

# Identificação Automática de Vegetais Fósseis Utilizando Visão Computacional

Davi Rodolfo Rodrigues da Silva<sup>1</sup>, Mislayne Oliveira de Araújo<sup>1</sup>,  
Maria Vitória Moura Santos<sup>2</sup>, Melissa Oliveira Alves<sup>1</sup>, Paulo Victor de Oliveira<sup>2</sup>,  
Romuere Rodrigues Veloso e Silva<sup>1</sup>

<sup>1</sup>Laboratório de Pesquisas Aplicadas a Visão e Inteligência Computacional (PAVIC), Universidade Federal do Piauí (UFPI), Picos, Piauí,

<sup>2</sup>Laboratório de Paleontologia de Picos (LPP), Universidade Federal do Piauí (UFPI), Picos, Piauí

{davi.rodolfo, mislayne.araujo, melissaalves}@ufpi.edu.br

{victoroliveira, romuere}@ufpi.edu.br

mavimoura@alu.ufc.br

**Abstract.** *The Devonian period marked the emergence of the first complex terrestrial plants. In the Parnaíba Basin, fossils from this period reveal important aspects of the evolution of flora and climate. However, manual identification of these specimens is slow and prone to errors due to fragmentation and morphological similarities, which compromise the accuracy and reproducibility of traditional analyses. This study proposes the use of neural networks to automate the identification of fossil plant specimens previously assigned to the genus Haplostigma. A total of 140 manually segmented images were used, along with data augmentation and different pre-trained CNN architectures. ResNet50V2 achieved the best results, with 90% accuracy and F1-Score, 86.3% precision, and 95% recall.*

**Resumo.** *O Devoniano marcou o surgimento das primeiras plantas terrestres complexas. Na Bacia do Parnaíba, fósseis desse período revelam aspectos da evolução da flora e do clima. No entanto, a identificação manual desses espécimes é lenta e sujeita a erros, devido a fragmentação e a similaridades morfológicas, o que compromete a precisão e a reprodutibilidade das análises tradicionais. Este estudo propõe o uso de redes neurais para automatizar a identificação de exemplares fósseis vegetais previamente atribuídos ao gênero Haplostigma. Foram utilizadas 140 imagens segmentadas manualmente, com aumento de dados e diferentes arquiteturas de CNNs pré-treinadas. A ResNet50V2 obteve os melhores resultados, com 90% de acurácia e F1-Score, 86,3% de precisão e 95% de recall.*

## 1. Introdução

O período geológico Devoniano, frequentemente denominado como “A Era dos Peixes” devido à explosão de diversidade nos ambientes aquáticos, também foi um período fundamental para a evolução das plantas terrestres. Durante esse período, as plantas desenvolveram sistemas vasculares mais complexos, o que permitiu sua colonização em

novos habitats terrestres, afastando-se dos corpos d'água e conquistando novos ambientes [Kenrick and Crane 1997]. O desenvolvimento desses sistemas foi importante, pois possibilitou às plantas do Devoniano a conquista de ecossistemas mais secos e variados, dando início à formação das florestas terrestres [Willis and McElwain 2002].

A Bacia do Parnaíba, abrangendo partes dos estados do Ceará, Bahia, Maranhão, Pará, Piauí e Tocantins, é de grande importância para os estudos paleobotânicos, especialmente devido à preservação de fósseis vegetais do Devoniano. Esses fósseis oferecem uma visão única da flora que existiu durante esse período geológico, além de fornecerem pistas sobre as primeiras adaptações das plantas às condições terrestres [Matsumura and Iannuzzi 2015]. Os depósitos geológicos da região, predominantemente compostos por arenitos e siltitos, favorecem a preservação desses fósseis, permitindo que os cientistas reconstruam ecossistemas antigos e compreendam a dinâmica das primeiras florações terrestres [Gracioso 2011].

Dentro deste contexto, o gênero *Haplostigma* tem se destacado como uma das mais recorrentes nos depósitos fósseis do Piauí, tornando-se o foco principal deste estudo. *Haplostigma* é um dos gêneros vegetais mais prevalentes nos fósseis do Devoniano, e sua identificação precisa tem grande relevância para a compreensão da evolução das plantas e dos ecossistemas do período [Matsumura et al. 2024]. No entanto, a análise manual enfrenta dificuldades devido às semelhanças morfológicas com outros gêneros, tornando o processo demorado e sujeito a erros. A identificação de fósseis exige uma comparação detalhada das características morfológicas e anatômicas, um processo altamente subjetivo, especialmente quando se trata de fósseis fragmentados [Cleal and Thomas 2009].

Além disso, o processo manual de identificação é limitado pela fragmentação e pelos danos nos fósseis, o que gera a necessidade de métodos mais rápidos e precisos. Nesse sentido, o uso de técnicas de Visão Computacional e Aprendizado de Máquina surge como uma solução promissora. Essas tecnologias podem automatizar o processo de classificação, permitindo a identificação mais eficiente de fósseis, mesmo diante das dificuldades de preservação [Liu and Song 2020]. A aplicação de Redes Neurais Convolucionais (CNNs), uma abordagem eficaz em tarefas de classificação de imagens e aplicável ao contexto de fósseis vegetais, pode identificar padrões complexos nas imagens, superando as limitações dos métodos tradicionais [Yu et al. 2024]. A utilização de Inteligência Artificial (IA) também contribui para a redução do custo computacional, tornando a análise mais acessível e escalável, sem a necessidade de grandes investimentos em infraestrutura.

Dessa forma, este trabalho propõe o uso de Redes Neurais Convolucionais para automatizar a identificação de fósseis do gênero *Haplostigma*, substituindo um processo manual que é, muitas vezes, lento, subjetivo e suscetível a erros. Ao incorporar técnicas de Visão Computacional, busca-se não apenas acelerar a etapa de análise, mas também garantir maior precisão e reprodutibilidade nas classificações. Essa abordagem representa um avanço significativo para a paleobotânica, ao fornecer uma ferramenta capaz de lidar com a complexidade morfológica dos fósseis e apoiar a produção de dados mais consistentes, objetivos e escaláveis para os estudos sobre a evolução das plantas.

O restante deste trabalho está estruturado da seguinte forma: a Seção 2 apresenta os estudos relacionados na literatura; a Seção 3 descreve a metodologia adotada para

a realização do estudo; a Seção 4 apresenta os resultados obtidos com a aplicação da metodologia proposta; e, por fim, a Seção 5 traz as conclusões e considerações finais sobre os achados e sugestões para futuras pesquisas.

## 2. Trabalhos Relacionados

Nesta seção, são apresentados e discutidos os principais estudos relacionados à aplicação de Visão Computacional para análise e classificação de fósseis. Os trabalhos foram analisados considerando quatro critérios principais: (1) as técnicas de Visão Computacional empregadas; (2) os objetivos específicos de cada estudo em relação à análise dos fósseis; (3) os tipos de fósseis analisados e (4) os períodos geológicos de origem. A análise detalhada inclui a descrição dos fósseis e dos períodos geológicos abordados, bem como das metodologias aplicadas, dos resultados alcançados e das limitações identificadas. Dessa forma, é possível traçar um panorama do estado atual da pesquisa, destacando as contribuições mais relevantes e as lacunas que oferecem oportunidades para avanços metodológicos, conforme apresentado na Tabela 1. Foram identificados trabalhos em dois grupos os que utilizam dados do período Cambriano, e dos demais períodos. A seguir esses trabalhos são detalhados.

**Table 1. Trabalhos Relacionados**

Trabalho	Técnicas	Objetivo do Estudo	Tipo de Fóssil	Período
[Zhang et al. 2024]	K-vizinhos mais próximos (KNN), Naive Bayes (NB), Árvores de Regressão e Classificação (CART), Máquinas de Vetores de Suporte (SVM), Regressão Logística (LR)	Identificação e Classificação automatizada de fósseis vegetais	Fóssil Vegetal Czekanowskiales	Mesozoico
[Wang et al. 2022]	Rede Neural Convolucional Transposta	Identificação automatizada de fósseis de braquiópodes	Fósseis de Braquiópodes	Cambriano
[Karaderi et al. 2022]	ResNet-50	Classificar foraminíferos planctônicos	Microfósseis	Holoceno
[Wang et al. 2023]	ResNet-34 + TS-ResNet	Identificação de espécies de microfósseis	Microfósseis	Cambriano
[Mimura et al. 2022]	Mask R-CNN + EfficientNet-V2	Segmentação e classificação automatizada de microdentos fósseis	Microdentos de peixes fósseis	Cenozoico
Este Trabalho	MobilenetV2, Resnet50, Resnet50V2, InceptionV3	Classificação e identificação automatizada de fósseis vegetais	Fósseis vegetais	Devoniano

Dentre os estudos que analisam fósseis do período Cambriano, [Wang et al. 2022] propõe o uso de Redes Neurais Convolucionais Transpostas (TCNN) [Dumoulin and Visin 2016] para a identificação de fósseis de braquiópodes, atingindo 98% de acurácia com apenas 400 imagens de treinamento, superando os 67% obtidos por modelos tradicionais. A TCNN mostrou-se eficiente em taxonomia de fósseis, mesmo com dados limitados. Já o estudo de [Wang et al. 2023] utiliza aprendizado por transferência com ResNet-34 [He et al. 2016a] para classificar microfósseis raros do Cambriano Inferior. Com modelos pré-treinados no ImageNet, alcançou 97% de precisão média com 50 imagens por táxon e 85% com apenas três imagens. A abordagem TS-ResNet [Duan and Gu 2023] demonstrou desempenho superior a métodos como SVM e TCNN, sendo eficaz em fósseis com alta variação morfológica.

Em relação aos demais períodos geológicos, foram encontrados estudos que analisam fósseis do Mesozoico, Jurássico, Holoceno, Cenozoico e Devoniano. O estudo de [Zhang et al. 2024] aplica Aprendizado de Máquina para classificar fósseis do gênero *Czekanowskiales*, destacando o CART, que alcançou 96,2% de acurácia em traços mistos, e mostrando que traços macro são mais relevantes para gêneros e cuticulares para espécies. Em [Karaderi et al. 2022], aprendizado métrico profundo com ResNet-50 atingiu 92% de acurácia na classificação de conchas de foraminíferos e 66,5% em cenários de *zero-shot*, mapeando o espaço morfológico das espécies. Já [Mimura et al. 2022] combina Mask R-CNN e EfficientNet-V2 para identificar microdentes fósseis do período Devoniano, alcançando 83,5% de F1-score e medições automáticas com mais de 90% de precisão em relação às medições manuais.

Este trabalho foca na análise de fósseis vegetais do período Devoniano, com o objetivo de desenvolver um sistema de classificação e identificação automatizada desses fósseis. Embora a literatura tenha apresentado avanços no uso de Visão Computacional para fósseis de diferentes grupos, como microfósseis e braquiópodes, ainda há uma lacuna na aplicação dessas tecnologias para fósseis vegetais desse período, que enfrentam desafios específicos, como fragmentação, baixa preservação e alta similaridade morfológica entre gêneros. Este trabalho busca preencher essa lacuna, promovendo não apenas a ampliação do conhecimento paleobotânico sobre o Devoniano, mas também o desenvolvimento de uma ferramenta que facilite a análise desses fósseis, contribuindo para a evolução das pesquisas na área.

### 3. Metodologia

Esta seção descreve a metodologia usada para classificar imagens de fósseis vegetais. As etapas incluem (1) aquisição de dados, (2) pré-processamento, (3) aumento de dados e (4) classificação, conforme ilustrado na Figura 1.

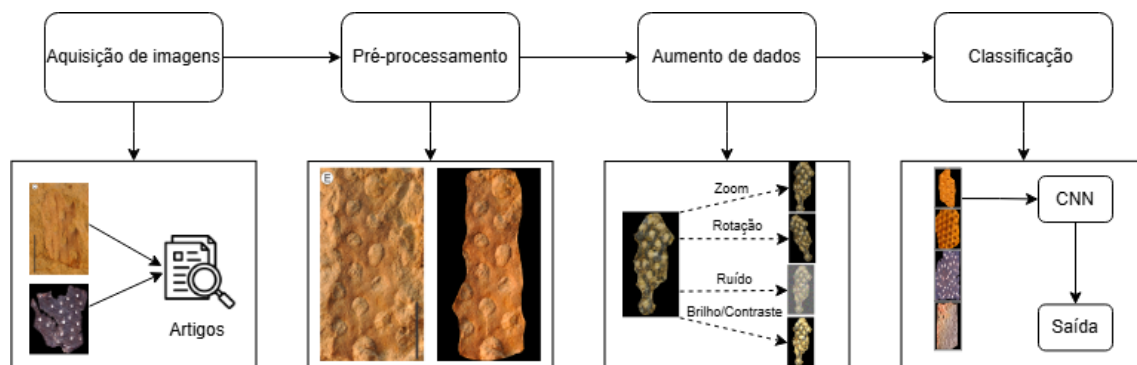


Figure 1. Fluxograma da metodologia utilizada para classificação de fósseis.

#### 3.1. Base de Dados

A base de dados utilizada neste estudo foi composta por imagens provenientes de artigos científicos especializados e da coleção científica do Laboratório de Paleontologia de Picos (LPP), que disponibilizou registros visuais de fósseis do período Devoniano. A pesquisa incluiu fósseis do gênero *Haplostigma* e de outros gêneros não pertencentes a essa categoria. Ao todo, foram coletadas 140 imagens, sendo 70 do gênero *Haplostigma* e 70 de

outros gêneros do período. As imagens apresentavam variações significativas de tamanho, com dimensões que iam de aproximadamente 182×780 até 600×900 pixels, refletindo a diversidade de formatos encontrados nas fontes. A seleção das amostras seguiu critérios específicos para garantir qualidade visual e diversidade morfológica.

### 3.2. Pre-processamento

Durante a etapa de pré-processamento, as imagens foram segmentadas manualmente, removendo o fundo e deixando apenas o fóssil visível, para garantir que a análise fosse focada nas características do objeto de interesse. Além disso, as imagens foram organizadas em três subconjuntos: treino, validação e teste. Cada imagem passou por técnicas de padronização de tamanho, utilizando padding com preenchimento por zeros, seguido de um redimensionamento para o tamanho fixo de 224×224 pixels, por ser o formato de entrada padrão em arquiteturas pré-treinadas, garantindo compatibilidade e melhor desempenho do modelo. Esse processo assegurou que todas as imagens tivessem o mesmo tamanho e centralização, independentemente das suas dimensões originais. Após o pré-processamento, a base foi dividida em 60% para o conjunto de treino, 10% para validação e 30% para teste, mantendo a proporcionalidade entre as classes e garantindo um aprendizado balanceado para o modelo.

### 3.3. Aumento de dados

Durante a metodologia, foram aplicadas técnicas de aumento de dados (*data augmentation*) com o objetivo de enriquecer o conjunto de treinamento da CNN. As transformações aplicadas incluíram rotações em múltiplos ângulos ( $-45^{\circ}$  a  $45^{\circ}$ ), variações de escala (zoom de 80% a 120%), ajustes de brilho e contraste por fatores variados (de 0.6 até 1.5), deslocamentos horizontais e verticais (de -10 a 10 pixels), além da adição de ruído gaussiano. Essas operações foram utilizadas para aumentar a diversidade das amostras de entrada, considerando que as características morfológicas das estruturas analisadas não seguem padrões fixos de forma ou tamanho. Tais transformações foram escolhidas por simular variações reais observadas nas imagens de fósseis, como mudanças de orientação, iluminação e pequenas imperfeições de preservação, garantindo maior robustez ao modelo sem comprometer a integridade morfológica das amostras.

### 3.4. Classificação de imagens

Neste trabalho, foram utilizadas CNNs como ferramentas para extrair atributos e realizar a classificação de imagens de fósseis do período Devoniano, distinguindo exemplares do gênero *Haplostigma* de outros gêneros.

A escolha por CNNs se deu pela eficácia desses modelos em tarefas de visão computacional, especialmente em cenários com bases de dados limitadas. Foram empregados quatro modelos pré-treinados: MobileNetV2 (MN) [Sandler et al. 2018]; ResNet50 (RN50) [He et al. 2016a]; ResNet50V2 (RNV2) [He et al. 2016b] e InceptionV3 (ITV3) [Szegedy et al. 2016]. Esses modelos foram selecionados por apresentarem bom desempenho na ImageNet, um dos maiores benchmarks de classificação de imagens, além de oferecerem menor custo computacional e tempos de inferência reduzidos, como mostrado na Tabela 2. Além disso, foi aplicada a técnica de transferência de aprendizado, uma vez que a base de dados é relativamente pequena (140 imagens), o que torna essa abordagem útil para o processo de treinamento e melhora dos resultados obtidos.

**Table 2. Parâmetros das CNNs utilizadas neste trabalho.**

<b>Modelo</b>	<b>Tamanho (MB)</b>	<b>Parâmetros</b>	<b>Tempo (ms) CPU</b>	<b>Tempo (ms) GPU</b>
MobileNetV2	14	3,5M	25,9	3,8
ResNet50	98	25,6M	58,2	4,6
ResNet50V2	98	25,6M	45,6	4,4
InceptionV3	92	23,8M	65,0	5,0

Durante o processo de treinamento do modelo, adotou-se uma abordagem inicial de transferência de aprendizado, congelando as camadas convolucionais da rede. Essa estratégia visou preservar os extratores de características previamente aprendidos, evitando que os filtros convolucionais fossem alterados durante o treinamento, o que garante que a rede mantenha sua capacidade de identificar padrões gerais de baixo nível.

Após essa etapa inicial, foi aplicada a técnica de *fine-tuning*, na qual as camadas convolucionais da rede foram descongeladas, permitindo um ajuste mais preciso aos dados específicos do estudo. O *fine-tuning* é importante para refinar os parâmetros da rede, promovendo uma adaptação mais eficaz às particularidades dos dados, o que melhora a generalização do modelo ao aprender padrões mais específicos.

Essas taxas de aprendizado foram escolhidas com base em boas práticas para cenários com transferência de aprendizado. Na primeira fase, a taxa de 0.0001 (1e-4) permite um treinamento mais rápido e eficaz das camadas densas recém-adicionadas sem afetar drasticamente as camadas convolucionais pré-treinadas. Já na fase de *fine-tuning*, a taxa reduzida para 0.000001 (1e-6) evita grandes atualizações nos pesos das camadas convolucionais, que já possuem conhecimento útil aprendido anteriormente, garantindo ajustes mais sutis e preservando esse conhecimento. Essa estratégia ajuda a evitar overfitting e melhora a estabilidade durante a otimização.

### 3.5. Avaliação de desempenho

Os resultados foram avaliados através do uso das seguintes métricas de classificação: Acurácia, Precisão, Recall, F1-Score [Fleiss et al. 2013].

A acurácia avalia o desempenho global do modelo, sendo definida como a proporção de previsões corretas em relação ao total de amostras. A precisão indica a proporção de previsões positivas que estavam corretas, ou seja, entre todas as vezes em que o modelo previu a classe *Haplostigma* (considerada a classe positiva neste trabalho), quantas de fato pertenciam a essa classe. O recall, por sua vez, representa a capacidade do modelo de identificar corretamente todas as amostras reais da classe *Haplostigma*. Por fim, o F1-Score corresponde à média harmônica entre precisão e recall, fornecendo uma métrica balanceada que considera tanto os falsos positivos quanto os falsos negativos.

## 4. Resultados

Esta seção apresenta os resultados obtidos com a aplicação das diferentes arquiteturas de CNNs. Todas as imagens estavam em formato RGB e passaram por um pré-processamento padronizado, garantindo consistência na entrada dos modelos. A Tabela 4 apresenta a média das métricas obtidas por cada modelo avaliado.

**Table 3. Métricas obtidas através das CNNs.**

CNN	Acc	Precisão	Recall	F1-Score
MN	0,750	0,666	0,750	0,734
ITV3	0,875	0,857	0,900	0,883
RN50	0,850	0,791	0,950	0,851
<b>RN50V2</b>	<b>0,900</b>	<b>0,863</b>	<b>0,950</b>	<b>0,900</b>

Ao analisar as métricas obtidas pelas diferentes arquiteturas de CNNs, observa-se que o modelo RN50V2 apresentou os maiores valores em todas as métricas avaliadas, com acurácia e F1-Score de 90%, precisão de 86,3% e recall de 95%. Embora outras CNNs, como a RN50 e a ITV3, também tenham obtido métricas superiores às do modelo MN, a RN50V2 apresentou melhor equilíbrio entre precisão (86,3%) e recall (95,0%). O modelo RN50, por exemplo, obteve o mesmo recall (95,0%), indicando sua capacidade de identificar corretamente fósseis da classe *Haplostigma*, mas com uma precisão inferior (79,1%) em comparação à RN50V2, o que reflete uma maior propensão a gerar falsos positivos. O modelo ITV3 apresentou precisão de 85,7%, maior que a da RN50, indicando uma menor taxa de falsos positivos em relação a esse modelo. No entanto, seu recall de 90,0% é inferior ao da RN50V2, que obteve valores mais altos em ambas as métricas. Já o modelo MN apresentou os menores valores entre os avaliados, com acurácia de 75%, precisão de 66,6% e F1-Score de 73,4%, o que evidencia limitações dessa arquitetura na tarefa de classificação de fósseis vegetais.

Esses resultados indicam que, embora modelos mais simples, como o MN, possam ser adequados para cenários com restrições de hardware ou menor necessidade de desempenho, redes mais profundas, como a RN50V2, apresentaram métricas superiores nas tarefas avaliadas, especialmente em sensibilidade e equilíbrio entre precisão e recall. O modelo RN50V2, por exemplo, obteve recall de 95%, assim como a RN50, o que reflete sua capacidade de identificar corretamente a maioria das amostras da classe *Haplostigma*. Além disso, o equilíbrio entre precisão (86,3%) e recall (95,0%) contribuiu para que a RN50V2 apresente menor taxa de falsos positivos em comparação aos demais modelos. Dessa forma, a RN50V2 demonstra maior consistência nas métricas avaliadas, configurando-se como a arquitetura com melhor desempenho na tarefa de classificação de fósseis vegetais do período Devoniano, considerando o conjunto de dados utilizado neste estudo.

O desempenho observado para o modelo RN50V2, em comparação com os demais modelos avaliados, está relacionado à sua arquitetura mais profunda e otimizada, que possibilita a extração de características com maior detalhamento e contribuiu para maior estabilidade durante o treinamento. Em relação à RN50, a versão V2 apresentou melhorias que resultaram em um equilíbrio diferenciado entre as métricas de precisão e recall. Dentro do conjunto de modelos avaliados, a arquitetura ITV3 alcançou o segundo melhor desempenho em termos de precisão, atribuídos à sua capacidade de capturar padrões em múltiplas escalas. Entretanto, seu recall foi inferior, indicando menor sensibilidade na detecção de todas as instâncias positivas. Já o modelo MN, projetado para maior eficiência computacional, apresentou desempenho inferior nas métricas avaliadas, possivelmente devido a limitações na representação de características para tarefas mais complexas.

A Tabela 4 apresenta a comparação entre os resultados deste trabalho e estudos anteriores, considerando não apenas as métricas, mas também aspectos como base de dados e métodos utilizados. O modelo baseado na RN50V2 obteve F1-Score de 90% e recall de 95%, mesmo com apenas 140 imagens de fósseis vegetais fragmentados, evidenciando sua eficácia em cenários com dados escassos e variabilidade morfológica. Em contraste, o estudo de [Wang et al. 2022] alcançou 98% de acurácia com a arquitetura TCNN, mas utilizou uma base maior, bem preservada e menos desafiadora em termos visuais. O trabalho de [Mimura et al. 2022] combinou Mask R-CNN e EfficientNet-V2 para detectar dentes fósseis em imagens microscópicas, mas obteve apenas 78,6% de recall e exigiu imagens especializadas em ambiente controlado. Já [Karaderi et al. 2022] utilizou deep metric learning com ResNet-50 em uma base extensa e padronizada de foraminíferos, alcançando F1-Score de 84,6%, com foco em generalização para novas classes. O estudo de [Wang et al. 2023] apresentou F1-Score superior a 95% com o modelo TS-ResNet, porém com imagens laboratoriais em condições ideais. Por fim, [Zhang et al. 2024] obteve 93,3% de acurácia utilizando características morfológicas medidas manualmente, o que limita sua escalabilidade. Assim, o modelo proposto se destaca por aliar simplicidade, adaptabilidade e alto desempenho, mesmo em um cenário realista com imagens brutas e fósseis danificados.

Essas comparações destacam que o presente trabalho apresenta uma solução eficaz mesmo em condições menos favoráveis, com fósseis fragmentados, poucos dados e imagens brutas, demonstrando a viabilidade do uso de CNNs pré-treinadas e técnicas de aumento de dados para identificação paleobotânica automatizada.

**Table 4. Comparação das métricas deste trabalho com o estado da arte.**

Trabalhos	Acc	Precisão	Recall	F1-Score
[Zhang et al. 2024]	0,962	-	-	-
[Wang et al. 2022]	<b>0,980</b>	-	-	-
[Karaderi et al. 2022]	0,919	<b>0,913</b>	0,819	0,846
[Wang et al. 2023]	0,970	-	-	<b>0,975</b>
[Mimura et al. 2022]	0,850	0,890	0,786	0,835
Este Trabalho	0,900	0,863	<b>0,950</b>	0,900

## 5. Conclusão

Este trabalho apresentou uma abordagem baseada em Redes Neurais Convolucionais para a classificação automatizada de fósseis vegetais do período Devoniano, com foco no gênero *Haplostigma*. Utilizando uma base de imagens reduzida, especialmente quando comparada a bases tradicionais que frequentemente envolvem milhares de amostras, e composta por imagens fragmentadas, o modelo alcançou desempenho expressivo em métricas como precisão, recall e F1-Score, mesmo sem a necessidade de grandes volumes de dados ou ambientes controlados. Em comparação com estudos anteriores, os resultados aqui obtidos demonstram que é possível alcançar classificações confiáveis com uma estrutura computacional enxuta, o que amplia a viabilidade da aplicação em contextos com recursos limitados. A metodologia adotada, que combina pré-processamento manual, aumento de dados e transferência de aprendizado, provou ser eficiente e reproduzível. Como trabalhos futuros, propõe-se a inclusão de um módulo de detecção automática para



localizar os fósseis nas imagens de entrada, além da exploração de arquiteturas ainda mais leves, visando à aplicação direta em dispositivos móveis e sistemas de baixo custo.

## Agradecimentos

A Fundação de Amparo à Pesquisa do Estado do Piauí (FAPEPI) <sup>1</sup> e à Universidade Federal do Piauí (UFPI) Campus Senador Helvídio Nunes de Barros (CSHNB) pela infraestrutura disponibilizada nos Laboratórios de Paleontologia de Picos e no Laboratório de Pesquisas Aplicadas à Visão e Inteligência Computacional (PAVIC).

## References

- Cleal, C. J. and Thomas, B. A. (2009). *An introduction to plant fossils*. Cambridge University Press, Cambridge.
- Duan, X.-Y. and Gu, S.-M. (2023). Identification of potato leaf disease based on the transfer net deep learning method. In *2023 International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR)*, pages 19–25.
- Dumoulin, V. and Visin, F. (2016). A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*.
- Fleiss, J. L., Levin, B., and Paik, M. C. (2013). *Statistical methods for rates and proportions*. John Wiley & Sons.
- Gracioso, D. E. (2011). Icnofósseis de invertebrados da formação pimenteira (devoniano) na borda leste da bacia do parnaíba.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016a). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016b). Identity mappings in deep residual networks. In *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14*, pages 630–645. Springer.
- Karaderi, T., Burghardt, T., Hsiang, A. Y., Ramaer, J., and Schmidt, D. N. (2022). Visual microfossil identification via deep metric learning. In El Yacoubi, M., Granger, E., Yuen, P. C., Pal, U., and Vincent, N., editors, *Pattern Recognition and Artificial Intelligence*, pages 34–46, Cham. Springer International Publishing.
- Kenrick, P. and Crane, P. R. (1997). The origin and early evolution of plants on land. *Nature*, 389:33–39.
- Liu, X. and Song, H. (2020). Automatic identification of fossils and abiotic grains during carbonate microfacies analysis using deep convolutional neural networks. *Sedimentary Geology*, 410:105790.
- Matsumura, W. M. K., Di Pasquo, M., Iannuzzi, R., and Bosetti, E. P. (2024). Plant diversification through the devonian in brazil. In *Brazilian Paleofloras: From Paleozoic to Holocene*, pages 125–202. Springer.

---

<sup>1</sup><https://www.fapepi.pi.gov.br>

- Matsumura, W. M. K. and Iannuzzi, R. (2015). Plantas devonianas do brasil e seu significado bioestratigráfico. *Boletim do Museu Paraense Emílio Goeldi-Ciências Naturais*, 10(1):19–36.
- Mimura, K., Minabe, S., Nakamura, K., Yasukawa, K., Ohta, J., and Kato, Y. (2022). Automated detection of microfossil fish teeth from slide images using combined deep learning models. *Applied Computing and Geosciences*, 16:100092.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L.-C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4510–4520.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2818–2826.
- Wang, B., Sun, R., Yang, X., Niu, B., Zhang, T., Zhao, Y., Zhang, Y., Zhang, Y., and Han, J. (2023). Recognition of rare microfossils using transfer learning and deep residual networks. *Biology*, 12(1).
- Wang, H., Li, C., Zhang, Z., Kershaw, S., Holmer, L. E., Zhang, Y., Wei, K., and Liu, P. (2022). Fossil brachiopod identification using a new deep convolutional neural network. *Gondwana Research*, 105:290–298.
- Willis, K. and McElwain, J. (2002). *The Evolution of Plants*. Oxford University Press.
- Yu, C., Qin, F., Watanabe, A., Yao, W., Li, Y., Qin, Z., Liu, Y., Wang, H., Jiangzuo, Q., Hsiang, A. Y., Ma, C., Rayfield, E., Benton, M. J., and Xu, X. (2024). Artificial intelligence in paleontology. *Earth-Science Reviews*, 252:104765.
- Zhang, B., Xin, C., Yang, D., Jiao, Z., Liu, S., Di, G., and Zhao, H. (2024). Numerical taxonomy and genus-species identification of czekanowskiales in china based on machine learning. *Palaeontologia Electronica*, 27(1):1–19.