

Aumento de Dados para Criação de Conjunto de Dados de Imagens de Vias de Acesso de Mineradora: Uma Revisão Sistemática

Mirella B. S. Rodrigues¹, Ingrid N. Mendes², Otávio N. Teixeira¹

¹Faculdade de Engenharia de Computação – Universidade Federal do Pará (UFPA)
Tucuruí – PA – Brasil

²Programa de Pós-Graduação em Engenharia Elétrica – Universidade Federal do Pará (UFPA)
Belém – Brasil

{mirella.rodrigues, ingrid.mendes}@tucuruui.ufpa.br, onoura@gmail.com

Abstract. *This systematic literature review aims to conduct an exploratory investigation of data augmentation techniques employed in computer vision tasks, specifically in the creation of open-pit mining road datasets for assessing pavement conditions. Conducted under the PRISMA protocol guidelines, the search resulted in the qualitative analysis of 8 primary studies. The predominant use of classical geometric techniques was observed, complemented by photometric and synthetic approaches, primarily used to overcome data scarcity, reduce overfitting, and increase the generalization capacity of the models. However, an absence of studies with a quantitative evaluation of the isolated impact of these techniques was identified, as well as research focused directly on the detection of structural road defects (such as potholes). Therefore, future works are proposed to address these gaps, including isolated empirical tests and the integration of these techniques into real-time autonomous road analysis systems*

Resumo. *Esta revisão sistemática da literatura objetiva realizar uma pesquisa exploratória acerca das técnicas de aumento de dados empregadas em tarefas de visão computacional, especificamente na criação de conjunto de dados de vias de mineração a céu aberto para a identificação das condições do pavimento. Conduzida sob as diretrizes do protocolo PRISMA, a busca resultou na análise qualitativa de 8 estudos primários. Observou-se a predominância do emprego de técnicas clássicas geométricas, complementadas por abordagens fotométricas e sintéticas, utilizadas primordialmente para contornar a escassez de dados, reduzir o sobreajuste (overfitting) e aumentar a capacidade de generalização dos modelos. Entretanto, identificou-se uma ausência de estudos com avaliação quantitativa do impacto dessas técnicas isoladamente, bem como pesquisas focadas diretamente na detecção de defeitos estruturais das vias (como buracos). Dessa forma, propõem-se trabalhos futuros para cobrir essas lacunas, incluindo testes empíricos isolados e a integração dessas técnicas em sistemas autônomos de análise viária em tempo real.*

1. Introdução

Os buracos são falhas nas vias, pavimentadas ou não, decorrentes de depressões causadas sobretudo pelo tráfego (carga, volume e tipo de veículo) e pelas condições climáticas, em especial umidade e chuva, que enfraquecem o material e aceleram sua degradação [Adlinge e Gupta 2013]. Em estradas não pavimentadas, usualmente construídas com cascalho, esses fatores intensificam a perda de material superficial, aumentam a rugosidade e favorecem defeitos como erosão [Kuleno e Lera 2020]. Embora tenham menor custo inicial e papel essencial em cadeias produtivas como a mineração, essas vias demandam recomposição frequente de agregado, elevando significativamente os custos operacionais ao longo de seu ciclo de vida [Yuzdepski e Merkosky 2004]. Um dos efeitos da presença de buracos, ondulações e outros defeitos no pavimento é o aumento do consumo de combustível, redução da velocidade média e aceleração do desgaste dos pneumáticos, elevando custos de manutenção e comprometendo a eficiência do transporte rodoviário [Magalhães e Da Silva 2018].

A avaliação convencional por vistorias visuais é subjetiva, demorada e custosa, enquanto algoritmos de processamento de imagens e redes neurais conseguem identificar buracos em grandes extensões com menor custo por quilômetro, permitindo direcionar a manutenção com mais precisão, otimizar recursos e melhorar o planejamento das intervenções [Saeed et al. 2020] [Ferreira e De Paiva 2004].

Um estudo de caso em uma mina a céu aberto em Nevada (EUA) demonstra o uso de *drones* (Veículos Aéreos Não Tripulados – VANTs), como alternativa aos métodos tradicionais de monitoramento, capturando imagens sobrepostas das estradas para avaliar condições, detectar buracos, desgaste e geometria inadequada, o que permite direcionar de forma mais assertiva e priorizada as equipes de manutenção, reduzindo custos, melhorando o estado das vias e, indiretamente, aumentando a vida útil dos pneus, a segurança e a produtividade [Medinac et al. 2020]. A adoção desse monitoramento abre espaço para maior automação, com o uso de visão computacional para detecção automatizada de defeitos nas estradas.

O avanço tecnológico tem impulsionado a manutenção viária por meio de ferramentas de visão computacional voltadas à detecção automática de buracos e outros defeitos, que empregam técnicas para identificar, localizar e categorizar danos a partir de dados visuais. Essas abordagens incluem processamento de imagens 2D, modelagem e segmentação de nuvens de pontos 3D, aprendizado de máquina (*machine learning*) e modelos híbridos. Contudo, métodos baseados em aprendizagem profunda (*deep learning*), como Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNNs), exigem grandes bases de dados rotuladas, cuja preparação é cara e demorada [Ma et al. 2022].

Em métodos baseados em aprendizado de máquina, é necessário um grande volume de dados, pois o desempenho de redes muito profundas melhora quando treinadas em bases de dados massivas. Em bases pequenas, aumenta-se o risco de sobreajuste¹ (*overfitting*), exigindo forte regularização², exemplo, aumento de dados

¹ O *overfitting* ocorre quando o modelo memoriza peculiaridades dos dados de treinamento em vez de aprender regras preditivas gerais (DIETTERICH, 1995).

(*data augmentation* – DA), que consiste em uma série de técnicas aplicadas às imagens gerando novos dados sem alterar o rótulo de anotação. Em tarefas visuais complexas, um grande conjunto de imagens rotuladas torna-se praticamente indispensável para alcançar desempenho de estado da arte (*state of the art*, SOTA) [Rawat e Wang 2017]. Segundo Mikołajczyk e Grochowski (2018), embora não eliminem completamente o sobreajuste, técnicas tradicionais de aumento de dados, ampliam artificialmente o conjunto de treino, ajudando a contornar a falta de dados e o desbalanceamento de classes, além de melhorar a generalização³ ao expor a rede a múltiplas variações geométricas e de cor [Maharana et al. 2022].

No contexto apresentado, o trabalho busca identificar, através de uma pesquisa exploratória, conduzida por uma Revisão Sistemática da Literatura (RSL), quais técnicas de aumento de dados têm sido empregadas para criar e enriquecer conjuntos de dados (*datasets*) de vias de mineração, bem como seu impacto no desempenho de modelos de visão computacional do estado da arte aplicados à avaliação de estradas. A pesquisa se desdobra em quatro eixos para responder à seguinte pergunta de pesquisa: Quais técnicas de aumento de dados têm sido aplicadas para a criação de conjunto de dados de vias de mineração e qual o impacto no desempenho dos modelos de estado da arte?

O restante deste artigo está organizado da seguinte forma: na Seção 2, são apresentados os trabalhos relacionados ao tema. Na Seção 3, é apresentada a metodologia, contendo o protocolo de RSL desenvolvido e suas etapas. Na Seção 4, são apresentados os resultados e discussões obtidos. A Seção 5 apresenta as conclusões. Por fim, a Seção 6 apresenta os trabalhos futuros.

2. Trabalhos relacionados

Realizou-se uma busca exploratória, empregando combinações mais amplas de termos associados à detecção de danos em pavimentos e vias de mineração, nas bases *ScienceDirect* e *SpringerLink*, com os termos ‘*open-pit mines*’ associado aos termos ‘*deep learning*’ e ‘*data augmentation*’, com o objetivo de localizar estudos e revisões similares, dos achados mais relevantes ao tema do estado da arte.

Em Azhari et al. (2023) é mostrado que técnicas de aumento de dados são amplamente usadas em aplicações de aprendizado profundo em mineração para contornar a escassez de dados reais, sobretudo em imagens, incluindo rotações, espelhamentos, escala, recorte, distorção e adição de ruído. Em vários estudos revisados, conjuntos pequenos, dezenas ou centenas de imagens, são expandidos para dezenas de milhares de amostras para treinar modelos de detecção de blocos, classificação de carga de caminhões, segmentação de materiais em correias e mapeamento de áreas de mina a partir de imagens aéreas ou de satélite. Mesmo que o artigo não trate diretamente de análise das vias de mineração, ele descreve modelos aplicados a tarefas diretamente ligadas ao tráfego em vias de mina, como navegação de

² **Regularização** é a estratégia para mitigar o *overfitting* em CNNs, causado pela insuficiência de dados frente à complexidade do treinamento, promovendo generalização para dados de teste por meio da otimização equilibrada da função de perda (SANTOS e PAPA, 2022).

³ **Generalização** é a capacidade do algoritmo de minimizar o erro em dados não observados, corrigindo a superestimação otimista do erro de treinamento, especialmente com poucas amostras (XU e MANNOR, 2012).

veículos, detecção de obstáculos, rochas, e segmentação de áreas de mina em imagens remotas. Essas aplicações poderiam ser adaptadas para monitorar e analisar o estado das vias em operações a céu aberto.

O artigo de Yang et al. (2025) revisa de forma abrangente o uso de inteligência artificial (IA) em exploração, lavra e processamento mineral, destacando desde modelos clássicos (*Support Vector Machine*, *random forest*, *Artificial Neural Network*) até aprendizado profundo (CNN, *Generative Adversarial Network*, *Graph Neural Network*) aplicados a mapeamento de prospectividade, detecção de anomalias geoquímicas, automação de mina e monitoramento de processos. No contexto de aumento de dados, o texto enfatiza explicitamente o trabalho de Yang et al. (2022), em que técnicas de aumento de dados são usadas para expandir conjuntos de imagens geológicas e melhorar o desempenho de CNNs em predição de prospectividade em cenários de dados escassos, alcançando acurácia de 91,38%. Essa estratégia é apontada como particularmente importante para problemas de mineração onde a coleta de dados rotulados é cara ou limitada, o que inclui aplicações visuais em operações a céu aberto, como detecção de caminhões, pessoas, fissuras e condições da superfície nas vias de transporte. Ao gerar variações sintéticas de imagens, o aumento de dados torna os modelos de visão mais robustos a poeira, variação de iluminação e mudanças de cenário típicas das estradas de mina, beneficiando diretamente sistemas de navegação, despacho e segurança em frotas de caminhões em minas a céu aberto.

O artigo de Pakdel e Erol (2025) é uma RSL, guiada por PRISMA, Page et al. (2021), e análise bibliométrica, que sintetiza 41 estudos sobre transformação digital na mineração, identificando 16 barreiras principais à adoção de tecnologias como IA, IoT (*Internet of Things*), gêmeos digitais, automação e *blockchain*, por exemplo, altos custos iniciais, integração com sistemas legados, falta de infraestrutura em locais remotos, riscos de cibersegurança e escassez de mão de obra qualificada. O texto não discute diretamente aumento de dados, mas enfatiza repetidamente que a adoção de soluções de IA e aprendizado de máquina depende de grandes volumes de dados de boa qualidade em minas a céu aberto. Nessa perspectiva, técnicas de aumento de dados sobre imagens, veículos, pessoas, obstáculos, estado da via, podem ser vistas como facilitadoras indiretas da transformação digital em vias de mineração a céu aberto, ajudando a suprir a falta de dados rotulados tornando mais viável, na prática, o uso de IA para navegação autônoma, monitoramento de segurança e otimização logística em estradas de mina, alinhando-se às metas de eficiência, segurança e sustentabilidade destacadas na revisão.

3. Metodologia

A presente pesquisa exploratória foi conduzida através de RSL, seguindo as diretrizes metodológicas propostas por Kitchenham et al. (2004), amplamente adotadas na área de Engenharia de Software. O relato dos resultados foi estruturado sob as diretrizes do protocolo PRISMA por Page et al. (2021), a fim de garantir a reprodutibilidade e rigor metodológico, no qual foi adotada uma abordagem qualitativa de síntese dos resultados, com foco descritivo e comparativo das técnicas, contextos de aplicação e métricas de

desempenho reportadas nos estudos primários. O protocolo foi disponibilizado através da plataforma Rayyan⁴, para assegurar a transparência [Ouzzani et al. 2016].

A RSL consiste em responder às seguintes perguntas:

1. Quais técnicas de aumento de dados têm sido aplicadas para a criação de aumento de dados de vias de mineração e qual o impacto no desempenho dos modelos de estado da arte?
2. Dentre essas técnicas, qual obteve melhor resultado de acordo com a pesquisa?
3. De acordo com a seleção final dos trabalhos, existe número de amostras mínimo para utilização como entrada para treinamento de algoritmo detector de objetos (aprendizado de máquina)?
4. Quais as características do *dataset* para utilização como entrada para treinamento de algoritmo detector de objetos (aprendizado de máquina)?

Alinhado à estrutura PICOC⁵, este protocolo considerou os critérios apresentados na Tabela 1.

3.1 Estratégia de busca

A estratégia de busca desta RSL foi desenvolvida com base na estratégia PICOC e contemplou estudos primários, incluindo estudos quantitativos ou qualitativos, observacionais, de viabilidade ou de caracterização, desde que alinhados ao protocolo. A partir de um conjunto de palavras-chave e descritores, foram construídas *strings* de busca específicas, que foram aplicadas nas bases definidas, assegurando a recuperação dos estudos. Os registros identificados foram listados e tiveram seus títulos, resumos e palavras-chave examinados seguindo os critérios de inclusão e exclusão. Aqueles que atenderam aos requisitos estabelecidos no protocolo foram selecionados para as etapas subsequentes.

Tabela 1: Descrição dos critérios da pesquisa (PICOC)

Critério	Descrição
População	Produções científicas relacionadas à utilização de técnicas de aumento de dados para criação de conjunto de dados de imagens
Intervenção	Avaliação das técnicas utilizadas de aumento de dados no contexto de imagens de vias de acesso de mineração a céu aberto
Controle	Comparar os resultados dos métodos selecionados
Resultado	Avaliar o desempenho da aplicação das técnicas
Contexto de Aplicação	Processamento de imagem, Aprendizado de Máquina, Vias de Acesso de Mineração a Céu Aberto

Fonte: Elaborado pelos autores (2026).

⁴ Link do **Rayyan**, plataforma colaborativa para revisões sistemáticas, desta RSL: <https://new.rayyan.ai/reviews/1825319/overview> (OUZZANI et al., 2016).

⁵ **PICOC** é uma estrutura que define *Population*, *Intervention*, *Comparison*, *Outcomes* e *Context* (KITCHENHAM et al., 2004).

3.2 Bases de dados e palavras-chave

Para a identificação dos estudos, foram selecionadas bases de dados amplamente reconhecidas nas áreas de computação, que possuem o rigoroso processo de revisão por pares (*peer review*), essencial para a garantir a credibilidade acadêmica. A busca foi conduzida nas plataformas *ScienceDirect*, *SpringerLink*, *IEEE Xplore*, *ACM Digital Library*, *Taylor & Francis* e *Web of Science*, complementada pelo repositório nacional da Sociedade Brasileira de Computação (SBC), a Biblioteca Digital da Sociedade Brasileira de Computação (SBC-OpenLib, SOL), de forma a contemplar tanto periódicos internacionais quanto publicações nacionais.

Para realizar a busca das fontes foi elaborado *string* padronizada para uso nas plataformas. Inicialmente, foi feito uma busca com a *string* “*data augmentation*” and (“*pothole*” or “*pothole detection*”) and “*mining roads*”, com a finalidade de obter artigos compatíveis com o tema desta revisão. Foram encontrados 3 artigos com a *string*. Somado aos 5 artigos de controle obtidos pela orientação do trabalho, obteve-se um total de 8 artigos de controle. Analisando os artigos, utilizando critérios de inclusão e exclusão, obteve-se um total de 7 artigos. A partir desses artigos, extraiu-se as palavras-chave e organizou-se em uma tabela com sua frequência. Dessas palavras-chave, foram selecionadas aquelas com maior frequência e com maior relação com o tema da revisão. Finalizado a etapa de seleção das palavras-chave, passou-se para a etapa de construção da *string*. Nessa etapa foi utilizado o *IEEE Thesaurus* (2025) para agrupar os termos e localizar os descritores.

Para responder às questões, foram selecionados termos que cobrem a intervenção “*open-pit mines*”, sendo sua tradução livre minas a céu aberto e população “*data augmentation*”, agrupado aos termos “*artificial intelligence*” e seus termos relacionados (RT) AI e “*machine learning*”, de acordo com o Tesouro, separados por conectores OR. Por fim, para os resultados esperados “*pothole detection*”, “*road damage detection*”, “*road pothole detection*” e “*object detection*”, agrupados e separados com conectores OR. Essa combinação garante que sejam recuperados estudos que exploram o uso de inteligência artificial, e seus termos relacionados, na detecção de buracos e danos nas estradas de acesso de mineração a céu aberto, priorizando a detecção de objetos.

Com todos os termos definidos foi construída a *string* abaixo, utilizando os descritores e conectores necessários, conforme Tabela 2. A *string* foi devidamente adaptada para se adequar a cada base de dados definida no escopo desta RSL.

Tabela 2: String de busca

“ <i>open-pit mines</i> ” AND (“ <i>pothole detection</i> ” OR “ <i>road damage detection</i> ” OR “ <i>road pothole detection</i> ” OR “ <i>object detection</i> ”) AND (“ <i>artificial intelligence</i> ” OR AI OR “ <i>machine learning</i> ” OR “ <i>data augmentation</i> ”)
--

Fonte: Elaborado pelos autores (2026).

3.3 Critérios de elegibilidade

Os critérios de elegibilidade foram definidos de forma a garantir a seleção de estudos diretamente relacionados ao uso de técnicas de aumento de dados aplicadas à criação de

conjunto de dados de imagens de vias de mineração. Foram incluídos trabalhos que atenderam os critérios de inclusão e exclusão conforme Tabela 3 e Tabela 4 abaixo.

Tabela 3: Critérios de inclusão

Critério	Descrição
CI1	O trabalho aborda o uso de aumento de dados no processo exposto
CI2	Utiliza processos de geração ou tratamento de dados (imagens) para avaliação do estado de estradas
CI3	As técnicas empregadas utilizam dados de imagens 2D digitais (fotográficas, drones, satélites ou câmeras embarcadas)
CI4	as técnicas são aplicadas na avaliação de estradas especialmente em contexto de mineração (vias de mineração, estradas internas, pátios, caminhões, entre outros)
CI5	Trabalhos publicados até 2025

Fonte: Elaborado pelos autores (2026).

Tabela 4: Critérios de exclusão

Critério	Descrição
CE1	o artigo não satisfaz nenhum critério de inclusão
CE2	a versão completa da obra não está disponível (<i>paywall</i> e/ou sem acesso via Portal da Capes)
CE3	o trabalho não está disponível em português e/ou inglês
CE4	o trabalho é um editorial, <i>workshop</i> , resumo, resumo expandido, vídeo, apresentação, relatório, blog, tutorial, enciclopédia ou dicionário

Fonte: Elaborado pelos autores (2026).

3.4 Avaliação da qualidade metodológica

A avaliação da qualidade metodológica dos estudos incluídos foi realizada por meio de um *checklist* composto por oito critérios, respondidos de forma binária (sim/não), atribuindo-se pontuação 1 para “sim” e 0 para “não”. Foram considerados os critérios descritos na Tabela 5. A soma desses itens resultou em uma pontuação global de qualidade, utilizada para caracterizar a robustez metodológica dos estudos selecionados. Artigos que obtiveram uma qualidade metodologia de pelo menos 60%, ou seja, cinco (5) pontos, foram incluídos ao escopo desta RSL.

3.5 Seleção dos estudos

A seleção dos estudos foi realizada seguindo as etapas de identificação, triagem, elegibilidade e inclusão dos estudos conforme as diretrizes do protocolo PRISMA 2020 (Figura 1), a partir do conjunto de registros obtidos nas bases de dados previamente definidas.

Todos os 179 registros foram importados para uma ferramenta de gerenciamento de referências (Rayyan) [Ouzzani et al. 2016]. Procedeu-se a remoção de duplicatas, o que resultou na exclusão de 8 registros, resultando 171 registros. Em seguida, realizou-se a triagem dos títulos e resumos, aplicando de forma preliminar os critérios de elegibilidade, o que resultou na inclusão de 18 registros. Os estudos potencialmente relevantes foram então avaliados em texto completo, reaplicaram-se os critérios de elegibilidade de maneira mais rigorosa, verificou-se a aderência à pergunta de pesquisa,

ao contexto de aplicação e aos critérios de qualidade metodológica previstos e, nessa etapa, foram selecionados 8 estudos. Nenhum dos estudos atingiu nota máxima nos critérios de qualidade, tendo 3 estudos atingido 5 pontos e 5 estudos, 6 pontos, tendo nenhum deles pontuado nos critérios de Avaliação experimental e Métricas de desempenho.

Tabela 5: Critérios de qualidade

Critério	Campo	Descrição do critério de qualidade
CQ1	Clareza metodológica	Possui clareza do objetivo e reprodutibilidade metodológica?
CQ2	Revisado por pares	Publicado em periódico ou conferência revisada por pares?
CQ3	Descrição do conjunto de dados	O estudo descreve adequadamente as características do conjunto de dados utilizado? (origem, quantidade de imagens, resolução, condições de coleta, etc.)
CQ4	Métodos de aumento de dados	As técnicas de aumento de dados são claramente descritas para replicação? (rotação, flip, <i>cropping</i> , GANs, etc.)
CQ5	Aplicabilidade na mineração	O estudo discute a aplicabilidade em cenários reais de vias de mineração ou áreas similares?
CQ6	Avaliação experimental	Há comparação entre modelos com ou sem aumento de dados? (Comparação entre cenários)
CQ7	Métricas de desempenho	Apresenta métricas quantitativas (<i>accuracy</i> , IoU, F1-score, etc.) para medir o impacto das técnicas?
CQ8	Validade das conclusões	As conclusões são consistentes com os resultados apresentados?

Fonte: Elaborado pelos autores (2026).

Inicialmente foram recuperados artigos que tratavam de mineração a céu aberto, porém com foco predominante no uso de ferramentas de visão computacional aplicadas a processos de extração de minério, detonação e análise de corpo geológico. Esses trabalhos foram excluídos por não atenderem à intervenção definida no protocolo. Por outro lado, estudos cujo objetivo principal é auxiliar o desempenho de caminhões autônomos, nos quais as técnicas de visão computacional e aumento de dados eram utilizadas para aprimorar a detecção de objetos em cenários que incluíam as vias de acesso, foram mantidos na amostra quando contemplavam, ainda que de forma indireta, a identificação de obstáculos ou irregularidades nas superfícies das estradas.

3.6 Síntese dos resultados

Nesta revisão, a síntese dos resultados foi conduzida por meio de uma abordagem narrativa qualitativa estruturada, organizada por população, intervenções e resultados. Os oito estudos incluídos são caracterizados como empíricos e quantitativos de pesquisa aplicada em visão computacional com foco em aplicações para ambiente de mineração. Entretanto, apresentam elevada heterogeneidade quanto às tarefas abordadas, às arquiteturas de modelos de visão computacional empregadas, ao conjunto de dados utilizados e às métricas de desempenho reportadas. Em razão dessa diversidade de desenhos experimentais e indicadores, não foi considerada apropriada a realização de meta-análise estatística. Assim, os resultados foram organizados e descritos em texto,

agrupando os estudos por tipo de técnicas de aumento de dados (geométricas, fotométricas e sintéticas) e por tarefa de visão computacional.

4. Resultados e discussões

4.1 Características dos estudos incluídos

Analisando os tipos de tarefas e objetivos dos estudos, é possível notar que eles podem ser agrupados em quatro tipos principais de tarefas, segmentação semântica de vias, mais especificamente os estudos que tem por objetivo identificar área trafegável, segmentação e detecção de áreas de cava em imagens de sensoriamento remoto, detecção de obstáculos ou caminhos em minas, principalmente para navegação e detecção de discontinuidades em taludes para monitoramento geotécnico. A Tabela 6 apresenta a seleção final de estudos analisados, identificando suas referências. Para auxiliar o entendimento dos dados quantitativos foi elaborada a Tabela 7.




Figura 1. Fluxograma PRISMA 2020 do processo de identificação, triagem, elegibilidade e inclusão dos estudos na revisão sistemática.

Fonte: Elaborado pelos autores (2026).

No grupo de estudos de segmentação semântica de vias, Yang et al. (2024) tem por objetivo extrair as vias em ambiente de mineração para apoiar a navegação autônoma. Devido à diferença na litologia, o estudo propõe a criação de um conjunto de dados aplicando uma técnica de pré-processamento, CLAHE (*Contrast Limited Adaptive Histogram Equalization*), com objetivo de aumentar o contraste de bordas. O conjunto de dados melhorado apresenta os melhores resultados aplicado a modelo UNet, fornecendo solução para construção de mapas atualizáveis em tempo real para veículos não tripulados. Com objetivo semelhante, Neto et al. (2022) desenvolve um sistema de percepção em tempo real para segmentar área trafegável e obstáculos,

visando estradas não pavimentadas de ambientes de mineração com baixa visibilidade. Para apoiar o objetivo, um conjunto de dados com cenários de clima adverso é desenvolvido. O estudo apresenta bom desempenho com abordagem de aprendizado profundo, aliado ao conjunto de dados desenvolvido, enfatizando que as redes treinadas em conjunto de dados de ambientes urbanos não são adequadas para a tarefa de veículos autônomos nessas áreas. Por fim, Sunwen, Yanwei e Guorui (2024) tem por objetivo segmentar e detectar estradas em áreas de mineração a céu aberto, apresentando melhores resultados com o modelo D-DMCATNet proposto do que com variações clássicas do modelo UNet. O modelo proposto apresenta uma melhora tanto na delimitação de bordas quanto na continuidade de estradas principais em contexto de cenários complexos, indicando maior capacidade de generalização com poucos dados, diferente dos estudos anteriores que apresentaram a necessidade de conjunto de dados muito mais robustos.

Tabela 6: Identificação dos estudos

Índice	Título	Referência
A1	A target detection model based on improved tiny-yolov3 under the environment of mining truck	[Xiao et al. 2019]
A2	Active Parallel Teacher for Human-in-the-Loop Sim2Real Object Detection in Autonomous Haulage Trucks	[Guo et al. 2024]
A3	DeepHaul: a deep learning and reinforcement learning-based smart automation framework for dump trucks	[Ali e Frimpong 2021]
A4	Extracting unstructured roads for smart Open-Pit mines based on computer vision: Implications for intelligent mining	[Yang et al. 2024]
A5	Lightweight Object Detection Network With Spatial-Channel Attention and Stair Fusion Structure for Remote Sensing Open-Pit	[Yuan et al. 2024]
A6	Low-latency perception in off-road dynamical low visibility environments	[Neto et al. 2022]
A7	Road detection in open-pit mining areas using d-dmcatnet network based on uav images	[Sunwen, Yanwei e Guorui 2024]
A8	Software Implementation of an Algorithm for Automatic Detection of Lineaments and Their Properties in Open-Pit Dumps	[Popov, Potapov e Zamaraev 2024]

Fonte: Elaborado pelos autores (2026).

O trabalho que aborda segmentação e detecção de áreas de cava em imagens de sensoriamento remoto, Yuan et al. (2024), apresenta um modelo de detecção e segmentação, em nível de pixel, de áreas de cava em imagens de satélite, para apoiar tarefas de monitoramento ambiental e de mineração. O modelo DASFNet desenvolvido, se destaca pela leveza, que permite seu uso em ambiente de *hardware* limitado, VANT ou satélite, sem perder o desempenho frente a condições climáticas adversas devido sua construção pensada para ruído e neblina.

Os três estudos que abordaram detecção de obstáculos ou caminhões em minas para navegação em mina trazem abordagens complementares e relevantes para esse segmento. O trabalho de Xiao et al. (2019) visa a construção de um detector de

obstáculos para *hardware* limitado. Os autores realizam pequenas mudanças estruturais no modelo existente, Tiny-YOLOv3, apresentando ganhos significativos sem perder a viabilidade para sistemas embarcados. Destaca-se para a melhoria na detecção correta de obstáculos, no qual, mais obstáculos são corretamente detectados nas imagens de mina. Em Guo et al. (2024), os autores visam a melhoria na detecção de obstáculos, de caminhões autônomos, dos modelos treinados em cenários virtuais para minas reais, realizando o mínimo possível de rotulagem manual. Com apenas 7,5% das imagens reais anotadas, alcança o desempenho do modelo totalmente supervisionado em alguns cenários, reduzindo drasticamente a necessidade de anotação real, sem perder a performance que modelos treinados apenas com dados reais apresenta. Esse resultado é alcançado utilizando a maior parte dos dados de treinamento a partir de dados virtuais anotados, no processo de misturar dados virtuais rotulados, reais rotulados e reais não rotulados com pseudo-rótulos. O estudo de Ali e Frimpong (2021) vai além dos objetivos anteriores, implementando um *framework* integrando reconhecimento de objetos e decisão de rota para caminhões de mina inteligentes. Une uma arquitetura CNN para detecção das classes com módulo de controle para decisão de ações de direção formulado com aprendizado por reforço (*reinforcement learning*). Apesar de atingir bons resultados, o *framework* não foi testado em uma situação real de mina. Apesar disso, os autores afirmam que a arquitetura com aprendizado profundo e aprendizado por reforço pode elevar significativamente a segurança do transporte em mina.

Tabela 7: Métricas de avaliação

Métrica	Descrição
<i>Accuracy</i> (acurácia)	Proporção de pixels corretamente classificados em relação ao total [Sunwen, Yanwei e Guorui 2024]
AP	Precisão média, área sob a curva Precisão-Recall para uma classe [Xiao et al. 2019]
F1-score	Média harmônica entre precisão e recall, balanceando as duas em uma única medida [Sunwen, Yanwei e Guorui 2024]
FPS	Quadros por segundo, número de imagens processadas por segundo [Xiao et al. 2019]
IoU (<i>Intersection over Union</i>)	Razão entre verdadeiros positivos e a soma de verdadeiros positivos, falsos negativos e falsos positivos para cada classe. mIoU é a média de IoU para todas as classes [Garcia-Garcia et al. 2018]
mAcc	Média da acurácia para todas as classes [Garcia-Garcia et al. 2018]
mAP	Média dos valores de AP das várias classes, usada como medida global de desempenho em detecção [Xiao et al. 2019]
<i>Precision</i> (precisão)	Razão entre verdadeiros positivos e o total de exemplos previstos como positivos [Xiao et al. 2019]
<i>Recall</i>	Razão entre verdadeiros positivos e o total de exemplos realmente positivos [Xiao et al. 2019]

Fonte: Elaborado pelos autores (2026).

Por fim, o trabalho de Popov, Potapov e Zamaraev (2024) que aborda detecção de descontinuidades em taludes para monitoramento geotécnico, tem por objetivo monitorar a estabilidade de taludes das cavas de minas, para prevenir deformações ou deslizamentos. É apresentado uma solução para contornar a complexidade visual do

conjunto das imagens de talude, pois, marcas de equipamentos, estruturas, tubulações e sombras presentes se assemelham às trincas, causando ruído e dificultando o uso de modelos clássicos. Ao transformar as imagens em binárias, utilizar rede UNet treinada especificamente para a tarefa de segmentação de classe de *lineaments* e aplicar pós-processamento por grafos e *skeletonization* para eliminar ruídos residuais, o modelo consegue distinguir apenas as estruturas coerentes e também calcular comprimento de área correto.

Pode-se observar que os estudos incluídos na pesquisa não abordam principalmente a análise de condições das vias de minas. Os modelos estão na sua maioria focados nas tarefas abordadas previamente, com a análise de obstáculos localizadas em alguns dos estudos sendo direcionada para obstáculos como veículos, pessoas, objetos, dentre outros, e não buracos, depressões ou condições das vias, com objetivo de evitar colisões em alguns deles. Isso demonstra que as técnicas de aumento de dados estão sendo aplicadas de forma mais recorrente em trabalhos que abordam as temáticas apresentadas, sugerindo que para tarefas de monitoramento de vias de mineração, ou não é necessária aplicação de técnicas robustas de pré-processamento de dados com aumento de dados, ou que está sendo dada pouca atenção ao tema. Na Tabela 8 são apresentadas as principais características extraídas dos estudos.

4.2 Técnicas de aumento de dados e impacto no desempenho dos modelos de estado da arte

Os estudos apresentaram uma variação nas técnicas de aumento de dados utilizadas, entre as clássicas geométricas, variações fotométricas e simulação de condições climáticas, que utilizam dados sintéticos. Para melhor compreensão dos resultados, desenvolveu-se uma taxonomia que classifica as técnicas de aumento de dados em três categorias, geométricas (*cropping, flipping, rotation, scaling, shearing, translation*), fotométricas (*Gaussian blur, noise addition*) e sintéticas (*copy and paste, cutmix*), conforme apresentado na Figura 2. Tal estrutura hierárquica facilitou a análise comparativa entre os 8 estudos selecionados, revelando predominância das abordagens geométricas (60%). Além disso, a Tabela 9 contém as técnicas de aumento de dados localizadas nesta revisão, com base nas definições da literatura, observando-se que pode haver diferenças na grafia.




Figura 2. Taxonomia das técnicas de aumento de dados.

Fonte: Elaborado pelos autores (2026).

Tabela 8: Características dos estudos

Índice	Data Augmentation	Modelo de Visão	Lacuna Identificada (Gap)
A1	<i>Rotation, Flipping</i>	Improved Tiny-YOLOv3	Inferior a YOLOv3 para alvos pequenos
A2	<i>Translation, Gaussian blur, Cutmix, Copy and paste</i>	Faster R-CNN + VGG16	Depende de simulações de alta qualidade
A3	<i>Rotation, Translation, Scaling Ratio, Flipping, Shearing</i>	CNN com Aprendizado por reforço	Testado apenas em dados ou simulações
A4	<i>Cropping, Flipping, Noise addition, Gaussian blur</i>	FCN, Unet, PSPNet, DeepLab v3+ com ResNet-50 (backbone)	Sensível a sombras, veículos e variação de iluminação
A5	<i>Flipping, Rotation, Scalling, Cropping, Gaussian blur</i>	DASFNet com MobileNetV2 (backbone)	Desempenho ainda fraco em alvos muito pequenos e falta de testes embarcados em tempo real
A6	<i>"random cuts from real images", "filters", "rendering fog, snow, and other impairments"</i>	CMSNet com MobileNetV2 (backbone)	Robustez limitada em visibilidade extremamente degradada
A7	<i>Rotation, Flipping, Scaling</i>	D-DMCATNet	Dificuldade com interferências
A8	<i>Flipping, Rotation</i>	UNet	Poucos datasets reais de taludes

Fonte: Elaborado pelos autores (2026).

4.2.1 Técnicas geométricas

Todos os estudos apresentaram algum tipo de aumento de dados geométrico, os quais são caracterizados por transformações que alteram a geometria ou posição da imagem no espaço [Maharana et al. 2022].

Nos estudos de segmentação semântica de vias ou área de tráfego, as técnicas geométricas são usadas, principalmente, para melhoria na qualidade, robustez e capacidade de generalização atribuídas ao conjunto de dados. Em Yang et al. (2024), os autores relatam que os modelos atingiram mIoU 0.9169, mAcc 0.9519, F-score 0.956 e *Precision* 0.9603, atribuindo esses ganhos à combinação do conjunto de dados trabalhado (incluindo *augmentations*) e módulos ECA (*Efficient Channel Attention*) e CLAHE. As técnicas geométricas citadas, *random cropping* e *flipping*, são utilizadas para aprimoramento do conjunto de dados. Entretanto, inicialmente os autores relatam que é dada pouca atenção à etapa de criação dos conjuntos de dados, classificando o uso de técnicas clássicas de aumento de dados geralmente utilizadas como “simples”. Além disso, o impacto do uso de aumento de dados não é avaliado separadamente, apenas entra como parte da construção dos conjuntos de dados de alta qualidade citado, resumindo os ganhos vagamente como melhoria na qualidade e bom desempenho geral. No trabalho de Neto et al. (2022), na etapa de aquisição do *dataset*, é utilizado *random*

cuts from real images, que pode ser caracterizado como uma técnica geométrica denominada *cropping*. No estudo, essa técnica tem como objetivo aumentar a diversidade do conjunto de dados. Na etapa de treinamento, também é descrito uso das técnicas com o objetivo de evitar sobreajuste e aumentar o desempenho do treinamento. Da mesma forma, o estudo não avalia o uso das técnicas isoladamente ou quantitativamente. Em Sunwen, Yanwei e Guorui (2024), também é enfatizado a necessidade do uso das técnicas geométricas, *random rotation*, *flipping* e *scaling*, para aumento de robustez e generalização do modelo D-DMCATNet, alcançando acurácia de 92,92%, precisão 92,18%, *recall* 66,28% e F1-score 0,7712, além de atribuir ganhos na diversificação do conjunto de dados, melhorando a capacidade de reconhecimento de estradas.

Tabela 9: Técnicas de aumento de dados

Técnica	Descrição	Classificação
<i>Copy and paste</i>	Copiar um objeto ou região de uma imagem e colar em outra imagem ou posição [Guo et al. 2024]	Sintética
<i>Cropping</i>	Recorta uma parte da imagem (porção central ou região aleatória) [Gonzalez-Naharro et al. 2024]	Geométrica
<i>Cutmix</i>	Mistura duas imagens cobrindo parte de uma com um pedaço da outra imagem [Lewy e Mańdziuk 2023]	Sintética
<i>Flipping</i>	A imagem é invertida em torno de seu eixo vertical ou horizontal [Gonzalez-Naharro et al. 2024]	Geométrica
<i>Gaussian blur</i>	Aplicar um desfoque gaussiano, suavizando detalhes e ruídos da imagem [Shorten e Khoshgoftaar 2019]	Fotométrica
<i>Noise addition</i>	Adiciona ruído (por exemplo, gaussiano) aos pixels da imagem [Shorten e Khoshgoftaar 2019]	Fotométrica
<i>Rotation</i>	Gira a imagem em torno do seu eixo (esquerda ou direita) em um certo ângulo (ex., 20°) [Shorten e Khoshgoftaar 2019]	Geométrica
<i>Scaling</i>	Redimensiona a imagem (<i>zoom</i>) nos eixos x e y, preservando seu tamanho [Gonzalez-Naharro et al. 2024]	Geométrica
<i>Shearing</i>	Aplica cisalhamento, inclinando a imagem em um eixo (distorção em forma de trapézio) [Lei et al. 2019]	Geométrica
<i>Translation</i>	Deslocar a imagem ou objetos em relação aos eixos horizontal e/ou vertical, preenchendo a área restante [Shorten e Khoshgoftaar 2019]	Geométrica

Fonte: Elaborada pelos autores (2026).

No contexto de segmentação e detecção de áreas de cava em imagens de sensoriamento remoto, no trabalho Yuan et al. (2024), os autores deixam claro que as técnicas utilizadas, *random flipping*, *rotation*, *scalling* e *cropping*, são necessárias “para enriquecer o conjunto de dados, evitar o sobreajuste e melhorar a capacidade de generalização do modelo”. Entretanto, o foco dos ganhos com aumento de dados está ligado diretamente com uma técnica fotométrica, especificamente, *Gaussian blur*, que será abordado na próxima subseção.

Dentre os modelos de detecção de obstáculos ou caminhos em minas para navegação, Xiao et al. (2019) afirma que, devido ao número limitado de imagens da

classe de caminhões de mineração, o uso das técnicas, *rotation* e *flipping*, são aplicadas para expandir o tamanho do conjunto dessa classe em cinco vezes, com o objetivo de reduzir a aleatoriedade de acurácia na detecção, o qual ocorre quando o tamanho de amostras de determinada classe é muito reduzido. No estudo de Guo et al. (2024), a técnica geométrica de aumento de dados utilizada, *translation*, dentre outras utilizadas, tem por objetivo borrar as linhas de borda entre os domínios para mitigar a mudança de domínio entre “simulado” e “real”, nas tarefas de classificação e detecção, atuando nos dados de amostragem, espaço de características e de rótulos, reportando ganhos quantitativos dessas técnicas incorporadas intrinsecamente à estratégia. O trabalho de Ali e Frimpong (2021) enfatiza a necessidade de aumento de dados devido modelos de *deep learning* requerer grande conjunto de dados para treinamento. As técnicas utilizadas pelos autores, *image rotation*, *shifting (translation)*, *zooming (scaling)*, *horizontal flipping* e *shearing*, foram empregadas selecionando uma técnica aleatoriamente a cada iteração de treinamento, com objetivo de melhorar o conjunto de treinamento e a robustez do modelo, pois ampliou a capacidade de generalização, permitindo extrair conhecimento das imagens criadas, apresentando bons resultados com o modelo “*variant 6*” atingindo acurácia de validação de 0.8960 e F1-score de 0.8937. Da mesma forma, não avalia o ganho utilizando as técnicas isoladamente ou de forma quantitativa.

Por fim, para a tarefa de detecção de descontinuidades em taludes para monitoramento geotécnico, Popov, Potapov e Zamaraev (2024) citam vagamente o uso de aumento de dados na etapa de preparação dos dados, sem adicionar muitos detalhes quanto aos ganhos quantitativos ou desempenho, apenas citando seu uso com objetivo de aumento do tamanho do conjunto de treinamento, atingindo um total de mais de 2000 imagens, aplicando as técnicas *vertical*, *horizontal* e *symmetrical reflection (flipping)* e *random rotation*. Entretanto o trabalho descreve claramente as técnicas utilizadas e a ferramenta utilizada para esse fim, a biblioteca *Albumentations*⁶.

Pode-se observar que, apesar de todos os oito estudos apresentarem alguma técnica de aumento de dados geométrica em seu processo, nenhum dos estudos realizaram análise do impacto no desempenho dos modelos “com” e “sem” aumento de dados isoladamente, as técnicas sempre são integradas ao *pipeline* dos modelos. Entretanto, observa-se que os estudos enfatizam a necessidade do uso de aumento de dados, destacando-se o uso para evitar o sobreajuste, melhorar a robustez e capacidade de generalização, tanto na aplicação de técnicas geométricas quanto fotométricas e físicas, que serão abordadas na sequência.

4.2.2 Técnicas fotométricas

Dentre os achados, apenas três estudos apresentaram técnicas de aumento de dados classificadas como fotométricas, que são caracterizadas por geram novas imagens alterando intrinsecamente os valores dos pixels das imagens, suas cores, gerando alterações na aparência [Gonzalez-Naharro et al. 2024].

⁶ *Albumentations* constitui uma biblioteca Python de código aberto para aumento de dados em imagens, projetada para oferecer transformações rápidas e flexíveis que superam as limitações dos frameworks tradicionais (TensorFlow, Keras, PyTorch), suportando tarefas complexas como classificação, segmentação e detecção de objetos com alta eficiência e ampla variedade de operações (BUSLAEV et al., 2020).

As técnicas fotométricas apresentaram funções mais específicas em seu uso nos estudos avaliados, diferentemente das técnicas geométricas que visavam ganhos mais abrangentes como, aumento quantitativo do conjunto de dados, redução de sobrejeste ou melhoria na generalização. Nos estudos de segmentação semântica de vias ou área de tráfego, Em Yang et al. (2024), além das técnicas descritas anteriormente, o trabalho também faz uso de técnicas fotométricas, *noise adition* e *Gaussian blur*, na etapa de preparação do conjunto de dados, da mesma forma, apenas para aprimorar o conjunto de dados e melhorar sua capacidade da rede de extração de estradas. O modelo CLAHE proposto pelos autores tem por objetivo melhorar o contraste de borda das imagens, devido ao baixo contraste em imagens de mina, para que o modelo consiga melhor “enxergar” e segmentar, tornando as vias mais distinguíveis após o processamento. Entretanto os autores, esclarecem que esse é um pré-processamento do *dataset*, não caracterizando-se como algum tipo de técnica de aumento de dados. No trabalho de Neto et al. (2022), é descrito a aplicação de “*filters*”, utilizando a biblioteca *Imgaug*⁷, podendo inferir alterações nas características intrínsecas das imagens, porém sem atribuir uma função mais específica.

No contexto de segmentação e detecção de áreas de cava em imagens de sensoriamento remoto, Yuan et al. (2024) aplica técnica fotométrica *Random Gaussian Blurring* para melhorar o treinamento do novo modelo proposto DASNet, simulando desfoque de bordas nas imagens, devido à grande presença de neblina nessas áreas, o que dificulta a distinção de bordas pelo modelo. A técnica empregada aliada ao Módulo de Compensação de Características de Borda (*Edge Feature Compensation Module* – EFCM) desenvolvido pelos autores, demonstra melhoria na delimitação de bordas em imagens com neblina, reduz falsos positivos, comparado a outros métodos SOTA, e aumenta a robustez do modelo em condições normais com neblina.

Por fim, dentre os modelos de detecção de obstáculos ou caminhões em minas para navegação, Guo et al (2024) faz uso da técnica *Gaussian blur* para confundir as linhas divisórias entre os domínios “virtual” e “real”, isto é, deixar as imagens da fonte e do alvo mais parecidas entre si e assim reduzir o *gap* de domínio entre dados virtuais e reais. A técnica é aplicada durante o treinamento, na fase de *Domain Adaptation* no espaço de amostras, para gerar versões modificadas das imagens de treino, e, assim, aproximar a distribuição entre o domínio virtual (fonte) e o real (alvo).

4.2.3 Técnicas sintéticas

Para concluir a análise, examinou-se o uso de técnicas de geração de dados sintéticos, caracterizadas por ultrapassar transformações geométricas elementares e produzir imagens sintéticas adicionais a partir do conjunto de dados originais, com elevado grau de fidelidade às imagens reais. Tais abordagens foram identificadas nos três estudos detalhados a seguir [Jain et al. 2022].

Dentre os trabalhos sobre segmentação semântica de vias ou área de tráfego, apenas Neto et al. (2022) apresentou uso de aumento de dados de forma sintética utilizando *script* criado com ajuda da biblioteca *Imgaug*, especificamente para simular

⁷ **ImgAug** é uma biblioteca para aumento de imagens em experimentos de aprendizado de máquina, suportando diversas técnicas, combinações flexíveis, execução paralela em CPU e aumento de imagens, *keypoints*, *bounding boxes*, *heatmaps* e mapas de segmentação (JUNGE, 2020).

neblina, neve, poeira e outras condições adversas de clima, com o objetivo de avaliar o desempenho do modelo quando afetado por essas condições, permitindo estudar o efeito de visibilidade extrema. O estudo permitiu mostrar que chuva e a neblina causaram maior impacto no modelo avaliado, do que outras condições como noite e poeira, e que em condições de clima extremo a qualidade de segmentação do modelo foi degradada.

O estudo de segmentação e detecção de áreas de cava em imagens de sensoriamento remoto, Yuan et al. (2024), os autores utilizaram uma técnica sobre o conjunto de dados desenvolvido originalmente (CIGMR), para criar um conjunto de dados que espelha o conjunto de dados original, apenas com adição de condições de neblina, denominado CIGMR(fog), com objetivo de testar o desempenho do modelo proposto sob condições adversas, pois as áreas de mineração geralmente se encontram em regiões de florestas.

Por fim, em relação aos estudos de detecção de obstáculos ou caminhões em minas para navegação, Guo et al (2024), apresenta uso de dados virtuais, sendo os datasets sintéticos Virtual-Mine , Sim10K e Synthia, construídos a partir de simuladores, como o conjunto de dados Virtual-Mine criado a partir da plataforma PMWorld, utilizados no treinamento do detector, com objetivo de reduzir os custos operacionais, pois a aquisição de dados reais de mina é custoso e enfrenta condições adversas de clima. Os dados sintéticos por si só, não são totalmente confiáveis para treinamento devido a mudança de domínio entre virtual e real. Dessa forma, os autores criam um esquema em que decide quando algumas imagens reais serão anotadas por humanos, criando um detector de obstáculos confiável para caminhões autônomos em condições reais de mineração, utilizando poucos dados reais anotados, aproveitando ao máximo os dados virtuais, já anotados e disponíveis em maior abundância, reduzindo ao máximo o esforço de anotação com a estratégia apresentada.

4.3 Técnica de aumento de dados com melhor desempenho

Nenhum dos estudos realiza a avaliação do impacto do uso de aumento de dados separadamente aplicados aos modelos apresentados, as técnicas entram de forma intrínseca ao *pipeline*, tornando difícil avaliação individual de seus efeitos nos trabalhos. Da mesma forma, Devido a heterogeneidade das tarefas abordadas nos estudos e da métricas de desempenho utilizadas para avaliar, uma avaliação quantitativa não se torna possível realizar, limitando-se a permitir uma análise qualitativa dos achados, levando em consideração em qual dos estudos as técnicas de aumento de dados foram mais essenciais e causaram maiores impactos nos resultados.

Abordagens em que as técnicas são utilizadas para melhoria na robustez e generalização e prevenir sobreajuste, são extremamente relevantes e apresentam excelentes resultados, porém não trazem as técnicas para além desses fatores.

Embora uma análise quantitativa não seja permitida, a combinação que mostrou melhor resultado foi apresentada por Yang et al. (2024), no qual deixa explícito que para contornar o problema de extração de estradas não estruturadas de minas a céu aberto, a solução está na construção de um *dataset* específico para as estradas de minas, pois métodos de segmentação e extração de estrada desenvolvidos para ambientes urbanos ou rurais não funcionam bem nesse contexto. A construção do conjunto de dados emprega as técnicas clássicas de *data augmentation* *cropping*, *flipping*, *noise*

addition e *Gaussian blur*, as quais são utilizadas para aprimorar o *dataset* e para melhorar a capacidade da rede de extrair estradas. Apesar disso, o autor enfatiza que os resultados satisfatórios são atribuídos aos módulos ECA-CLAHE, do modelo UNet-ECA-CLAHE, e não às técnicas de aumento de dados, no qual atinge mIoU 0,9169 e F-score 0,956, os maiores resultados apresentados dentre os achados desta revisão.

Em resumo, não é possível definir quantitativamente o desempenho do emprego de aumento de dados separadamente nos modelos apresentados, entretanto as técnicas apresentadas em Yang et al. (2024) foram fundamentais para que o trabalho atingisse o melhor resultado entre os estudos.

4.4 Número mínimo de amostras para detector de objetos

Nos oito estudos avaliados não foi proposto ou estabelecido número mínimo de amostras de imagens, entretanto, apresentaram um padrão empírico de milhares de imagens utilizadas. Apenas o estudo de Sunwen, Yanwei e Guorui (2024) apresentou uma quantidade de imagens fora do padrão, com um total inicial de 36 imagens. Apesar do número reduzido do *dataset* os autores não apresentaram dificuldades com a quantidade de imagens, apenas sendo descrito que foram realizadas etapas de aumento de dados para melhorar a robustez e generalização do modelo. O estudo apresentou melhor desempenho em todas as métricas avaliadas em relação a todos os outros modelos utilizados na comparação.

Dentre os estudos que executam tarefas de detecção de obstáculos ou caminhões em minas para navegação, em Xiao et al. (2019), os autores realizam o aumento de dados para multiplicar por cinco o número de amostras apenas da classe “*mining truck*” com o objetivo de reduzir desbalanceamento entre classes. Entretanto não fica claro a quantidade de amostras de nenhuma classe do *dataset*.

Diferentemente, no estudo de Guo et al. (2024) é descrito que o conjunto de dados fonte virtuais de mina, Virtual-Mine, possui 5000 imagens e o conjunto Actual-Mine, dados alvo reais de mina, possui 3.975 imagens rotuladas. Em Ali e Frimpong (2021), é descrito que a construção do *dataset* foi realizada através de mecanismos de busca *online*, e que contem mais de 3000 imagens. Nos dois estudos, ainda é realizado aumento de dados nos *datasets*, demonstrando a necessidade de um *dataset* robusto.

Dessa forma, apesar de não haver número mínimo de amostras definido para treinar detectores de objetos em vias de mineração, o que os autores convergem em mostrar é que, na prática, trabalham com pelo menos alguns milhares de imagens, podendo ainda recorrer ao aumento de dados para compensar a escassez de dados reais, reduzir a aleatoriedade da detecção e o *gap* entre classes. Entretanto, o tamanho do *dataset* vai depender do desenvolvimento do modelo e da complexidade da tarefa. A Tabela 10 resume a quantidade de imagens aproximada de cada estudo.

Tabela 10: Quantidade de imagens por *dataset* para detector de objetos

Índice	Quantidade
A2	Virtual-Mine 5.000, Actual-Mine 3.975
A3	3000

Fonte: Elaborada pelos autores (2026).

4.5 Características de datasets para detector de objetos

A análise dos estudos demonstra que os conjunto de dados para tarefas de detecção de obstáculos ou caminhões em minas para navegação, exige mais do que um número mínimo de amostras, mas da combinação de volume de dados, diversidade e anotações de qualidade.

Conforme respondido na seção anterior, os estudos não apontam número mínimo de amostras para tais tarefas, porém demonstram número típico de quantidade da ordem de milhares de imagens rotuladas. Os conjuntos de dados de estrada que apresentarem desbalanceamento entre classes, com a estrada compondo a maior parte, devem ser balanceados por meio de aumento de dados das classes afetadas. Deve possuir a escolha correta de anotação para o tipo de tarefa, para detecção de objetos, *bounding boxes* e rótulos de classe. Nas etapas de pré-processamento a normalização do tamanho, exemplo 512x512, é obrigatória e geram maior eficiência, agilizando tempo de treinamento. Por fim, os conjuntos de dados devem pressupor aumento de dados, para aumentar a variação de ponto de vista e escala, melhorar robustez e simular condições de clima.

Em relação às características, deve possuir informação das estradas de cava, rampas, plataformas, curvas fechadas. Além disso, deve cobrir litologia abrangente como minérios, carvão, superfície de estéril, solo exposto, sob diferentes perspectivas como câmeras, satélite, VANT, dentre outros. Finalizando as características, deve abranger condições ambientais variadas como, iluminação, clima, visibilidade e desfoque, ruído ou sombras. A Tabela 11 apresenta resumo das características.

Tabela 11: Principais características do *dataset* ideal para a tarefa de detecção de objetos

Característica	Descrição
Tamanho	Milhares de imagens anotadas
Classes	Tratar o desbalanceamento
Anotação	Específica para a tarefa, <i>bounding boxes</i> e rótulos de classe
Normalização	Aplicar normalização no tamanho das imagens
Aumento de dados	Diversificar o <i>dataset</i> , aumentar robustez, melhorar generalização, evitar sobreajuste
Geometria	Estradas, estradas de cava, rampas, plataformas, curvas
Litologia	Carvão, minérios, superfície estéril, solo exposto
Perspectiva	Câmera embarcada, VANT, satélite
Condições ambientais	Dia, fim de tarde, noite, céu limpo, chuva, poeira, neblina, desfoque, ruído, sombras

Fonte: Elaborada pelos autores (2026).

5. Conclusões

A partir desta revisão, conclui-se que o uso de aumento de dados na construção de conjunto de dados e aplicação em modelos de visão computacional é essencial para atingir bons resultados nas principais métricas de avaliação, pois os modelos, principalmente de detecção de objetos baseados em CNNs, apresentam necessidade de grande volume de dados. Observou-se a predominância de técnicas geométricas clássicas (*rotation, flipping, cropping, scaling*) para aumento do *dataset*,

complementado por abordagens fotométricas (*noise addition*, *Gaussian blur*) e sintéticas (*cutmix*, *copy and paste*) para simular condições adversas de clima. Em conjunto, essas técnicas desempenharam ganhos como ampliação do *dataset*, desbalanceamento de classes, redução do sobreajuste e aumento da capacidade de generalização.

Os estudos também trouxeram ganhos específicos, das técnicas geométricas clássicas aliadas às técnicas fotométricas e sintéticas, como capacidade de generalização para diferentes litologias de ambiente de mineração, simulação de dados para condições ambientais adversas (clima, neblina, poeira, baixa visibilidade) para melhorar o desempenho de treinamento dos modelos nessas condições e aproximar domínios reais e virtuais utilizando combinação de dados sintéticos e reais, para diminuir a necessidade de rotulagem manual. Apesar de nenhum dos estudos isolarem os resultados do impacto das técnicas individualmente, os que apresentaram melhores resultados, dependeram menos de uma técnica específica e mais do desenho detalhado do *dataset*, devendo possuir uma quantidade de dados na grandeza de milhares de imagens e diferentes aspectos de geometria, litologia, perspectiva, condições ambientais, dentre outros.

Persistem lacunas importantes, como a ausência de estudos com análise quantitativa isolada das técnicas de aumento de dados nos modelos e pouca ênfase na análise de defeitos do pavimento das vias de mineração, o que reforça a necessidade de estudos empíricos futuros. Os estudos também reforçam que ainda há poucos conjuntos de dados reais e anotados de vias de mineração, o que o levam a recorrer a técnicas de aumento de dados e a conjunto de dados de domínio urbano.

6. Trabalhos futuros

Como trabalhos futuros, propõe-se: (1) realizar estudo empírico comparativo das técnicas de aumento de dados empregadas aos modelos de forma isolada para quantificar o impacto dessa estratégia no desempenho dos modelos, auxiliando a tomada de decisão na escolha da técnica; (2) aplicar as técnicas com melhor desempenho na identificação de buracos e defeitos das vias de mineração; (3) integrar essa abordagem a sistemas de navegação autônoma capazes de realizar simultaneamente a navegação do veículo e a análise das condições das vias (2 em 1); e (4) considera-se desenvolver uma interface gráfica (motor de jogos) que possibilite a visualização e interação dos resultados pelos usuários finais, em um cenário mais "recreativo", como em um ambiente tridimensional virtual (3D).

Referências

- ADLINGE, Sharad S.; GUPTA, A. K. Pavement deterioration and its causes. *International journal of innovative research and development*, v. 2, n. 4, p. 437-450, 2013.
- ALI, Danish; FRIMPONG, Samuel. DeepHaul: a deep learning and reinforcement learning-based smart automation framework for dump trucks. *Progress in Artificial Intelligence*, v. 10, n. 2, p. 157-180, 2021.
- AZHARI, Faris et al. Deep learning implementations in mining applications: a compact critical review. *Artificial Intelligence Review*, [s.l.], v. 56, p. 14367-14402, 2023. DOI: 10.1007/s10462-023-10500-9.

- BUSLAEV, Alexander et al. Albumentations: fast and flexible image augmentations. *Information*, v. 11, n. 2, p. 125, 2020.
- DIETTERICH, Tom. Overfitting and undercomputing in machine learning. *ACM computing surveys (CSUR)*, v. 27, n. 3, p. 326-327, 1995.
- FERREIRA, Fábio Mutti; DE PAIVA, Cassio Eduardo Lima. Uma Aplicação Comparativa de Métodos de Avaliação das Condições Superficiais de Estrada. 2004. Tese de Doutorado. Master's thesis, Faculty of Civil Engineering, Universidade Estadual de Campinas.
- GARCIA-GARCIA, Alberto et al. A survey on deep learning techniques for image and video semantic segmentation. *Applied Soft Computing*, v. 70, p. 41-65, 2018.
- GONZALEZ-NAHARRO, Luis et al. Evaluation of data augmentation techniques on subjective tasks. *Machine Vision and Applications*, v. 35, n. 4, p. 99, 2024.
- GUO, Lunfeng et al. Active Parallel Teacher for Human-in-the-Loop Sim2Real Object Detection in Autonomous Haulage Trucks. *IEEE Transactions on Intelligent Vehicles*, 2024.
- IEEE Thesaurus. Version 1.04. New York: Institute of Electrical and Electronics Engineers, 2025. 1 v. (JULY 2025 IEEE Thesaurus). Disponível em: <https://www.ieee.org/publications/services/thesaurus-thank-you>. Acesso em: 9 set. 2025.
- JAIN, Saksham et al. Synthetic data augmentation for surface defect detection and classification using deep learning. *Journal of Intelligent Manufacturing*, v. 33, n. 4, p. 1007-1020, 2022.
- JUNGE, Alexander. *imgaug: Image Augmentation for Machine Learning*. [S.l.], 2020. Disponível em: <https://imgaug.readthedocs.io/en/latest>. Acesso em: 11 mar. 2026.
- KITCHENHAM, Barbara et al. Procedures for performing systematic reviews. Keele, UK, Keele University, v. 33, n. 2004, p. 1-26, 2004.
- KULENO, Mengistu Mena; LERA, Eshetu Zekarias. CAUSE AND EFFECTS OF UNPAVED ROAD DETERIORATION-AREVIEW. *GSJ*, v. 8, n. 1, 2020.
- LEI, Cheng et al. A preliminary study on data augmentation of deep learning for image classification. In: *Proceedings of the 11th Asia-pacific symposium on internetware*. 2019. p. 1-6.
- LEWY, Dominik; MAŃDZIUK, Jacek. An overview of mixing augmentation methods and augmentation strategies. *Artificial Intelligence Review*, v. 56, n. 3, p. 2111-2169, 2023.
- MA, Nachuan et al. Computer vision for road imaging and pothole detection: a state-of-the-art review of systems and algorithms. *Transportation safety and Environment*, v. 4, n. 4, p. tdac026, 2022.
- MAGALHÃES, Eduardo Nunes; DA SILVA, Paulo Caetano. Consequências diretas da má conservação das estradas com vistas ao consumo de combustível, velocidade média e desgaste dos pneumáticos. *Revista Sustinere*, v. 6, n. 2, p. 337-358, 2018.

- MAHARANA, Kiran; MONDAL, Surajit; NEMADE, Bhushankumar. A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, v. 3, n. 1, p. 91-99, 2022.
- MEDINAC, Filip et al. Haul road monitoring in open pit mines using unmanned aerial vehicles: A case study at Bald Mountain Mine Site. *Mining, Metallurgy & Exploration*, v. 37, n. 6, p. 1877-1883, 2020.
- MIKOŁAJCZYK, Agnieszka; GROCHOWSKI, Michał. Data augmentation for improving deep learning in image classification problem. In: 2018 international interdisciplinary PhD workshop (IIPhDW). IEEE, 2018. p. 117-122.
- NETO, Nelson Alves Ferreira et al. Low-latency perception in off-road dynamical low visibility environments. *Expert Systems with Applications*, v. 201, p. 117010, 2022.
- OUZZANI, Mourad et al. Rayyan—a web and mobile app for systematic reviews. *Systematic reviews*, v. 5, n. 1, p. 210, 2016.
- PAGE, Matthew J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *bmj*, v. 372, 2021.
- PAKDEL, J.; EROL, I. Scrutinizing challenges to adopting digital technologies in the mining industry: a systematic review through PRISMA and bibliometric analysis. *Resources Policy*, v. 109, 105713, 2025.
- POPOV, S. E.; POTAPOV, V. P.; ZAMARAEV, R. Yu. Software Implementation of an Algorithm for Automatic Detection of Lineaments and Their Properties in Open-Pit Dumps. *Programming and Computer Software*, v. 50, n. 1, p. 31-41, 2024.
- RAWAT, Waseem; WANG, Zenghui. Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, v. 29, n. 9, p. 2352-2449, 2017.
- SAEED, Nausheen et al. A review of intelligent methods for unpaved roads condition assessment. In: 2020 15th IEEE conference on industrial electronics and applications (ICIEA). IEEE, 2020. p. 79-84.
- SANTOS, Claudio Filipi Gonçalves Dos; PAPA, João Paulo. Avoiding overfitting: A survey on regularization methods for convolutional neural networks. *ACM Computing Surveys (Csur)*, v. 54, n. 10s, p. 1-25, 2022.
- SHORTEN, Connor; KHOSHGOFTAAR, Taghi M. A survey on image data augmentation for deep learning. *Journal of big data*, v. 6, n. 1, p. 1-48, 2019.
- SUNWEN, Du; YANWEI, Chen; GUORUI, Feng. Road detection in open-pit mining areas using d-dmcatnet network based on uav images. *IEEE Geoscience and Remote Sensing Letters*, v. 22, p. 1-5, 2024.
- XIAO, Dong et al. A target detection model based on improved tiny-yolov3 under the environment of mining truck. *IEEE Access*, v. 7, p. 123757-123764, 2019.
- XU, Huan; MANNOR, Shie. Robustness and generalization. *Machine learning*, v. 86, n. 3, p. 391-423, 2012.
- YANG, H.; FENG, W.; DIAO, H.; XIA, S. Artificial intelligence transforming minerals engineering: key trends in literature and applications. *Minerals Engineering*, v. 234, 109741, 2025.

- YANG, Na et al. Applications of data augmentation in mineral prospectivity prediction based on convolutional neural networks. *Computers & geosciences*, v. 161, p. 105075, 2022.
- YANG, Yukun et al. Extracting unstructured roads for smart Open-Pit mines based on computer vision: Implications for intelligent mining. *Expert Systems with Applications*, v. 249, p. 123628, 2024.
- YUAN, Jianjun et al. Lightweight Object Detection Network With Spatial-Channel Attention and Stair Fusion Structure for Remote Sensing Open-Pit. *IEEE Transactions on Geoscience and Remote Sensing*, v. 62, p. 1-11, 2024.
- YUZDEPSKI, K.; MERKOSKY, R. Minimizing the Environmental and Economic Impact of Unpaved Road Maintenance. In: 2004 ANNUAL CONFERENCE AND EXHIBITION OF THE TRANSPORTATION ASSOCIATION OF CANADA-TRANSPORTATION INNOVATION-ACCELERATING THE PACE. 2004.