

ARTIGO ORIGINAL

# Análise da classificação de símbolos de arte rupestre usando a Inteligência Artificial a partir da plataforma Orange Canvas

## Classification analysis of rock art symbols using Artificial Intelligence from the Orange Canvas platform

Kawan Nascimento Santos <sup>1</sup> and Francisco Gerson Amorim de Meneses <sup>2</sup>

<sup>1</sup>Instituto Federal do Piauí – Campus Parnaíba – IFPI

\*capar.2022113tads0383@aluno.ifpi.edu.br; gerson@ifpi.edu.br

Recebido: 13/03/2025. Revisado: 30/03/2025. Aceito: 26/04/2026.

### Resumo

A classificação de símbolos de arte rupestre, a partir da semelhança entre suas variadas formas, é fundamental para a análise desses antiquíssimos símbolos, porém o processo de classificação manual é demorado, trabalhoso e suscetível a erros. Assim, este estudo investiga o uso da plataforma Orange Canvas e a sua viabilidade para automatizar essa tarefa, utilizando modelos de Aprendizado de Máquina. Dessa forma, foram analisadas 3.137 imagens de símbolos de arte rupestre, divididas em três categorias: antropomorfos, círculos e mãos. Antes do treinamento e classificação, as imagens passaram por um pré-processamento envolvendo redimensionamento, recorte e conversão para formatos compatíveis, além do processo de data augmentation. Para a extração de características, foram testados na plataforma Orange Canvas, modelos de redes neurais convolucionais, como: Inception V3, SqueezeNet, VGG-16 e VGG-19, e a classificação foi realizada por meio dos algoritmos: Neural Network, SVM e Logistic Regression. Os resultados indicaram que o modelo Inception V3 obteve o melhor desempenho, alcançando 97% de Acurácia, F1-Score, Precisão e Recall, com Neural Network. Com essas métricas, a abordagem demonstrou ser eficiente na classificação de símbolos de arte rupestre, contribuindo para a análise automatizada desses símbolos. Conclui-se que é promissor o uso da abordagem supracitada, na classificação de símbolos de arte rupestre.

**Palavras-Chave:** aprendizado de máquina; arte rupestre; classificação; inteligência artificial; orange canvas

### Abstract

The classification of rock art symbols, based on the similarity between their various forms, is fundamental for the analysis of these ancient symbols; however, the manual classification process is time-consuming, laborious, and prone to errors. Therefore, this study investigates the use of the Orange Canvas platform and its viability for automating this task using Machine Learning models. Thus, 3,137 images of rock art symbols were analyzed, divided into three categories: anthropomorphic figures, circles, and hands. Before training and classification, the images underwent pre-processing involving resizing, cropping, and conversion to compatible formats, in addition to data augmentation. For feature extraction, convolutional neural network models such as Inception V3, SqueezeNet, VGG-16, and VGG-19 were tested on the Orange Canvas platform, and classification was performed using the Neural Network, SVM, and Logistic Regression algorithms. The results indicated that the Inception V3 model achieved the best performance, reaching 97% Accuracy, F1-Score, Precision, and Recall with a Neural Network. With these metrics, the approach proved to be efficient in classifying rock art symbols, contributing to the automated analysis of these symbols. It is concluded that the aforementioned approach shows promise for classifying rock art symbols.

**Keywords:** machine learning; rock art; classification; artificial intelligence; orange canvas

## 1 Introdução

Um dos legados culturais mais importantes da humanidade é a arte rupestre, caracterizada por suas complexas e variadas representações. Ela marcou o início da comunicação visual dos seres humanos, refletindo práticas sociais e culturais ao longo de sua história (Viana et al., 2017). Alguns exemplos de arte rupestre são apresentados na Fig. 1

Nesse contexto, a Inteligência Artificial (IA) e seus avanços surgem como ferramentas promissoras, oferecendo novas perspectivas para a pesquisa de arte rupestre. Essas tecnologias podem acelerar a análise de grandes volumes de símbolos, simplificar processos anteriormente limitados ao trabalho manual de especialistas e, conseqüentemente, contribuir para o avanço das investigações na área. Historicamente, a classificação desses símbolos tem sido realizada manualmente, o que torna o processo lento e trabalhoso devido ao grande volume de dados a ser analisado. Além disso, os métodos baseados na observação manual, embora precisos, são demorados e exigem um esforço considerável para a conclusão das análises (Jalandoni et al., 2022; Suhaimi et al., 2023)

O uso de técnicas baseadas em IA, como Aprendizado de Máquina (ML) e classificação de padrões, apresenta uma abordagem inovadora para superar essas limitações. A plataforma Orange Canvas, com sua interface visual intuitiva e facilidade de uso, possibilita a implementação de modelos preditivos capazes de auxiliar na classificação e análise de símbolos, otimizando os esforços dos pesquisadores (Mohi, 2020).

Dessa forma, o presente trabalho tem como objetivo principal avaliar a eficiência de modelos baseados em IA, implementados na plataforma Orange Canvas, para a classificação de símbolos de arte rupestre, considerando diferentes abordagens e métricas de desempenho.

O conteúdo deste trabalho está organizado em cinco capítulos. O capítulo 1 apresenta a introdução ao tema, destacando sua relevância. No Capítulo 2, são discutidos os conceitos fundamentais relacionados à arte rupestre, IA e à plataforma Orange Canvas. O capítulo 3 aborda os trabalhos relacionados e os avanços no uso da IA para análise de símbolos. No Capítulo 4, são descritas a metodologia aplicada, os dados utilizados e as técnicas de modelagem. Finalmente, os resultados, discussões e conclusões são apresentados nos Capítulos 5 e 6, respectivamente.

## 2 Fundamentação Teórica

Nessa seção, serão apresentados todos os fundamentos teóricos que embasam e contribuem para a compreensão do tema em estudo. No tópico 2.1, aprofunda-se no conceito de arte rupestre. O tópico 2.2 aborda algumas aplicações da IA na arte rupestre. O tópico 2.3 traz informações sobre a plataforma Orange Canvas. Por fim, o tópico 2.4 apresenta alguns trabalhos desenvolvidos utilizando o Orange Canvas.

### 2.1 Arte Rupestre

No passado, o homem fez registros nos lugares em que usava como abrigo, esses registros são chamados gene-



Figura 1: Exemplos de símbolos de Arte rupestre

Fonte: Autor, 2026

ricamente de arte rupestre (Magalhães, 2023) e serviam não apenas como expressões estéticas, mas também como ferramentas práticas e simbólicas para os seres humanos no período paleolítico. A arte rupestre revela uma profunda interação entre o homem e seu ambiente natural, era produzida nas paredes das cavernas ou em outras superfícies rochosas para representar experiências, conhecimentos e cenas de caça, além de suas funções simbólicas. Essas representações tinham grandes significados como transmissão de conhecimento sobre as técnicas de caça e a identificação das espécies de animais (Guthrie, 2005).

Uma das primeiras impressões visuais da humanidade, a arte rupestre surgiu por volta de 45.500 anos AP (antes do presente), segundo Fernández Navarro et al. (2024), essas expressões fornecem percepções valiosas da cultura dos povos antigos, demonstrando os meios que eles utilizavam para sobreviver. Além disso, as marcas das suas mãos nas paredes das cavernas são testemunhas claras de que realmente existiram. Inicialmente, a arte rupestre não foi aceita como uma manifestação do paleolítico, sendo erroneamente atribuída a indivíduos simples da época mais recente. A sua aceitação como paleolítica foi aceita apenas nos anos 1900. A arte rupestre simboliza não só o cotidiano dos povos, como também mostrava as crenças espirituais e sociais, símbolos sexuais, ritos de iniciação, sonhos xamânicos, que possibilitam análise sobre o estilo de vida dos nossos ancestrais (Guthrie, 2005).

## 2.2 Algoritmos de Classificação

Para realizar a análise comparativa da classificação dos símbolos do Projeto [Artes do Bitorocaia](#), foram selecionados três algoritmos de aprendizado de máquina apoiados por uma técnica avançada de extração de características visuais. Essa variedade foi fundamental para observar, de forma prática, qual modelo se adapta melhor às variações morfológicas, muitas vezes sutis e complexas, presentes nas imagens analisadas.

Como etapa inicial, utilizou-se o *Image Embedding*, baseado em Redes Neurais Convolucionais (CNN). Esse método é responsável por extrair características profundas das imagens, convertendo os pixels em vetores numéricos de alta dimensão. Com isso, os dados se tornam mais organizados e adequados para o processamento e para a análise preditiva realizada pelos modelos ([Krizhevsky et al., 2017](#)).

A partir dessas representações, foi aplicado o Logistic Regression, um modelo linear que estima a probabilidade de uma amostra pertencer a uma determinada classe por meio de uma função sigmoide. Por ser um método eficiente, de fácil interpretação e bastante utilizado em tarefas de classificação, ele foi adotado como base de comparação (*baseline*) neste estudo ([Kleinbaum et al., 2002](#)).

De forma complementar, empregou-se o algoritmo Neural Network, que simula o processamento de informações do cérebro humano através de camadas de neurônios artificiais interconectados. Este modelo é particularmente eficaz na identificação de padrões não lineares complexos, ajustando seus pesos internos durante o treinamento para minimizar o erro de classificação, o que o torna ideal para a diversidade visual dos símbolos rupestres.

Por fim, foi utilizado o SVM, que busca identificar o hiperplano que melhor separa as classes em um espaço multidimensional. Esse algoritmo se destaca especialmente em cenários com alta dimensionalidade, apresentando bom desempenho na classificação de padrões visuais após a etapa de extração de características ([Suthaharan, 2016](#); [James et al., 2013](#)).

A integração desses métodos à plataforma Orange Canvas ([Nurtriana et al., 2024](#); [Mohi, 2020](#)) possibilitou uma análise cuidadosa e consistente do desempenho dos modelos, considerando os desafios texturais característicos dos registros de arte rupestre.

## 2.3 Classificação da Arte Rupestre

A classificação de símbolos de arte rupestre tem sido realizada há anos, de forma manual, por especialistas em arqueologia e antropologia, que identificam características visuais, como formas, padrões, tamanhos e estilos, comparando-as com catálogos de símbolos já existentes. O objetivo é classificar símbolos semelhantes, o que torna essa uma tarefa trabalhosa. No entanto, levando em consideração os avanços no uso de recursos computacionais na arqueologia, especialmente com algoritmos de IA e ML, foi possível ampliar o uso dessas técnicas para a classificação de imagens de símbolos rupestres ([Jalandoni et al., 2022](#)).

A aplicação da IA na arte rupestre ocorreu em alguns estudos, como o de [Horn et al. \(2022\)](#) que explorou o desenvolvimento de uma abordagem para a detecção automática de padrões, desenhos e símbolos em painéis de arte rupestre.

Em [Suhaimi et al. \(2023\)](#), foi realizada uma avaliação da eficácia de modelos de um estágio (apenas uma etapa principal) e dois estágios (duas etapas principais) para a detecção de objetos nas imagens de arte rupestre.

Além da IA ajudar os pesquisadores, também pode desempenhar um papel crucial na preservação digital da arte rupestre, possibilitando o arquivamento e a catalogação digital das imagens, facilitando o acesso a pesquisadores, arqueólogos e ao público em geral que precise acessar esses dados ([Horn et al., 2022](#)). Em [Jalandoni et al. \(2022\)](#), são apresentadas e discutidas várias técnicas de classificação de imagens. Nesse estudo os pesquisadores criaram um modelo para identificar e também categorizar os objetos que estão nas imagens de sítios de petróglifos (arte rupestre talhada na rocha) localizados na Suécia.

Esse modelo foi treinado utilizando a arquitetura Fast R-CNN (Rede Neural Convolucional), essa rede funciona em dois estágios (duas fases principais), juntamente com técnicas de aumento de dados e transferência de aprendizado a partir de imagens geradas por digitalização 3D.

## 2.4 Orange Canvas

Orange Canvas é uma plataforma de software com código aberto baseada na biblioteca Python Orange, amplamente utilizada em ML e mineração de dados. A plataforma oferece uma interface intuitiva que facilita a visualização (conforme a [Fig. 2](#)) e a construção de fluxos de trabalho para análise de dados. A biblioteca Orange Canvas inclui uma seleção abrangente de métodos populares em ML, além de técnicas de pré-processamento, como filtragem, imputação (processo de substituição de dados ausentes) e categorização. Também conta com técnicas de amostragem, incluindo bootstrap e validação cruzada, que permitem uma análise de dados mais eficiente e flexível ([Štajdohar e Demšar, 2013](#)).

Além de suas capacidades de análise e pré-processamento de dados, a plataforma Orange Canvas se destaca por seu método visual para a construção e manipulação de fluxos de trabalho. A interface gráfica do usuário é composta por widgets, que são componentes gráficos de uma interface que permitem interagir com o software de forma intuitiva. Esses widgets possibilitam a criação de esquemas altamente interativos, facilitando a integração e a visualização de dados.

Os widgets permitem que os usuários definam e ajustem os fluxos de trabalho de maneira intuitiva. Além disso, a plataforma Orange Canvas também possibilita a criação de esquemas por meio da programação visual ([Demšar et al., 2004](#)).

A plataforma Orange Canvas oferece várias opções de redes neurais profundas para a incorporação de imagens, permitindo a transformação dessas em vetores numéricos que podem ser utilizados em análises futuras. Entre as redes disponíveis, destacam-se Inception V3, SqueezeNet, VGG-16 e VGG-19, como mostrado na [Fig. 3](#).

O Inception V3, desenvolvido pelo Google e treinado no conjunto de dados ImageNet, utiliza as ativações da penúltima camada para representar as imagens. A SqueezeNet, por outro lado, é um modelo altamente eficiente, capaz de alcançar Precisão similar à da AlexNet com 50 vezes menos parâmetros, sendo ideal para avaliações rápidas

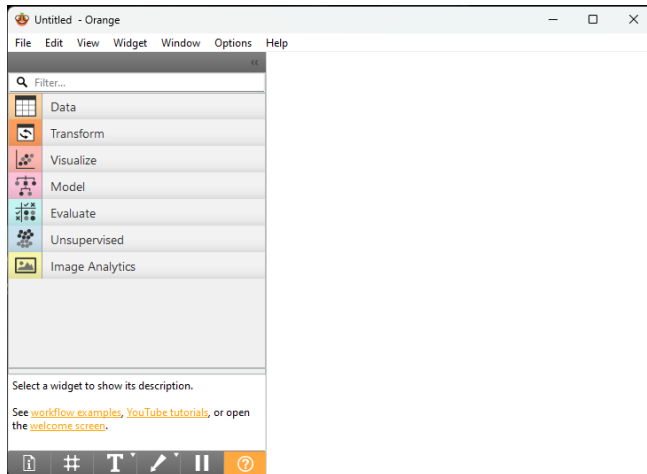


Figura 2: Tela inicial da plataforma Orange Canvas

Fonte: Autor, 2026

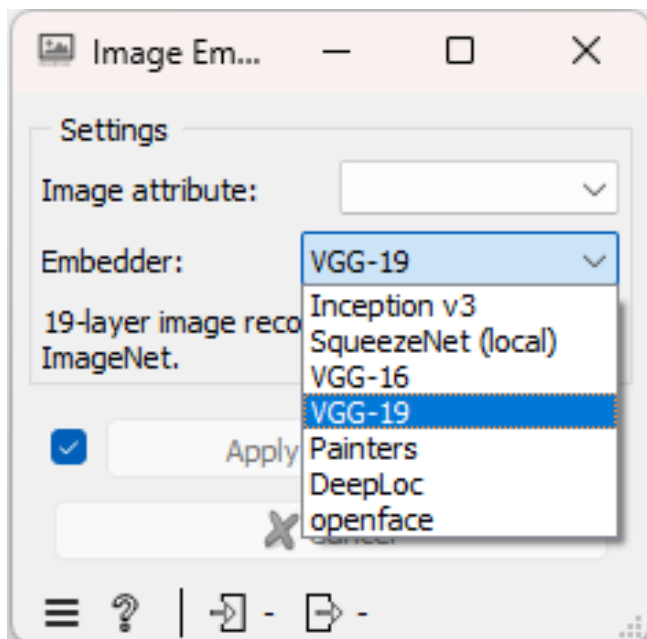


Figura 3: Modelos de Aprendizado de Máquina na plataforma Orange Canvas

Fonte: Autor, 2026

sem necessidade de conexão com a internet. Já as redes VGG-16 e VGG-19, propostas pelo Visual Geometry Group da Universidade de Oxford, também foram treinadas no ImageNet e utilizam as ativações da penúltima camada como incorporações (Orange Data Mining, n.d.).

## 2.5 Classificação de Imagens com Orange Canvas

Entre as plataformas para mineração de dados, o Orange Canvas destaca-se por ser uma solução de código aberto que combina acessibilidade com funcionalidades avançadas.

Com uma interface altamente interativa, permite que os usuários construam e analisem fluxos de trabalho sem a necessidade de programação. Dessa forma, torna-se amplamente utilizado em aplicações práticas, como classificação de dados médicos e visualização preditiva (Mohi, 2020).

## 3 Trabalhos Relacionados

Ao longo do tempo, a plataforma Orange Canvas se mostrou bastante útil em diversos estudos que utilizam IA para otimizar e facilitar diferentes processos e atividades. Nessa seção, serão mostrados alguns trabalhos que envolvem o uso da plataforma Orange Canvas e modelos de IA na arte rupestre.

### 3.1 Classificação de imagens com a plataforma Orange Canvas

Mohi (2020) utilizou os seguintes algoritmos de classificação: decision tree, Naive Bayes e K-Nearest, e fizeram a comparação do desempenho de cada um deles nas doenças câncer de mama e doenças cardíacas, utilizando a plataforma Orange Canvas. E ao final, conclui-se que o K-Nearest foi o que teve melhores resultados em ambos os conjuntos, com Acurácia de 93% em câncer de mama e 96% em doenças cardíacas.

Doungpaisan e Khunarsa (2025) fez um estudo que avaliava o desempenho de seis modelos pré-treinados - Inception V3, SqueezeNet, VGG-16, VGG-19, painter e DeepLoc, na classificação de imagens de fenômenos meteorológicos. Entre eles, no final do estudo, o que se destacou com os melhores resultados foi o Inception V3, chegando com maior Acurácia de 96,1%. Além dele, o Painter e SqueezeNet demonstraram resultados na Acurácia de 95,1% e 86,7%.

Indriany et al. (2024) utilizou a plataforma Orange Canvas para auxiliar em seu estudo, cujo objetivo era verificar quais modelos de Machine Learning, incluindo Artificial Neural Network, Random Forest, Gradient Boosting, Naive Bayes, modelos baseados em árvores e Logistic Regression, seriam mais precisos na previsão da gravidade da insuficiência cardíaca (IC) e as readmissões hospitalares (paciente volta ao hospital para mais tratamentos dentro de um curto período após ter alta) na Indonésia. Ao final dos experimentos, o autor demonstrou que a rede Neural Artificial apresentou os melhores resultados, com uma Acurácia de 99,8% para a previsão da gravidade da doença e com Acurácia de 97,7% para prever readmissões hospitalares.

Arabiati e Altayeb (2024) em seu estudo sobre a avaliação de duas ferramentas amplamente conhecidas na mineração de dados, o Orange Canvas e o WEKA, avaliou a eficiência de ambas na previsão de congestionamentos na capital do Reino Hachemita, Jordânia e Amã. Ao final do estudo, chegou à conclusão de que a ferramenta Orange Canvas superou o WEKA, pois a Precisão obtida com ela apresentou os melhores resultados, Random Forest e Logistic Regression têm uma nota mais alta de 100% em todas as métricas.

Nurtriana et al. (2024) selecionou os algoritmos de classificação SVM, Random Forest e Logistic Regression den-

tro da plataforma Orange Canvas, com o objetivo de analisar a eficiência deles na previsão da rotatividade de clientes de telecomunicações. Ao final dos testes realizados, chegou à conclusão de que o algoritmo Logistic Regression obteve a melhor taxa de Acurácia, com o valor de 79%, seguido pela SVM com 74% e pela Random Forest com 76%.

### 3.2 O Uso de IA na Arte Rupestre

Banerjee e Srivastava (2013) realizou um estudo com o objetivo de analisar mudanças no uso e cobertura da terra em uma região do centro da Índia, conhecida por abrigar um dos maiores acervos de sítios arqueológicos do mundo. O estudo empregou classificadores MLC (Máxima Verossimilhança) e SVM (Máquina de Vetores de Suporte) para analisar imagens de satélite Landsat de 1989, 2000 e 2011. Os resultados mostram que o SVM foi mais preciso na detecção de mudanças naturais e arqueológicas.

Ponmagal e Srinivasan (2015) propôs no seu artigo uma abordagem de ML para analisar e dar sentido às artes rupestres, utilizando a infraestrutura de nuvem. Com o uso do ML, os símbolos da arte rupestre podem ser juntados com os vinte e seis alfabetos ingleses. No trabalho, é feita a interpretação dos antigos símbolos de arte rupestre, fazendo a previsão do que eles desejam transmitir.

Deufemia et al. (2012) Apresentou no seu estudo um novo algoritmo, combinando um reconhecedor não supervisionado Self-organizing Maps (SOM) e outro que seria um analisador de linguagem visual furry. Esse novo algoritmo realiza o reconhecimento de arte rupestre em momentos onde há mais de um símbolo gravado no mesmo lugar. Durante a avaliação, o algoritmo obteve bons resultados.

Turner-Jones et al. (2024) selecionou um aplicativo de ciência desenvolvido especificamente para envolver jovens indígenas em exercícios educacionais e utilizou modelos, empregando transfer learning (aprendizado por transferência), para adaptar esses modelos a novas tarefas de ML. Os modelos foram treinados com as imagens fornecidas pelo aplicativo, com o objetivo de ajudar na classificação de novas imagens de arte rupestre, contribuindo para a conservação de sítios arqueológicos. O estudo usou aproximadamente 3.100 imagens de arte rupestre rotuladas e avaliou algumas arquiteturas pré-treinadas proeminentes, como VGG-19, ResNet50 e EfficientV2. Transfer learning permitiu alcançar uma Acurácia de 79,76% na classificação de arte rupestre.

## 4 Materiais e Métodos

Esta seção apresenta os procedimentos adotados para a realização do estudo. Primeiramente, descreve-se a modalidade de pesquisa utilizada, seguida dos procedimentos gerais empregados na classificação dos símbolos de arte rupestre. Além disso, são detalhadas as métricas de avaliação aplicadas para analisar o desempenho dos modelos testados. A seguir, cada um desses aspectos será abordado em detalhes.

### 4.1 Modalidade de Pesquisa

Este estudo caracteriza-se como exploratório e descritivo. Foi exploratório ao investigar o uso de algoritmos de IA para a classificação de símbolos de arte rupestre, uma área ainda em desenvolvimento. Foi descritivo ao detalhar os resultados obtidos pelos modelos testados, destacando o desempenho e a adequação de cada abordagem. A abordagem adotada foi quantitativa, pois analisou o desempenho dos modelos testados por meio de métricas específicas de classificação. A pesquisa também incluiu elementos bibliográficos e documentais, utilizando livros, artigos científicos e bases de dados.

### 4.2 Procedimentos Gerais

#### 4.2.1 Coleta e Seleção das Amostras

Foram utilizadas 3.137 imagens de símbolos rupestres, divididas em 3 grupos: antropomorfo com 1.044 imagens, mãos com 1.040 imagens e, por fim, círculos com 1.053 imagens. Amostras dos três modelos de símbolos testados com as suas respectivas quantidades podem ser vistas na Fig. 4. Essas imagens foram coletadas do banco de imagens de símbolos rupestres do projeto [Artes do Bitorocaia](#), que desde 2018, o projeto vem catalogando sítios arqueológicos no norte do Piauí, reunindo um banco de dados composto por fotografias coloridas que registram os símbolos em diferentes ângulos e estados de conservação. Para este estudo, foi realizada uma curadoria manual cuidadosa, priorizando imagens capturadas em ângulo frontal, por oferecerem melhor clareza e padronização para análise.

Em muitos painéis rochosos, a grande concentração de grafismos faz com que os símbolos apareçam muito próximos entre si. Por isso, foi necessário aplicar um processo rigoroso de recorte, com o objetivo de isolar cada símbolo individualmente. Essa etapa foi fundamental para definir corretamente a Região de Interesse (ROI), evitando que partes de símbolos vizinhos fossem incluídas na mesma imagem.

Ao garantir esse nível de Precisão na seleção das amostras, foi possível reduzir ruídos nos dados e melhorar a capacidade de generalização dos modelos de aprendizado de máquina, contribuindo diretamente para resultados mais confiáveis.

#### 4.2.2 Pré-Processamento de Imagem

As imagens passaram por um pré-processamento para garantir uniformidade e compatibilidade com os modelos de IA. O processo incluiu:

- Redimensionamento: Todas as imagens foram ajustadas para uma resolução de 1000 x 1000 pixels.
- Recorte: Foram eliminados elementos irrelevantes, destacando apenas as partes relacionadas à arte rupestre.
- Conversão: foram convertidas para formatos compatíveis com a plataforma Orange Canvas.

#### 4.2.3 Data Augmentation

Para melhorar a robustez do modelo e evitar o overfitting (que aprende tão bem os dados de treinamento e se sai mal quando é apresentado a novos dados que não estavam no treinamento), utilizou-se a técnica de Data Augmen-




| Símbolos      | Quantidade de amostras | Imagem de exemplo   |
|---------------|------------------------|---|
| Antropomorfos | 1.044                  |  |
| Círculos      | 1,053                  |  |
| Mãos          | 1,040                  |  |

Figura 4: Quantidades e Exemplos

Fonte: Autor, 2026

tation durante o pré-processamento das imagens. Essa técnica gerou novas imagens a partir das amostras originais, aplicando transformações como rotações, inversões, ampliações, ajustes de brilho e contraste, e translações. Essas modificações aumentaram a diversidade do conjunto de dados e permitiram que o modelo generalizasse melhor para novos dados (Wang et al., 2024).

#### 4.2.4 Algoritmos de Classificação

A escolha dos algoritmos de classificação no presente trabalho foi baseada em suas características e aplicações na literatura científica. As Máquinas de Vetores de Suporte (SVM) foram selecionadas por sua robustez na separação de classes e capacidade de uso com conjuntos menores de dados (Cortes e Vapnik, 1995). O Logistic Regression foi escolhido por ser um modelo amplamente utilizado para classificação binária e multiclasse (Hosmer et al., 2013). Já o Neural Network é um modelo computacional inspirados no funcionamento do cérebro humano e são eficazes para tarefas de reconhecimento de padrões complexos (LeCun et al., 2015). O uso desses três algoritmos permitiu uma comparação abrangente para a classificação dos símbolos de arte rupestre.

#### 4.2.5 Classificação de símbolos de arte rupestre na plataforma Orange Canvas

O processo de classificação foi realizado na plataforma Orange Canvas, seguindo as seguintes etapas:

- i. Importação das Imagens: As imagens foram carrega-

das no ambiente da plataforma usando o widget “Import Images”.

ii. Transformação em Representações Numéricas: Tanto as imagens que irão treinar os modelos quanto as imagens que serão classificadas por eles devem passar pela transformação. Utilizou-se o widget “Image Embedding” para converter as imagens em vetores numéricos, empregando algoritmos como Inception V3, SqueezeNet (local), VGG-16 e VGG-19. O mesmo modelo utilizado para o treinamento das imagens também deve ser usado na transformação das imagens que serão classificadas.

iii. Avaliação de Algoritmos: As representações numéricas foram avaliadas usando o widget “Test and Score”, que calculou métricas como Acurácia, F1-Score, Precisão e Recall. Os algoritmos testados incluíram Logistic Regression, SVM e Neural Network. A Fig. 5 apresenta um exemplo da estruturação dos widgets.

iv. Classificação Final: O melhor algoritmo foi conectado ao widget “Image Embedding” (das imagens usadas para o treinamento). Em seguida, o algoritmo e o “Image Embedding” (das imagens a serem classificadas) foram conectados ao widget “Predictions”, e os resultados foram visualizados no “Image Viewer”. A Fig. 6, apresenta um exemplo da estruturação dos widgets para a classificação.




Figura 5: Estrutura dos widgets para o treinamento

Fonte: Autor, 2026

### 4.3 Métricas de Avaliação

De acordo com Elgendy (2020), a avaliação do desempenho dos modelos foi realizada utilizando as seguintes métricas:

- Acurácia: serve para avaliar o modelo em geral, o quanto classificou corretamente em relação ao total.
- Precisão: Entre todas as predições que o modelo fez como sendo de uma determinada classe (positivas), quantas realmente pertencem a essa classe.
- Recall (Revocação): Entre todos os exemplos que realmente pertencem a uma determinada classe, quantos foram corretamente identificados pelo modelo.
- F1-Score: é a média harmônica entre a Precisão e o Recall, Ele fornece uma única métrica que equilibra tanto

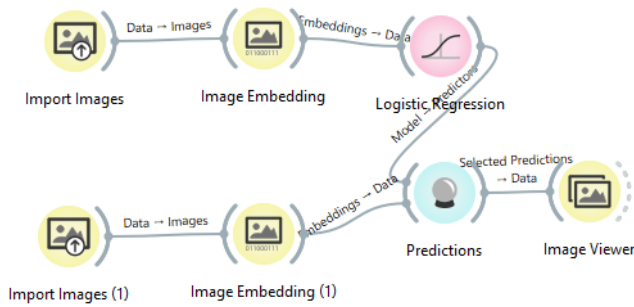


Figura 6: Estrutura dos widgets para a classificação das imagens

Fonte: Autor, 2026

a Precisão quanto o Recall.

## 5 Resultados

Neste estudo, foram utilizadas imagens do Banco de Imagens de Símbolos Rupestres do Projeto [Artes do Bitoroçaia](#) para o treinamento dos modelos de classificação de arte rupestre. As imagens passaram, inicialmente, por um processo de pré-processamento e data augmentation antes de serem aplicadas aos modelos. Os modelos testados na plataforma Orange Canvas foram as redes Inception V3, SqueezeNet (local), VGG-16 e VGG-19. Cada modelo foi avaliado utilizando três algoritmos de classificação distintos: Logistic Regression, SVM e Neural Network.

Ao final dos testes, os resultados foram gerados, sendo possível vê-los graficamente nas [Fig. 7](#), [Fig. 8](#), [Fig. 9](#) e [Fig. 10](#), com as métricas de desempenho: Acurácia, F1-Score, Precisão e Recall.

| Inception V3        |          |          |          |        |
|---------------------|----------|----------|----------|--------|
|                     | Acurácia | F1 score | Precisão | Recall |
| Logistic Regression | 96,6%    | 96,6%    | 96,6%    | 96,6%  |
| Neural Network      | 97%      | 97%      | 97%      | 97%    |
| SVM                 | 87,2%    | 87,2%    | 87,3%    | 87,2%  |

Figura 7: Resultados do modelo Inception V3

Fonte: Autor, 2026

Ao analisar as métricas de desempenho, observou-se que o modelo Inception V3 ([Fig. 7](#)) apresentou os melhores resultados entre os algoritmos testados. Para o algoritmo Neural Network, os valores alcançados foram:

- Acurácia: 97%
- F1-Score: 97%
- Precisão: 97%
- Recall: 97%

Nos demais algoritmos, os desempenhos foram os se-

| SqueezeNet (local)  |          |          |          |        |
|---------------------|----------|----------|----------|--------|
|                     | Acurácia | F1 score | Precisão | Recall |
| Logistic Regression | 91,4%    | 91,4%    | 91,4%    | 91,4%  |
| Neural Network      | 95,4%    | 95,4%    | 95,4%    | 95,4%  |
| SVM                 | 62,1%    | 61,6%    | 61,7%    | 62,1%  |

Figura 8: Resultados do modelo SqueezeNet

Fonte: Autor, 2026

| VGG 16              |          |          |          |        |
|---------------------|----------|----------|----------|--------|
|                     | Acurácia | F1 score | Precisão | Recall |
| Logistic Regression | 91,4%    | 91,4%    | 91,4%    | 91,4%  |
| Neural Network      | 95,2%    | 95,2%    | 95,2%    | 95,2%  |
| SVM                 | 62,9%    | 62,4%    | 62,3%    | 62,9%  |

Figura 9: Resultados do modelo VGG-16

Fonte: Autor, 2026

| VGG 19              |          |          |          |        |
|---------------------|----------|----------|----------|--------|
|                     | Acurácia | F1 score | Precisão | Recall |
| Logistic Regression | 94,5%    | 94,6%    | 94,6%    | 94,5%  |
| Neural Network      | 95,7%    | 95,7%    | 95,7%    | 95,7%  |
| SVM                 | 67,5%    | 67,6%    | 69,3%    | 67,5%  |

Figura 10: Resultados do modelo VGG-19

Fonte: Autor, 2026

guintes:

- SVM: Acurácia: 87,2%, F1-Score: 87,2%, Precisão: 87,3% e Recall: 87,2%
- Logistic Regression: Acurácia: 96,6%, F1-Score: 96,6%, Precisão: 96,6% e Recall: 96,6%

Os gráficos Fig. 8, Fig. 9 e Fig. 10 destacam as métricas obtidas pelos outros modelos testados: SqueezeNet, VGG-16 e VGG-19, respectivamente.

O modelo VGG-19 apresentou um desempenho um pouco inferior ao Inception v3, mas ainda bastante elevado. Para o algoritmo Neural Network os valores obtidos foram: 95,7% para Acurácia, F1-Score, Precisão e Recall. Para os demais algoritmos, os resultados foram: Logistic Regression com 94,5%, 94,6%, 94,6% e 94,5% e SVM com 67,5%, 67,6%, 69,3% e 67,5%.

O modelo VGG-16 apresentou métricas semelhantes ao VGG-19, com o Neural Network atingindo: 95,2%, 95,2%, 95,2% e 95,2%, para Acurácia, F1-Score, Precisão e Recall. Outros algoritmos apresentaram os seguintes resultados: Logistic Regression com 91,4%, 91,4%, 91,4% e 91,4% e SVM com 62,9%, 62,4%, 62,3% e 62,9%.

Por fim, o modelo SqueezeNet, com Neural Network obteve 95,4%, 95,4%, 95,4% e 95,4% para Acurácia, F1-Score, Precisão e Recall. Já para os demais algoritmos: Logistic Regression com 91,4%, 91,4%, 91,4% e 91,4% e por fim SVM com 62,1%, 61,6%, 61,7% e 62,1%.

O melhor desempenho geral foi alcançado pelo modelo Inception V3 utilizando o algoritmo Neural Network, que apresentou resultados superiores e consistentes para todas as métricas avaliadas. Comparativamente, este modelo demonstrou um desempenho mais eficiente em relação às demais combinações testadas.

Os resultados evidenciam que a combinação Inception V3 + Neural Network é a mais adequada para a classificação de imagens de arte rupestre, proporcionando métricas superiores e um melhor equilíbrio entre Precisão e Recall (Fig. 7).

## 5.1 Análise Detalhada do Melhor Modelo e Algoritmo

A combinação da arquitetura Inception v3 para a extração de características visuais com um classificador baseado em Neural Network apresentou o desempenho mais robusto entre os testes realizados na plataforma Orange Canvas. Para compreender a eficiência deste modelo na categorização dos símbolos do Projeto *Artes do Bitorocaia*, analisou-se a sua matriz de confusão, que permite identificar padrões de erro e a proximidade morfológica entre as classes (James et al., 2013).

### 5.1.1 Desempenho por Categoria

O modelo demonstrou uma alta capacidade de generalização, mantendo uma taxa de acerto consistente em todas as categorias. A Fig. 11 detalha o desempenho quantitativo observado na matriz.

### 5.1.2 Análise dos Erros de Classificação

Embora o desempenho global seja elevado, a matriz de confusão expõe padrões específicos de sobreposição visual

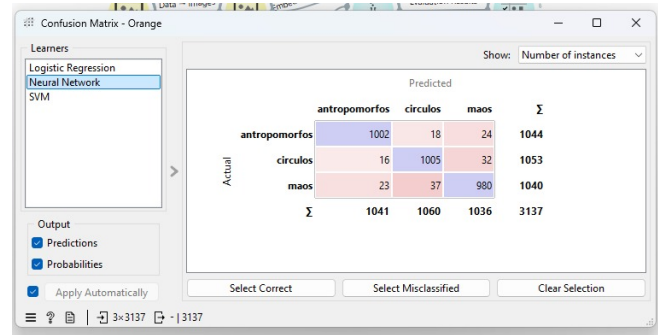


Figura 11: Detalhamento de acertos do modelo Inception v3 + Neural Network.

Fonte: Autor, 2026

entre as representações rupestres:

- **A Classe Mãos:** Foi a categoria que apresentou o maior desafio para o extrator Inception v3, com 60 instâncias mal classificadas. O erro mais frequente foi a classificação de 37 mãos como "círculos", o que sugere que a estilização das palmas ou a curvatura dos dedos nas pinturas pode gerar descritores visuais semelhantes às formas geométricas circulares.
- **A Classe Antropomorfos:** Obteve o maior índice de acerto absoluto (1002 de 1044). Os erros residuais dividiram-se entre "mãos" (24 casos) e "círculos" (18 casos), indicando que a silhueta antropomórfica é bem distinta das demais para este modelo.
- **Interseção Círculos-Mãos:** Observa-se uma ambiguidade bidirecional entre estas duas classes, visto que 32 instâncias de "círculos" foram confundidas com "mãos". Esta similaridade morfológica é comum em registros arqueológicos onde formas arredondadas podem compor diferentes tipos de símbolos.

### 5.1.3 Conclusão da Análise

Os dados extraídos da matriz de confusão validam a eficácia da utilização de modelos de *Deep Learning* para a catalogação dos registros do Projeto *Artes do Bitorocaia*. A concentração de acertos na diagonal principal e a natureza compreensível dos erros demonstram que a abordagem proposta é uma ferramenta confiável para auxiliar na preservação e no estudo sistemático deste patrimônio arqueológico.

## 6 Conclusão

O desenvolvimento de técnicas automatizadas para a classificação de símbolos de arte rupestre utilizando IA demonstrou ser uma ferramenta valiosa para a arqueologia. Essas técnicas não apenas aceleram o processo de catalogação, mas também facilitam a identificação de padrões morfológicos, tornando a pesquisa mais acessível e sistemática.

Neste estudo, a comparação entre diferentes modelos de *Machine Learning* na plataforma Orange Canvas revelou que a combinação da arquitetura Inception v3 com o algoritmo *Neural Network* obteve o desempenho mais robusto.

A análise detalhada por meio da matriz de confusão confirmou a alta Precisão do modelo, evidenciando que a maior parte dos erros de classificação se concentrou em ambiguidades morfológicas entre as classes "mão" e "círculo". Esse fenômeno reflete a própria natureza dos registros arqueológicos, onde a estilização dos grafismos pode apresentar sobreposições visuais desafiadoras até mesmo para especialistas humanos.

Espera-se que este estudo forneça um direcionamento claro para a escolha de recursos de IA em softwares voltados à preservação do patrimônio rupestre. Entretanto, a escassez de amostras de determinadas categorias foi identificada como uma limitação. Para trabalhos futuros, recomenda-se a exploração de técnicas de *data augmentation* e a ampliação do *dataset* para aumentar a robustez dos modelos.

## Referências

- Arabiati, A. e Altayeb, M. (2024). Assessing the effectiveness of data mining tools in classifying and predicting road traffic congestion, *Indonesian Journal of Electrical Engineering and Computer Science* 34(2): 1295–1303. <https://doi.org/10.11591/ijeecs.v34.i2.pp1295-1303>.
- Banerjee, R. e Srivastava, P. K. (2013). Reconstruction of contested landscape: Detecting land cover transformation hosting cultural heritage sites from central india using remote sensing, *Land use policy* 34: 193–203. <https://doi.org/10.1016/j.landusepol.2013.03.005>.
- Cortes, C. e Vapnik, V. (1995). Support-vector networks, *Machine Learning* 20(3): 273–297. <https://doi.org/10.1007/BF00994018>.
- Demšar, J., Zupan, B., Leban, G. e Curk, T. (2004). Orange: From experimental machine learning to interactive data mining, *Knowledge Discovery in Databases: PKDD 2004: 8th European Conference on Principles and Practice of Knowledge Discovery in Databases, Pisa, Italy, September 20–24, 2004. Proceedings 8*, Springer, pp. 537–539. [https://doi.org/10.1007/978-3-540-30116-5\\_58](https://doi.org/10.1007/978-3-540-30116-5_58).
- Deufemia, V., Paolino, L. e de Lumley, H. (2012). Petroglyph recognition using self-organizing maps and fuzzy visual language parsing, *2012 IEEE 24th International Conference on Tools with Artificial Intelligence*, Vol. 1, IEEE, pp. 852–859. <https://doi.org/10.1109/ICTAI.2012.119>.
- Doungpaisan, P. e Khunarsa, P. (2025). A comparative study of pre-trained models for image feature extraction in weather image classification using orange data mining, *Indonesian Journal of Electrical Engineering and Computer Science* 37(1): 241. <https://doi.org/10.11591/ijeecs.v37.i1.pp241-249>.
- Elgendy, M. (2020). *Deep learning for vision systems*, Simon and Schuster. Disponível em <https://books.google.com.br/books?hl=pt-BR&lr=&id=sDszEAAAQBAJ&oi=fnd&pg=PR13&dq=Deep+Learning+for++Vision+Systems&ots=8DyG0seYD9&sig=ZNmc4avnMNsT5ofLlcm7N8Wfkq8#v=onepage&q=Deep%20Learning%20for%20Vision%20Systems&f=false>.
- Fernández Navarro, V., Godinho, R. M., García Martínez, D. e Garate Maidagan, D. (2024). Exploring the utility of geometric morphometrics to analyse prehistoric hand stencils, *Scientific Reports* 14(1): 6336. <https://doi.org/10.1038/s41598-024-56889-3>.
- Guthrie, R. D. (2005). *The nature of Paleolithic art*, University of Chicago Press. Disponível em [https://books.google.com.br/books?hl=pt-BR&lr=&id=3u6JNwMyMCEC&oi=fnd&pg=PA10&dq=The+nature+of+Paleolithic+art&ots=JRpURk\\_e0o&sig=3cUZbfXjuHxPf8dYc8hAPIES1w8#v=onepage&q=The%20nature%20of%20Paleolithic%20art&f=false](https://books.google.com.br/books?hl=pt-BR&lr=&id=3u6JNwMyMCEC&oi=fnd&pg=PA10&dq=The+nature+of+Paleolithic+art&ots=JRpURk_e0o&sig=3cUZbfXjuHxPf8dYc8hAPIES1w8#v=onepage&q=The%20nature%20of%20Paleolithic%20art&f=false).
- Horn, C., Ivarsson, O., Lindhé, C., Potter, R., Green, A. e Ling, J. (2022). Artificial intelligence, 3d documentation, and rock art—approaching and reflecting on the automation of identification and classification of rock art images, *Journal of Archaeological Method and Theory* 29(1): 188–213. <https://doi.org/10.1007/s10816-021-09518-6>.
- Hosmer, D. W., Lemeshow, S. e Sturdivant, R. X. (2013). *Applied Logistic Regression*, John Wiley & Sons. Disponível em [https://books.google.com.br/books?hl=pt-BR&lr=&id=bRoxQBIZRd4C&oi=fnd&pg=PR13&dq=Hosmer,+D.+W.,+Lemeshow,+S.,+%26+Sturdivant,+R.+X.+%20\(2013\).+Applied+Logistic+Regression.+Wiley.&ots=kM3Tqo7Sh8&sig=rGAcBTFjLceLSh0dF3S\\_EgURvgA#v=onepage&q=Hosmer%2C%20D.%20W.%2C%20Lemeshow%2C%20S.%2C%20%26%20Sturdivant%2C%20R.%20X.%20\(2013\).%20Applied%20Logistic%20Regression.%20Wiley.&f=false5](https://books.google.com.br/books?hl=pt-BR&lr=&id=bRoxQBIZRd4C&oi=fnd&pg=PR13&dq=Hosmer,+D.+W.,+Lemeshow,+S.,+%26+Sturdivant,+R.+X.+%20(2013).+Applied+Logistic+Regression.+Wiley.&ots=kM3Tqo7Sh8&sig=rGAcBTFjLceLSh0dF3S_EgURvgA#v=onepage&q=Hosmer%2C%20D.%20W.%2C%20Lemeshow%2C%20S.%2C%20%26%20Sturdivant%2C%20R.%20X.%20(2013).%20Applied%20Logistic%20Regression.%20Wiley.&f=false5).
- Indriany, F. E., Siregar, K. N., Purwowiyoto, B. S., Siswanto, B. B., Sutedia, I. e Wijaya, H. R. (2024). Predicting the risk of severity and readmission in patients with heart failure in indonesia: A machine learning approach, *Healthcare Informatics Research* 30(3): 253–265. <https://doi.org/10.4258/hir.2024.30.3.253>.
- Jalandoni, A., Zhang, Y. e Zaidi, N. A. (2022). On the use of machine learning methods in rock art research with application to automatic painted rock art identification, *Journal of Archaeological Science* 144: 105629. Disponível em <https://doi.org/10.1016/j.jas.2022.105629>.
- James, G., Witten, D., Hastie, T. e Tibshirani, R. (2013). *An introduction to statistical learning: with applications in R*, Springer. <https://doi.org/10.1007/978-1-4614-7138-7>.
- Kleinbaum, D. G., Dietz, K., Gail, M., Klein, M. e Klein, M. (2002). Logistic regression, *Statistics for Biology and Health*. <https://doi.org/10.1007/978-1-4419-1742-3>.
- Krizhevsky, A., Sutskever, I. e Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks, *Communications of the ACM* 60(6): 84–90. <https://doi.org/10.1145/3065386>.
- LeCun, Y., Bengio, Y. e Hinton, G. (2015). Deep learning, *Nature* 521(7553): 436–444. <https://doi.org/10.1038/nature14539>.
- Magalhães, S. M. C. (2023). A arte rupestre do centro-norte do piauí: indícios de narrativas icônicas. Disponível em <http://app.uff.br/riuff/handle/1/28686>.

- Mohi, Z. R. (2020). Orange data mining as a tool to compare classification algorithms, *Dijlah Journal of Sciences and Engineering* 3(3): 13–23. Disponível em <https://www.iraqoaj.net/iasj/download/abfe3f657e55524a.pdf>.
- Nurtriana, A., Rachmawati, D. D., Artiyasa, M. e Sidiq, D. S. Z. (2024). Churn prediction analysis of telecom customers using svm, random forest and logistic regression models using orange data mining tools, *E3S Web of Conferences*, Vol. 501, EDP Sciences, p. 02012. <https://doi.org/10.1051/e3sconf/202450102012>.
- Orange Data Mining (n.d.). Image embedding, <https://orangedatamining.com/widget-catalog/image-analytics/imageembedding/>. Acesso em: 12 fev. 2025.
- Ponmagal, R. e Srinivasan, N. (2015). Machine learning approach for exploring rock arts through the cloud infrastructure, *2015 IEEE International Conference on Computational Intelligence and Computing Research (ICIC)*, IEEE, pp. 1–6. <https://doi.org/10.1109/ICIC.2015.7435682>.
- Štajdohar, M. e Demšar, J. (2013). Interactive network exploration with orange, *Journal of Statistical Software* 53: 1–24. <https://doi.org/10.18637/jss.v053.i06>.
- Suhaimi, M. S., Zainuddin, K., Ghazali, M. D., Marzukhi, F., Majid, Z., Ariff, M. F. M. et al. (2023). Comparison of one-stage and two-stage strategies of machine learning model for rock art object detection, *2023 IEEE 13th International Conference on System Engineering and Technology (ICSET)*, IEEE, pp. 215–220. <https://doi.org/10.1109/ICSET59111.2023.10295089>.
- Suthaharan, S. (2016). Support vector machine, *Machine learning models and algorithms for big data classification* pp. 207–235. <https://doi.org/10.1007/978-1-4899-7641-3>.
- Turner-Jones, R. N., Tuxworth, G., Hautb, R. A. e Wallis, L. (2024). Digitising the deep past: Machine learning for rock art motif classification in an educational citizen science application, *ACM Journal on Computing and Cultural Heritage* 17(4): 1–19. <https://doi.org/10.1145/3665796>.
- Viana, V., Bucu, C., SANTOS, T. d. e SOUSA, L. D. (2017). Arte rupestre, *Dicionário IPHAN de Patrimônio Cultural* 2. Disponível em [https://diwqtxtsixzle7.cloudfront.net/52010512/VERBETE\\_ARTE\\_RUPESTRE\\_-\\_pronto\\_pdf-libre.pdf?1488550036=&response-content-disposition=inline%3B+filename%3DARTE\\_RUPESTRE.pdf&Expires=1739309308&Signature=QiAlJgxv02L1mX9cGRQA0HaCF17qGDDcpvMjxzHIBgQXfdSDXiJv7cHojVIWo~-FTUX11D39EsXTHL1gr1tSs1gmG31WIuH1h00dUeV-Ni7NYsK3dkuMLGCBnGn2V k26kjU819Bg9DUr4rSnzApNv41xjPFvD3lqkaGpHdcCyU9f3eU42vapL8eAXD48g~YKeCSD51SqTVuFgS-FqY71ND08JIeWpcRd6CL~ih7HJgayh6fKFi5pjJJC0IPc~q1EntrD8ylALX9pXrfMY9K5kTQ7M1sJ-QKDoff00ho2A4nIiyMChTesTQmDBRv-QR5x9009j6MDqkATVxm7pWcMA\\_&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA](https://diwqtxtsixzle7.cloudfront.net/52010512/VERBETE_ARTE_RUPESTRE_-_pronto_pdf-libre.pdf?1488550036=&response-content-disposition=inline%3B+filename%3DARTE_RUPESTRE.pdf&Expires=1739309308&Signature=QiAlJgxv02L1mX9cGRQA0HaCF17qGDDcpvMjxzHIBgQXfdSDXiJv7cHojVIWo~-FTUX11D39EsXTHL1gr1tSs1gmG31WIuH1h00dUeV-Ni7NYsK3dkuMLGCBnGn2V k26kjU819Bg9DUr4rSnzApNv41xjPFvD3lqkaGpHdcCyU9f3eU42vapL8eAXD48g~YKeCSD51SqTVuFgS-FqY71ND08JIeWpcRd6CL~ih7HJgayh6fKFi5pjJJC0IPc~q1EntrD8ylALX9pXrfMY9K5kTQ7M1sJ-QKDoff00ho2A4nIiyMChTesTQmDBRv-QR5x9009j6MDqkATVxm7pWcMA_&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA).
- Wang, Z., Wang, P., Liu, K., Wang, P., Fu, Y., Lu, C.-T., Aggarwal, C. C., Pei, J. e Zhou, Y. (2024). A comprehensive survey on data augmentation, *arXiv preprint ar-*

Xiv:2405.09591 . <https://doi.org/10.48550/arXiv.2405.09591>.