

# MAPEAMENTO DA CAPACIDADE DE SUPORTE NA PRODUÇÃO DE BOVINOS A PASTO OBTIDA POR SENSORIAMENTO REMOTO

*Data de aceite: 02/09/2024*

**Hadilson Chaves Rodrigues de Miranda**

Universidade de Federal Viçosa  
Florestal – Minas Gerais (Brasil)

**Leonardo França da Silva**

Universidade Federal da Grande  
Dourados  
Dourados – Mato Grosso do Sul (Brasil)  
<https://orcid.org/0000-0002-9710-8100>

**João Carlos de Freitas Alves**

Universidade de Federal Viçosa  
Florestal – Minas Gerais (Brasil)

**Jessica Mansur Siqueira Crusóé**

Universidade de Federal Viçosa  
Florestal – Minas Gerais (Brasil)  
<https://orcid.org/0009-0007-4210-8430>

**Cristiano Márcio Alves de Souza**

Universidade Federal da Grande  
Dourados  
Dourados – Mato Grosso do Sul (Brasil)  
<https://orcid.org/0000-0002-5347-1709>

**Luciano José Minette**

Universidade Federal de Viçosa, Campus  
Viçosa  
Viçosa - MG (Brasil)  
<https://orcid.org/0000-0002-2038-334X>

**Denis Medina Guedes**

Universidade Federal de Viçosa  
Florestal - Minas Gerais (Brasil)  
<https://orcid.org/0009-0004-9847-8471>

**RESUMO:** A pecuária brasileira é em sua maioria a pasto, o que torna a avaliação das pastagens algo extremamente necessário. Nesse sentido a análise das imagens obtidas a partir sensores presentes nos satélites, se tornou uma importante ferramenta para a análise das pastagens. Dentre os objetivos desse trabalho estão: coletar dados de produtividade de matéria seca de uma pastagem degradada em um período seco; mapear diferentes índices de refletância da pastagem nas áreas estudadas, como o NDVI, SAVI e CO<sub>2</sub>-Flux; analisar a correlação entre a matéria seca e os índices mapeados; e mapear a capacidade de suporte na produção de bovinos a pasto obtida por sensoriamento remoto. A correlação entre os índices de reflectância e a matéria seca, obtiveram os seguintes valores:  $r = 0,54$  para CO<sub>2</sub>-Flux,  $r = 0,67$  para SAVI e  $r = 0,70$  para NDVI. O NDVI foi o que apresentou maior correlação entre os índices. Por esse motivo, foi gerado uma regressão linear com o intuito de estimar a capacidade de suporte em função dos valores de NDVI. A regressão apresentou valor de  $R^2 = 0,47$ , o que indica que o modelo explica 47% da variabilidade da variável resposta. A partir da equação gerada pela regressão linear, foi feito um

mapa da capacidade de suporte da área. O mapa gerado nos permite ter uma ideia da capacidade de suporte da área analisada, porém apenas a observação do mapa não nos possibilita ter uma visão real da área, pois possui intervalos muito amplos entre os valores de UA por hectare. Dessa forma ao definir o número de animais apenas observando o mapa há chance de faltar ou sobrar forragem, logo definir a capacidade de suporte apenas pelo mapa gerado não seria a melhor forma de manejo possível. Como sugestão para a criação de um modelo que explique melhor a capacidade de suporte em função do NDVI, deve-se realizar o mesmo experimento em uma área mais uniforme, bem manejada, não degradada, e sem a presença de matas. Além disso, atribuir outros fatores para criação do modelo, como o índice de área foliar, dados de precipitação e doses de fertilizantes podem melhorar a funcionalidade do modelo.

**PALAVRAS-CHAVE:** Agricultura digital; Geoestatística; Pecuária de corte.

**ABSTRACT:** Brazilian livestock farming is predominantly pasture-based, which makes the evaluation of pastures extremely necessary. In this context, the analysis of images obtained from sensors present on satellites has become an important tool for pasture analysis. The objectives of this study include: collecting dry matter productivity data from a degraded pasture during a dry period; mapping different reflectance indices of the pasture in the studied areas, such as NDVI, SAVI, and CO<sub>2</sub>-Flux; analyzing the correlation between dry matter and the mapped indices; and mapping the carrying capacity for cattle production on pasture obtained by remote sensing. The correlation between the reflectance indices and dry matter yielded the following values:  $r=0.54$  for CO<sub>2</sub>-Flux,  $r=0.67$  for SAVI, and  $r=0.70$  for NDVI. NDVI showed the highest correlation among the indices. For this reason, a linear regression was generated to estimate the carrying capacity based on NDVI values. The regression presented an  $R^2$  value of 0.47, indicating that the model explains 47% of the variability of the response variable. Based on the equation generated by the linear regression, a carrying capacity map of the area was created. The generated map allows us to get an idea of the carrying capacity of the analyzed area; however, merely observing the map does not provide a realistic view of the area, as it has very wide intervals between values of AU per hectare. Therefore, defining the number of animals by only observing the map could result in either a shortage or surplus of forage, making it clear that defining carrying capacity based solely on the generated map would not be the best management approach. As a suggestion for creating a model that better explains carrying capacity based on NDVI, the same experiment should be conducted in a more uniform, well-managed, non-degraded area without the presence of forests. Additionally, incorporating other factors into the model, such as leaf area index, precipitation data, and fertilizer doses, may improve the model's functionality.

**KEYWORDS:** Digital Agriculture; Geostatistics; Beef Cattle Farming

## INTRODUÇÃO GERAL

Na década de 1970, as primeiras pastagens oriundas da África começaram a chegar no Brasil, principalmente a *Brachiaria decumbens*, hoje conhecida como *Urochloa decumbens*. Cultivar esta que é extremamente adaptada a solos ácidos e de baixa fertilidade. Nesse período houve um aumento na taxa de lotação que passou de 0,9 para 1 animal por hectare. O ganho de peso dos animais também aumentou em 2 a 3 vezes se comparado a pastagem nativa em um mesmo período. O resultado disso foi um grande aumento na exploração da pecuária no país (BORGHI, et al., 2018).

Em 2017 as áreas de pastagens ocupavam cerca de 178 milhões de hectares (PARENTE, et al., 2017), já o rebanho bovino brasileiro em 2022 conta com 234,6 milhões de cabeças de gado, esse dado faz parte da Pesquisa da Pecuária Municipal (PPM), divulgada pelo Instituto Brasileiro de Geografia e Estatística (IBGE 2022). A pecuária brasileira é em sua maioria a pasto, o que torna a avaliação das pastagens algo extremamente necessário.

A análise das imagens obtidas a partir sensores presentes nos satélites, se tornou uma importante ferramenta para a análise das pastagens. Conforme Souza Jr, et al., (2020), entre 1985 e 2020 essa ferramenta permitiu avaliar a qualidade das pastagens brasileiras e constatar uma queda nas áreas com sinais de degradação de 70% em 2000 para 53% em 2020. Apesar dos progressos notáveis, a atividade pecuária ainda é vista como uma grande “vilã” do agronegócio brasileiro.

Atualmente, a produção de carne e leite é a principal fonte de emissões de gases que contribuem para o efeito estufa, especialmente devido à forma como tem sido conduzida desde seu crescimento a partir da década de 1970. De maneira geral, a pecuária até a década de 1990 buscou a expansão das áreas de pastagens. Esse modelo extrativista passou a ser menos atrativo a partir de 1990, a razão disso foi a necessidade de um modelo de negócio sustentável e competitividade acirrada dentro do mercado. Na busca para aumentar a produtividade de leite e carne por hectare, os produtores inicialmente investiram em cruzamentos genéticos entre raças zebuínas e europeias. Entretanto, a questão alimentar dos animais ainda não estava planejada como deveria, por essa razão a questão genética sozinha não foi capaz de apresentar ganhos de produtividade satisfatórios (BORGHI, et al., 2018).

Na COP15, o Brasil se comprometeu a reduzir a emissões de gases do efeito estufa em até 1 bilhão de toneladas até 2020. Uma das alternativas propostas para o cumprimento dessa meta foi a recuperação das pastagens degradadas, a recuperação dessas áreas está prevista no plano ABC (Agricultura de baixa emissão de carbono), instituído pelo MAPA (Ministério da Agricultura, pecuária e abastecimento) (TERRA, et al., 2019). Segundo o IEMA (Instituto de energia e meio ambiente), em 2020 as emissões dos gases do efeito estufa aumentaram em 9,5% no Brasil, enquanto no mundo inteiro diminuíram 7% devido a pandemia da Covid 19 (POTENZA, et al., 2021).

Pastagens degradadas provocam a diminuição no sequestro de carbono que representa uma compensação às emissões de metano e óxido nitroso. Em contrapartida, o manejo adequado das pastagens traz benefícios como maior produção forrageira, maior eficiência no uso das forragens, maior produção animal por área, o retorno econômico, melhorar a distribuição estacional de forragem e garantir a persistência da pastagem (PAULINO, et al., 2009).

Vários fatores indicam o estado de degradação das pastagens, são eles: A presença de invasoras, a alta percentagem de solo exposto, os cupins e a erosão são indicadores de pastagens degradadas. Entretanto, é indispensável ferramentas para auxiliar a caracterização e monitorar as pastagens, com o intuito de recuperá-las. No contexto da degradação das pastagens, o uso de índices de vegetação pode ser uma ferramenta importante para a identificação de áreas degradadas. Isso ocorre porque os índices de vegetação se relacionam com a quantidade de biomassa, que é um indicador direto dos níveis de degradação (FERRARI, et al., 2009).

Diante do referido exposto objetivou-se mapear a produtividade de pastagem e capacidade de suporte de produção de bovinos, através de índices de refletância obtidos por sensoriamento remoto.

## **MATERIAL E MÉTODOS**

### **Realização do experimento**

Este experimento foi realizado em duas áreas distintas da Universidade Federal de Viçosa – Campus Florestal. Para o desenvolvimento do experimento foi criado um mapa do perímetro para cada uma dessas áreas, e foram definidos aleatoriamente 20 pontos para coleta da Parte aérea da vegetação encontrada. A partir da composição colorida das imagens das áreas foi feita uma avaliação da localização dos pontos amostrais, de forma a realocar pontos que foram gerados para que não sobrepuassem uma área de mata presente no local.

Todo este processo foi feito por meio do software QGIS, com imagens obtidas pelo sensor PS2.SD (PlanetScope SuperDove) que possui resolução de imagem de 3 metros por pixel. Os mapas com os pontos foram carregados no aplicativo 4farm, dessa forma foi possível encontrar os pontos com o uso do GPS de navegação do celular. Em um raio de até 2m dos pontos marcados, foram coletadas 3 subamostras da parte aérea da vegetação para cada ponto.

Para essa coleta foi utilizado um quadrado de 50x50cm sendo então uma área de 0,25m<sup>2</sup> e as 3 subamostras, colocadas em um saco de ráfia, foram misturadas e pesadas para gerar uma amostra uniforme de 100g. No total foram 20 amostras para cada área, as amostras coletadas foram levadas para uma estufa com circulação de ar forçada, na

temperatura de 65°C, durante 72 horas para determinação da matéria seca seguindo metodologia convencional de estufa (BORGES et al., 2011). O cálculo de matéria seca foi realizado por meio da equação (1).

Os mapas dos índices de refletância (NDVI, SAVI e CO2 Flux), foram elaborados no software QGIS a partir de imagens feitas pelo sensor PS2.SD (PlanetScope SuperDove): Este sensor é usado para coletar imagens com resolução espacial de 3m. As bandas das imagens obtidas através desse sensor são nos comprimentos de onda referentes a: Banda 1: Blue, Banda 2: Green, Banda 3: Red, Banda 4: NIR.

$$\%MS = \frac{Ps * 100}{Pu} \quad (1)$$

onde:

*MS* = Matéria seca

*Ps* = Peso seco

*Pu* = Peso úmido

O cálculo de matéria seca por hectare foi feito por meio da seguinte equação (2).

$$MS \text{ kg por ha}^{-1} = \left( \frac{Put * 10.000m^2}{0,75m^2 * 1000} \right) * \frac{\%MS}{100} \quad (2)$$

onde:

O índice NDVI foi elaborado por meio da seguinte equação (3).

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (3)$$

O índice SAVI foi previsto pela seguinte equação (4).

$$SAVI = (1 + L) * \frac{NIR - RED}{(NIR + RED + L)} \quad (4)$$

Para o cálculo do índice CO2 FLUX, primeiro foi calculado o índice PRI pela seguinte equação (5).

$$PRI = \frac{GREEN - BLUE}{GREEN + BLUE} \quad (5)$$

Posteriormente o valor foi reescalado para obter valores positivos (Rahman et al., 2000), o que gerou o índice sPRI. A equação utilizada foi a seguinte equação (6).

$$sPRI = \frac{PRI + 1}{2} \quad (6)$$

Por fim para calcular o índice CO<sub>2</sub> FLUX foi utilizado a equação proposta por (Rahman et al. 2000) (7).

$$CO_2 Flux = (sPRI * NDVI) \quad (7)$$

Ainda no QGIS, foi realizada uma interpolação de pixels pelo método de vizinho mais próximo para os valores próximos aos pontos de coleta. O intuito dessa interpolação, foi estimar um número que representasse com mais coesão o pixel ou

pixels onde foram coletadas as amostras. Com os valores interpolados, no software R foram gerados os gráficos e realizada no Correlação de Pearson entre os valores obtidos nos indices de refletância e a matéria seca coletada no local em toneladas por hectare. Para o cálculo da capacidade de suporte foi utilizada a metodologia proposta por Dias-Filho (2012).

O cálculo da forragem disponível foi calculado pela equação (8).

$$Forragem\ disponível = MS\ por\ ha^{-1} * 0,8 * 0,5 \quad (8)$$

onde:

0,5 = Extrato pastejável

0,8 = Eficiência de pastejo em períodos secos

O cálculo da forragem consumida por dia é dado da seguinte maneira, equação (9).

$$Consumo\ diário\ de\ uma\ UA = 450kg * 2,5\% \quad (9)$$

onde:

UA = Unidade animal (450kg de peso vivo)

O cálculo do consumo por período foi representado na seguinte equação (10).

$$Consumo\ de\ forragem\ no\ período\ (kg/UA)/ha = c.d * p.o \quad (10)$$

onde:

Período de ocupação = p.o (100 dias)

Consumo diário = c.d


Por fim, a capacidade de suporte é dada pela forragem disponível dividida pelo consumo de forragem (kg/UA/ha), como demonstrado na equação (11).

$$\text{Capacidade de suporte (UA/ha)} = \frac{\text{Forragem disponível}}{\text{Consumo de forragem no período de ocupação}} \quad (11)$$


Com o cálculo da capacidade de suporte em mãos, foi realizado uma regressão linear no R usando a capacidade de suporte como variável dependente e os valores de NDVI como variáveis independentes, afim de gerar um modelo de regressão que estimasse a capacidade de suporte em função do NDVI. Utilizando dessa regressão, foi gerado um mapa no QGIS estimando a capacidade de suporte da área estudada.

## RESULTADOS E DISCUSSÃO

Os resultados e discussões apresentadas, são referentes apenas a uma das áreas, a outra foi descartada devido a erros amostrais. Durante a coleta não foi possível alcançar alguns pontos, pois estavam cobertos por árvores, esses pontos são representados pela Figura 1-a e 1-b. Alguns locais apresentaram solo exposto com a presença de cupinzeiros (Figura 1-c), o que segundo Dias-Filho (2014) é um indicador de degradação. Os pontos similares a Figura 1-a e 1-b foram descartados, pois nesses pontos não foi possível coletar a parte aérea das plantas. Pontos exemplificados por pela Figura 1-c foram mantidos, pois representam a realidade da área estudada.



(a) Árvore sobre o ponto de coleta



(b) Árvore caída sobre o ponto de coleta



(c) Solo exposto e cupinzeiro

Figura 1- Pontos de coleta

Na Figura 2 é apresentado o mapa de composição colorida da área com a demarcação dos pontos coletados. O mapa RGB, nos permitiu ter uma ideia sobre a realidade desta área de pastagem. Através da composição colorida, foi possível perceber que na parte central do mapa há uma região de mata (parte verde escura) que praticamente separa o pasto em duas partes, entretanto uma trilha liga uma parte do pasto a outra. Os pontos foram realocados para não sobrepossem a área de mata, tornando assim a forragem o principal objeto de estudo. Em geral, os locais pontoados apresentam uma coloração verde-amarronzada o que é um sinal de vegetação esparsa.




Figura 2- Mapa de composição colorida (RGB)

O mapa de NDVI pode ser observado na Figura 3. Ao analisar o mapa NDVI junto ao RGB, foi possível ter uma ideia geral da vegetação local. As áreas de mata apresentaram coloração verde escura, e em algumas partes verde clara, sendo que no que diz respeito a superfícies vegetadas o NDVI tende a ter valores positivos altos entre 0.5 e 1.0 para vegetação densa típica de florestas tropicais .



Em contrapartida, as áreas coloridas de amarelo que representam as áreas de pastagens, apresentaram valores mais baixos variando de 0.48 a 0.59, o que é normal em períodos secos, onde a vegetação entra em senescência. Gramíneas, vegetação de pequeno porte, e ou arbustiva e vegetação esparsa, geralmente possuem valores aproximados entre 0.2 e 0.5. As áreas laranjadas, apresentam valores inferiores a 0.48, o que é um indicativo de áreas de solo exposto (YASIR et al., 2023).

O SAVI (Figura 4) utilizou do fator de correção igual a 0,5; proposto para solos de cobertura vegetal intermediária por Huete (1988). O SAVI e o NDVI apresentaram resultados semelhantes em áreas com alta cobertura vegetal. No entanto, o SAVI é mais adequado para áreas com baixa cobertura vegetal, pois é menos afetado pelas variações no solo (GAMEIRO et al, 2016). Para a área representada acima o SAVI permitiu uma boa visualização das áreas com solo exposto e de vegetação espaçara, sendo considerado um bom índice para visualização da área.

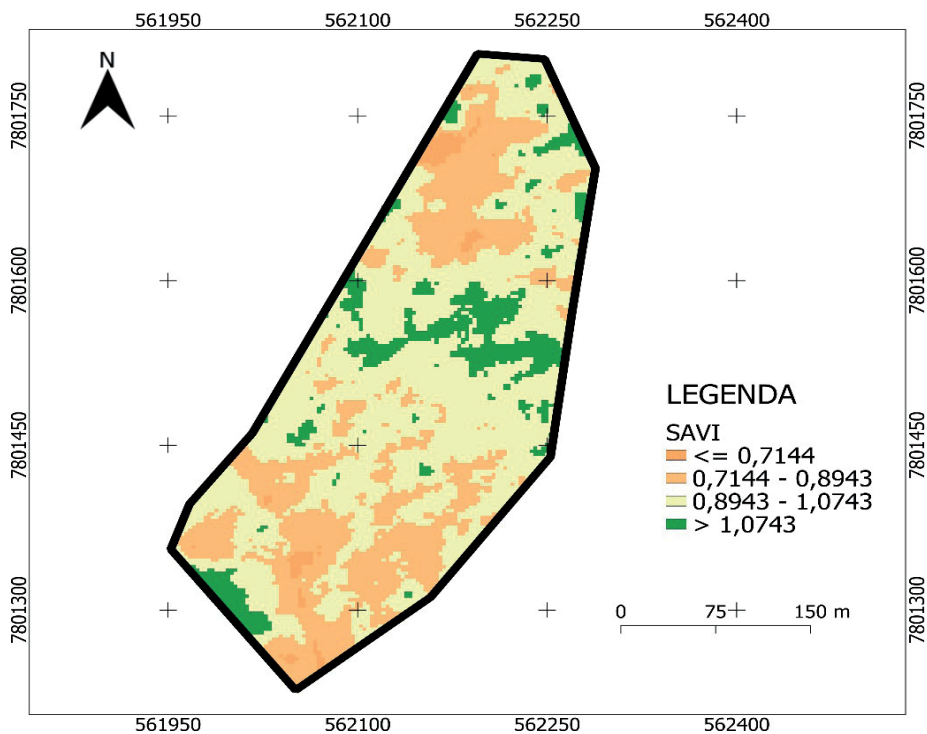


Figura 4 - Mapa SAVI

Na Figura 5 é apresentado o mapa de CO<sub>2</sub>-Flux, que foi gerado a partir dos mapas de NDVI e sPRI. O CO<sub>2</sub>-Flux, apresentou valores maiores próximos a região de mata, isso se dá pois este índice mede a eficiência do processo de sequestro de carbono pela vegetação (DE MELLO BAPTISTA, 2004). De maneira geral, as pastagens degradadas sequestram menos carbono se comparadas a pastagens bem manejadas. A implementação de melhores práticas de manejo, pode levar à redução das emissões de carbono ao promover o acúmulo e a estabilidade do carbono no solo (FIGUEIREDO et al., 2017).




Figura 5 – Mapa CO<sub>2</sub>-Flux

O NDVI obteve maior a correlação dentre os três índices estudados, apresentando  $r=0,7$ . Enquanto o SAVI apresentou  $r= 0,67$  e o CO<sub>2</sub>-Flux  $r= 0,54$ . Por apresentar maior correlação, a continuidade do trabalho se deu a partir do NDVI. Na Figura 6 foi apresentado o gráfico de matéria seca calculada por hectare e os valores obtidos no NDVI, em seguida na Tabela 3 apresentou-se a estatística referente a correlação de Pearson.




Figura 6 – Gráfico M.S/ha por NDVI

<b>Correlação de Pearson M.S por ha e NDVI</b>	
R de Person	0.7071935
p-valor	0.002185
Graus de Liberdade	14
Limite superior do IC a 95%	0.8906670
Limite inferior do IC a 95%	0.3256468

Tabela 1 – Correlação entre matéria seca e NDVI.

A análise estatística foi realizada com 14 graus de liberdade, e um índice de confiança de 95%. A análise apresentou um p-valor < que 0.05, o que indica que devemos rejeitar a hipótese nula, ou seja, que não existência de correlação entre as variáveis. Dessa forma a correlação entre NDVI e matéria seca foi comprovada estatisticamente. Entretanto o limite superior e inferior, apresentaram uma grande discrepância em seus valores, o que significa que as duas variáveis podem ser influenciadas por outras variáveis. Outra hipótese é que tal discrepância pode estar relacionada a um número amostral pequeno, sendo necessário um número maior de amostras para aproximar os limites.

A correlação de NDVI e matéria seca encontrada, corrobora o resultado encontrado por POVH (et al., 2008), que teve como objetivo em seu trabalho avaliar o comportamento nas culturas de trigo, triticale, cevada e milho. Ele obteve uma correlação de Pearson positiva de 0,98 entre NDVI e M.S para a cultura do trigo. Nesse caso, um dos fatores que pode ter influenciado em uma correlação extremamente alta, é que o experimento foi realizado em um campo experimental uniforme.

Dancey e Reidy (2018), classificam os valores obtidos pela correlação de Pearson da seguinte maneira,  $r = 0,10$  até  $0,3$  (fraco);  $r = 0,40$  até  $0,6$  (moderado);  $r = 0,70$  até  $1$  (forte). Ou seja, CO<sub>2</sub>-Flux e SAVI apresentaram correlações moderadas, enquanto o NDVI uma correlação forte, por essa razão o NDVI foi escolhido para gerar o modelo de regressão linear. O modelo de regressão linear gerado no R, obteve o  $R^2 = 0,47$ , a equação de regressão está presente na Figura 7 junto ao gráfico de dispersão.




Figura 7 - Regressão linear UA/ha gerado pelo NDVI

O valor de  $R^2 = 0,47$ , indica que o modelo explica 47% da variabilidade da variável resposta. Ademais o modelo gerado pode ser útil para fazer previsões, porém ainda possui uma margem de erro grande. Como sugestão para aperfeiçoar o modelo, recomenda-se a utilização de um maior número amostral, atrelado ao estudo de outras variáveis além da matéria seca, como o índice de área foliar, e a escolha de uma área mais uniforme sem sinais de degradação.

O mapa de capacidade de suporte apresentado na Figura 8, é utilizado para ilustrar utilização da equação feita para estimar a capacidade de suporte a partir do NDVI. Os valores foram divididos em três classes, sendo a parte vermelha de  $0,4$  UA/ha-1 /100 dias ou menos, a parte amarela entre  $0,4$  e  $1,28$  UA/ha-1 /100 dias e a parte verde maior que  $1,28$  UA/ha-1 /100 dias.

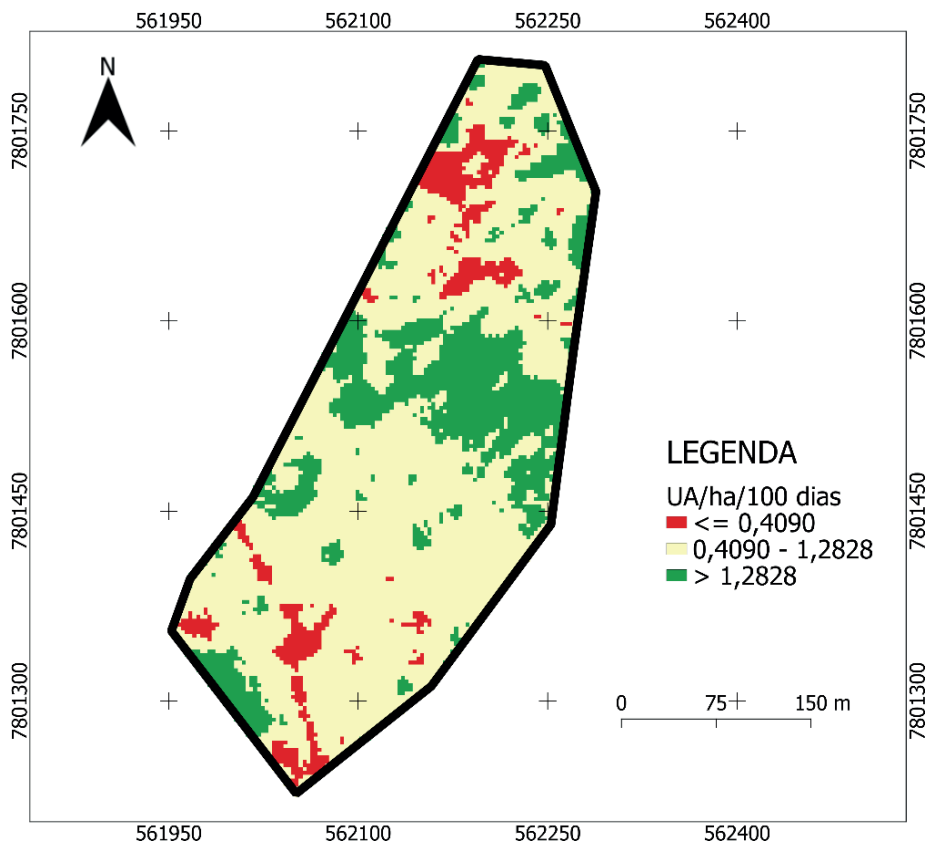


Figura 8 – Mapa da capacidade de suporte

Apesar do mapa nos dar uma ideia da capacidade de suporte da área analisada, apenas a observação do mapa não nos possibilita ter uma visão real da área. As partes em verde escuro que pressupõe a maior taxa de lotação, correspondem a áreas de mata ou a pequenos conjuntos de árvores como é possível observar através da composição colorida (Figura 2). O NDVI não é capaz de distinguir a mata da forragem, o que gerou resultados que não representam de fato a capacidade de suporte. Ademais as áreas em vermelho são áreas de solo exposto, o que é um indicativo de uma baixíssima capacidade de suporte, estando entre 0 e 0,4 UA/ha-1 /100 dias. Sendo 0,4 UA/ha-1 /100 dias um valor bem otimista, pois se trata de uma área que em sua maior parte apresenta solo exposto.

A cor amarela é predominante no mapa, a área representada por ela apresenta os resultados mais confiáveis, visto que é nessa área que de fato estão presentes as plantas forrageiras. Todavia, o intervalo entre os possíveis valores de UA gerados pelo modelo matemático, torna difícil uma possível tomada de decisão apenas observando o mapa, visto a amplitude do intervalo. Por exemplo, considerando uma capacidade de suporte de 0,4 UA/ha-1 por 100 dias, haveria um consumo de 450kg de matéria seca. Enquanto

em 1,28 UA/ha-1 o consumo seria de 1.440 kg em 100 dias. Nesse caso, o valor máximo do intervalo é aproximadamente três vezes maior que o mínimo, dessa forma ao definir o número de animais apenas observando o mapa há chance de faltar ou sobrar forragem, logo definir a capacidade de suporte apenas pelo mapa gerado não seria a melhor forma de manejo possível.

## REFERÊNCIAS

- Borghi, E., Neto, M. M. G., Resende, R. M. S., Zimmer, A. H., De Almeida, R. G., & Macedo, M. C. M. **Agricultura de baixo carbono: tecnologias e estratégias de implantação. Brasília, DF: Embrapa**, v. 4, p. 105-138, 2018.
- Borges, B. M. M. N., Lucas, F. T., Modesto, V. C., Prado, R. D. M., Silva, E. D., & Braos, B. B. Métodos de determinação da matéria seca e dos teores de macronutrientes em folhas de alface. **Revista Trópica**, v. 5, p. 12-16, 2011.
- Braz, S. P., Urquiaga, S., ALVES, B. J. R., & Boddey, R. M. **Degradação de pastagens, matéria orgânica do solo e a recuperação do potencial produtivo em sistemas de baixo” input” tecnológico na região dos cerrados**. Embrapa Agrobiologia 2004.
- Dancey, C., & Reidy, J. **Estatística Sem Matemática para Psicologia-7**. Penso Editora, 2018.
- da Silva, L. G., & Galvêncio, J. D. Análise Comparativa da Variação nos Índices NDVI e SAVI no Sítio PELD-22, em Petrolina-PE, na Primeira Década do Século XXI (Comparative Analysis of Changes in NDVI and SAVI in PELD-22-Petrolina-PE, in the First Decade of the XXI Century). **Revista Brasileira de Geografia Física**, v. 5, n. 6, p. 1446-1456, 2013.
- de Mello Baptista, G. M. (2004). Mapeamento do sequestro de carbono e de domos urbanas de CO2 em ambientes tropicais, por meio de sensoriamento remoto hiperespectral. **Geografia**, v. 29, n. 2, p. 189-202, 2004.
- DIAS-FILHO, M. B. (2012). DIAS-FILHO, Moacyr B. Formação e manejo de pastagens. 2012.
- Dias-Filho, M. B. Diagnóstico das pastagens no Brasil. 2014
- Ferraz, J. B. S.; Felício, P. E. D. Production systems: an example from Brazil. **Meat Science**, v. 84, n. 2, p. 238243, 2010.
- Fontgalland, I. L., de Menezes, G. C., de França Paz, M. A., de Souza, Ê. P., Farias, S. A. R., & de Sousa Rêgo, V. G. Normalized Difference Vegetation Index Analysis Using Ndvi and Savi Indices in the Conservation Unit Serra da Borborema Municipal Nature Park, Campina Grande, Paraíba, Brazil. **Revista de Gestão Social e Ambiental-RGSA**, v. 17, n. 1, p. e03116-e03116, 2023.
- Figueiredo, E. B. D., Panosso, A. R., Bordonal, R. D. O., Teixeira, D. D. B., Berchielli, T. T., & La Scala Jr, N. Soil CO2-C emissions and correlations with soil properties in degraded and managed pastures in southern Brazil. **Land Degradation & Development**, v. 28, n. 4, p. 1263-1273, 2017.
- Formaggio, A. R., & Sanches, I. D. A. **Sensoriamento remoto em agricultura**. Oficina de Textos, 2017.

- Frazier, A. E., & Hemingway, B. L. Benjamin L. A technical review of planet smallsat data: Practical considerations for processing and using planetscope imagery. **Remote Sensing**, v. 13, n. 19, p. 3930, 2021.
- Gameiro, S., Teixeira, C. P. B., Silva Neto, T. A., Lopes, M. F. L., Duarte, C. R., Souto, M. V. S., & Zimback, C. R. L. Avaliação da cobertura vegetal por meio de índices de vegetação (NDVI, SAVI e IAF) na Sub-Bacia Hidrográfica do Baixo Jaguaribe, CE. **Terræ**, v. 13, n. 1-2, p. 15-22, 2016.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.
- Macedo, M. C. M., Kichel, A. N., & Zimmer, A. H. **Degradação e alternativas de recuperação e renovação de pastagens**. 2000.
- Paulino, V. T., & Teixeira, E. M. L. Sustentabilidade de pastagens—manejo adequado como medida redutora da emissão de gases de efeito estufa. **CPG-produção animal sustentável, ecologia de pastagens, iz, apta/saa**, v. 16, 2009.
- Parente, L., Mesquita, V., Mizziara, F., Baumann, L., & Ferreira, L. Assessing the pasturelands and livestock dynamics in Brazil, from 1985 to 2017: A novel approach based on high spatial resolution imagery and Google Earth Engine cloud computing. **Remote Sensing of Environment**, v. 232, p. 111301, 2019.
- Osborne, B. G. Near-infrared spectroscopy in food analysis. **Encyclopedia of analytical chemistry: applications, theory and instrumentation**, 2006.
- Ponzoni, F. J., Shimabukuro, Y. E., & Kuplich, T. M. **Sensoriamento remoto da vegetação. Oficina de textos**, 2015.
- Potenza, R. F., Quintana, G. O., Cardoso, A. M., Tsai, S. D., Cremer, M. S., Silva, F. B., ... & AZEVEDO, T. Análise das Emissões Brasileiras de e suas Implicações para as metas Climáticas do Brasil 1970–2020 Gases de Efeito Estufa. *Revista Brasileira de Ecoturismo*, p. 630-645, 2021.
- Povh, F. P., Molin, J. P., Gimenez, L. M., Pauletti, V., Molin, R., & Salvi, J. V. Comportamento do NDVI obtido por sensor ótico ativo em cereais. **Pesquisa Agropecuária Brasileira**, v. 43, p. 1075-1083, 2008.
- Planet imagery product specifications 2022. Disponível em < <https://www.planet.com/products/planet-imagery/> > Acesso: 06/11/2023.
- PPM - Pesquisa da Pecuária Municipal. Disponível em: < <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9107-producao-da-pecuaria-municipal.html> > Acesso 30/11/2023
- Prudencio, M. F., da Silva Freitas, G., & Soares Filho, C. V. New technologies in pasture and grazing management in the face of climate change perspectives. **Research, Society and Development**, v. 11, n. 9, p. e20311931680-e20311931680, 2022.
- Souza Jr, C. M., Z. Shimbo, J., Rosa, M. R., Parente, L. L., A. Alencar, A., Rudorff, B. F., & Azevedo, T. Reconstructing three decades of land use and land cover changes in brazilian biomes with landsat archive and earth engine. **Remote Sensing**, v. 12, n. 17, p. 2735, 2020.
- Yasir, Q. M., Zhang, Z., Tang, J., Naveed, M., & Jahangir, Z. Spectral indices for tracing leaf water status with hyperspectral reflectance data. **Journal of Applied Remote Sensing**, v. 17, n. 1, p. 014523-014523, 2023.