

# Deep learning e segmentação semântica de imagens para diagnóstico de níveis de degradação de pastagem.

Luan Porto Vieira<sup>1</sup>, Margareth Simões<sup>2</sup>, Rodrigo P D Ferraz<sup>3</sup> e João Araújo Ribeiro<sup>4</sup>

<sup>1</sup>Estudante de graduação em Engenharia de Sistemas e Computação (UERJ/DESC), luanportovieira@gmail.com;

<sup>2</sup>Engenheira, Doutora, Pesquisadora da Embrapa Solos e Professora do Dep. de Sistemas e Computação (UERJ/DESC), margareth.simoies@embrapa.br; <sup>3</sup>Engenheiro Agrônomo, Doutor, Pesquisador da Embrapa Solos - Rio de Janeiro, rodrigo.demonte@embrapa.br; e <sup>4</sup>Engenheiro, Doutor e Professor do Dep. De Sistemas e Computação (UERJ/DESC), araujo@eng.uerj.br

## RESUMO

O processo de degradação de pastagem pode ser identificado quando a produção de forragem diminui, conseqüentemente, o aumento das áreas descobertas e plantas invasoras. Este trabalho objetivou avaliar técnicas de segmentação semântica de fotografias para diferenciação de plantas invasoras, forrageiras, solo exposto e palhada por meio do modelo DeeplabV3+. Primeiramente o modelo foi treinado com amostras do banco de dados The GrassClover Image Dataset for Semantic and Hierarchical Species Understanding in Agriculture. Um pequeno banco de dados foi construído a partir das fotografias ortogonais, retiradas da plataforma Atlas das Pastagens. Após o processo de treinamento com os dois bancos de imagens os resultados demonstraram satisfatórios com valores de MIoU de 87,6% com o primeiro banco de imagens e 75,4% com segundo banco de imagens. Conclui-se que as técnicas de segmentação semântica de imagens apresentam potencial para subsidiar a classificação da degradação de pastagens.

**Palavras-chave** — Visão Computacional, Aprendizado de máquina, Redes Neurais Convolucionais, Plano ABC.

## ABSTRACT

*The process of pasture degradation can be identified when forage production decreases, consequently, the increase in uncovered areas and weed plants. This work aimed to evaluate techniques of semantic segmentation of photographs to differentiate weed plants, forages, soils and straw by using the DeeplabV3+ model. First, the model was trained with samples from The GrassClover Image Dataset for Semantic and Hierarchical Species Understanding in Agriculture. A small database was built from the orthogonal photographs taken from the Atlas das Pastagens platform. After the training process with the two datasets, the results were satisfactory, with MIoU values of 87.6% with the first dataset and 75.4% with the second dataset. It is concluded that semantic image segmentation techniques have the potential to support the classification of pasture degradation.*

**Key words** — Computer Vision, Machine learning, Convolutional Neural Network, Plano ABC.

## 1. INTRODUÇÃO

O Brasil é um dos líderes em produção pecuária do mundo, onde é caracterizado, em sua maioria, pela exploração extensiva baseada em sistema de pastejo sob pastagens naturais ou cultivadas com baixo emprego encontrado de capital e tecnologia. Um dos problemas da relativa baixa produtividade do setor é devido ao mal estabelecimento e/ou ao mal manejo das pastagens que condicionam a baixa capacidade de suporte e o desencadeamento de processos de degradação. Estima-se que 80% das pastagens cultivadas presentes do Brasil encontram-se em algum nível de degradação, sendo que essa problemática afeta diretamente a sustentabilidade da pecuária [1].

Degradação das pastagens é definido como um processo evolutivo da perda do vigor, de produtividade, da capacidade de recuperação natural das pastagens para sustentar os níveis de produção e qualidade exigida pelos animais, bem como o de superar os efeitos nocivos de pragas, doenças e invasoras, culminando com a degradação avançada dos recursos naturais em razão de manejos inadequados [2].

Uma pastagem está em processo de degradação quando a produção de forragem diminui com a redução da sua qualidade e quantidade, mesmo nas épocas favoráveis ao seu crescimento. Há diminuição na área coberta do solo pela pastagem e existe pequeno número de plantas novas, provenientes da ressemeadura natural. O aparecimento de espécies invasoras de folha larga, competindo por nutrientes e de processos erosivos pela ação das chuvas, promovendo a colonização da pastagem por gramíneas nativas [3].

Para contribuir com a solução deste problema é proposto neste trabalho uma abordagem de segmentação semântica automática entre plantas daninhas, gramíneas, solo exposto e material seco (palhada) a partir de fotografias, através das técnicas de Visão Computacional e Aprendizado de Máquina.

A segmentação é de fundamental importância para a fase de análise do processo de classificação, pois por meio dela

torna-se possível extrair informações valiosas a partir das imagens digitais [4]. A tarefa de segmentação semântica é complexa e é uma das poucas áreas de visão computacional em que o desempenho das redes neurais profundas está além da performance humana.

O objetivo desse artigo foi avaliar o desempenho do modelo Deeplabv3+ para segmentação semântica de fotografias ortogonais de pastagens contendo gramíneas, plantas invasoras, solo exposto e palhada, visando subsidiar a classificação da degradação de pastagens.

## 2. MATERIAL E MÉTODOS

### 2.1. Ferramenta

O modelo de segmentação semântica DeepLabV3+ foi construído no ano de 2018 com uma arquitetura FCN (Fully Convolutional Network)[5]. O modelo pode ser acessado gratuitamente no repositório <https://github.com/tensorflow/models/tree/master/research/deeplab>, desenvolvido na linguagem de programação Python junto com a biblioteca Tensorflow. Para este trabalho, foi usado a versão de julho de 2020 do modelo Deeplabv3+, Python na versão 2.7.18 e Tensorflow na versão tensorflow-gpu 1.15. O ambiente escolhido para executar o modelo foi a ferramenta Google Colaboratory, a ferramenta torna possível o desenvolvimento de aplicações de machine learning através do navegador além da disponibilidade de placas gráficas que aceleram o processo de treinamento dos modelos.

### 2.2. Bancos de imagens

A obtenção de imagens relacionadas a pastagens segmentadas é geralmente um grande desafio. A base mais promissora encontrada é denominada como The GrassClover Image Dataset for Semantic and Hierarchical Species Understanding in Agriculture [6]. O conjunto de imagens é composto por 8000 imagens sintéticas de alta resolução com anotações perfeitas, divididas em 15 classes.


O primeiro banco de imagens é constituído por 100 imagens, escolhida de forma aleatória, do Dataset GrassClover. Devido às limitações do ambiente de execução, que não suportava a realização das imagens do tamanho original, cada imagem foi dividida em pequenas imagens de tamanho máximo de 512 x 512 pixels resultando em 17196 imagens. A escolha do recorte das imagens e não do redimensionamento foi optado devido às perdas de informações no processo de diminuição da imagem, sendo assim, afetando a acurácia do modelo de segmentação semântica.

Fora os recortes das imagens, o número de classes foi alterado de 15 para 3 classes. A fim de atender o objeto do trabalho, às classes diferentes de Solo Exposto e Gramíneas foram remarcadas como Plantas Invasoras, com a finalidade

de atender a definição de plantas invasoras, como plantas que crescem onde não são desejadas [7].

Para trazer a solução para as pastagens brasileiras, o segundo banco de imagens foi construído a partir das fotografias ortogonais de pastagens brasileiras, retiradas da plataforma Atlas das Pastagens (<https://atlasdaspastagens.ufg.br/map>). Cada imagem foi recortada seguindo a mesma regra do primeiro banco de imagens.

A partir das imagens recortadas, cada recorte foi segmentado manualmente com o auxílio do editor de imagens GIMP e de um algoritmo construído em Python pelos autores. Por ser um processo penoso, o segundo banco é constituído por 110 imagens com 4 classes, além das classes Solo Exposto, Gramínea e Planta Invasora; foi adicionada a classe Palhada. O exemplo das imagens dos bancos de dados, seguido da segmentação, podem ser observados na (Figura 1).



**Figura 1. Exemplos das imagens dos bancos de dados; a) e b) pertencem ao primeiro banco de imagens, onde b) é a segmentação semântica de a); c) e d) pertencem ao segundo banco de imagens, onde, d) é a segmentação semântica de c)**

### 2.3. Metodologia

O desenvolvimento desta pesquisa foi efetuada através das etapas descritas a seguir:

- Acesso ao data set The GrassClover;
- Seleção das 100 imagens, recorte e remarcação;
- Seleção das fotografias do Atlas das Pastagens, recorte e segmentação;
- Configuração do modelo DeepLabV3+ na plataforma Google Colab;
- Divisão dos Bancos de imagens em  $\frac{2}{3}$  para treinamento e  $\frac{1}{3}$  para validação
- Treinamento com o primeiro banco;
- Validação com o primeiro banco;
- Treinamento com o segundo banco, usando os pesos adquiridos no primeiro treinamento;

- Validação com o segundo banco.

Os bancos foram treinados e validados utilizando os três extratores de características disponíveis: Xception 65, MobileNet V2 e ResNet 101.

### 2.4. Análise estatística

Para avaliação dos modelos de segmentação semântica, as seguintes métricas podem ser utilizadas: Precision, Pixel Accuracy, Intersection Over Union (IoU), Mean Intersection Over Union (MIoU) e F1-Score. Todas as métricas citadas, podem ser encontradas a partir da matriz de confusão seguindo as equações a seguir:

$$Precision = \frac{TP}{TP+FP}$$

$$Pixel Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

$$IoU = \frac{TP}{TP+FN+FP}$$

$$MIoU = \frac{\sum_{i=1}^n IoU_i}{n}$$

$$S = \frac{TP}{TP+FN}$$

$$F1 - Score = \frac{Precision \times S}{Precision + S}$$

### 3. RESULTADOS

Após os treinamentos com os dois bancos de imagens, pode-se calcular as métricas de avaliação citadas anteriormente, as tabelas (Tabela 1) e (Tabela 2) apresentam os resultados do primeiro banco e segundo banco de imagens, respectivamente.

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>

**Tabela 1. Resultados utilizando o primeiro banco de imagens (The GrassClover Image Dataset for Semantic and Hierarchical Species Understanding in Agriculture)**

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>

**Tabela 2. Resultados utilizando o segundo banco de imagens (Imagens do Brasil)**

#### 4. DISCUSSÃO

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 2), destacados em negrito.

#### 5. CONCLUSÕES

No contexto da segmentação semântica de pastagens, esse trabalho apresenta a aplicação do modelo de segmentação

semântica DeeplabV3+. Diante dos resultados apresentados, pode-se concluir que o modelo DeepLabV3+ é apto em realizar a segmentação semântica nos dois bancos apresentados neste trabalho, sendo assim, o modelo pode subsidiar a classificação da degradação de pastagens.

#### 6. REFERÊNCIAS

- [1] Paulino, V. T., Schumann, A. M., da Silva, S. C., Rasquinho, N. M., & dos Santos, K. M. Impactos ambientais da exploração pecuária em sistemas intensivos de pastagem, *Informe Agropecuário, Belo Horizonte*, volume 33:páginas 7-14, 2012.
- [2] Macedo, M. C. M., and Zimmer, A. H. Sistema pasto-lavoura e seus efeitos na produtividade agropecuária, *Simpósio sobre ecossistema de Pastagens*, volume 2:páginas 216-245, 1993.
- [3] Soares Filho, C. V., Monteiro, F. A., & Corsi, M. Recuperação de pastagens degradadas de *Brachiaria decumbens*. 2. Variação sazonal de parâmetros bioquímico-fisiológicos, *Pasturas Tropicales*, volume 14:páginas 7-13, 1992.
- [4] Saldanha, M. F., and FREITAS, C. Segmentação de imagens digitais: Uma revisão, *Divisão de Processamento de Imagens-Instituto Nacional de Pesquisas Espaciais (INPE), São Paulo*, 2009.
- [5] Long, J., Shelhamer, E., and Darrell, T. Fully convolutional networks for semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, volume 1:páginas 3431-3440, 2015..
- [6] Skovsen, S., Dyrmann, M., Mortensen, A. K., Laursen, M. S., Gislum, R., Eriksen, J., and Jorgensen, R. N. The GrassClover image dataset for semantic and hierarchical species understanding in agriculture, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 2019.
- [7] Voll, E., Gazziero, D. L. P., Brighenti, A. M., Adegas, F. S., Gaudêncio, C. D. A., & Voll, C. E. A dinâmica das plantas daninhas e práticas de manejo, *Londrina: Embrapa Soja*, volume 260, 2005..