



**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS PARNAÍBA
CURSO TECNOLOGIA ANÁLISE E DESENVOLVIMENTO DE SISTEMAS**

KAWAN NASCIMENTO SANTOS

**ANÁLISE DA CLASSIFICAÇÃO DE SÍMBOLOS DE ARTE RUPESTRE USANDO
A INTELIGÊNCIA ARTIFICIAL A PARTIR DA PLATAFORMA ORANGE CANVAS**

**Parnaíba
2025**

KAWAN NASCIMENTO SANTOS

ANÁLISE DA CLASSIFICAÇÃO DE SÍMBOLOS DE ARTE RUPESTRE USANDO A
INTELIGÊNCIA ARTIFICIAL A PARTIR DA PLATAFORMA ORANGE CANVAS

Trabalho de Conclusão de Curso (artigo científico) apresentado como exigência parcial para obtenção do diploma do Curso Superior de Tecnologia em Análise e Desenvolvimento de Sistema do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Parnaíba .

Orientador: Prof. Dr. Francisco Gerson Amorim de Meneses

Parnaíba

2025

Análise da classificação de símbolos de arte rupestre usando a Inteligência Artificial a partir da plataforma orange canvas

Kawan Nascimento Santos¹
Francisco Gerson Amorim de Meneses²

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, são elas: 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 shapes, is essential for the analysis of these ancient symbols. However, the manual classification process is time-consuming, laborious, and prone to errors. Thus, this study investigates the use of the Orange Canvas platform and its feasibility to automate this task, using Machine Learning models. Thus, 3,137 images of rock art symbols were analyzed, divided into three categories: anthropomorphs, circles, and hands. Before training and classification, the images underwent preprocessing involving resizing, cropping, and conversion to compatible formats, in addition to the data augmentation process. For feature extraction, convolutional neural network models, such as Inception V3, SqueezeNet, VGG-16, and VGG-19, were tested on

¹ Acadêmico do curso de Tecnologia em Análise e Desenvolvimento de Sistemas. Instituto Federal de Educação Ciência e Tecnologia do Piauí (IFPI) - Campus Parnaíba. E-mail: kawannascimento013@gmail.com

² Prof. Dr. Francisco Gerson Amorim de Meneses. Docente do Instituto Federal de Educação Ciência e Tecnologia do Piauí (IFPI) - Campus Parnaíba. E-mail: gerson@ifpi.edu.br

the Orange Canvas platform, and the classification was performed using the algorithms: Neural Network, SVM, and Logistic Regression. The results indicated that the Inception V3 model achieved the best performance, reaching 97% accuracy, F1 Score, Precision and Recall, with Neural Network. With these metrics, the approach demonstrated to be efficient in the classification of rock art symbols, contributing to the automated analysis of these symbols. It is concluded that the use of the aforementioned approach in the classification of rock art symbols is promising.

Keywords: Machine learning ; Rock art ; Classification ; Artificial intelligence ; Orange canvas.

Data de aprovação: 18/02/2025

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 Tab. 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.

Tabela 1 – Exemplos de símbolos de Arte rupestre

Antropomorfos	Círculos	Mãos
		
		
		

Fonte: Autor, 2025

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 genericamente 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 sobre as paredes das cavernas ou qualquer outra parede para representar experiência, conhecimento 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 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.

2.3 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 and 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 (Demšaret 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 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.).

Figura 1 – Tela inicial da plataforma Orange Canvas



Fonte: Autor, 2025

Figura 2 – Modelos de Aprendizagem de Máquina na plataforma Orange Canvas



Fonte: Autor, 2025

2.4 CLASSIFICAÇÃO DE IMAGENS COM ORANGE CANVAS

Entre as plataformas para mineração de dados, o Orange 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 and 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, Naïve 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 and 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 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 dentro da plataforma Orange, 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 and 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 and 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 faria 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 Tab. 2. Essas imagens foram coletadas do Banco de imagens de símbolos rupestres do Projeto [Artes do Bitorocara](#).

Tabela 2 – Quantidades e Exemplos

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

Fonte: Autor, 2025

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: 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 Augmentation durante o pré-processamento das imagens. Essa técnica gerou novas imagens a partir das amostras originais, aplicando transformações como rotação, 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 and 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, são modelos computacionais 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:

1. Importação das Imagens: As imagens foram carregadas no ambiente da plataforma usando o widget "Import Images".
2. 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.


3. 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. 4 apresenta um exemplo da estruturação dos widgets.
4. 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. 5, apresenta um exemplo da estruturação dos widgets para a classificação.

Figura 3 – Estrutura dos widgets para o treinamento



Fonte: Autor, 2025

Figura 4 – Estrutura dos widgets para a classificação das imagens



Fonte: Autor, 2025

4.2.6 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 a precisão quanto o recall.

5 RESULTADOS

Neste estudo, foram utilizadas imagens do Banco de Imagens de Símbolos Rupestres do Projeto [Artes do Bitorocaia](#) 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 nas Tabelas 3, 4, 5 e 6 com as métricas de desempenho: Acurácia, F1-Score, Precisão e Recall.

Tabela 3 – Resultados do modelo inception V3

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%

Fonte: Autor, 2025

Tabela 4 – Resultados do modelo SqueezeNet

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%

Fonte: Autor, 2025

Tabela 5 – Resultados do modelo VGG-16

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%

Fonte: Autor, 2025

Tabela 6 – Resultados do modelo VGG-19

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%

Fonte: Autor, 2025

Ao analisar as métricas de desempenho, observou-se que o modelo Inception V3 (Tab. 3) 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 seguintes:

- 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%

As tabelas 4, 5 e 6 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 (Tab. 3).

6 CONSIDERAÇÕES FINAIS

O desenvolvimento de técnicas automatizadas para a classificação de símbolos de arte rupestre utilizando IA pode ser uma ferramenta valiosa para

pesquisadores em arqueologia. Essas técnicas aceleram o processo de catalogação e facilitam a identificação de padrões e semelhanças entre imagens, tornando a pesquisa mais acessível e promovendo a disseminação do conhecimento na área.

Neste estudo, avaliamos e comparamos diferentes modelos de ML disponíveis na plataforma Orange Canvas para a classificação de imagens de arte rupestre. Os experimentos demonstraram que o modelo Inception V3, em combinação com o algoritmo Neural Network, obteve os melhores resultados, apresentando métricas de desempenho superiores às demais combinações testadas. Além disso, modelos como VGG-19, VGG-16 e SqueezeNet também demonstraram taxas de acurácia satisfatórias, reforçando a viabilidade do uso dessas redes neurais para essa aplicação.

Espera-se que este estudo contribua para futuras pesquisas na área de computação aplicada, fornecendo um direcionamento para a escolha dos recursos de IA mais adequados à implementação de um software para a classificação automatizada de símbolos rupestres.

Entretanto, uma das principais limitações do trabalho foi a escassez de amostras de imagens, o que restringiu a abrangência dos resultados. A disponibilidade limitada de imagens de determinados símbolos pode impactar a generalização do modelo. Para estudos futuros, recomenda-se a ampliação do conjunto de dados e a exploração de técnicas de aumento de dados (data augmentation) para melhorar a robustez dos modelos.

REFERÊNCIAS

ARABIAT, A.; ALTAYEB, M. **Assessing the effectiveness of data mining tools in classifying and predicting road traffic congestion.** Indonesian Journal of Electrical Engineering and Computer Science, v. 34, n. 2, p. 1295–1303, 2024. <<https://doi.org/10.11591/ijeecs.v34.i2.pp1295-1303>>.

BANERJEE, R.; SRIVASTAVA, P. K. **Reconstruction of contested landscape: Detecting land cover transformation hosting cultural heritage sites from central india using remote sensing.** Land use policy, Elsevier, v. 34, p. 193–203, 2013. <<https://doi.org/10.1016/j.landusepol.2013.03.005>>.

CORTES, C.; VAPNIK, V. **Support-vector networks.** Machine Learning, Springer, v. 20, n. 3, p. 273–297, 1995. <<https://doi.org/10.1007/BF00994018>>.

DEMŠAR, J. et al. **Orange: From experimental machine learning to interactive data mining.** In: SPRINGER. 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. [S.l.], 2004. p. 537–539. <https://doi.org/10.1007/978-3-540-30116-5_58>

DEUFEMIA, V.; PAOLINO, L.; LUMLEY, H. de. **Petroglyph recognition using self-organizing maps and fuzzy visual language parsing.** In: IEEE. 2012 IEEE 24th International Conference on Tools with Artificial Intelligence. [S.l.], 2012. v. 1, p. 852–859. <<https://doi.org/10.1109/ICTAI.2012.119>>.

DOUNGPAISAN, P.; KHUNARSA, P. **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, v. 37, n. 1, p. 241, 2025. <<https://doi.org/10.11591/ijeecs.v37.i1.pp241-249>>.

ELGENDY, M. **Deep learning for vision systems.** Simon and Schuster, 2020. Disponível em: <<https://books.google.com.br/books?hl=pt-BR&lr=&id=sDsZEAQAQBAJ&oi=fnd&pg=PR13&dq=Deep+Learning+for++Vision+Systems&ots=8DyGOseYD9&sig=ZNmc4avnMNsT5ofLlcm7N8Wfkq8#v=onepage&q=Deep%20Learning%20for%20%20Vision%20Systems&f=false>>

GUTHRIE, R. D. **The nature of Paleolithic art.** University of Chicago Press, 2005. 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_eOo&sig=3cUZbfXjuHxPf8dYc8hAPIES1w8#v=onepage&q=The%20nature%20of%20Paleolithic%20art&f=false>.

HORN, C. et al. **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, Springer, v. 29, n. 1, p. 188–213, 2022. <<https://doi.org/10.1007/s10816-021-09518-6>>.

HOSMER, D. W.; LEMESHOW, S.; STURDIVANT, R. X. **Applied Logistic Regression.** John Wiley & Sons, 2013. 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.+\(2013\).+Applied+Logistic+Regression.+Wiley.&ots=kM3Tqo7Sh8&sig=rGAcBTFjLceLShOdF3S_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.+(2013).+Applied+Logistic+Regression.+Wiley.&ots=kM3Tqo7Sh8&sig=rGAcBTFjLceLShOdF3S_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. et al. **Predicting the risk of severity and readmission in patients with heart failure in indonesia: A machine learning approach.** Healthcare

Informatics Research, Korean Society of Medical Informatics, v. 30, n. 3, p. 253–265, 2024. <<https://doi.org/10.4258/hir.2024.30.3.253>>.

JALANDONI, A.; ZHANG, Y.; ZAIDI, N. A. **On the use of machine learning methods in rock art research with application to automatic painted rock art identification.** Journal of Archaeological Science, v. 144, p. 105629, 2022. ISSN 0305-4403. Disponível em <<https://doi.org/10.1016/j.jas.2022.105629>>.

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep learning.** Nature, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. <<https://doi.org/10.1038/nature14539>>.

MAGALHÃES, S. M. C. **A arte rupestre do centro-norte do piauí: indícios de narrativas icônicas.** 2023. Disponível em <<http://app.uff.br/riuff/handle/1/28686>>

MOHI, Z. R. **Orange data mining as a tool to compare classification algorithms.** Dijlah Journal of Sciences and Engineering, v. 3, n. 3, p. 13–23, 2020. Disponível em <<https://www.iraqoj.net/iasj/download/abfe3f657e55524a.pdf>>.

NAVARRO, V. F. et al. **Exploring the utility of geometric morphometrics to analyse prehistoric hand stencils.** Scientific Reports, Nature Publishing Group UK London, v. 14, n. 1, p. 6336, 2024. <<https://doi.org/10.1038/s41598-024-56889-3>>.

NURTRIANA, A. et al. **Churn prediction analysis of telecom customers using svm, random forest and logistic regression models using orange data mining tools.** In: EDP SCIENCES. E3S Web of Conferences. [S.l.], 2024. v. 501, p. 02012. <<https://doi.org/10.1051/e3sconf/202450102012>>.

Orange Data Mining. **Image Embedding.** Disponível em: <<https://orangedatamining.com/widget-catalog/image-analytics/imageembedding/>>.

PONMAGAL, R.; SRINIVASAN, N. **Machine learning approach for exploring rock arts through the cloud infrastructure.** In: IEEE. 2015 IEEE International Conference on Computational Intelligence and Computing Research (ICCIIC). [S.l.], 2015. p. 1–6. <<https://doi.org/10.1109/ICCIIC.2015.7435682>>.

ŠTAJDOHAR, M.; DEMŠAR, J. **Interactive network exploration with orange.** Journal of Statistical Software, v. 53, p. 1–24, 2013. <<https://doi.org/10.18637/jss.v053.i06>>.

SUHAIMI, M. S. et al. **Comparison of one-stage and two-stage strategies of machine learning model for rock art object detection.** In: IEEE. 2023 IEEE 13th International Conference on System Engineering and Technology (ICSET). [S.l.], 2023. p. 215–220. <<https://doi.org/10.1109/ICSET59111.2023.10295089>>.

TURNER-JONES, R. N. et al. **Digitising the deep past: Machine learning for rock art motif classification in an educational citizen science application.** ACM Journal on Computing and Cultural Heritage, ACM New York, NY, v. 17, n. 4, p. 1–19, 2024. <<https://doi.org/10.1145/3665796>>.

VIANA, V. et al. **Arte rupestre.** Dicionário IPHAN de Patrimônio Cultural, v. 2, 2017.

Disponível em: <https://d1wqtxts1xzle7.cloudfront.net/52010512/VERBETE_ARTE_RUPESTRE_-_pronto_pdf-libre.pdf?1488550036=&response-content-disposition=inline%3B+filename%3DARTE_RUPESTRE.pdf&Expires=1739309308&Signature=QiAIJgxvO2L1mX9cGRQA0HaCFI7qGDDcpvMjxzHIBgQXfdSDXiJv7cHojVIWo~-FTUXIID39EsXTH_&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA>.

WANG, Z. et al. **A comprehensive survey on data augmentation.** arXiv preprint arXiv:2405.09591, 2024. <<https://doi.org/10.48550/arXiv.2405.09591>>.