

**Inteligência artificial para a avaliação de pastagens degradadas a partir de fotos de smartphones e de series temporais de imagens de satélite: uma abordagem baseada em deep e machine learning para subsidiar o cálculo de indicadores agro-socioambientais**

**Artificial intelligence for the evaluation of degraded pastures from photos of smartphones and time series of satellite images: an approach based on deep and machine learning to subsidize the calculation of agro-socioenvironmental indicators**

DOI: 10.54033/cadpedv20n10-018

Recebimento dos originais: 23/11/2023

Aceitação para publicação: 26/12/2023

---

**Margareth Simões**

Doutora em Geografia

Instituição: EMBRAPA Solos e Universidade do Estado do Rio de Janeiro (UERJ)

Endereço: R. Jardim Botânico, 1024, Jardim Botânico, Rio de Janeiro – RJ, CEP: 22460-000

E-mail: margareth.simoes@embrapa.br

**Rodrigo Peçanha Demonte Ferraz**

Doutor em Ciências Ambientais

Instituição: EMBRAPA Solos

Endereço: R. Jardim Botânico, 1024, Jardim Botânico, Rio de Janeiro – RJ, CEP: 22460-000

E-mail: rodrigo.demonte@embrapa.br

**Patrick Calvano Kuchler**

Doutor em Ciências Ambientais

Instituição: Universidade do Estado do Rio de Janeiro (UERJ)

Endereço: R. São Francisco Xavier, 524, Maracanã, Rio de Janeiro – RJ, CEP: 20550-900

E-mail: geocalvano@gmail.com

**Matheus Benchimol Ferreira de Almeida**

Doutor em Ciências do Meio Ambiente

Instituição: EMBRAPA Solos

Endereço: R. Jardim Botânico, 1024, Jardim Botânico, Rio de Janeiro – RJ, CEP: 22460-000

E-mail: mateusbenchimol@hotmail.com

### Luan Porto Vieira

Graduado em Engenharia Elétrica – Ênfase em Sistemas e Computação

Instituição: Universidade do Estado do Rio de Janeiro (UERJ)

Endereço: R. São Francisco Xavier, 524, Maracanã, Rio de Janeiro – RJ,

CEP: 20550-900

E-mail: luanportovieira@gmail.com

### Sofia Martins Lage

Graduada em Geografia

Instituição: EMBRAPA Solos

Endereço: R. Jardim Botânico, 1024, Jardim Botânico, Rio de Janeiro – RJ,

CEP: 22460-000

E-mail: sofmlage@gmail.com

### Pedro Luiz de Freitas

Doutor em Ciência do Solo

Instituição: EMBRAPA Solos

Endereço: R. Jardim Botânico, 1024, Jardim Botânico, Rio de Janeiro – RJ,

CEP: 22460-000

E-mail: pedro.freitas@embrapa.br

---

## RESUMO

Entre as principais potências agropecuárias, o Brasil se destaca como um dos poucos países que ainda dispõe de extensas áreas de terra com potencial de produção agropecuária, sem a necessidade do desmatamento. O país busca reverter a degradação do solo por meio de políticas públicas, incluindo a criação de indicadores Sócio-Agro-Ambientais multiescalares. Este trabalho tem como objetivo desenvolver uma solução para diagnosticar áreas degradadas, oferecendo recomendações técnicas regionalizadas para a conservação, recuperação e reintegração dessas áreas à cadeia produtiva de alto rendimento. Duas abordagens inovadoras foram adotadas: (i) uso de deep learning, com uma acurácia de 95,9% para diagnósticos locais por smartphones; (ii) baseada em machine learning e satélites, que alcançou 95,90% de acurácia para avaliações regionais. Ambas as metodologias convergem para soluções acessíveis e inovadoras, estimulando ações de recuperação de áreas degradadas.

**Palavras-chave:** indicadores sócio-agro-ambientais, degradação do solo, is\_agro.

## ABSTRACT

Brazil, an important agricultural power, faces challenges when it comes to transforming degraded areas into productive areas, but using sustainable agriculture. The country aims to reverse soil degradation through public policies, including the creation of multi-scale Socio-Agro-Environmental indicators. The objective of this work is to develop a solution to diagnose degraded areas, providing region-specific technical recommendations for the conservation, recovery, and reintegration of these areas into high-yield production chains. Two innovative

approaches were adopted: (i) the use of deep learning, with an accuracy of 95.9% for local diagnoses using smartphones; (ii) based on machine learning and satellites, achieving 95.90% accuracy for regional assessments. Both methodologies converge towards accessible and innovative solutions, stimulating actions for the recovery of degraded areas.

**Keywords:** socio-agro-environmental indicators, soil degradation, is\_agro.

## 1 INTRODUÇÃO

Dentre as potências agropecuárias, o Brasil se destaca como um dos poucos países que ainda possuem vastas extensões de terras com potencial para produção agropecuária, sem a necessidade de desmatar novas áreas. A preservação dos remanescentes naturais, legalmente protegidos pelo Código Florestal, e a existência de terras subutilizadas que podem ser reintegradas à cadeia produtiva tornam a conversão de novas áreas de vegetação natural uma opção pouco estratégica para o país. No entanto, é importante salientar que o Brasil ainda enfrenta um considerável passivo socioeconômico e ambiental decorrente da degradação dos solos, perda de biodiversidade, contaminação e sobre-exploração dos recursos hídricos, comprometendo o ideal de desenvolvimento sustentável na agropecuária nacional. Esses desafios representam um legado dos diversos ciclos agroecônômicos que ocorreram sem um adequado planejamento conservacionista. Atualmente, no Brasil encontram-se vastas áreas abandonadas, subutilizadas com pastagens degradadas sem o devido e efetivo controle da erosão, cujo resultado é a diminuição da capacidade produtiva de solos potencialmente agricultáveis. Segundo dados do MAPBIOMAS (2021), O Brasil possui uma área de cerca de 150 milhões de hectares de pastagens, o que equivale a 21% do território nacional. Estima-se que cerca de 60% destas pastagens estão degradadas (LAPIG, GO, [2018.]; PARENTE; FERREIRA, 2018). Diminuição de renda, abandono da atividade agropecuária, insustentabilidade socioeconômica e ambiental são as consequências mais diretas para os produtores. O desafio que se impõe, portanto, é a reversão desse quadro de massiva degradação dos solos agricultáveis do país a partir da implementação de políticas públicas estratégicas

orientadas à conservação, à recuperação e à reinserção das áreas degradadas à cadeia de produção agropecuária. Neste contexto, os programas de pesquisa, desenvolvimento, inovação (PD&I) e transferência de tecnologia (TT), assumem relevante importância à operacionalização dessas políticas. Desta forma, o objetivo deste trabalho é desenvolver uma solução tecnológica inovadora que possa eficientemente diagnosticar áreas degradadas, oferecendo recomendações técnicas regionalizadas para a conservação, recuperação e reintegração dessas áreas à produção agropecuária de alto rendimento. Para tanto, foram desenvolvidas duas soluções tecnológicas complementares. A primeira solução consiste na integração de um protocolo metodológico para o diagnóstico expedito de áreas degradadas com um sistema especialista que realiza inferências sobre o nível de degradação da área avaliada, apontando os principais fatores críticos. A segunda solução de inovação consiste em uma máquina de inferência que especifica as recomendações técnicas mais apropriadas para cada caso de recuperação das áreas degradadas. Os principais resultados que o trabalho visou atingir são: o protocolo metodológico para o diagnóstico expedito de campo de áreas degradadas, a avaliação de métodos para a automação do diagnóstico de campo de áreas degradadas subsidiando o apoio a decisão para a recuperação das áreas degradadas sob pastagens ou em abandono.

Espera-se um impacto significativo no setor produtivo, estimulando ações de recuperação de áreas degradadas apresentando forte alinhamento com as políticas públicas de recuperação de pastagens degradadas como o Plano ABC e ABC+ (BRASIL, 2012) e degradação neutra (ODS15).

## **2 CARACTERIZAÇÃO DO PROBLEMA E JUSTIFICATIVA**

A conversão de áreas naturais em áreas produtivas possibilitou aumentar a oferta de alimentos, fibras, energia e outras matérias primas para o desenvolvimento da humanidade. Entretanto, muitas terras que geraram riquezas por meio da atividade agropecuária, atualmente, encontram-se degradadas ou em processo de degradação. Estima-se que, no mundo, cerca de 33% das terras apresentam algum tipo de degradação (FAO, 2015). Somente no ano de 2011,

estima-se que foram perdidas cerca de 24 bilhões de toneladas de solo fértil em áreas agrícolas em todo o mundo. Dessa forma, a erosão hídrica acelerada pelo uso e manejo inadequado do solo deve ser considerada como um dos mais graves problemas ambientais que a humanidade enfrenta na atualidade, na medida em que ocasiona a remoção da camada mais rica do solo com a consequente perda de nutrientes, poluição e assoreamento dos cursos d'água, enchentes e queda acentuada da produtividade agrícola (DOMINATI et al., 2010, ZHAO et al., 2012). Em um cenário de crescimento da população mundial e de aumento da demanda por produtos agropecuários e florestais a pressão sobre os recursos solo e água se intensificam ainda mais, podendo levar o mundo a um quadro de extrema insegurança alimentar, nutricional e socioeconômica. O problema da degradação das terras e erosão dos solos não atinge apenas o setor da agropecuária. O assoreamento dos corpos hídricos causado pela erosão das áreas de entorno é também potencialmente danoso, causando a diminuição da oferta e qualidade de água; a redução da vida útil de reservatórios e desgaste nas turbinas, além do comprometimento da biodiversidade aquática. Da mesma forma, pode acarretar o aumento do custo do tratamento de água para abastecimento urbano. Na dimensão socioeconômica o problema da erosão e perda de solos férteis tem forte influência na diminuição da oferta de emprego e renda na área rural. A desvalorização da propriedade rural, o abandono de terras anteriormente produtivas e o êxodo rural com migração para grandes centros agravam os problemas sociais relacionados aos aglomerados urbanos, merecendo também especial destaque.

No que tange às metas de aumento da produção agropecuária nacional e de degradação neutra das terras, o Brasil apresenta um potencial único no mundo (UNCCD, *United Nations Conventional for Combat Desertification*, 2018).

A mitigação dos problemas ensejados pela vastidão de áreas degradadas em nosso país, requer a instrumentação de políticas públicas que possibilitem a implementação de programas de crédito financeiro e transferência de tecnologia que possam apoiar os produtores rurais no enfrentamento do problema no nível operacional de suas propriedades. Neste sentido, destacam-se as principais diretrizes de ação:

- ✓ Reinserção das áreas subutilizadas com pastagens degradadas e/ou abandonadas por degradação à cadeia de produção agropecuária de alto rendimento;
- ✓ Recuperação de pastagens degradadas, visando o aumento da produtividade forrageira e o fortalecimento da cadeia de produção pecuária a pastoreio;
- ✓ Fortalecimento das ações de P&D e TT visando à expansão da adoção de práticas de conservação de solos (Técnicas de controle mecânico e vegetativo, etc.);
- ✓ Fortalecimento das ações de P&D e TT visando à expansão da adoção de sistemas de produção agropecuária que promovam a melhoria da qualidade dos solos e o controle da erosão (PDP, ILPFs, etc);
- ✓ Recuperação de áreas degradadas para fins de recomposição ambiental (APP, RL, etc);
- ✓ Recuperação de áreas extremamente degradadas – voçorocamento, cavas de mineração, cortes de engenharia civil – visando à estabilidade geotécnica ou recomposição ambiental;
- ✓ Combate à arenização, desertificação e à insegurança hídrica.

A oportunidade que se apresenta diante deste grande desafio é a de promover de forma sinérgica e complementar diversas ações integradas de PD&I (Pesquisa, Desenvolvimento e Integração), TT (Transferência de Tecnologia) e TIC (Tecnologia da Informação e Comunicação) que possam apoiar as diretrizes acima apresentadas, considerando suas diferentes dimensões de ação: nível estratégico, tático e operacional. A oportunidade reside na possibilidade de desenvolver e disponibilizar para o setor produtivo ferramentas computacionais que possam apoiar o produtor em seus processos de tomada de decisão e planejamento de uso da propriedade.

O trabalho, é parte do projeto ReinserTec (Tecnologias avançadas para a avaliação e recomendação técnica visando recuperação e reinserção de áreas degradadas às cadeias de produção agropecuária). Através das soluções baseadas em sensores multifontes deste trabalho, pretende-se subsidiar a avaliação dos indicadores agro-socioambientais do Projeto IS\_Agro –

Indicadores Agro-Socioambientais do Brasil: Inteligência Estratégica para a Sustentabilidade da Agropecuária Nacional, Executado pela Embrapa e Financiado pelo Ministério de Agricultura e Pecuária (Termo de Execução Descentralizada nº 450/2021 celebrado em 23/12/2021), contribuindo com a edificação da sustentabilidade da agropecuária nacional baseada na formulação de uma Inteligência Estratégica.

### **3 INDICADORES AGRO-SOCIOAMBIENTAIS (IS\_Agro)**

Definidos internacionalmente (FAO, OCDE<sup>1</sup>) como um conjunto de informações quantitativas disponíveis para avaliar e identificar os impactos econômicos, sociais e ambientais da agricultura e da pecuária e para medir o impacto de diferentes políticas públicas no meio ambiente, os IS\_Agro são fundamentais para planejar, implementar e monitorar o impacto de políticas públicas e projetos, públicos e privados, para a intensificação sustentável da Agricultura.

Como ferramentas para tomadores de decisão em todos os níveis os IS\_Agro devem:

- Estimar, mapear e qualificar os níveis de impacto da agricultura;
- Dar suporte ao planejamento agrícola e à elaboração, melhoria e avaliação de políticas públicas nos níveis federal, estadual e municipal; e,
- Dar suporte ao estabelecimento de metas e ações para o desenvolvimento sustentável da agropecuária brasileira.

---

<sup>1</sup> Organização para Cooperação e Desenvolvimento Econômico.

“Os impactos da agricultura sobre o meio ambiente e a conquista de uma agricultura sustentável são de grande preocupação pública no contexto da reforma da política agrícola, liberalização do comércio e acordos ambientais multilaterais. Os indicadores agroambientais permitem uma avaliação do desempenho ambiental da agricultura, considerando uma série de questões agroambientais relevantes para as políticas dos países da OCDE.”

(fonte: OECD. Compendium of Agri-environmental Indicators <http://dx.doi.org/10.1787/9789264181151-en>)

#### 4 MATERIAL E MÉTODOS

Este trabalho oferece duas soluções, a primeira baseia-se no uso de técnicas de inteligência artificial, mais especificamente *deep learning* através do modelo *deeplabv3+* para a obtenção de diagnóstico de degradação de pastagem via câmera de celular (*smartphone*), em uma abordagem local, ou seja, a nível de parcela/gleba, visando subsidiar a tomada de decisão do proprietário rural. A segunda utiliza imagens de sensores remotos orbitais (satélite) e algoritmo de *machine learning* para classificar a degradação de pastagem a nível regional, com enfoque no tomador de decisão a nível governamental. Nesta abordagem, buscou-se analisar abordagens inovadoras no campo do Sensoriamento Remoto e na integração de dados espaciais, se baseando em metodologias para detectar sistemas de produção agrícola alinhados aos princípios da agricultura com baixa emissão de carbono (BRASIL, 2012; KUCHLER et al., 2019, 2022).

#### 5 ABORDAGEM LOCAL NA PROPRIEDADE RURAL POR SMARTPHONE E DEEP LEARNING

Como ambiente computacional, o modelo *deeplabv3+* utilizado neste trabalho está disponível gratuitamente no repositório <https://github.com/tensorflow/models/tree/master/research/deeplab>. O modelo foi desenvolvido utilizando a linguagem de programação *Python* junto com a biblioteca *Tensorflow* (MARTÍN ABADI et al., 2015). Para este trabalho foi usada a versão do *python 2.7.18*, *Tensorflow* na versão *tensorflow-gpu 1.15*. O ambiente utilizado para executar o modelo foi a ferramenta *Google Colab* (“Google Colab”, [s.d.]).

As imagens usadas para o treinamento e validação do modelo foram retiradas do conjunto de imagens denominado “*The GrassClover Image Dataset*”



for *Semantic and Hierarchical Species Understanding in Agriculture*” (SKOVSEN et al., 2019). Esse conjunto é composto por 8000 imagens sintéticas de alta resolução, com anotações perfeitas, e está dividido em 15 classes.

Na criação do banco de treinamento e validação, foi utilizado um conjunto de 100 imagens selecionadas aleatoriamente da base de dados GrassClover. Devido às limitações do ambiente de execução, que não permitia o processamento das imagens em seu tamanho original, cada imagem foi dividida em pequenas partes (*slices*), com dimensões máximas de 512 x 512 pixels. Esse procedimento resultou em um total de 17.196 imagens. Além disso, o número de classes foi reduzido de 15 para 3. Para cumprir o objetivo do estudo, as classes de Solo Exposto e Gramíneas foram reclassificadas como Plantas Invasoras, conforme a definição de plantas invasoras, que são aquelas que crescem em locais indesejados. Na Figura 1, temos um exemplo que exhibe um *slice* de entrada e sua segmentação semântica correspondente.

Figura 1. Exemplo de um *slice* de entrada (a), com a imagem original e sua segmentação semântica correspondente (b), onde verde representa gramíneas, vermelho representa plantas invasoras e preto representa solo exposto



Fonte: Próprio autor.

Foram separadas de forma aleatória do conjunto de imagens em 2/3 para treinamento e 1/3 para validação.

As configurações do modelo DeepLabelV3+ para o processo de treinamento foram definidas como apresentada na tabela 1.

Tabela 1. Configurações do processo de treinamento

```
--logtostderr \  
--training_number_of_steps=50000 \  
--train_split="train" \  
--model_variant="xception_65", "resnet_101" e "mobilenet_v2" \  
--atrous_rates=6 \  
--atrous_rates=12 \  
--atrous_rates=18 \  
--output_stride=16 \  
--decoder_output_stride=4 \  
--train_crop_size="512,512" \  
--train_batch_size=1 \  
--optimizer="adam" \  
--fine_tune_batch_norm=False \  
--initialize_last_layer=False \  
--last_layers_contain_logits_only=True \  

```

Fonte: Próprio autor.

Para a abordagem regional por Sensoriamento Remoto, onde foram utilizadas séries temporais de Imagens de Satélite e algoritmos de *machine learning*, a avaliação dos níveis de degradação de pastagens por foi realizada na plataforma *Google Earth Engine* (GEE), por meio da elaboração de um código em linguagem de programação *JavaScript*. O GEE é uma plataforma de computação em nuvem desenvolvida pelo Google, focada no processamento e análise de grandes conjuntos de dados geoespaciais. Ele oferece uma variedade de ferramentas e recursos para cientistas, pesquisadores e desenvolvedores trabalharem com imagens de satélite, dados de Sensoriamento Remoto e informações geoespaciais para realizar análises espaciais e monitoramento ambiental (GORELICK et al., 2017). Deste modo, achou-se oportuno o uso de imagens de satélite Sentinel-2 (S2), devido as características das suas bandas espectrais (diversas bandas espectrais), bem com a resolução espacial (20m). Por conseguinte, com base nas características do processo de degradação de pastagens, bem como no estudo de diversos artigos científicos (ARVOR et al., 2011; BARONA et al., 2010; BELLÓN et al., 2017; CAO et al., 2018; HMIMINA et al., 2013; KUCHLER et al., 2020, 2022), calculou-se os índices de vegetação (IV) mais adequados para o presente estudo. Deste modo, as camadas (*layers*) usadas foram as seguintes: B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12, NCI, CRI2, STI, CAI, NDTI, NDVI, VIgreen, CRI1, RGR, NDI7, REP, TVI,

Transformação de Kauth-Thomas “*Tasseled Cap*” (brilho, verdor e umidade) e Textura18 GLCM (18 texturas GLCM), com série temporal de 1 ano.

Na fase de trabalho de campo foram coletadas amostras nos níveis de degradação N1 = 65, N2/N3 = 124 e N4 = 90, conforme a Figura 2.

Figura 2. Níveis de degradação de pastagens: N1, N2, N3 e N4, respectivamente



Fonte: Próprio autor.

Os níveis N2 e N3 foram mesclados devido à similaridade espectral de ambos.

## 6 RESULTADOS E DISCUSSÃO

Após os treinamentos com os dois bancos de imagens, pode-se calcular as métricas de avaliação citadas anteriormente, as tabelas (Tabela 2) e (Tabela 3) apresentam os resultados do primeiro banco e segundo banco de imagens, respectivamente.

Tabela 2. Resultados utilizando o primeiro banco de imagens (*The GrassClover Image Dataset for Semantic and Hierarchical Species Understanding in Agriculture*)

Xception 65				
	Solo	Invasora	Gramínea	Total
Precision	<b>97,7%</b>	<b>93,8%</b>	85,1%	-
S	97%	94%	<b>85,3%</b>	-
F1-Score	97,3%	94%	85%	-
IoU	94,8%	88,7%	74,2%	-
MIoU	-	-	-	85,9%
Pixel Accuracy	-	-	-	92,3%
MobileNet V2				
	Solo	Invasora	Gramínea	Total
Precision	95,5%	90,3%	86,6%	-
S	<b>98,8%</b>	94,8%	74,3%	-
F1-Score	97,1%	92,5%	79,9%	-
IoU	94,5%	86,1%	66,6%	-
MIoU	-	-	-	82,4%
Pixel Accuracy	-	-	-	90,3%
Resnet 101				
	Solo	Invasora	Gramínea	Total
Precision	97,4%	93,6%	<b>90,6%</b>	-
S	97,8%	<b>96,4%</b>	83,8%	-
F1-Score	<b>97,6%</b>	<b>95%</b>	<b>87,1%</b>	-
IoU	<b>95,3%</b>	<b>90,5%</b>	<b>77,1%</b>	-
MIoU	-	-	-	<b>87,6%</b>
Pixel Accuracy	-	-	-	<b>93,5%</b>

Fonte: Próprio autor.

Tabela 3. Resultados utilizando o segundo banco de imagens (Imagens do Brasil)

Xception 65					
	Solo	Invasora	Gramínea	Palhada	Total
Precision	85,5%	78,1%	77,6%	65,5%	-
S	87,2%	70,5%	82,9%	62%	-
F1-Score	86,4%	74,1%	80,1%	63,7%	-
IoU	76%	58,9%	66,9%	46,7%	-
MIoU	-	-	-	-	62,1%
Pixel Accuracy	-	-	-	-	79,3%
MobileNet V2					
	Solo	Invasora	Gramínea	Palhada	Total
Precision	83,3%	75%	67,1%	68,1%	-
S	91,1%	45,1%	82,6%	55,6%	-
F1-Score	87%	56,3%	74,1%	61,2%	-
IoU	77%	39,2%	58,8%	44,1%	-
MIoU	-	-	-	-	54,8%
Pixel Accuracy	-	-	-	-	76,3%
Resnet 101					
	Solo	Invasora	Gramínea	Palhada	Total
Precision	<b>88,7%</b>	<b>95%</b>	<b>86,1%</b>	<b>77,1%</b>	-
S	<b>91,3%</b>	<b>83%</b>	<b>91,6%</b>	<b>73,3%</b>	-
F1-Score	<b>89,9%</b>	<b>88,6%</b>	<b>88,8%</b>	<b>75,2</b>	-
IoU	<b>81,8%</b>	<b>79,6%</b>	<b>79,8%</b>	<b>60,2</b>	-
MIoU	-	-	-	-	<b>75,4%</b>
Pixel Accuracy	-	-	-	-	<b>86,8%</b>

Fonte: Próprio autor.

Inicialmente foi necessário o uso do conjunto de dados *The GrassClover Image Dataset for Semantic and Hierarchical Species Understanding in*

*Agriculture*, banco de imagens mais promissor encontrado que atendesse o objetivo deste trabalho. Depois da rotulação das classes para adequar o banco de imagens e recortes devido às limitações de hardware, o modelo DeepLabV3+ mostrou-se ser uma arquitetura confiável com resultados de MIoU até 87,6% utilizando o extrator de características ResNet 101.

Para tornar o modelo funcional com pastagens nacionais, um pequeno banco de imagens foi construído com fotografias do Brasil. Utilizou-se a técnica de transferência de aprendizado com os pesos obtidos no treinamento anterior, com objetivo de aumentar a eficiência do modelo com um pequeno montante de imagens. Diferente dos primeiros resultados, nesta etapa pode-se observar um destaque utilizando a rede convolucional ResNet 101 em comparação às demais redes, tendo os melhores resultados com as métricas apresentadas neste trabalho: *precision*, sensibilidade F1-score, IoU, MIoU e Pixel Accuracy; os valores de cada métrica podem ser observado na (Tabela 3), destacados em negrito.

Abordagem em escala Regional a partir da classificação digital de imagens de satélite e Machine Learning

- i. O processo de classificação foi realizado com base no algoritmo de classificação supervisionada *Random Forest*, a partir do qual, as camadas (*layers*) e as amostras coletadas em campo foram processadas no *Google Earth Engine*.
- ii. Na classificação supervisionada *Random Forest* foram utilizadas 500 árvores de decisão. O resultado da classificação é apresentado na Figura 03.
- iii. A Tabela 2 apresenta o controle estatístico para a avaliação da acurácia do mapa dos níveis de degradação das pastagens da área de estudo (Valença/RJ).


Tabela 2. Controle da acurácia da classificação *Random Forest* com base em (S2 + IV + Textura)

Série temporal	Nível de Degradação	Acurácia do Produtor	Acurácia do Usuário	F-score	Acurácia Global (AG)	Kappa (K)
1 ano (Jan – Dez)	N1	1	0.95	0.97	0.93	0.89
	N2N3	0.97	0.90	0.93		
	N4	0.81	0.95	0.88		

Fonte: Próprio autor.

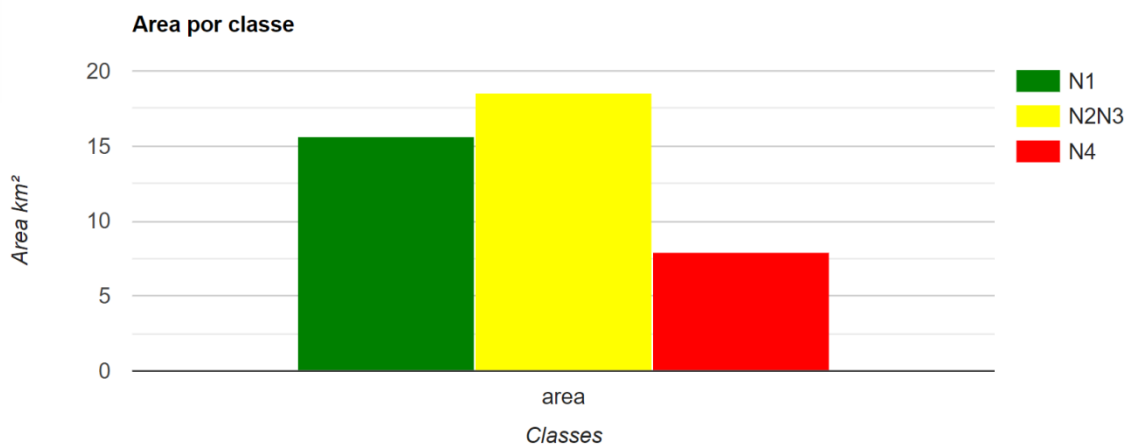
De acordo com a Tabela 02, consideram-se satisfatórias as acurácias (AG, K, F-Score) do mapa dos níveis de degradação das pastagens da área de estudo (Valença/RJ), resultante da classificação supervisionada *Random Forest*, conforme Figura 3.

Figura 3. Mapa dos níveis de degradação de pastagens da área de estudo (Valença/RJ) baseado em (S2 + IV + Textura)



Fonte: Próprio autor.

Figura 4. Áreas das classes N1, N2N3 e N4 do mapa apresentado na Figura 3.



Os resultados apresentaram 95,90% de acurácia total. Na figura 3 pode-se comparar a porcentagem de acertos de cada classe. Pode-se notar ainda que a classe com menor porcentagem é a classe Gramínea, com 92,18% de acurácia, o que pode ter ocorrido devido a diferença na quantidade de imagens do tipo Gramínea em relação a quantidade de imagens do tipo Planta daninha no processo de treinamento do modelo, uma vez que foram selecionadas 65 imagens de Plantas daninhas e 27 imagens de Gramíneas. O resultado visual pode ser analisado na figura 4.

## 7 CONCLUSÕES

Para a abordagem local com *deep learning*, a acurácia do modelo foi de 95,9%, provando seu ótimo desempenho e mostrando ser uma excelente ferramenta para segmentação semântica, sendo assim, poderá ser usado para auxiliar a classificação do nível da degradação de pastagens degradadas com mais precisão a partir de uma imagem. Dentre as alternativas e possíveis abordagens para o desenvolvimento de soluções para o problema explicitado, o presente trabalho se destaca pelo seu caráter inovador ao propor o desenvolvimento de uma solução alicerçada em tecnologias de grande alcance em termos de acessibilidade, comunicação e funcionalidade.

Para a abordagem regional por *machine learning* e uso de séries temporais por satélite Sentinel-2, sabe-se que algoritmos de aprendizado de máquina, como o *random forest*, aprendem melhor quanto maior for a quantidade de



informações. Por isso, na metodologia proposta foi necessário a aplicação de uma série temporal de 1 ano para a separabilidade dos níveis de degradação das pastagens. Por fim, a metodologia proposta (S2 + IV + Textura18) se mostrou robusta, eficiente e eficaz para o objetivo proposto de separabilidade dos níveis de degradação de pastagens por meio de técnicas de Sensoriamento Remoto e Processamento Digital de Imagens, obtendo-se acurácia satisfatória (AG = 0.93 e K = 0.89).

As metodologias apresentadas para diferentes escalas de tomada de decisão, se alinham às tendências atuais da convergência da tecnologia da informação e comunicação (TIC) aliadas às novas ferramentas de tecnologia operacional (TO), dispositivos com tecnologias incorporadas e aplicativos orientados para o usuário com base em ferramentas computacionais de gestão e processamento de dados (Webservices, SIGWeb, Big Data, Computação em Nuvens, Processamento Paralelo e Modelagem Cognitiva). Assim, com base no potencial e escalabilidade dos serviços web a estratégia adotada é a de disponibilizar um serviço especializado via web para os mapeamentos obtidos, que agregue valor para o usuário pela interatividade, praticidade e rapidez na caracterização do problema e oferta de soluções correlatas, atendendo deste modo às demandas dos beneficiários e usuários.

Considerando que o problema das áreas degradadas com pastagens ou em abandono encontra-se disseminado em quase todas as regiões rurais do país, a solução tem aplicação generalizada para qualquer região de produção agropecuária. Considerando, ainda, que a metodologia por satélite, tem como público alvo os tomadores de decisão, planejadores e organismos governamentais, e que a metodologia baseada em classificação a partir de fotos de smartphone por *deep learning*, tratar-se de uma metodologia orientada a resolução dos problemas de áreas degradadas no nível operacional, ou seja, no âmbito das propriedades rurais, a solução tem como público-alvo os produtores rurais e/ou profissionais, engenheiros ou técnicos agrícolas da extensão rural ou assistência técnica. Neste caso, cabe ressaltar, que a ideia essencial é possibilitar que o próprio produtor ou seu encarregado possam fazer uso da metodologia proposta.

Por fim espera-se que estas soluções tecnológicas contribuam para os objetivos do Projeto IS\_Agro através do cálculo de indicadores agrosocioambientais. Tendo e vista que os impactos da agricultura sobre o meio ambiente e a conquista de uma agricultura sustentável são de grande preocupação pública. Os indicadores agroambientais permitem uma avaliação do desempenho ambiental da agricultura, considerando uma série de questões agroambientais relevantes para as políticas dos países.

### AGRADECIMENTOS

Os autores agradecem a Embrapa Solos (Projeto REINSERTEC) e a Universidade do Estado do Rio de Janeiro – UERJ (Faculdade de Engenharia, Departamento de Engenharia de Sistemas e Computação) e ao Programa de doutorado em Meio Ambiente (PPGMA/UERJ) que deram o suporte técnico-científico e acadêmico necessário para a realização do presente trabalho. Agradecemos ainda ao CNPq pelo financiamento na forma de bolsa de iniciação científica (PIBIC). Agradecemos também a todos os parceiros do Projeto IS\_Agro – Indicadores Agro-Socioambientais do Brasil: Inteligência Estratégica para a Sustentabilidade da Agropecuária Nacional, Executado pela Embrapa e Financiado pelo Ministério de Agricultura e Pecuária (Termo de Execução Descentralizada nº 450/2021 celebrado em 23/12/2021).

## REFERÊNCIAS

ARVOR, D. et al. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil. *International Journal of Remote Sensing*, v. 32, n. 22, p. 7847–7871, 20 nov. 2011.

BARONA, E. et al. The role of pasture and soybean in deforestation of the Brazilian Amazon. *Environmental Research Letters*, v. 5, n. 2, p. 024002, abr. 2010.

BELLÓN, B. et al. A Remote Sensing Approach for Regional-Scale Mapping of Agricultural Land-Use Systems Based on NDVI Time Series. *Remote Sensing*, v. 9, p. 600, 2017.

BRASIL. Plano ABC – Agricultura de Baixa Emissão de Carbono. Disponível em: <<https://www.gov.br/agricultura/pt-br/assuntos/sustentabilidade/plano-abc/plano-abc-agricultura-de-baixa-emissao-de-carbono>>. Acesso em: 14 jan. 2021.

CAO, R. et al. A simple method to improve the quality of NDVI time-series data by integrating spatiotemporal information with the Savitzky-Golay filter. *Remote Sensing of Environment*, v. 217, p. 244–257, nov. 2018.

CHEN, Liang-Chieh et al. Encoder-decoder with atrous separable convolution for semantic image segmentation. In: *Proceedings of the European conference on computer vision (ECCV)*. 2018. p. 801-818.

DOMINATI, Estelle; PATTERSON, Murray; MACKAY, Alec. A framework for classifying and quantifying the natural capital and ecosystem services of soils. *Ecological Economics*, v. 69, n. 9, p. 1858-1868, 2010.,

EMBRAPA. *GeoABC: Metodologias e inovações tecnológicas para o monitoramento e o planejamento da agricultura de baixa emissão de carbono em apoio à governança do Plano ABC*. 2015.

FAO. *The State of Food Security and Nutrition in the World Security: Transforming Food Systems for Food Security, Improved Nutrition and Affordable Healthy Diets for All*. 2021.

FAO e ITPS. Status of the World's Soil Resources (SWSR) – Technical Summary. Food and Agriculture Organization of the United Nations and Intergovernmental Technical Panel on Soils. Italy, Rome.77p., 2015.

FAO. Food and Agriculture Organization of the United Nations (FAO). *The State of Food and Agriculture: Livestock in the Balance*. 2009.

GAUTRONNEAU, Y. & MANICHON, H. Guide méthodique du profil cultural. Lyon, CEREF-GEARA, 1987. 71p

Google Colab. Disponível em: <<https://research.google.com/colaboratory/intl/pt-BR/faq.html>>. Acesso em: 19 dez. 2023.

GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, v. 202, p. 18–27, dez. 2017.

HMIMINA, G. et al. Evaluation of the potential of MODIS satellite data to predict vegetation phenology in different biomes: An investigation using ground-based NDVI measurements. *Remote Sensing of Environment*, v. 132, p. 145–158, maio 2013.

IPCC. *Assessment Report 6 Climate Change 2021: The Physical Science Basis*. 2021

KUCHLER, P. C. et al. SENSORIAMENTO REMOTO E ANÁLISE ESPACIAL: UMA CONTRIBUIÇÃO PARA O MAPEAMENTO DOS SISTEMAS INTEGRADOS DE PRODUÇÃO AGROPECUÁRIA. Em: *Aplicações e Princípios do Sensoriamento Remoto 3*. [s.l.] Atena Editora, 2019. p. 1–10.

KUCHLER, P. C. et al. Assessing the optimal preprocessing steps of MODIS time series to map cropping systems in Mato Grosso, Brazil. *International Journal of Applied Earth Observation and Geoinformation*, v. 92, p. 102150, out. 2020.

KUCHLER, P. C. et al. Monitoring Complex Integrated Crop&ndash;Livestock Systems at Regional Scale in Brazil: A Big Earth Observation Data Approach. *Remote Sensing*, v. 14, n. 7, 2022.

LAPIG, GO. Atlas das Pastagens. Disponível em: <<https://atlasdaspastagens.ufg.br>>. Acesso em: 19 set. 2023.

M. B. Dias-Filho. *Degradação de pastagens: processos, causas e estratégias de recuperação*. 4 ed. Embrapa Amazônia Oriental. 2015.

MapBiomas. *Projeto MapBiomas – Coleção 6 da Série Anual de Mapas de Uso e Cobertura da Terra do Brasil*. 2021.

MARTÍN ABADI et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems. , 2015. Disponível em: <https://www.tensorflow.org/>.

Ministério da Agricultura Pecuária e Abastecimento. *Plano Setorial de Mitigação e Adaptação às Mudanças Climáticas para Consolidação da Economia de Baixa Emissão de Carbono na Agricultura – Plano ABC*. 2012.

ONU. *World population prospects 2019*. 2019.

PARENTE, L. FERREIRA, L. Assessing the spatial and occupation dynamics of the Brazilian pasturelands based on the automated classification of MODIS images from 2000 to 2016. *Remote Sensing*. v. 10, nº 4: pp. 606, 2018.

PAULINO, V.T.; SCHUMANN, A.M.; SILVA, S.C.; RASQUINHO, N.M.; SANTOS, K.M. Impactos ambientais da exploração pecuária em sistemas intensivos de pastagens. Informe Agropecuário, Belo Horizonte, v.33, n.266, p.17-24, 2012.

PEREIRA, J.R.P.; SILVA, W. Controle de plantas daninhas em pastagens. Instrução Técnica para o produtor de leite. Juiz de Fora: EMBRAPA, 2000. 20p.

RALISCH, R., DEBIASI, H., FRANCHINI, J., TOMAZI, M., HERNANI, L., MELO, A. D. S., ... & MARTINS, A. D. S. (2017). Diagnóstico rápido da estrutura do solo-DRES. Embrapa Soja-Documentos (INFOTECA-E).

SALDANHA, Marcus FS; FREITAS, C. Segmentação de imagens digitais: Uma revisão. Divisão de Processamento de Imagens-Instituto Nacional de Pesquisas Espaciais (INPE), São Paulo, 2009.

SILVA, A.A.; WERLANG, R.C.; FERREIRA, L.R. Controle de plantas daninhas em pastagens. In: SIMPÓSIO SOBRE MANEJO ESTRATÉGICO DA PASTAGEM, 1., 2002, Viçosa. Anais... Viçosa: SBZ, 2002, p. 273-310.

SILVA, D.S.M.; DIAS FILHO, M.B. Banco de sementes de plantas daninhas em solo cultivado com pastagens de Brachiaria brizantha e Brachiaria humidicola de diferentes idades. Planta Daninha, Viçosa-MG. v.19, n.2, p.179-185, 2001.

SKOVSEN, S. et al. The GrassClover Image Dataset for Semantic and Hierarchical Species Understanding in Agriculture. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Anais.2019.

SOLOS, Embrapa. Sistema brasileiro de classificação de solos. Centro Nacional de Pesquisa de Solos: Rio de Janeiro, 2013.

TAVARES FILHO, J. et al. Método do perfil cultural para avaliação do estado físico de solos em condições tropicais. Revista Brasileira de Ciência do Solo, v. 23, n. 2, 1999.

UNCCD, United Nations Conventional for Combat Desertification, 2018.