composição de um catálogo de chapas de granito e mármore, para exportação?

O objetivo geral em decorrência da questão de pesquisa é desenvolver um sistema de transformação digital de imagens de rochas ornamentais, de chapa de mármore ou granito, para um catálogo de produtos. E, os objetivos específicos para alcançar o objetivo geral são:

- descrever o processo de beneficiamento de rochas e a geração do Catálogo de produtos do Portfólio;
- analisar e descrever os fatores que envolvem automatização de processos e sua qualidade;
- analisar e descrever os métodos e variáveis de bibliotecas para tratamento de imagens relacionados às funcionalidades do sistema proposto, como OpenCV e U²-Net;
- descrever o processo atual e o processo automatizado com o sistema proposto.

A história da automação de processos e os sistemas de informação que a suportam contemplam a transformação do ambiente empresarial. Com a ascensão da era digital, as organizações passaram a priorizar a automação de processos para melhorar a eficiência, a produtividade e a competitividade (Davenport & Ronanki, 2018; Davenport, 1995).

Inicialmente, a automação de processos era predominantemente em operações de manufatura, caracterizada pela utilização de máquinas e equipamentos para substituir o trabalho manual. O desenvolvimento de tecnologias de controle, como o sistema de controle numérico computadorizado (CNC) na década de 1950, foi um marco nesta fase (Groover, 2007).

No entanto, a automação de processos tomou uma nova direção com o advento dos computadores e dos sistemas de informação na década de 1960. Os primeiros sistemas de informação, como os sistemas de processamento de transações, facilitaram a automação de tarefas rotineiras de negócios, como contabilidade e folha de pagamento (Kenneth C. Laudon et al., 2024; Laudon & Laudon, 2021).

O advento dos sistemas integrados de gestão (ERP) na década de 1990 representou outro marco importante, ao permitir a integração e a automação de vários processos de negócios em uma única plataforma (Davenport, 1995).

Mais recentemente, a automação de processos tem sido impulsionada pela adoção de tecnologias digitais emergentes, como a Robotic Process Automation (RPA), que permite a automação de tarefas baseadas em regras, e a Inteligência Artificial (IA), que facilita a automação de tarefas mais complexas que exigem tomada de decisão (Lacity & Willcocks, 2016).

Estes desenvolvimentos ilustram a contínua evolução da automação de processos, dos sistemas de informação e a gestão das mudanças associadas. Com o crescente foco na eficiência operacional e na transformação digital, a automação de processos tende a ser uma prioridade estratégica para as empresas na era digital (Kumar et al., 2020).

A inovação empresarial é fundamental para a competitividade e sobrevivência no mercado. Drucker e Maciariello (2014) argumentam que a inovação deve ser vista como uma disciplina que pode ser aprendida e gerenciada, e não apenas como um ato de genialidade ou inspiração.

O conceito de inovação é multidimensional e, segundo Schumpeter (2017), a inovação pode ser entendida como a introdução de novos produtos, processos, mercados e formas de organização na economia, resultantes em aumento de produtividade e geração de riqueza.

Existem diferentes tipos de inovação, entre os quais a inovação de processos se destaca como uma ferramenta para aprimorar a eficiência e a qualidade na produção. Segundo (Tidd & Bessant, 2015), a inovação de processos envolve a implementação de um método de produção ou distribuição, novo ou melhorado, implicando em mudanças nas técnicas, equipamentos e/ou softwares.

Crosby (1979) destaca que a qualidade é definida pela conformidade às especificações, e que o objetivo deve ser a busca pelo "zero defeito". Juran (1986), por sua vez, argumenta que a qualidade envolve a adequação ao uso, indicando que um produto ou processo de alta qualidade deve atender, ou superar as expectativas dos usuários.

A implementação de inovações de processo de alta qualidade pode trazer benefícios para as empresas e indústrias, como a redução de custos, a melhoria da eficiência, o aumento da satisfação do cliente e a obtenção de vantagem competitiva (Tidd & Bessant, 2015). No entanto, há resistência às mudanças, que pode ocorrer tanto no nível individual quanto

organizacional. De acordo com Rogers (1995), a adoção de inovações é um processo que envolve cinco etapas: conhecimento, persuasão, decisão, implementação e confirmação. Em cada uma dessas etapas, podem surgir barreiras e resistências que precisam ser superadas.

Além disso, a inovação de processos requer investimentos em pesquisa e desenvolvimento, aquisição de novas tecnologias, treinamento de pessoal e mudanças organizacionais (Tidd&Bessant, 2015).

Segundo Garvin (1992), existem cinco abordagens principais para a definição de qualidade: transcendental, baseada no produto, baseada no usuário, baseada na produção e baseada no valor. A transcendental considera a qualidade como uma característica inerente ao produto ou serviço, enquanto a abordagem baseada no produto enfatiza as características técnicas do produto e a baseada no usuário considera a qualidade como algo que atende às necessidades do cliente. A abordagem baseada na produção enfatiza o controle dos processos produtivos e a baseada no valor considera que a qualidade é definida pelo valor percebido pelo cliente.

A digitalização dos processos produtivos, por meio de tecnologias como a Internet das Coisas, a Inteligência Artificial, o Big Data, entre outras, pode impulsionar a inovação de processos e a qualidade na produção. No entanto, essa transformação digital também necessita de investimentos em infraestrutura tecnológica, formação de competências digitais e segurança cibernética (Schwab, 2019).

Os sistemas de informação são combinações de hardware, software, infraestrutura de rede, dados e pessoas que coletam, processam, armazenam e distribuem informações para apoiar a tomada de decisão, a coordenação, o controle e a análise em uma organização (Laudon&Laudon, 2021). Eles podem promover a inovação, proporcionando insights baseados em dados, melhorando a coordenação e a colaboração, automatizando tarefas e processos e habilitando novos modelos de negócios digitais. A tecnologia da informação (TI) pode facilitar a inovação em produtos, processos e modelos de negócios, permitindo novas formas de comunicação, colaboração, análise de dados e tomada de decisão (Porter &Heppelmann, 2014).

A automação, por sua vez, refere-se ao uso de sistemas de controle e tecnologias para operar equipamentos, processos e sistemas com mínimo ou nenhum envolvimento humano. A automação pode aumentar a eficiência, a precisão e a consistência dos processos, reduzindo os custos e erros associados ao trabalho humano. Além disso, a automação pode liberar os trabalhadores de tarefas rotineiras e perigosas, permitindo que se concentrem em atividades de maior valor agregado (Davenport &Ronanki, 2018).

As organizações devem alinhar suas estratégias de TI, automação e sistemas de informação com suas estratégias de negócios e inovação. Além disso, elas devem envolver os *stakeholders* - incluindo funcionários, clientes, fornecedores, reguladores e comunidades - no processo de inovação. Ao fazer isso, as organizações podem maximizar os benefícios e minimizar os riscos da inovação (Ross et al., 2018).

3 TRATAMENTO DE IMAGEM E INTELIGÊNCIA ARTIFICIAL

O tratamento de imagem, ou processamento de imagem, é um campo crítico da visão computacional que lida com a manipulação e análise de imagens digitais. O objetivo principal é melhorar a qualidade da imagem ou extrair informações úteis (Gonzalez & Woods, 2018). Este processo inclui uma ampla gama de operações, desde correção de cores e filtragem de ruído até realce de contraste e detecção de bordas (Russ & Neal, 2016).

A segmentação de imagem é o processo de dividir uma imagem em múltiplas partes ou regiões. É uma etapa crítica para simplificar a representação da imagem ou alterá-la de

forma a facilitar a análise posterior. Na segmentação, pixels semelhantes são agrupados com base em critérios como cor, textura e intensidade, para identificar objetos ou limites dentro da imagem.

A segmentação enfrenta seus próprios desafios. A definição de critérios de similaridade é fundamental e varia de acordo com aplicação específica. Imagens com múltiplos objetos, sobreposições ou fundos complexos apresentam dificuldades adicionais para a segmentação eficaz. Além disso, variações na iluminação e na sombra podem confundir a identificação dos limites dos objetos. A escolha do algoritmo de segmentação é crítica e deve ser feita com base nas necessidades da aplicação. Por fim, a presença de ruído e artefatos na imagem pode levar a erros de segmentação, resultando em agrupamentos inadequados de pixels (Plaksyvyi et al., 2023).

Na geração da fotografia e no tratamento digital subsequente das imagens para edição, segmentação e melhoria da qualidade da imagem resultante, alguns pontos devem ser considerados, como:

- a iluminação na fotografia pode variar bastante, em um ambiente de produção, o que pode levar a inconsistências na captura da imagem. Isto pode tornar a segmentação da imagem mais desafiadora e afetar a qualidade geral da imagem. Portanto, é importante que a iluminação seja controlada e consistente ao longo do tempo (Y. J. Zhang, 1996);
- diferenças nas texturas e cores dos objetos fotografados podem tornar mais complexo o tratamento da imagem (Pal&Pal, 1993);
- a movimentação durante o processo de captação de imagem pode introduzir borrões ou distorções na imagem. Isso pode complicar a segmentação e o tratamento da imagem. É importante ter em conta o movimento ao desenvolver os algoritmos de segmentação e tratamento de imagem (Klette&Zamperoni, 1996);
- a complexidade computacional para a segmentação e o tratamento de imagem são processos que podem ser computacionalmente intensivos, especialmente para um grande número de imagens. Isto pode resultar em tempos de processamento mais longos e necessitar de hardware de alto desempenho (Sonka et al., 1998).

Além disso, conforme Gonzalez e Woods (2018) o desenvolvimento de um código para o processamento de imagens deve considerar:

- desempenho do código: a manipulação de imagens requer uma quantidade de recursos de computação, principalmente quando grandes volumes de dados estão envolvidos. Isso é importante para garantir um processamento de imagens em tempo real ou próximo do tempo real, o que pode envolver a utilização de técnicas de programação paralela ou de programação orientada a desempenho;
- ajuste de parâmetros: as técnicas de processamento de imagens frequentemente envolvem a seleção de vários parâmetros, tais como limiares de detecção de bordas ou o tamanho do filtro em um filtro de desfoque. A escolha desses parâmetros pode ter um impacto no resultado do processamento da imagem. Assim, determinar como ajustar esses parâmetros pode envolver técnicas de aprendizado de máquina ou otimização;
- variações na iluminação: podem alterar drasticamente a aparência de uma imagem e dificultar a análise. Portanto, é importante desenvolver técnicas que possam compensar variações na iluminação;
- robustez: dada a grande variedade de imagens que um sistema de processamento de imagens pode encontrar, é fundamental que o código considere as variações nas

imagens de entrada. Isso pode envolver a utilização de diferentes técnicas de processamento de imagens, bem como a implementação de verificações e balanços adequados no código para lidar com possíveis erros ou entradas inesperadas;

- manutenção e atualização: a medida que novas técnicas de processamento de imagens são desenvolvidas e aprimoradas, pode ser necessário atualizar o código para incorporar esses avanços. E, assim garantir que o código seja projetado de maneira flexível e sustentável, permitindo atualizações e manutenção fáceis.

O desenvolvimento bem-sucedido de um código para processamento de imagens não se limita apenas à competência técnica na programação. Também exige uma compreensão sólida do domínio do problema, a fim de fazer escolhas acertadas sobre quais técnicas usar. Dentre as técnicas existentes é interessante entender a suavização de imagem, os ajustes de cores e iluminação e a correspondência de características de imagens.

A suavização de imagem, também conhecida como desfocagem ou *blur*, é um processo de alteração das intensidades dos pixels em uma imagem para reduzir o ruído e o detalhe. A suavização de imagem é necessária por vários motivos. E, ela é geralmente aplicada como um pré-processamento em imagens para melhorar a qualidade antes de realizar operações adicionais, como detecção de bordas e segmentação (Gonzalez & Woods, 2018).

A suavização é frequentemente realizada por meio de operações de convolução entre a imagem e um filtro ou kernel. A convolução é uma operação matemática para muitas técnicas de processamento de imagem e aprendizado de máquina, especialmente na área de redes neurais convolucionais.

Na convolução de imagens, um filtro é uma pequena matriz aplicada a uma imagem para transformá-la de alguma forma. Esta transformação pode ser para efeitos de desfoque, afiação, detecção de bordas, entre outros.

A operação de convolução envolve o deslizamento do kernel sobre a imagem, da esquerda para a direita e de cima para baixo. Em cada posição, o produto de cada elemento do kernel é multiplicado pelo elemento correspondente na imagem sob o kernel, e todos esses produtos são somados para produzir um único valor de pixel na imagem de saída. Este processo é repetido até que cada pixel da imagem de entrada tenha sido processado. Essencialmente, o kernel atua como uma "janela deslizante" que pondera os pixels sob ele e gera um único valor de saída, proporcionando uma forma de calcular uma representação modificada da imagem (Szeliski, 2022).

A inteligência artificial (IA) é uma área da ciência da computação que se relaciona ao desenvolvimento de sistemas capazes de realizar atividades complexas como, por exemplo, aquelas que tradicionalmente necessitam de intervenção humana, como reconhecimento de padrões, aprendizado, raciocínio e interpretação de linguagem. Originada na década de 1950, a IA progrediu com o avanço em algoritmos, aumento do poder de processamento e a disponibilidade de grande quantidade de dados. Esta área engloba técnicas, incluindo aprendizado de máquina e redes neurais, também contribuindo para a tomada de decisões.

A IA computacional é um campo que se concentra em dotar máquinas capazes de interpretar e entender o ambiente visual. Essa área utiliza algoritmos para detectar e interpretar imagens e vídeos, permitindo que as máquinas identifiquem padrões, objetos e realizem análises visuais. A visão computacional tem aplicações em vários setores, como segurança, automação industrial e sistemas de navegação autônoma (Valdati, 2021).

O campo da Inteligência Artificial ganhou mais atenção do público após a divulgação do GPT-3, um modelo de linguagem amplo (LLM ou Large Language Model), treinado grande número de dados por meio de Aprendizado de Máquina (Machine Learning), mais especificamente por Aprendizado Profundo (Deep Learning) (Valdati, 2021).

Nos últimos anos, o Aprendizado Profundo tornou-se um campo de pesquisa em aprendizado de máquina e tem contribuído para diferentes aplicações na área de Visão Computacional como em agricultura (Bukhari et al., 2021), medicina (Shao et al., 2022), engenharia de materiais (Y. Zhang et al., 2022), sensoriamento remoto (Li et al., 2023), tratamento acústico (Liu et al., 2022) e microbiologia (Graczyk et al., 2022), dentre outras.

No contexto da visão computacional, a aprendizagem de máquina fornece as bases para algoritmos que permitem a interpretação e análise de imagens e vídeos. Utilizando aprendizagem de máquina, sistemas de visão computacional podem ser treinados para reconhecer padrões visuais complexos, identificar objetos, e realizar tarefas de processamento de imagem (Silveira & Menechelli, 2017).

O Aprendizado Profundo utiliza diferentes tipos de redes neurais. As Redes Neurais Convolucionais (CNNs - Convolutional Neural Networks) são apropriadas a aplicações na área de Visão Computacional. A Figura 1 a seguir apresenta uma relação entre essas áreas de pesquisa.

Figura 1
Áreas de pesquisa em IA

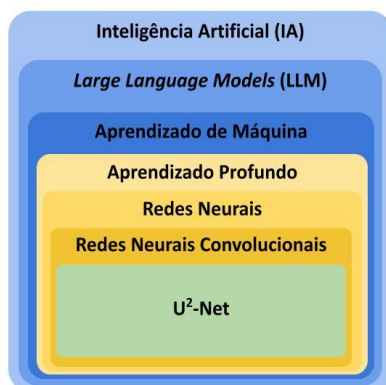


Figura 1 - Áreas de pesquisa em IA

Large Language Models (LLMs) são sistemas de inteligência artificial projetados para entender, gerar e interagir com linguagem humana em uma escala extensa. Estes modelos são treinados em grandes conjuntos de dados textuais e utilizam técnicas de aprendizado de máquina, principalmente redes neurais profundas, para processar e analisar linguagem. LLMs são capazes de realizar uma variedade de tarefas relacionadas à linguagem, incluindo tradução, resumo, geração de texto, e compreensão de perguntas e respostas. A eficácia destes modelos depende da qualidade e da diversidade dos dados de treinamento, bem como da arquitetura e dos algoritmos empregados em seu desenvolvimento.

A combinação de Visão Computacional com LLMs abre oportunidades para aplicações que requerem uma compreensão integrada de imagens e texto, como em sistemas de assistência visual para deficientes visuais ou em análises automatizadas de conteúdo multimídia (Amaratunga, 2023).

Aprendizado Profundo é uma subárea do aprendizado de máquina que envolve o uso de redes neurais com múltiplas camadas, conhecidas como redes neurais profundas. Essas redes são capazes de aprender representações de dados em vários níveis de abstração, facilitando a identificação de padrões complexos em grandes conjuntos de dados. O Aprendizado Profundo se diferencia pelo número de camadas em suas redes, que permitem uma modelagem mais complexa e uma maior capacidade de generalização em comparação com redes neurais mais simples. O treinamento de redes neurais profundas utiliza grandes volumes de dados e técnicas como *backpropagation*, que ajustam os pesos das conexões na rede para minimizar o erro entre as saídas previstas e as reais.


Na visão computacional, o aprendizado profundo permite reconhecimento de objetos, detecção de rostos e análise de vídeos, por exemplo. Redes Neurais Convolucionais, uma classe especial de redes neurais profundas, são amplamente utilizadas nesse campo devido à sua eficiência em processar dados visuais. As CNNs aplicam filtros convolucionais que capturam características locais em imagens, como bordas e texturas, e aprendem hierarquicamente características mais complexas nas camadas subsequentes, Inteligência artificial, Processos de aprendizado de máquina, aprendizado profundo e automação (Adamssen, 2020).

Redes Neurais Convolucionais são um tipo de rede neural profunda que realiza processamento de dados com uma estrutura de grade, como imagens. São utilizadas em aplicações de visão computacional, como reconhecimento de imagens e vídeo, sistemas de recomendação e processamento de linguagem natural.

Uma CNN possui camadas de convolução, *pooling* e *fullyconnected*. Representadas na sequência da Figura 2 as camadas de convolução aplicam filtros que detectam padrões espaciais, como bordas ou texturas, em diferentes partes da imagem (Albawi et al., 2017). As camadas de *pooling* reduzem a dimensionalidade dos dados, resumindo características importantes. As camadas *fullyconnected*, semelhantes às de redes neurais tradicionais, interpretam esses recursos extraídos para realizar tarefas como classificação (Silva, 2018).

Figura 2

Etapas da CNN



(Silva, 2018)

Ferreira e Giraldi (2017) indicam que o uso de abordagens de aprendizado profundo, como CNNs, pode superar as abordagens tradicionais de engenharia de características na classificação de pedras naturais. Araujo (2022) destaca que a classificação automatizada contribui para a redução de erros e substitui o caráter subjetivo da classificação visual por critérios objetivos. Isso permite que o processo visual seja complementado ou substituído por um sistema automatizado. O estudo também ressalta a eficiência da Rede Neural Convolucional na extração de características relevantes das imagens de chapas polidas.

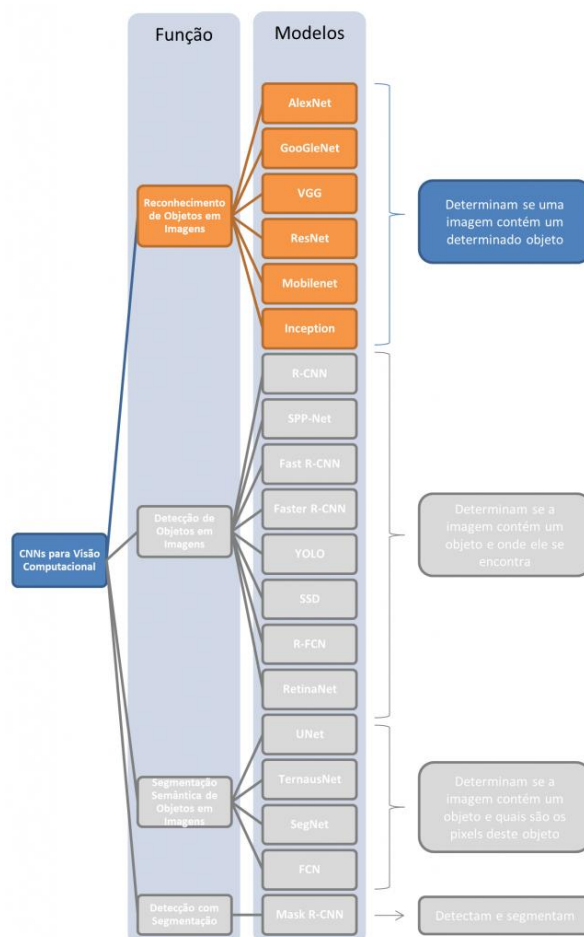
O treinamento de uma CNN envolve a ajustar os pesos dos filtros nas camadas de convolução, o que é feito via um processo chamado backpropagation. Durante o treinamento, a rede aprende a reconhecer padrões cada vez mais complexos. Inicialmente, ela pode detectar linhas simples, mas à medida que as informações avançam pelas camadas, a rede começa a reconhecer formas e objetos mais complexos (Silva, 2018).

3.1 BIBLIOTECA U2-Net e OpenCV

As CNNs possuem ramificações, Figura 3, de acordo com suas funções até chegar no modelo Unet, que possui função de segmentação semântica de objetos em imagens para determinar se a imagem contém um objeto e quais são os pixels deste objeto (Von Wangenheim, 2018).

.Figura 3

Ramificações das Redes Neurais Convolucionais(Von Wangenheim, 2018).



(Von Wangenheim, 2018).

A biblioteca U²-Net¹ é uma modificação do modelo UNet, desenvolvida para tarefas de segmentação de imagens, uma técnica usada em visão computacional. A principal característica da U²-Net é sua estrutura em forma de "U", que permite processar informações em diferentes escalas, capturando tanto detalhes finos quanto contextos mais amplos das imagens.

Qin et al. (2020) são responsáveis pelo desenvolvimento da biblioteca U2-Net, que surgiu após os avanços das Redes Neurais Convolucionais (Convolutional Neural Networks, CNNs) e suas contribuições para a área de segmentação de imagens. Trata-se de biblioteca aplicada à Detecção de Objetos Salientes (SalientObjectDetections, SOD). Os *backbones* SOD, como Alexnet ou VGG, foram criados tendo por objetivo a classificação de imagens e usando a base ImageNet para treino, extraindo características de maneira semântica. É essencial que a detecção de objetos salientes seja feita contrastando detalhes locais com

¹<https://github.com/xuebinqin/U-2-Net>

informações globais, usando uma base de dados diferente, treinada desde o início (Qin et al., 2020).

A biblioteca OpenCV ou Open Source Computer Vision Library, é uma biblioteca de software de código aberto para processamento de imagem e visão computacional. Lançada inicialmente em 1999 pela Intel, foi construída para fornecer uma infraestrutura comum para aplicações de visão computacional e acelerar o uso de percepção de máquina em produtos comerciais. Sendo escrita em C e C++, OpenCV suporta também Python, Java, e outras linguagens (Bradski, 2009).

A biblioteca OpenCV é utilizada para tarefas de processamento de imagem e visão computacional, incluindo reconhecimento de objetos, análise facial, e processamento de vídeo. Suas funções abrangem áreas como detecção de movimento, extração de características e correspondência de imagens.

No código fornecido, OpenCV² é utilizada para remover o fundo de imagens usando máscaras correspondentes. O código carrega conjuntos de imagens e máscaras de pastas específicas e aplica operações de processamento de imagem para mesclar imagens com seus respectivos canais alfa derivados das máscaras.

O processo inclui a conversão de máscaras em canais alfa, onde os pixels pretos (representando o fundo) são tornados transparentes. Em seguida, este canal alfa é adicionado à imagem original para criar uma versão final com o fundo removido. O código demonstra a flexibilidade de OpenCV em manipular canais de imagem e sua aplicabilidade em tarefas específicas de edição de imagens.

4 MÉTODOS E PROCEDIMENTOS

Para realização do objetivo principal deste trabalho, de desenvolver um sistema de transformação digital de imagens de rochas ornamentais para gerar uma imagem de qualidade com somente a chapa de mármore ou granito para o Catálogo de Produtos realizou-se observação direta dos processos na empresa estudada. E, assim, entender como os trabalhadores interagem com as rochas e as máquinas, e como as imagens são capturadas e processadas.

A revisão de literatura para elaboração do referencial teórico abordou as temáticas de inovação, gestão e qualidade de processos, automação, empresa de beneficiamento de rochas ornamentais, visão computacional e Biblioteca OpenCV e U²-Net. Para tanto, realizou-se uma pesquisa utilizando palavras-chave relacionadas ao tema, nas seguintes fontes: Google Acadêmico; Banco de Teses e Dissertações (BTDT) e na base do Periódico Capes SciELO. Através desta pesquisa, foi possível identificar um conjunto de estudos que discutiram os conceitos, práticas adotadas e ferramentas desenvolvidas. Cada um desses estudos foram analisados e depois foram selecionados os que mais contribuíam para o conhecimento da temática abordada, para entender suas principais descobertas, métodos e conclusões.

A pesquisa documental é uma parte da metodologia desta pesquisa. Ela envolve a análise de documentos da empresa e do Centro de Tecnologia Mineral - CETEM³ para obter uma compreensão dos processos de beneficiamento de rochas e tratamento de imagens, contribuindo para a modelagem do processo e do desenvolvimento do sistema proposto. Os documentos do CETEM ofereceram informações sobre o processo estudado, as melhores práticas e inovações na indústria de beneficiamento de rochas.

² <https://opencv.org>

³ <https://www.gov.br/cetem/pt-br>

4.1 A EMPRESA E PROCESSO ESTUDADO

A empresa estudada é capixaba, referência em revestimentos de rochas ornamentais e sintéticas e atende ao mercado nacional e internacional há mais de 15 anos. Ela possui jazidas próprias para a extração dos quartzitos, cujas cores variam do totalmente branco com linhas acinzentadas ou movimento de cores entre branco, cinza, negro e verde-escuro.

É uma empresa que prima pela qualidade em todas as etapas do processo e a satisfação do cliente, provendo produtos de alta qualidade; e, busca a constante inovação dos processos organizacionais, e de seus produtos. Isso, considerando dentre as etapas dos seus processos a extração do bloco, aquisição até categorização da rocha, corte e acabamento da chapa, geração do catálogo de produtos e vendas.

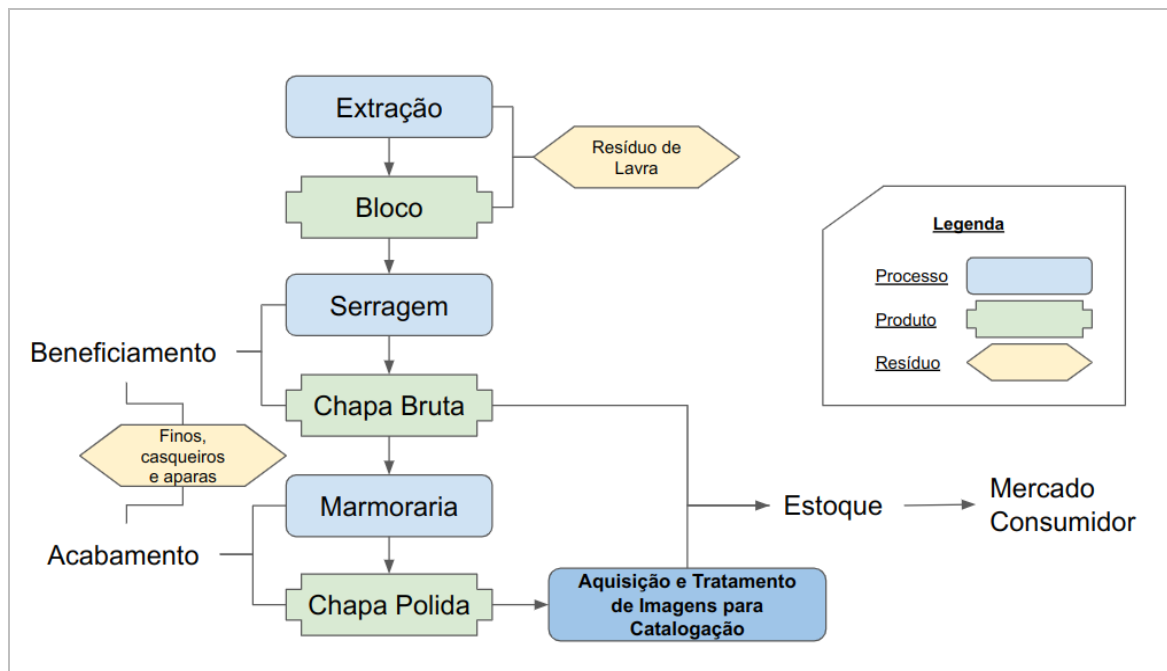
A empresa investe em tecnologia da informação e possui equipe para sua gestão e operação. Dentre as tecnologias adotadas, ela implantou um sistema ERP (Enterprise Resource Planning) para empresas de grande porte.

No processo de produção de placas de rochas ela utiliza duas esteiras e corta mensalmente 10.000 placas aproximadamente.

A Figura 4 apresenta o Processo de Produção de Rochas Ornamentais no qual está inserido o processo estudado. E, conforme (Bastos et al., 2013; Gonçalves, 2000; Uliana, 2014), são apresentados os subprocessos, seus resultados e/ou produtos e resíduos resultantes,

Figura 4

Processo de Produção de Rochas Ornamentais



A produção de rochas ornamentais inicia com uma pesquisa e escolha do local de extração dos blocos, a lavra, seguida da retirada dos mesmos. São áreas permitidas de extração de rochas para a empresa. O processo de Extração corresponde a extração do bloco da lavra,

geralmente cortado com volume de 5-10 m³. Na extração além de gerar o produto Bloco cortado, também gera o resíduo da lavra, que corresponde aos pedaços de rochas não aproveitados ou rochas fissuradas. Após a extração, o Bloco cortado é codificado e transportado para beneficiamento.

No Beneficiamento de Rochas, o processo de Serragem transforma em chapas ou placas semi-acabadas, geralmente com espessura de 1 a 3 cm. Inicialmente, se realiza a serragem com teares de lâminas metálicas ou fios diamantados. Portanto, no final do beneficiamento, gera-se o produto Chapa Bruta Serrada com espessura de 20mm e resíduos lama do beneficiamento, casqueiros e aparas. E, a seguir, a Chapa Brutas Serrada é codificada e transportada para Acabamento ou para o Estoque.

No Acabamento, o processo de Marmoraria gera o polimento da Chapa Bruta Serrada e resíduos finos do acabamento, aparas e lama de acabamento. Assim, o produto resultante do acabamento é a Chapa Polida. Esta é codificada e vai para Aquisição e Tratamento de Imagens para catalogação, depois vai para o Estoque.

O processo de Aquisição e Tratamento de Imagens para Catalogação ocorre depois do Acabamento, onde a Chapa Polida é colocada na esteira e esta é parada, na posição central onde se encontra sob ela uma máquina fotográfica para captura da imagem da Chapa. Depois que esta é fotografada e validada a qualidade da imagem por um técnico que salva o arquivo da imagem, cujo nome corresponde a codificação da imagem da Chapa Polida. E, se a imagem não possuir qualidade, tira-se uma nova imagem ou é transportada para o estúdio fotográfico para tirar uma nova foto, tornando o processo moroso e custoso.

O Tratamento da imagem e o Catálogo de Produtos de Chapas é descrito considerando 3 cenários, o atual, utilizando o sistema proposto e utilizando o sistema proposto automatizado.

No Processo atual, que corresponde ao processo original antes da proposta deste estudo, um técnico realiza o tratamento de imagem, editando e fazendo a segmentação da imagem manualmente em um software de edição. Nesse processo existem as etapas de tratamento de imagem realizadas pelo técnico com ferramentas de tratamento de imagens. E, a seguir, a imagem é salva em um arquivo com o nome do código da chapa. Estas imagens ficam disponíveis para o setor comercial.

4.2 AMBIENTE DE DESENVOLVIMENTO

O IDE (Ambiente de Desenvolvimento Integrado) utilizado foi o Microsoft Visual Studio, uma ferramenta para desenvolvedores que permite escrita, edição, depuração e criação códigos, incluindo compiladores, ferramentas que completam o código automaticamente, controle do código-fonte, dentre outros recursos a partir de extensões (Microsoft, 2023).

No IDE Visual Studio Code foram utilizadas as linguagens javascript com framework vue.js², a linguagem python utilizando FastAPI, as bibliotecas U²-Net e OpenCV. O provedor de serviços de banco de dados e armazenamento de arquivos na nuvem escolhido foi o Supabase⁴, um conjunto de serviços de computação em nuvem de back-end e plataformas de desenvolvimento de aplicativos.

Para elaboração desta pesquisa, foram analisadas 195 imagens fornecidas pela empresa estudada. Essas imagens correspondem às obtidas no processo final de produção, quando a pedra se encontra na esteira antes da catalogação e estocagem. Para treinar a rede neural foram separadas 176 imagens para treino e 19 imagens para teste.

⁴ <https://supabase.com/>

No contexto das redes neurais convolucionais, especialmente em tarefas como a segmentação de imagem, inicialmente o tamanho da base de dados utilizada parece limitado. Normalmente, redes neurais, incluindo aquelas usadas para segmentação de imagem, requerem um grande volume de dados para um treinamento eficaz. Isso se deve à necessidade de capturar uma variedade de características e variações nas imagens para que a rede possa aprender a generalizar bem para dados não vistos durante o treinamento.

A proporção de divisão entre os conjuntos de treinamento e teste também é importante. A divisão mencionada (176 para treinamento e 19 para teste) segue uma proporção frequentemente utilizada.

A base de dados desta rede neural consiste em imagens de chapas de mármore e granito com diferentes padrões de textura, repetindo o mesmo tipo de fundo, que é uma esteira na linha de produção de uma indústria de tratamento de rochas. O objetivo deste treinamento é identificar este fundo. É consistente afirmar que as características das chapas e do fundo permitiram o alcance do objetivo, com a rede neural identificando o fundo, pois os resultados na prática foram bons.

Pretendendo-se segmentar o fundo (a esteira) em imagens de chapas de mármore e granito, neste contexto, as características específicas das chapas e do fundo contribuíram positivamente no treinamento com a base de dados utilizada, pois as chapas de mármore e granito apresentam padrões de textura distintos do fundo (esteira).

A consistência do fundo (esteira) das imagens possui um padrão sem muita variação e, ao contrário, as imagens das chapas de mármore e granito tinham grande diferença entre si. O conjunto de dados, com essas características, apesar de pequeno (195 imagens), foi suficiente para alcance do objetivo específico de identificar o fundo.

Considerando que esta pesquisa propõe uma solução para a empresa estudada, bem como utilizou fontes públicas e um banco de imagens cedido, não se configura pesquisa com seres humanos; e, portanto, não se aplica submissão a comitê de ética em pesquisa em seres humanos, nem há dados sensíveis para fundamentação de tratamento pela Lei Geral de Proteção de Dados Pessoais (LGPD)⁵.

5 BIBLIOTECAS E RESTRIÇÕES

Nos estágios iniciais da pesquisa, o trabalho de segmentação de imagens de peças na esteira foi desenvolvido utilizando apenas as funcionalidades do Opencv, as máscaras para realizar a segmentação da imagem original eram geradas pelo próprio OpenCV; porém as imagens resultantes do processo não foram satisfatórias já que apresentaram defeitos devido à imprecisão das máscaras. Após várias tentativas de realizar a segmentação das imagens com parâmetros diferentes do OpenCV foi constatado que seria necessário aplicar outra técnica de geração dinâmica de máscaras.

A segunda tecnologia de segmentação a ser testada foi o projeto BackgroundRemoval⁶ utilizando as bibliotecas rembg e streamlit⁷. Esse projeto é capaz de segmentar imagens utilizando uma rede neural previamente treinada para segmentar uma variedade de imagens. Porém os resultados obtidos continuaram insatisfatórios, apresentando falhas ao delimitar a borda da imagem a ser recortada como ilustrado na imagem da Figura 5.

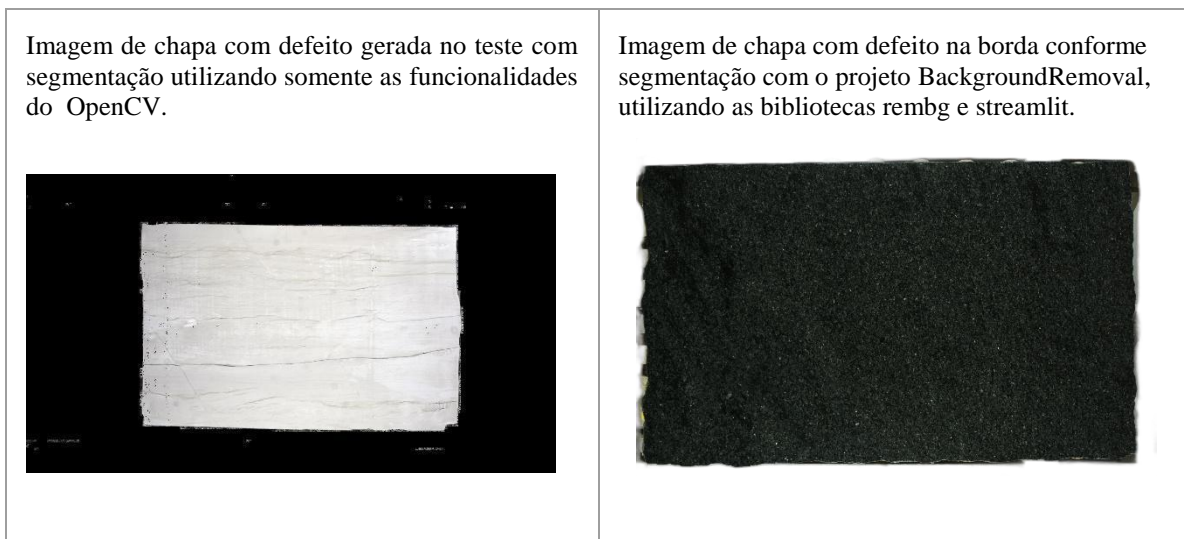
⁵ <https://www.gov.br/esporte/pt-br/aceso-a-informacao/lgpd>

⁶ <https://github.com/tyler-simons/BackgroundRemoval>

⁷ <https://github.com/danielgatis/rembg> e <https://streamlit.io>

Figura 5

Imagem de chapa com defeito



Este problema ocorreu porque essa rede neural não pode ser treinada para cortar imagens em um cenário específico, causando grande inconsistência nos resultados obtidos. Portanto, foi necessário encontrar uma rede neural capaz de ser treinada com uma base de dados específica para solucionar o problema.

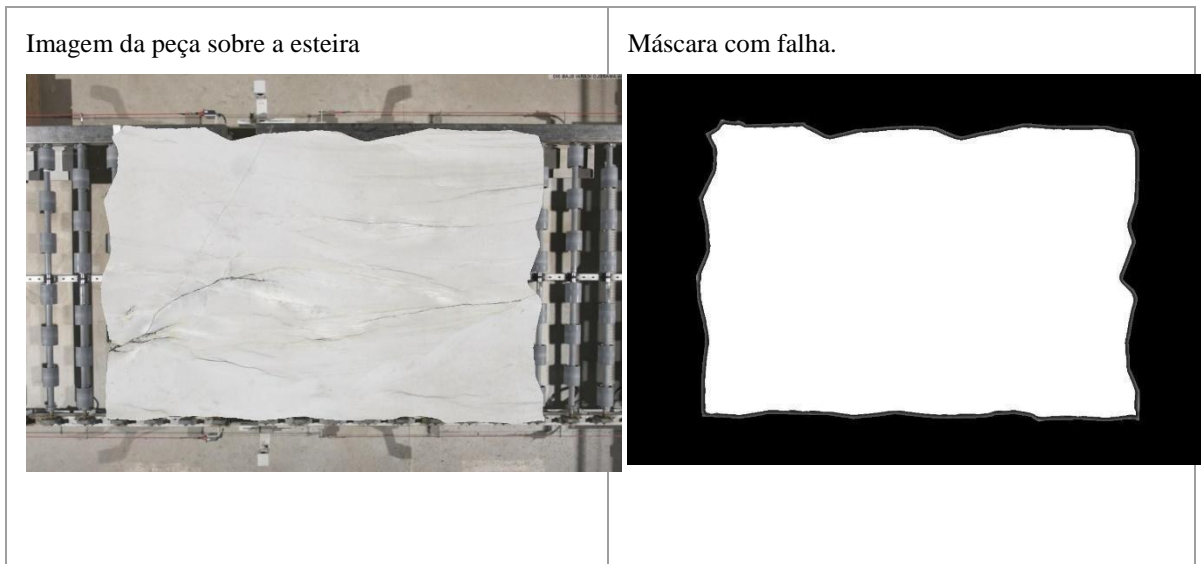
5.1 TRATAMENTO DOS DADOS - CONSIDERAÇÕES SOBRE MÁSCARAS NO TESTE

As máscaras geradas pelo sistema são resultantes do modelo de rede neural selecionado, seus parâmetros definidos e a qualidade dos dados de treino. A qualidade dos dados de treino é especialmente importante, pois afeta os dados de saída. Neste trabalho, esses dados são as imagens das peças sobre a esteira, e a máscara de cada uma dessas imagens feitas em um software de edição de imagens, por um ser humano. Durante a avaliação preliminar dos resultados do treino, foram percebidos problemas na segmentação de imagens, constatando-se falhas nas bordas das chapas das imagens quando se recortaram os fundos. Identificou-se que a origem deste problema estava nas máscaras geradas inicialmente por um técnico utilizando o software GIMP.

Na Figura 6 é mostrado um exemplar de imagem de uma peça na esteira um exemplar de máscara com problema. É identificada a existência de uma zona cinza em torno da máscara branca da peça. Essa característica presente neste dado de entrada influencia diretamente o treinamento do modelo, afetando sua capacidade de fazer generalizações.

Figura 6

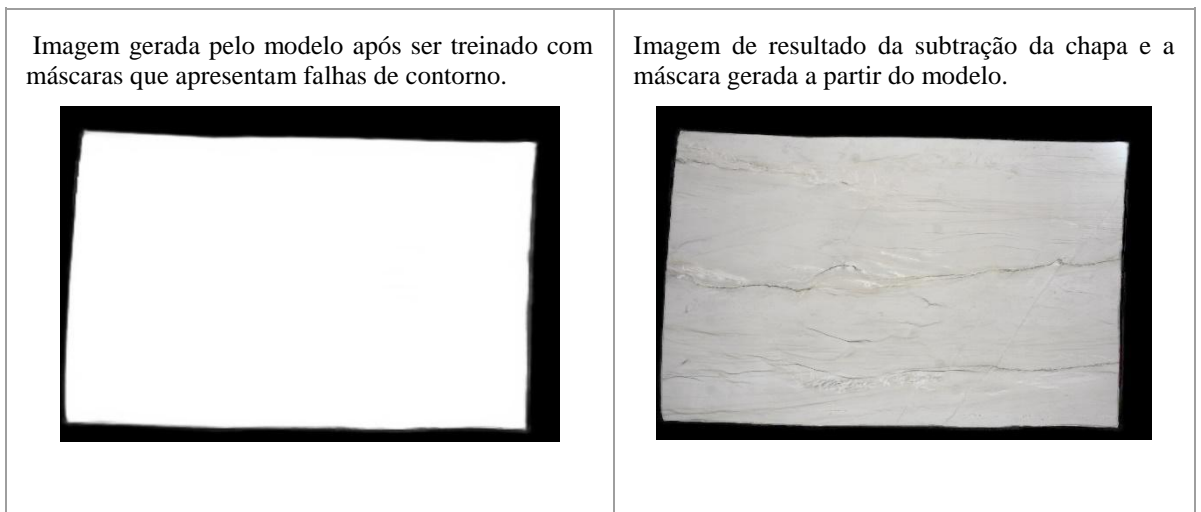
Imagem da peça sobre a esteira e máscara com falha.



A Figura 7 mostra uma máscara gerada a partir do modelo treinado com máscaras que apresentam essas falhas. Nesta figura, é possível observar, no contorno da zona branca, borrões em tons de cinza. E, a imagem final segmentada, apresenta frutos dessa falha da máscara em seu contorno, apresentando um emaranhado de cores que não deveriam estar presentes na imagem final segmentada.

Figura 7

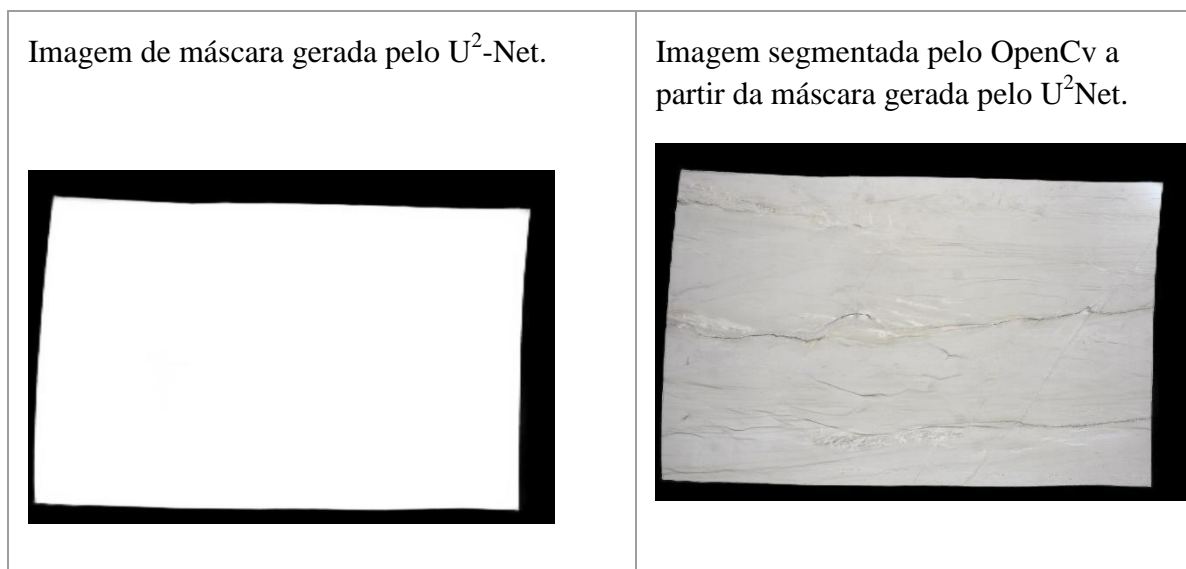
Imagem de máscara e imagens após treinamento com falhas



Ao corrigir o problema das máscaras de treinamento que apresentavam bordas cinzas em seu contorno, a qualidade das imagens de saída passou a se tornar satisfatória, sem que fosse necessário alterações em hiperparâmetros do treinamento ou no modelo. As máscaras deixaram de apresentar borrões em seu contorno acarretando uma melhor segmentação, como visto na Figura 8.

Figura8

Imagem de máscara gerada pelo U²-Net



6 PROCESSO E SISTEMA PROPOSTO

No processo de Produção do Catálogo de Produtos com o Sistema TIC Rochas, nome dado ao sistema proposto nesta pesquisa, o técnico entra na opção “Tratamento”, para realizar o tratamento da imagem. Ele clica em “Escolher imagem”, seleciona o arquivo da imagem e o nome do arquivo e a imagem são exibidos na tela. O técnico pode “Confirmar” que é para segmentar ou “Cancelar”. Se ele “Confirmar”, o sistema realiza a segmentação da imagem, exibindo a imagem somente da chapa de rocha sem a esteira. Assim, ele apresenta as duas imagens, a chapa na esteira e a chapa sem fundo. O técnico avalia a segmentação e se ele aprovar a qualidade clica em “Salvar” no arquivo do catálogo.

Outra versão do Sistema TIC Rochas é denominada Sistema TIC Rochas Automatizado que executabatch o tratamento da imagem, em determinada hora. O sistema, para cada imagem da base de dados para tratamento, faz upload de cada imagem para segmentar e realiza a segmentação da imagem, e grava no arquivo do catálogo.

Considerando o processo analisado e a solução proposta entende-se que, à luz da automatização na indústria, conforme Lasi et al. (2014), ela promove a precisão das operações, a redução de custos e a liberação de recursos humanos.

Como também, entende-se que a integração ocorrida na empresa com a implantação de ERP promoveu a automação de vários processos de negócios em uma única plataforma, melhorando o processo e a qualidade da informação, segundo Davenport (1995); e nesse

sentido o Sistema TIC Rochast deve ser integrado com o sistema ERP, sistema de gestão empresarial da empresa estudada.

6.2 SISTEMA TIC Rochas

O Sistema TIC Rochas – Sistema de Tratamento de Imagens de Catálogo de Rochas Ornamentais é o nome dado ao sistema proposto nesta pesquisa. O sistema possui duas funcionalidades: Tratamento de imagem e Catálogo de Produtos.

A Figura 9 proporciona uma visão geral do sistema TIC Rochas, ilustrando uma situação típica de utilização do sistema TIC Rochas. Na representação, observa-se um técnico na operação do sistema. Antes e durante o processo de utilização, uma câmera integrada ao sistema de captura de imagens de chapas sob a esteira registra no final do processo de acabamento de cada chapa de rocha novas imagens. Estas imagens são segmentadas pelo sistema por solicitação do técnico.

Em um *loop*, o código realiza a remoção do fundo das imagens. Primeiro, extrai-se o canal alfa da respectiva máscara, e é então ajustado para tornar-se transparente nos pontos correspondentes ao fundo preto na máscara. Esse canal alfa modificado é combinado com a imagem original, resultando em uma imagem com o fundo removido. Cada imagem processada é salva em um diretório de resultados, mantendo uma parte do nome do arquivo original. O resultado é um conjunto de imagens com o fundo removido, destinadas ao catálogo de produtos.

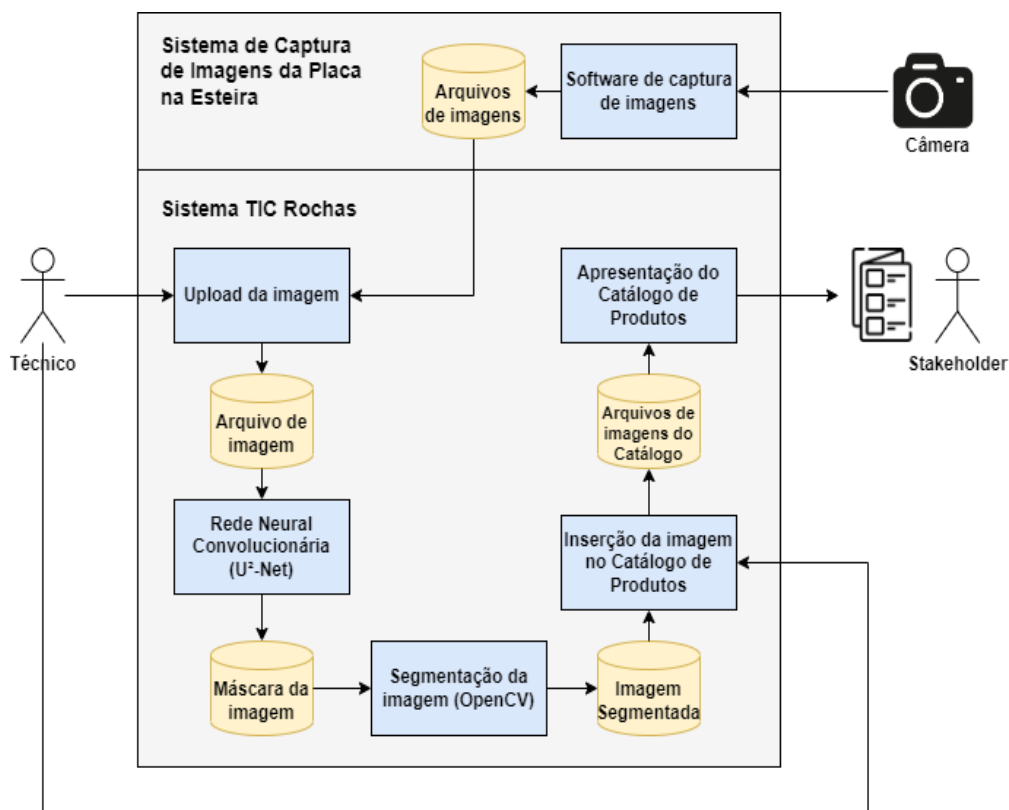
O técnico dispõe da opção de selecionar uma imagem dentre as capturadas, encaminhando-a à rede neural para a geração de uma máscara personalizada. Subsequentemente, o sistema realiza a segmentação da imagem original utilizando a máscara gerada.

O técnico, por sua vez, é responsável por decidir se a imagem segmentada deve ser incorporada ao catálogo de produtos.

Ao concluir este processo, o stakeholder tem a opção de visualizar as imagens presentes no catálogo, proporcionando uma avaliação das imagens resultantes, isto é, a imagem somente da chapa sem a esteira.

Figura 9

Visão geral do Sistema TIC Rochas

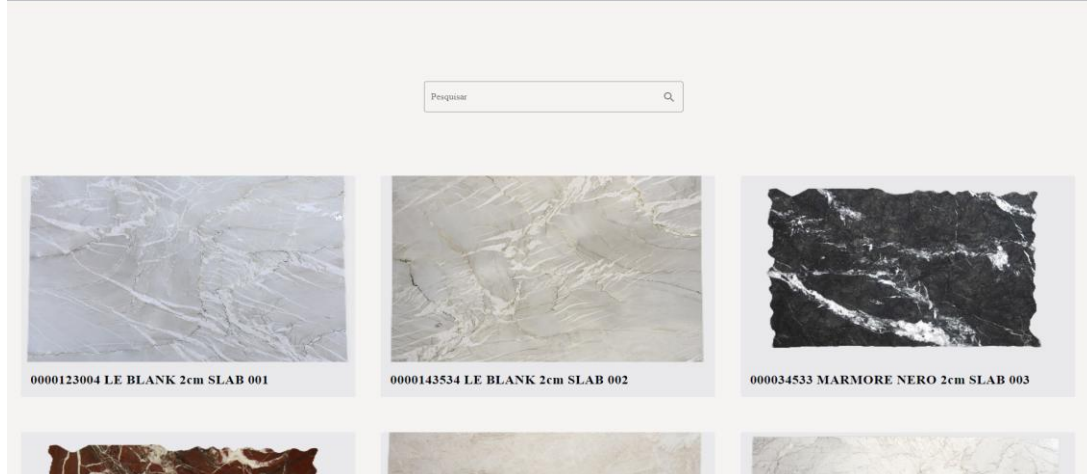


6.2.1 TELAS DO SISTEMA TIC ROCHAS

A Figura 10 apresenta a tela do Catálogo de Produtos do TIC Rochas.

Figura 10

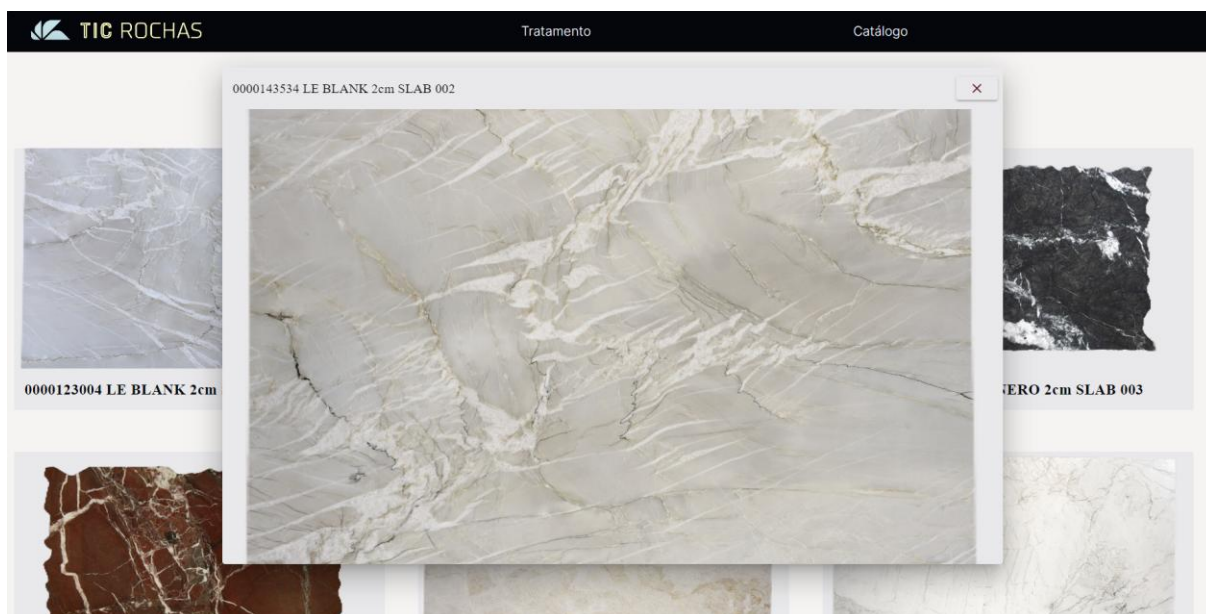
Tela do Catálogo de Produtos do TIC Rochas



A Figura 11 apresenta a tela da visualização da chapa selecionada do Catálogo de Produtos do TIC Rochas.

Figura 11

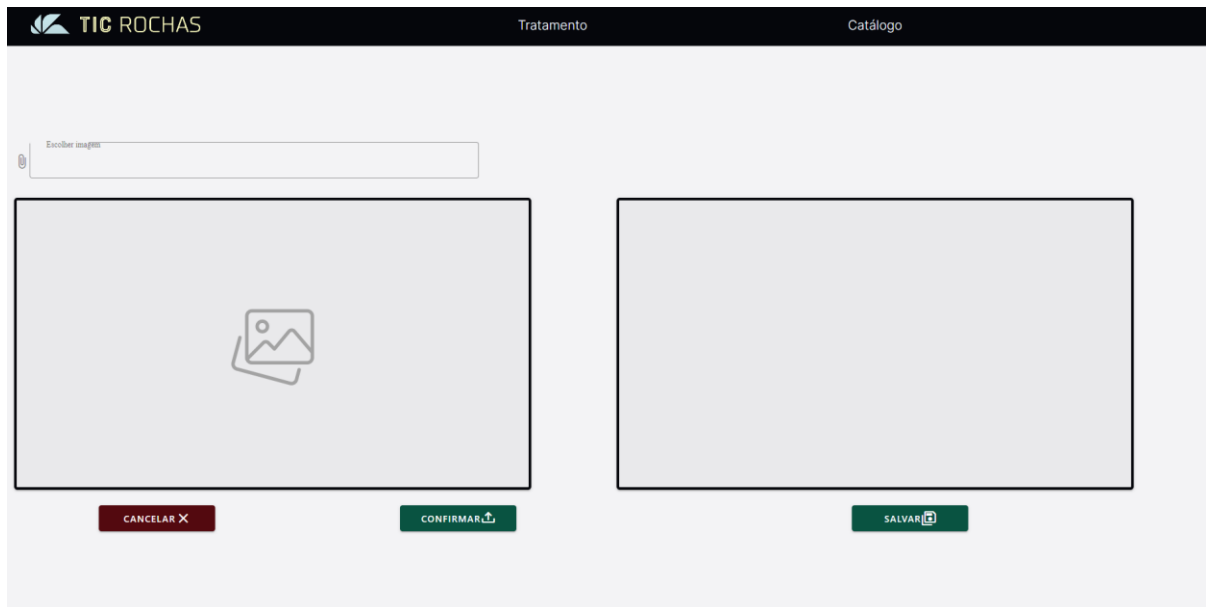
Tela do Catálogo de Produtos do TIC Rochas



A Figura 12 apresenta a tela de tratamento da imagem da chapa para o Catálogo de Produtos do TIC Rochas.

Figura 12

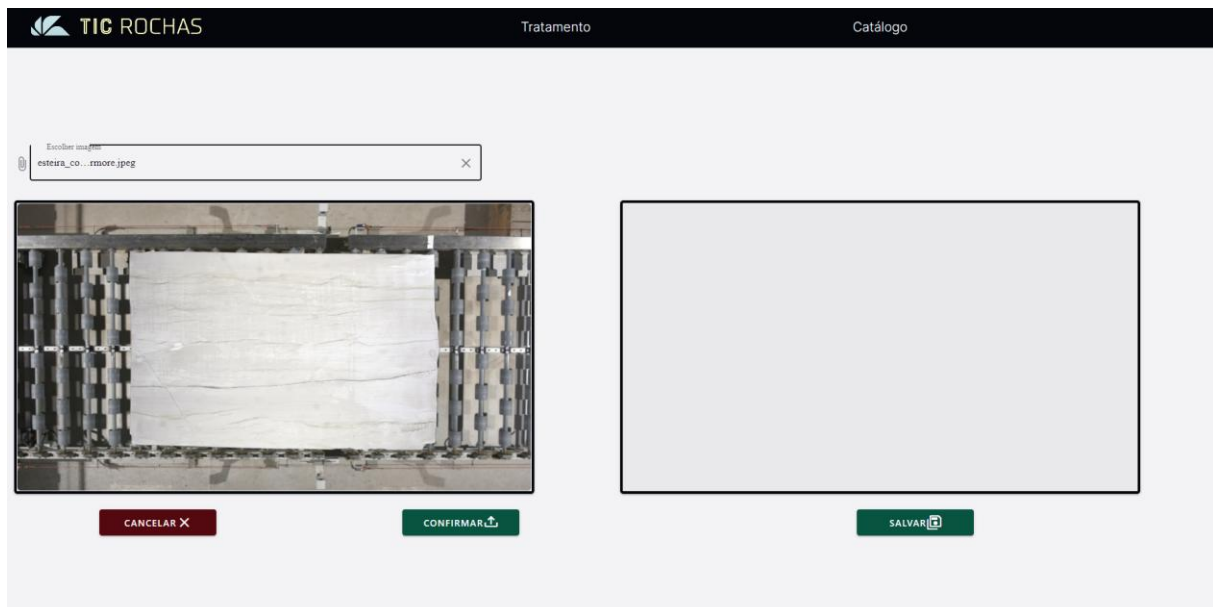
Tela do Tratamento de imagem da chapa na esteira TIC Rochas



A Figura 13 apresenta a tela de tratamento da imagem da chapa na esteira do Catálogo de Produtos do TIC Rochas.

Figura 13

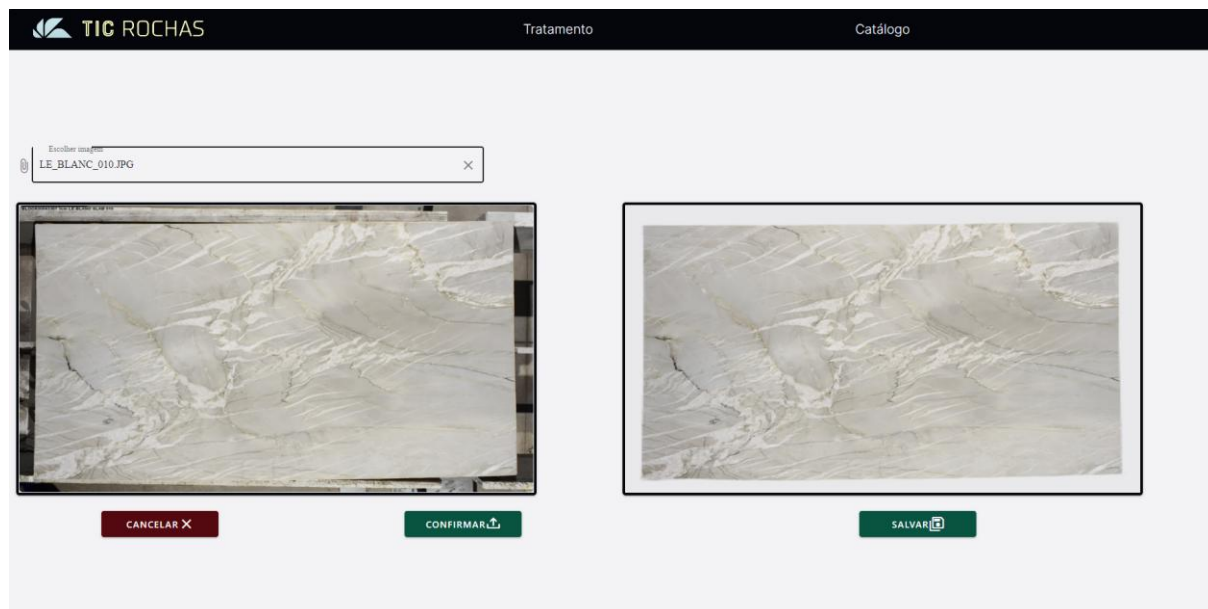
Tela do Tratamento de imagem da chapa na esteira TIC Rochas com uma chapa selecionada



A Figura 14 apresenta a tela de tratamento da imagem da chapa na esteira do Catálogo de Produtos do TIC Rochas.

Figura 14

Tela do Tratamento de imagem da chapa na esteira TIC Rochas com uma chapa segmentada



7 CONSIDERAÇÕES FINAIS

Diante da crescente demanda no mercado de rochas ornamentais e da necessidade de visualização dos produtos mais próximos da realidade para a comercialização de chapas de granitos e mármore, este trabalho de conclusão de curso alcançou seu objetivo geral; desenvolvendo um sistema de transformação digital de imagens de rochas ornamentais, de chapa de mármore ou granito, para um catálogo de produtos, denominado TIC Rochas - Tratamento de Imagem para Catálogo de Rochas. Os objetivos específicos foram trabalhados e contribuíram com o desenvolvimento da solução proposta.

Para o desenvolvimento da aplicação, foi detalhado o processo de beneficiamento de rochas e a geração do Catálogo de produtos do Portfólio da empresa estudada para uma compreensão do domínio do problema e da realidade estudada; que auxiliou na especificação das funcionalidades do sistema e na proposta de um processo otimizado, utilizando o sistema desenvolvido. E, provendo uma solução capaz de resolver o problema de pesquisa de produção de uma imagem com somente o produto, ou seja, a chapa de rocha ornamental, já que a foto da chapa é capturada no processo final do beneficiamento da rocha, e portanto a imagem obtida é da rocha na esteira.

Assim a solução proposta buscou a otimização do processo para gerar um produto de qualidade. Para isso, foram analisados e descritos os fatores que envolvem os aspectos da Indústria 4.0, automatização de processos e sua qualidade. E concluiu-se que o Catálogo de Produtos e o processo de sua produção, corresponde a uma inovação capaz de prover uma imagem com a delimitação da chapa de rocha mais precisa, que corresponde a uma imagem somente da chapa com sua delimitação mais próxima da realidade. Isso auxilia na satisfação do cliente e no processo de comercialização, já que possibilita a visualização de um produto mais próximo da realidade.

Os processos, atual e propostos, foram descritos. E, foi constatado que o processo proposto, utilizando o sistema desenvolvido, melhora o desempenho, reduz o tempo de produção do catálogo e minimiza o envolvimento humano, neste caso, do técnico de tratamento de

imagem. Ele garante uma padronização de processo e da imagem resultante do tratamento de imagem definido e aumenta a produtividade. Também, pode ser melhorado se este for integrado com o sistema ERP utilizado pela organização, provendo mais agilidade, confiabilidade e informações de qualidade.

Nesse sentido, este estudo, também apresenta uma alternativa do sistema proposto para um processo mais eficiente e eficaz, utilizando uma versão do sistema, denominada Sistema TIC Rochas Automatizado, para um processo com a minimização da operação de um técnico. Nessa versão do sistema proposto, é realizado o tratamento da imagem, em lote, gerando automaticamente as imagens de Produtos. Neste caso, todas as imagens do Catálogo são geradas automaticamente, sem a interferência de Técnico.

A análise e descrição realizada dos métodos e variáveis de bibliotecas para tratamento de imagens contribuiu com a compreensão e definição das funcionalidades do sistema proposto, e na definição das técnicas e escolhas de bibliotecas existentes para o tratamento de imagens. Para realizar o tratamento de imagens adotou-se as bibliotecas: U²-Net e OpenCV. O processo de segmentação de imagens de chapas sobre esteira requer a geração de máscara para ser feito o corte da imagem original. O OpenCV, no projeto, é utilizado para realizar a remoção do fundo de uma imagem, dado que se tenha a máscara correspondente à imagem. Foi constatado que a biblioteca do OpenCV pode gerar a máscara sem o uso de inteligência artificial, mas ele requer ajustes nos valores do código para cada imagem recebida para obter uma máscara com poucas falhas. Esse tipo de solução se mostrou inadequada para o projeto.

O uso de inteligência artificial permitiu a automação do processo e a geração de um produto com maior qualidade. Para isto, o sistema passou a utilizar a biblioteca U2-Net, uma solução capaz de retirar o técnico do processo de tratamento de imagem. Com o U2-Net, as máscaras puderam ser produzidas de maneira acelerada com o uso de Redes Neurais Convolucionais. Para que essa solução funcionasse, foi necessário realizar o apropriado treino da rede neural, processo que, para que se alcance dados de saída satisfatórios, necessita primariamente de dados de treinamento de alta qualidade. Esse é um requisito relevante para a qualidade do resultado.

O treinamento de uma rede neural convolucional como a do U²-Net envolve ajustar os pesos dos filtros nas camadas de convolução. Durante o treinamento, a rede aprende a reconhecer padrões cada vez mais complexos. Inicialmente, ela pode detectar linhas simples, mas à medida que as informações avançam pelas camadas, a rede começa a reconhecer formas e objetos mais complexos.

O objetivo final da fase de treinamento é a geração de um modelo estatístico capaz de realizar a geração de máscaras das imagens de entrada. Antes de realizar o treinamento, o desenvolvedor deve alterar os hiperparâmetros do treino, como o número de épocas que a inteligência artificial será treinada e a frequência de salvamento dos modelos gerados. Quanto maior a quantidade de épocas, maior será o tempo levado para a conclusão do treino. Cada arquivo de modelo estatístico gerado ocupa grande espaço em disco, e quanto maior a frequência de salvamento dos modelos e maior a quantidade de épocas, mais espaço no disco será consumido.

Durante o desenvolvimento do sistema, após o primeiro treinamento foi notado que os resultados das segmentações apresentaram defeitos nas bordas, detalhes além de apenas a chapa segmentada estavam sendo mantidas nos dados de saída de teste. Foi constatado posteriormente que este defeito foi causado pela base de dados, que apresentava máscaras com contornos cinzas de diferentes grossuras, e isso foi mantido pelo modelo após o treinamento. A partir desta observação, procedeu-se à análise e tratamento dos dados de treinamento para remover o contorno cinza, seguido por um retreinamento da inteligência artificial utilizando os dados tratados. O objetivo foi obter um modelo capaz de gerar

máscaras na fase final sem replicar os defeitos presentes nas máscaras utilizadas durante o treinamento. Por isso é importante enfatizar que a qualidade das máscaras utilizadas para o treinamento da rede neural é de grande importância para a geração de um modelo satisfatório.

Os trabalhos futuros sugeridos são: o desenvolvimento de uma versão do sistema TIC Rochas que realize o tratamento das imagens das chapas de produtos para o Catálogo em lote, promovendo maior automação e menor envolvimento humano no processo; incluir técnicas de processamento de imagem para melhorar o contraste e o brilho no tratamento de imagens, para melhoria da qualidade da imagem da chapa do catálogo, realizando ajustes da cor e da iluminação; realizar um estudo de viabilidade de implantação da solução proposta e sua integração com o ERP na empresa estudada e outras do mercado; incluir no sistema desenvolvido uma funcionalidade de comparação de imagens, considerando que o cliente, em caso de dúvida sobre o produto escolhido versus o produto recebido, realize a confirmação do produto escolhido comparando as imagens do produto capturada pelo cliente e a imagem do catálogo; desenvolver uma proposta de apresentação do catálogo no portal da empresa; definir métricas e indicadores para avaliar o impacto da inovação; e, desenvolver novas funcionalidades de tratamento de imagem e para visualização da chapa.

REFERÊNCIAS BIBLIOGRÁFICAS

- Adamssen, J. (2020). *Inteligência artificial: Como aprendizado de máquina, robótica e automação moldaram nossa sociedade*. EfalonAcies.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. *2017 International Conference on Engineering and Technology (ICET)*, 1–6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Amaratunga, T. (2023). *Understanding Large Language Models: Learning Their Underlying Concepts and Technologies*. Apress.
- Araujo, J. V. C. (2022). *Rede neural convolucional para classificação de chapas polidas de rochas ornamentais [Trabalho de Conclusão de Curso]*. Instituto Federal do Espírito Santo - Campus Cachoeiro.
- Bastos, R., Uliana, J., Calmon, J., Tristão, F., VIEIRA, G., & Degen, M. (2013). Revisão bibliográfica dos estudos sobre a aplicação da lama do beneficiamento de rochas ornamentais na produção de materiais de construção. *Congresso brasileiro do concreto*, 54.
- Bradski, G. (2009). *OpenCV*.
- Bukhari, H. R., Mumtaz, R., Inayat, S., Shafi, U., Haq, I. U., Zaidi, S. M. H., & Hafeez, M. (2021). *Assessing the Impact of Segmentation on Wheat Stripe Rust Disease Classification Using Computer Vision and Deep Learning*. *IEEE Access*, 9, 164986–165004. <https://doi.org/10.1109/ACCESS.2021.3134196>
- Crosby, P. B. (1979). *Quality is free: The art of making quality certain*. McGraw-Hill.

Harvard business review, 96(1), 108–116.

Davenport, T. H. (1995). *Reengenharia de processos: Como inovar na empresa através da tecnologia da informação* (5ª ed.). Campus.

Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world.

Drucker, P., & Maciariello, J. (2014). *Innovation and entrepreneurship*. Routledge.

Ferreira, A., & Giraldo, G. (2017). Convolutional Neural Network approaches to granite tiles classification. *Expert Systems with Applications*, 84, 1–11.
<https://doi.org/10.1016/j.eswa.2017.04.053>

Garvin, D. A. (1992). *Gerenciando a qualidade: A visão estratégica e competitiva*. Qualitymark.

Gonçalves, J. P. (2000). *Utilização do resíduo de corte de granito (RCG) como adição para produção de concretos* [Universidade Federal do Rio Grande do Sul].
<https://lume.ufrgs.br/handle/10183/1676>

Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing*. Pearson.

Graczyk, K. M., Pawłowski, J., Majchrowska, S., & Golan, T. (2022). Self-normalized density map (SNDM) for counting microbiological objects. *Scientific Reports*, 12(1), 10583.
<https://doi.org/10.1038/s41598-022-14879-3>

Groover, M. P. (2007). *Work systems and the methods, measurement, and management of work*. Pearson Prentice Hall Upper Saddle River, NJ.

Juran, J. M. (1986). The quality trilogy: A universal approach to managing for quality. *Quality progress*, 19–24.

Kenneth C. Laudon, Jane P. Laudon, & Carol G. Traver. (2024). *Essentials of MIS*. Pearson.

Klette, R., & Zamperoni, P. (1996). *Handbook of image processing operators*. John Wiley & Sons.

Kumar, R., Singh, R. K., & Dwivedi, Y. K. (2020). Application of industry 4.0 technologies in SMEs for ethical and sustainable operations: Analysis of challenges. *Journal of cleaner production*, 275, 124063.

Lacity, M. C., & Willcocks, L. (2016). *Rethinking legal services in the face of globalization and technology innovation: The case of Radiant Law*. 6(1), 15–22.

Lasi, H., Fettke, P., Kemper, H.-G., Feld, T., & Hoffmann, M. (2014). Industry 4.0. *Business & information systems engineering*, 6, 239–242.

Laudon, K. C., & Laudon, J. (2021). *Management information systems: Managing the digital firm, global edition* (17^o ed). Pearson Education.

Li, Y., Li, H., Fan, D., Li, Z., & Ji, S. (2023). Improved Sea Ice Image Segmentation Using U2-Net and Dataset Augmentation. *Applied Sciences*, 13(16), 9402.
<https://doi.org/10.3390/app13169402>

Liu, F., Wang, H., Ke, Y., & Zheng, C. (2022). One-shot voice conversion using a combination of U2-Net and vector quantization. *Applied Acoustics*, 199, 109014.
<https://doi.org/10.1016/j.apacoust.2022.109014>

Microsoft. (2023, outubro 29). *O que é o Visual Studio?* <https://learn.microsoft.com/pt-br/visualstudio/get-started/visual-studio-ide?view=vs-2022>

Pal, N. R., & Pal, S. K. (1993). A review on image segmentation techniques. *Pattern Recognition*, 26(9), 1277–1294.

Plaksyvyi, A., Skublewska-Paszowska, M., & Powroznik, P. (2023). *A Comparative Analysis of Image Segmentation Using Classical and Deep Learning Approach*. *Advances in Science and Technology Research Journal*, 17(6), 127-139. <https://doi.org/10.12913/22998624/172771>

Porter, M. E., & Heppelmann, J. E. (2014). How smart, connected products are transforming competition. *Harvard Business Review*, 11, 64–88.

Qin, X., Zhang, Z., Huang, C., Dehghan, M., Zaiane, O. R., & Jagersand, M. (2020). U²-Net: Going Deeper with Nested U-Structure for Salient Object Detection. *Pattern Recognition*, 106, 107404. <https://doi.org/10.1016/j.patcog.2020.107404>

Rogers, E. (1995). *Diffusion of innovation*. New York: Free Press.

Ross, J. W., Sebastian, I. M., & Beath, C. M. (2018). How to develop a great digital strategy. Em *How to go digital* (p. 3–12). The MIT Press.

Russ, J.C., & Neal, F.B. (2016). *The Image Processing Handbook* (7th ed.). CRC Press. <https://doi.org/10.1201/b18983>

Schumpeter, J. (2017). *Capitalismo, socialismo e democracia – edição integral*.

Schwab, K. (2019). *A quarta revolução industrial*. Edipro.

Shao, J., Zhou, K., Cai, Y.-H., & Geng, D.-Y. (2022). Application of an Improved U2-Net Model in Ultrasound Median Neural Image Segmentation. *Ultrasound in Medicine & Biology*, 48(12), 2512–2520. <https://doi.org/10.1016/j.ultrasmedbio.2022.08.003>

Silva, J. C. da. (2018, setembro 24). *Aprendizagem de Máquina é Divertido! Parte 3. Machina Sapiens*. <https://medium.com/machina-sapiens/aprendizagem-de-m%C3%A1quina-%C3%A9-divertido-parte-3-deep-learning-e-redes-neuronais-convolutivas-879e0ee7ba48>

Silveira, M. R., & Menechelli, F. B. (2017). O uso de filtros no processamento digital de imagens. *Anais do unic-congresso de iniciação científica-unifev*, 4(1), 219–220.

Sonka, M., Hlavac, V., & Boyle, R. (1998). *Imageprocessing, analysis, and machine vision*. 1999. *Champion & Hall*, 2–6.

Szeliski, R. (2022). *Computer vision: Algorithms and applications*. Springer Nature.

Tidd, J., & Bessant, J. (2015). *Gestão da inovação*. 1(4), 6.

Uliana, J. G. (2014). *Tratamento térmico da lama do beneficiamento de rochas ornamentais: Aplicação como pozolana em matrizes cimentícias* [Universidade Federal do Espírito Santo]. <https://repositorio.ufes.br/items/c5e95b6a-161d-4286-b8ac-7fd24b407308>

Valdati, A. D. B. (2021). *Inteligência Artificial—IA*. Contentus.

Vidal, F. W. H., Azevedo, H. C. A. de, Castro, N. F., & others. (2013). *Tecnologia de rochas*

Von Wangenheim, A. (2018). *Deep Learning: Reconhecimento de Imagens*. UFSC.
<https://lapix.ufsc.br/ensino/visao/visao-computacionaldeep-learning/deep-learningreconhecimento-de-imagens/>

Zhang, Y. J. (1996). A survey on evaluation methods for image segmentation. *Pattern Recognition*, 29(8), 1335–1346. [https://doi.org/10.1016/0031-3203\(95\)00169-7](https://doi.org/10.1016/0031-3203(95)00169-7)

Zhang, Y., Zhang, H., Zhou, S., Liu, G., & Zhu, J. (2022). Deep Learning-Based Layer Identification of 2D Nanomaterials. *Coatings*, 12(10), 1551. <https://doi.org/10.3390/coatings12101551>