

AVALIAÇÃO DO CONDICIONAMENTO DO SOLO: UMA ABORDAGEM UTILIZANDO O TEACHABLE MACHINE

SOIL CONDITIONING ASSESSMENT: AN APPROACH USING
THE TEACHABLE MACHINE

Jéssica Figuera Oliveira Miranda

Doutoranda em Modelagem em Ciências da Terra e do Ambiente (UEFS). <http://lattes.cnpq.br/8985717830628943>. <https://orcid.org/0000-0002-1217-9146>. j.figuera@ufms.br

João Antonio Assis de Santana Batista

Mestrando em Modelagem e Simulação de Biosistemas (UNEB). <http://lattes.cnpq.br/8346245065149508>. <https://orcid.org/0009-0005-9746-3785>. AntonioAssis28@outlook.com.

Andressa Morais Amâncio

Graduada em Ciências Biológicas (UNEB). <http://lattes.cnpq.br/7754580261539226>. <https://orcid.org/0009-0001-9735-2461>. dressamancio@gmail.com.

Resumo: Redes neurais são eficazes na análise de imagens, identificando características do solo como texturas, cores e formas, essenciais para a extração de informações relevantes das amostras analisadas. O objetivo deste artigo consiste na triagem de figuras obtidas na plataforma de pesquisa Google Imagens® para avaliação do condicionamento do solo através do Teachable Machine. O modelo de aprendizado de máquina foi configurado com 100 epochs e um batch size de 64 para treinar 200 imagens, visando aprimorar a classificação e identificação de características. Os resultados obtidos evidenciam o potencial dessa tecnologia para auxiliar na avaliação do estado do solo em áreas agrícolas e florestais. O estudo realizado comprovou a viabilidade do uso de Redes Neurais Convolucionais para a identificação e classificação de imagens de solo em diferentes estados de erosão e saúde. A ferramenta Teachable Machine demonstrou ser eficaz no treinamento de modelos para essa finalidade, alcançando percentuais de acerto de até 100% em algumas categorias.

Palavras-chave: Erosão. Identificação Ambiental. Redes Neurais. Treinamento.

Abstract: Neural networks are effective in image analysis, identifying soil characteristics such as textures, colors and shapes, which are essential for extracting relevant information from the analyzed samples. The objective of this article is to screen images obtained from the Google Images® search platform to assess soil conditioning using Teachable Machine. The machine learning model was configured with 100 epochs and a batch size of 64 to train 200 images, aiming to improve classification and identification of characteristics. The results obtained demonstrate the potential of this technology to assist in assessing soil condition in agricultural and forestry areas. The study demonstrated the feasibility of using Convolutional Neural Networks to identify and classify soil images in different states of erosion and health. The Teachable Machine tool has proven to be effective in training models for this purpose, achieving accuracy rates of up to 100% in some categories.

Keywords: Erosion. Environmental Identification. Neural Networks. Training.

Introdução

Com o advento da Inteligência Artificial (IA), é nítido que sua participação vem sendo cada vez mais significativa na vida das pessoas, com isso tecnologias como Processamento de Linguagem Natural, Redes Neurais, aplicações a Visão Computacional vem se tornando cada vez mais predominante. Sistemas de segurança, mapeamento de áreas, reconhecimento facial, reconhecimento de fala e sensores são apenas algumas ferramentas que estão no dia a dia.

Acompanhando a evolução tecnológica, um dos segmentos que se destaca é o sistema de reconhecimento facial. Este sistema possibilita a identificação de indivíduos em grandes aglomerações e tem aplicações significativas na segurança pública e privada, além de ser utilizado para desbloquear dispositivos digitais. Além do reconhecimento facial, existem outras técnicas de biometria para identificar pessoas, como o reconhecimento da íris, da retina, das impressões digitais, das veias da mão, da voz, do cheiro e do rosto, entre outros (Koch, 2012).

Desde a inovação do sistema de detecção facial concebido por Viola-Jones, aplicado com destreza em uma ampla gama de contextos, desde câmeras digitais até os intrincados mecanismos de verificação de nível de garrafas em fábricas de refrigerantes e nos sofisticados sistemas visuais dos veículos autônomos, a visão computacional tem firmado sua posição como uma ferramenta poderosa. Ela não apenas substitui, mas também complementa habilmente as capacidades humanas em tarefas monótonas, desafiadoras ou que demandam atenção constante. Suas proezas se entrelaçam harmoniosamente com as aplicações da engenharia de controle e automação, abrindo caminho para uma era onde a colaboração entre humanos e máquinas redefine os limites do possível.

A visão computacional se desdobra em diversas subáreas, algumas se entrelaçando mais intimamente com outros campos do conhecimento humano do que outras. Uma dessas subáreas em evidência nos dias atuais é a utilização de algoritmos de aprendizado de máquina para o reconhecimento de objetos em imagens, frequentemente empregando redes neurais convolucionais profundas. O destaque dessas redes tem ampliado seu impacto, culminando em aplicações que alcançaram notoriedade pública, como as fascinantes experiências do DeepDream desenvolvidas pelo Google® ou o popular aplicativo móvel Prisma. Para Barelli (2018), a visão computacional estuda e programa sistemas capazes de enxergar por meio de processos artificiais, implementados por *hardware* e *software*.

As redes neurais têm se mostrado uma ferramenta poderosa para a análise de imagens em uma variedade de contextos, como por exemplo, a extração de características das imagens do solo. As redes neurais convolucionais podem ser treinadas para reconhecer características importantes nas imagens do solo, como texturas, padrões de cores e formas das amostras de solo. Hepner *et al.* (1990), empregaram redes neurais para a classificação da cobertura do solo a partir de imagens do Landsat TM, concluindo que a abordagem baseada em redes neurais foi mais eficaz do que a classificação estatística convencional.

Para Bischof *et al.* (1992), empregaram uma rede neural para classificar imagens multiespectrais, comparando os resultados com os obtidos pelo classificador Maxver. Esses autores observaram uma taxa de precisão global de 93,1%, em contraste com os 89,7% alcançados pelo Maxver. O objetivo deste artigo consiste na triagem de figuras obtidas na plataforma de pesquisa Google Imagens® para avaliação do condicionamento do solo através do Teachable Machine.

Metodologia

O Processo de Aprendizado em Redes Neurais Artificiais

O processo de aprendizado, ou treinamento, de uma rede neural artificial é definido como a identificação de todos os pesos que, quando dado um conjunto de entradas, se combinam da melhor forma para produzir uma saída mais próxima do resultado esperado. Durante o treinamento, conjuntos de exemplos são apresentados à ANN, aos quais ela deve se ajustar (Gallant, 1990; Ramchoun *et al.*, 2017). As redes neurais artificiais (ANN) buscam replicar o funcionamento do


cérebro humano, modelando-se com base no comportamento dos neurônios (Noriega, 2005).

Para Costa (2022), a Teachable Machine é uma ferramenta desenvolvida pelo Google®, que se baseia em uma técnica popular de aprendizado profundo chamada transferência de aprendizado. Nessa abordagem, a maior parte da arquitetura da rede neural de um modelo já treinado é mantida, enquanto apenas uma pequena parte dela é substituída com base nos novos dados. Após o treinamento da rede, é possível fazer o download do modelo resultante. Portanto, na etapa de classificação, foi viável aplicar a mesma metodologia tanto para o modelo obtido por meio da Rede Neural Convolutiva (RNC) desenvolvida, quanto para o modelo obtido com a Teachable Machine.

Explorando o Potencial: Utilização da ferramenta Teachable Machine

A utilização do Teachable Machine para classificar imagens e reconhecer diferentes aspectos de conservação dos solos. O processo começa com o manuseio da ferramenta de treinamento de modelos, onde as imagens são divididas em classes, com cada objeto representando uma classe. Em seguida, múltiplas imagens do objeto especificado são capturadas dentro da própria ferramenta, possibilitando também o carregamento de imagens externas, se necessário (Teachable Machine, 2022; Costa, 2022). Após a captura e configuração das fotos, o treinamento é iniciado. O Teachable Machine oferece a capacidade de exportar o modelo em formato Tensor Flow Lite, permitindo sua integração com outras tecnologias (Figura 1).

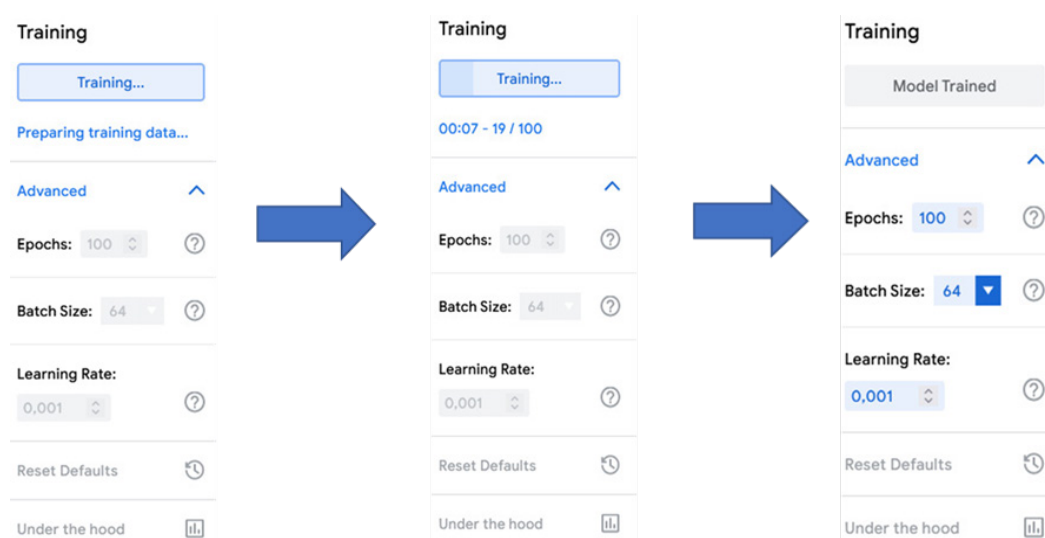
Figura 1. Conjuntos de imagens classificadas para treino no Teachable Machine



Fonte: autoria própria (2024)

Segundo o Teachable (2022), o parâmetro “*Epoch*” refere-se à quantidade de vezes que cada amostra no conjunto de dados de treinamento é processada pelo modelo. Em outras palavras, especifica o número de passagens completas de todo o conjunto de dados durante o processo de treinamento (JigSaw Academy, 2022). Por exemplo, se o parâmetro for definido como 50, significa que o modelo será treinado 50 vezes em todo o conjunto de dados, e geralmente quanto maior esse número, melhor será a capacidade do modelo em fazer previsões precisas. Já o “*Batch*”, de acordo com o Teachable (2022), é o conjunto de amostras utilizado em uma iteração de treinamento. Conforme Brownlee (2022) descreve, o *batch* pode ser considerado como um “*loop for*” iterando sobre uma ou mais amostras e realizando previsões.

Figura 2. Processo de treinamento de imagens no Teachable Machine



Fonte: autoria própria (2024)

No treinamento realizado e exemplificado na figura 2, o modelo recebeu uma quantidade de Epochs definida por 100, o tamanho do lote (*Batch Size*) foi definido como 64, enquanto cada conjunto de imagens possui um total de 200 figuras, onde as mesmas tem por objetivo serem aplicadas ao treinamento afim de aprimorar o aprendizado de máquina que a ferramenta processa para realizar a classificação e identificação das características da figura de teste. Isso indica que os dados serão divididos em $200/64$, resultando em aproximadamente 3,125 *batches*. Somente após todos esses *batches* serem processados é que uma Epoch é concluída. Após o término do treinamento do modelo, é possível testá-lo e verificar a precisão dos resultados obtidos. Com o modelo preparado, a própria ferramenta permite exportá-lo de acordo com a tecnologia que será integrada.

Referencial Teórico

Desdobramentos da Degradação do Solo: Impactos na Biodiversidade e nas Relações Ecológicas

O solo é uma componente essencial do meio ambiente e dos ecossistemas, desempenhando um papel fundamental em processos ecológicos vitais para os seres vivos e para as sociedades humanas. Em virtude disso, sua importância tem sido reconhecida através da atribuição de diversas funções, conforme evidenciado por estudos como os de FAO (1995), Blum (1998) e Hillel (1998).

De acordo com Gonçalves *et al.* (2000), solo degradado é definido como aquele que perdeu total ou parcialmente sua capacidade de sustentação, o que prejudica o desenvolvimento de plantas e outros organismos. Eles indicam que, no Brasil, essa degradação está ligada às práticas de cultivo e ao desmatamento. Quando se trata da pecuária intensiva sem manejo adequado do solo, a conversão da vegetação original pode levar à deterioração dos atributos físicos do solo, afetando sua capacidade de infiltração e aumento do escoamento superficial, desestabilizando assim o equilíbrio do sistema.

Segundo Bertol, Cogo e Levien (1997), a erosão do solo pode levar à degradação química, resultando na diminuição da qualidade e quantidade de matéria orgânica, bem como na redução dos teores de macro e micronutrientes. Oliveira *et al.* (2023), atribui essa degradação química à diminuição dos macroporos, ao aumento dos microporos e à densificação do solo. Essas condições físicas e químicas afetam diretamente os macro e microrganismos, causando mudanças drásticas em suas comunidades em períodos curtos. Em condições adversas, a diversidade e a abundância desses organismos são rapidamente comprometidas, o que, por sua vez, impactam a biodiversidade da flora e fauna local (Oliveira *et al.*, 2023).

Para Helene e Marcondes (1996), a diminuição da diversidade de espécies é um indicador crucial de perda de resiliência, o que por sua vez resulta na degradação da qualidade do solo. A extinção de espécies é uma das consequências diretas da exploração inadequada do meio ambiente, dos modos de vida e de nossa própria compreensão do que é essencial para nossa sobrevivência. Ações humanas, como a exploração excessiva dos recursos naturais, a expansão urbana e a degradação da biodiversidade, levam à extinção de espécies e à diminuição da diversidade genética. Além disso, em relação à perda de funcionalidades ecológicas, é importante mencionar o assoreamento ou colmatagem do leito dos rios como uma consequência negativa do processo erosivo. O assoreamento pode resultar no aumento da biodiversidade vegetal devido à elevação do nível freático, o que favorece a hidromorfia completa dos solos (Lévêque, 1999).

Segundo Meysman *et al.* (2006), as interações entre a fauna do solo e a vegetação são numerosas e complexas, demandando uma compreensão mais detalhada dos efeitos da bioturbação nos microrganismos do solo, nos invertebrados do solo, na dinâmica de nutrientes e nos sistemas radiculares. Para conter e reverter os processos de degradação do solo, intervenções fundamentadas em práticas de uso e manejo apropriadas são essenciais. Isso inclui evitar a pulverização, compactação e erosão provocadas pelas chuvas, além de restaurar funções vitais como drenagem e retenção de água e nutrientes (Miranda; Matos; Orge, 2024).

A necessidade cada vez maior de dados geotecnológicos é evidente, especialmente em áreas onde se planeja implementar unidades de conservação ou realizar intervenções e recuperações ambientais em regiões degradadas. Essas demandas são atendidas por equipes transdisciplinares, conforme destacado por Araújo, Monteiro e Abarkeli (2003). Para controlar esses processos erosivos, é crucial determinar as formas e práticas de uso e ocupação mais adequadas, o que é alcançado através do entendimento de como os fatores naturais contribuem para a erosão.

Na seleção de práticas de conservação do solo, especialmente em áreas cultivadas, uma ferramenta importante é a estimativa das perdas de solo por erosão hídrica, utilizando equações empíricas para identificar as áreas de risco de erosão. A Equação Universal de Perdas de Solo (EUPS), desenvolvida por Wischmeier e Smith (1978), incorpora os principais fatores do processo erosivo, incluindo a erosividade da chuva (R), a erodibilidade do solo (K), a topografia (LS), a cobertura vegetal e o manejo do cultivo (C) e as práticas de conservação (P).

Explorando o Aspecto Visual: Técnicas e Aplicações do Reconhecimento e Processamento de Imagens

Conforme expresso por Queiroz e Gomes (2006), o processamento digital de imagens, que envolve técnicas para analisar dados multidimensionais de vários sensores, é usado para aprimorar a qualidade visual das imagens, facilitar sua interpretação e gerar produtos para processamentos subsequentes. Este sistema abrange processos como digitalização, pré-processamento, segmentação, pós-processamento, extração de atributos, classificação e reconhecimento. Ele tem aplicações em diversas áreas, incluindo análise de recursos naturais e meteorologia através de imagens de satélite, transmissão digital de TV, análise de imagens biomédicas, obtenção de imagens médicas por ultrassom, radiação nuclear ou técnicas de tomografia computadorizada, e automação industrial com o uso de sensores visuais em robôs. As imagens digitais, que são capturas do mundo real feitas por um sensor, têm a capacidade de representar informações que podem ser imprecisas e ambíguas (Jawahar; Ray, 1996).

Segundo Acharya e Ray (2005), para analisar e identificar objetos, é preciso uma série extensa de processos. Inicialmente, é necessário extrair atributos ou características das imagens, como bordas, texturas e elementos vizinhos. O movimento é outra característica crucial. Posteriormente, os objetos devem ser diferenciados do plano de fundo, o que implica na identificação de características constantes e descontinuidades por meio de um processo de segmentação. Por exemplo, existem aplicações para identificação e segmentação de objetos ou imagens humanas, reconstrução tridimensional de cenas reais, uso de prototipagem rápida para criar objetos de formas complexas a partir de dados 3D, rastreamento em tempo real e navegação de robôs móveis ou veículos autônomos, e controle de processos de manufatura ou sistemas industriais (Denis, 2009).

As Redes Neurais Convolucionais (CNN) desempenham um papel significativo no reconhecimento e classificação de imagens, atingindo o estado da arte em diversas implementações (Zhao *et al.*, 2017). Uma CNN é um algoritmo de Deep Learning que consegue processar uma entrada específica, atribuir relevância a diferentes aspectos por meio de filtros e distinguir seus elementos principais. Desenvolvida por Yann Lecun em 1998, é considerada uma das grandes realizações da matemática aplicada às redes neurais artificiais e ao reconhecimento de padrões (Piva Jr.; De Carvalho, 2022).

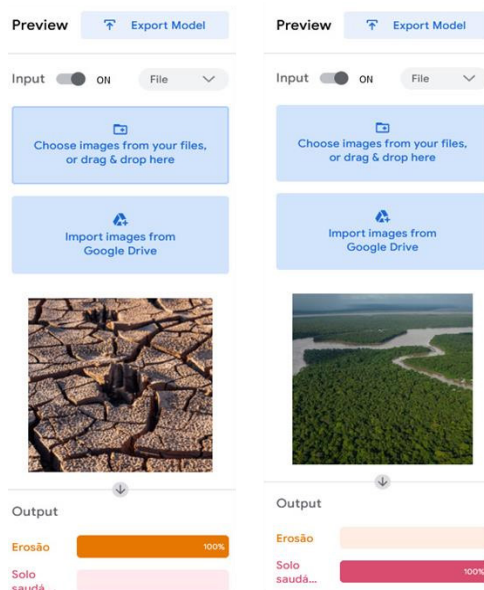
Segundo Du, Cai e Wang (2016), a classificação de imagem envolve a atribuição de imagens a uma de várias classes preestabelecidas. É um problema fundamental na visão computacional, assim como a localização, detecção e segmentação de imagens. Nos últimos tempos, a aprendizagem profunda tem encontrado aplicações em diversas áreas do saber (Braga; Coelho, 2022).

Uma CNN pode ser comparada a um sistema de encanamento complexo com múltiplas etapas. As imagens são introduzidas em uma extremidade e, na outra, surge a probabilidade de a imagem representar o rosto de interesse. Existem três camadas principais nesta rede: convolucionais, de agrupamento (*pooling*) e totalmente conectadas. A camada convolucional é formada por um conjunto de filtros (*kernels*) que a CNN utiliza para aprender a partir do conjunto de dados de treinamento. É como se a rede estivesse “observando” diferentes aspectos da imagem através de várias lentes. A camada de agrupamento atua como um redutor de complexidade, diminuindo o tamanho das matrizes resultantes do processo de convolução. Isso ajuda a reduzir a quantidade de parâmetros de aprendizagem da rede, tornando o modelo mais eficiente. Na camada totalmente conectada, cada elemento das matrizes de saída da convolução é conectado a um neurônio de entrada. Esta camada é semelhante à última camada de uma ANN tradicional. A disposição dessas camadas em uma CNN é conhecida como a arquitetura da CNN (Venkatesan; Li, 2017).

Resultados e discussão

O principal objetivo deste trabalho foi realizar o condicionamento de figuras obtidas na plataforma de pesquisa Google®, onde as mesmas foram treinadas no Teachable Machine, onde esta ferramenta dispõe de Redes Neurais Convolucionais para identificar e classificar os conjuntos de imagens por meio de treinamento. No primeiro resultado do treinamento (Figura 3) pode-se observar que a imagem que ilustra o processo de erosão acusou o percentual de 100%, pois, a erodibilidade do solo é característica pela ausência de matéria orgânica no solo, o que resulta em uma redução da sua fertilidade. Isso também afeta a capacidade do solo de reter umidade. Além disso, a porosidade do solo e a capacidade de absorver água também são reduzidas (Guerra, 1994).

Figura 3 . Resultado do treinamento 1




Fonte: autoria própria (2024)

No primeiro resultado do treinamento (Figura 3) pode-se observar que a imagem que ilustra o aspecto de solo saudável acusou o percentual de 100%, pois, a ideia de saúde ou qualidade do solo está ligada à sua habilidade de operar para oferecer serviços ambientais significativos. Isso inclui: sustentar a capacidade de produção biológica (como a produção de grãos, carne, madeira, agroenergia, fibras, entre outros), favorecer a saúde de seres humanos, plantas e animais (através de solos saudáveis, criando ambientes saudáveis) e também preservara qualidade ambiental (por meio do armazenamento e filtragem de água, sequestro de carbono) (Mendes *et al.*, 2018).

No segundo resultado do treinamento (Figura 4) pode-se observar que a imagem que ilustra o processo de erosão acusou o percentual de 100%, pois, a erodibilidade do solo é acelerada e é um fenômeno rápido e destrutivo que é desencadeado principalmente pela atividade humana, resultando em taxas de remoção de solo que excedem as taxas de sua formação natural. A nível global, a erosão causada por atividades não-agrícolas, como construção civil e mineração, é relativamente insignificante, afetando apenas uma pequena fração da superfície terrestre. No entanto, a agricultura, devido à sua extensa distribuição e seu potencial para intensificar os processos erosivos, torna-se muito mais significativa nesse contexto.

Quase todas as práticas agrícolas acabam exacerbando o processo erosivo. O desmatamento remove a cobertura vegetal, expondo o solo e criando condições para a ação direta de ventos e água. Isso resulta na falta de absorção do impacto das gotas de chuva, na remoção de obstáculos à movimentação do vento e na promoção do escoamento superficial, formando enxurradas e intensificando ainda mais o processo erosivo. Além disso, o cultivo do solo contribui para a sua desestruturação, aumentando a individualização das partículas ou reduzindo o tamanho dos agregados, o que facilita sua movimentação pelo vento e pela água.

Figura 4. Resultado do treinamento 02




Fonte: autoria própria (2024)

No segundo resultado do treinamento (Figura 4) pode-se observar que a imagem que ilustra o aspecto de solo saudável acusou o percentual de 100%, pois, a produção de biomassa desempenha um papel essencial no sistema, proporcionando proteção ao solo contra a erosão, contribuindo para a melhoria da fertilidade e aumentando a infiltração e a disponibilidade de água para as plantas. Diversas espécies, incluindo leguminosas, gramíneas, crucíferas e outras, são utilizadas para a cobertura, tanto na pré-safra quanto para viabilizar o plantio direto (PD), visando a produção de biomassa. Os resíduos dessas plantas são mantidos na superfície do solo, formando uma cobertura morta. A cobertura com leguminosas é particularmente eficaz devido ao seu alto poder de fixação de nitrogênio no solo, conforme observado por Andrioli *et al.* (2008), resultando em economia de nitrogênio para a cultura subsequente.

No terceiro resultado do treinamento (Figura 5), observamos que a “erosão” corresponde a 36% da área, enquanto 64% do solo é considerado saudável. Esse entendimento se deve ao fato de que o modelo de treinamento identificou danos no solo na imagem analisada, provavelmente causados pela ação humana no que diz respeito ao arar o solo, esta ação tem como objetivo propiciar melhores condições para o solo. Essas alterações são visíveis na camada superficial do solo, levando à conclusão de que houve um entendimento errôneo da parte da ferramenta, no que diz respeito à técnica de aração do solo. A ferramenta confundiu a técnica de aeração do solo com o aspecto de erodibilidade do solo. A imagem apresenta uma vegetação verde, demonstrando que as plântulas estão se desenvolvendo, por conta dessa incidência de características o resultado foi apresentado desta forma.

Figura 5. Resultado do treinamentos 03



Fonte: autoria própria (2024)

No terceiro resultado do treinamento (Figura 5), a ferramenta Teachable Machine se destaca por sua perspicácia, detectando com precisão impecável a erosão no solo, alcançando um índice de acerto de 100%. Essa acuidade se deve à sua capacidade de identificar os sinais reveladores da degradação do solo, como a opacidade acinzentada da superfície, as rachaduras esculpidas pela água e pelo vento, a perda irreversível de nutrientes essenciais para a produtividade agrícola e a ausência de cobertura vegetal que protegia o solo da ação erosiva. A combinação desses fatores na imagem analisada não deixa dúvidas: o solo está sofrendo erosão. Essa identificação precisa é fundamental para que medidas adequadas de manejo e recuperação do solo sejam tomadas, garantindo a sustentabilidade da produção agrícola e a preservação do meio ambiente.

Conclusão

O estudo realizado comprovou a viabilidade do uso de Redes Neurais Convolucionais para a identificação e classificação de imagens de solo em diferentes estados de erosão e saúde. A ferramenta demonstrou ser eficaz no treinamento de modelos para essa finalidade, alcançando percentuais de acerto de até 100% em algumas categorias.

Os resultados obtidos evidenciam o potencial dessa tecnologia para auxiliar na avaliação do estado do solo em áreas agrícolas e florestais. Através da análise de imagens de satélite ou aéreas, é possível identificar áreas com sinais de erosão e direcionar ações de manejo adequadas para a recuperação do solo.

No entanto, é importante ressaltar que a ferramenta ainda se encontra em fase de desenvolvimento e que novos testes são necessários para aprimorar sua precisão e generalização para diferentes tipos de solo e condições climáticas. Além disso, a interpretação dos resultados da ferramenta deve ser feita por um especialista em solo, que possa considerar outros fatores que influenciam a saúde do solo, como a análise química e física do solo.

Ainda assim, o estudo apresenta-se como um importante passo para o desenvolvimento de ferramentas tecnológicas que auxiliem na gestão sustentável do solo, contribuindo para a preservação desse recurso natural vital para a produção de alimentos e a manutenção da qualidade ambiental.

Referências

ACHARYA, T.; RAY, A. K. **Image processing**: principles and applications. New Jersey: John Wiley & Sons, 2005.

ANDRIOLI, I.; BEUTLER, A. N.; CENTURION, J. F. Produção de milho em plantio direto com adubação nitrogenada e cobertura do solo na pré-safra. **Revista Brasileira de Ciência do Solo**, Viçosa, 2008.

ARAÚJO, A. S. F. de.; MONTEIRO, R. T. R.; ABARKELI, R. B. Effect of glyphosate on the microbial activity of two Brazilian soils. **Chemosphere**, v. 52, n. 5, p. 799–804, 2003.

BARELLI, F. **Introdução à visão computacional**: uma abordagem prática com Python e OpenCV. Editora Casa do Código, 2018.

BERTOL, I.; COGO, N. P.; LEVIEN, R. Erosão hídrica em diferentes preparos do solo logo após as colheitas de milho e trigo, na presença e ausência dos resíduos culturais. **Revista Brasileira de Ciência do Solo**, v. 21, p. 409–418, 1997.

BISCHOF, H.; SCHNEIDER, W.; PINZ, A. J. Multi-spectral classification of Landsat images using neural network. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, p. 482–490, 1992.

BLUM, W. E. **Basic concepts**: degradation, resilience and rehabilitation. In: LAL, R. (org.). *Methods for assessment of soil degradation*. Boca Raton: CRC Press, 1998.

BRAGA, H. C. dos R.; COELHO, A. D. **Reconhecimento de padrões em imagem empregando aprendizagem profunda**. CIPEEX, v. 2, p. 2629–2631, 2018.

BROWNLEE, J. **Machine learning mastery**. 2022. Disponível em: <https://machinelearningmastery.com>. Acesso em: 25 fev. 2026.

COSTA, Á. E. do R. **Uaraná: aplicativo para identificação de animais do bioma amazônico impressos em 3D**. 2022. Trabalho de Conclusão de Curso (Graduação em Análise e Desenvolvimento de Sistemas) — Instituto Federal de Educação, Ciência e Tecnologia do Amazonas, 2022.

DENIS, C.; ASSIS, W. O.; COELHO, A. D. Sorting Tomatoes for Industrial Processing Through of Computer Vision System Based on Neural Networks. **Anais COBEM**, 2009.

DU, X.; CAI, Y.; WANG, S. Overview of deep learning. In: **31st Youth Academic Annual Conference of Chinese Association of Automation**, 2016.

FAO. **Planning for sustainable use of land resources: towards a new approach**. Rome: FAO, 1995.

GALLANT, S. Perceptron-based learning algorithms. **IEEE Transactions on Neural Networks**, v. 1, p. 179–191, 1990.

GONÇALVES, J. L. M. *et al.* Reflexos do cultivo mínimo e intensivo do solo em sua fertilidade e nutrição das árvores. In: GONÇALVES, J. L. M.; BENEDETTI, V. (org.). **Nutrição e fertilização florestal**. Piracicaba, 2000.

GUERRA, A. J. T. **A erosão dos solos no contexto social**. Anuário do Instituto de Geociências, v. 17, p. 14–23, 1994.

HELENE, M. E. M.; MARCONDES, B. **Evolução e biodiversidade: o que nós temos com isso?** São Paulo: Scipione, 1996.

HEPNER, G. F. *et al.* Artificial neural network classification using a minimal training set: comparison to conventional supervised classification. **Photogrammetric Engineering and Remote Sensing**, v. 56, p. 469–473, 1990.

HILLEL, D. **Environmental soil physics**. San Diego: Academic Press, 1998.

JAWAHAR, C.; RAY, A. Fuzzy statistics of digital images. **IEEE Signal Processing Letters**, v. 3, n. 8, p. 225–227, 1996.

JIGSAW ACADEMY. **Epoch and batch size in machine learning**. 2022. Disponível em: <https://www.jigsawacademy.com>. Acesso em: 25 fev. 2026.

KOCH, M. **Visão computacional para reconhecimento de faces aplicado na identificação e autenticação de usuários na web**. Trabalho de conclusão de curso (Graduação) – Universidade Regional de Blumenau, 2012.

LÉVÊQUE, C. **Biodiversidade**. Bauru: EDUSC, 1999.

MEYSMAN, F. J. R.; MIDDELBURG, J. J.; HEIP, C. H. R. Bioturbation: a fresh look at Darwin's last idea. **Trends in Ecology & Evolution**, v. 21, n. 12, p. 688–695, 2006.

MENDES, I. de C.; SOUSA, D. M. G. de; REIS JUNIOR, F. B. dos; LOPES, A. A. de C. **Bioanálise de solo: como acessar e interpretar a saúde do solo**. Planaltina, DF: Embrapa Cerrados, 2018. 23 p. (Circular

Técnica, 38). Disponível em: <https://www.sidalc.net/search/Record/dig-infoteca-e-doc-1110832/Description>. Acesso em: 26 fev. 2026

MIRANDA, J. F. O.; MATOS, M. R. B.; ORGE, M. D. R. Aplicação da modelagem de distribuição de espécies (MDE) no bioma Mata Atlântica: uma análise bibliométrica. **Revista Políticas Públicas & Cidades**, v. 13, n. 2, e1017, 2024.

NORIEGA, L. Multilayer perceptron tutorial. **School of Computing – Staffordshire University**, v. 4, n. 5, 2005.

OLIVEIRA, J. F. *et al.* A importância de práticas promotoras de conservação do solo. *In: Anais Sustentare WIPIS*, 2023. Disponível em: <https://www.even3.com.br>. Acesso em: 25 fev. 2026.

PIVA JR., D.; CARVALHO, A. S. A. de. Análise de algoritmos de reconhecimento facial: Haar Cascade (Viola-Jones) e CNN (Convolutional Neural Networks). *In: CONTECSI – International Conference on Information Systems and Technology Management*, v.19, São Paulo: TECSI/FEA-USP, 2022.

RAMCHOUN, H. *et al.* Multilayer perceptron: Architecture optimization and training with mixed activation functions. *In: Proceedings of the 2nd international Conference on Big Data, Cloud and Applications*, p. 1-6, 2017.

QUEIROZ, J. E. R. de.; GOMES, H. M. Introdução ao Processamento Digital de Imagens. **Rita**, v. 13, n. 2, p. 11-42, 2006.

TEACHABLE MACHINE. **Teachable Machine by Google**. 2022. Disponível em: <https://teachablemachine.withgoogle.com>. Acesso em: 25 fev. 2026.

VENKATESAN, R.; LI, B. **Convolutional neural networks in visual recognition**. CRC Press, 2017.

WISCHMEIER, W. H.; SMITH, D. D. **Predicting rainfall erosion losses: a guide to conservation planning**. Washington: USDA, 1978.

ZHAO, B. *et al.* A survey on deep learning-based fine-grained object classification and semantic segmentation. **International Journal of Automation and Computing**, v. 14, n. 2, p. 119-135, 2017.

Recebido em 17 de dezembro de 2024

Aceito em 25 de fevereiro de 2026