



**Universidade de Évora - Escola de Ciências e Tecnologia**

**Mestrado em Engenharia Zootécnica**

Dissertação

**Utilização de índices nas bandas da área do visível para  
determinação da quantidade e qualidade da pastagem**

**Catarina Isabel dos Santos Candeias**

Orientador(es) | Manuel D'Orey D'Abreu

Elvira Sales-Baptista

Évora 2022





**Universidade de Évora - Escola de Ciências e Tecnologia**

**Mestrado em Engenharia Zootécnica**

Dissertação

**Utilização de índices nas bandas da área do visível para  
determinação da quantidade e qualidade da pastagem**

**Catarina Isabel dos Santos Candeias**

Orientador(es) | Manuel D'Orey D'Abreu  
Elvira Sales-Baptista

Évora 2022

---

---

---

---



A dissertação foi objeto de apreciação e discussão pública pelo seguinte júri nomeado pelo Diretor da Escola de Ciências e Tecnologia:

Presidente | José Manuel Martins (Universidade de Évora)

Vogais | Amadeu António Freitas (Universidade de Évora) (Arguente)  
Elvira Sales-Baptista (Universidade de Évora) (Orientador)

## **Agradecimentos**

Em primeiro lugar à Professora Elvira Sales Baptista pela predisposição para aceitar ser orientadora pela Universidade, pelo apoio dado e pela exigência. Apesar do longo período de pandemia continuou a ajudar-me e apoiar-me nesta caminhada.

Ao Professor Manuel Cancela D'Abreu, pelos conhecimentos transmitidos ao longo do percurso académico na Universidade de Évora.

À minha família, mas principalmente aos meus pais e irmão pelo apoio incondicional, incentivo e auxílio ao longo de todo o processo de elaboração da dissertação.

À minha avó que sempre foi um dos meus pilares, e para quem o meu percurso académico era motivo de grande orgulho e alegria.

A todos os meus amigos e colegas, bem como a todos os que de alguma forma contribuíram para a elaboração desta dissertação.

## **Utilização de índices nas bandas da área do visível para determinação da quantidade e qualidade da pastagem**

### **Resumo**

À medida que a vegetação da pastagem matura sofre alterações de cor, e por isso a taxa de crescimento das plantas está relacionada com variabilidade do espectro luminoso. Câmaras fotográficas normais podem funcionar como sensores de proximidade porque capturam as bandas vermelho (R), verde (G) e azul (B) do espectro eletromagnético, com as quais se podem construir índices RGB da vegetação. Utilizámos imagens digitais de pastagem captadas com uma câmara Go-Pro para determinar o valor nutritivo. As fotos da pastagem foram centradas na perpendicular de uma área limitadas por um aro com 0,25m<sup>2</sup> (50cmX50cm) que serviu igualmente para colher amostras da pastagem para determinação e cálculo de matéria seca (MS), proteína bruta (PB) e fibra insolúvel em detergente neutro (NDF), e ainda determinação das cinzas totais para cálculo da matéria orgânica (MO). Foram efetuadas colheitas de pastagem em 4 datas distintas: 22 de abril, 13 de maio, 3 de junho e 24 de junho de 2013. As imagens foram analisadas para extrair quantidade de pixéis em cada banda e utilizadas para testar vários índices RGB que foram correlacionados com a composição química das amostras colhidas. Os resultados indicam que os índices correlacionaram-se melhor em abril do que em etapas mais avançadas da maturação. Os índices com melhor desempenho foram o MGVRI e o MPRI, com correlações positivas e significativas com a PB (MGVRI ( $r=.704$ ,  $p<.01$ ) e MPRI ( $r=.701$ ,  $p<.01$ )) e negativas com o NDF (MGVRI ( $r=-.481$ ,  $p<.01$ ) e MPRI ( $r=-.476$ ,  $p<.01$ )). Concluiu-se que a partir de imagens digitais se pode prever de forma simples o valor nutritivo da pastagem complexas e quais os índices mais promissores que merecem ser explorados futuramente.

**Palavras-Chave:** Pastagens, Sensores de proximidade, Valor Nutritivo, Métodos Indiretos, Imagens Digitais

## Using indices in the visible area bands to determine pasture quantity and quality

### Abstract

As pasture vegetation matures the plants undergoes color changes and plants growth rate is then related to the variability of the light spectrum. Normal cameras can be used as proximity sensors because they capture the red (R), green (G) and blue (B) bands of the electromagnetic spectrum, with which vegetation (RGB) indices can be built. We used digital images of grasslands captured with a Go-Pro camera to determine the nutritional value. The photos of the pasture were centered on the perpendicular of an area limited by a frame with 0.25m<sup>2</sup> (50cmX50cm) which also served to collect samples of the pasture for the determination and calculation of dry matter (DM), crude protein (CP) and insoluble fiber in neutral detergent (NDF), and also determination of total ash for calculation of organic matter (OC). Pasture samplings were carried out on 4 different dates: April 22, May 13, June 3 and June 24, 2013. The images were analyzed to extract the number of pixels in each band and used to test various RGB indices that were correlated with the chemical composition of the samples collected. The results indicate that the indices correlated better in April than in more advanced stages of maturation. The indices with the best performance were MGVRI and MPRI, with positive and significant correlations with BP (MGVRI ( $r=.704$ ,  $p<.01$ ) and MPRI ( $r=.701$ ,  $p<.01$ )) and negative with the NDF (MGVRI ( $r=-.481$ ,  $p<.01$ ) and MPRI ( $r=-.476$ ,  $p<.01$ )). It was concluded that it is possible to predict the nutritional value of complex pastures from digital images. Which are the most promising indices that deserve to be explored in the future were evidenced.

**Keywords:** Pastures, Nutritional Value, Quantity, Indirect Methods, Digital Images

## Índice

Índice de Tabelas.....	8
Índice de Equações.....	8
Índice de Figuras .....	8
Lista de Abreviaturas, Acrónimos e Siglas.....	10
1. Introdução.....	12
2. Métodos para estimar a massa forrageira .....	13
2.1 Métodos Diretos.....	13
2.2 Métodos Indiretos.....	15
2.2.1 Uso da Régua.....	16
2.2.2 Uso do Disco Medidor .....	17
2.2.3 Estimativa Visual .....	19
2.2.4 Sensores de Proximidade e Remotos.....	20
3. Imagens Digitais e Determinação da Qualidade das Pastagens.....	23
3.1 Modified Green Red Vegetation Index (MGVRI).....	26
3.2 Green Leaf Index (GLI).....	26
3.3 Modified Photochemical Reflectance Index (MPRI) .....	27
3.4 Red Green Blue Vegetation Index (RGVBI).....	27
3.5 Excess of green (ExG) .....	28
3.6 Vegetativen (VEG) .....	28
4. Materiais e Métodos .....	30
4.1 Local dos ensaios.....	30
4.2 Recolha das amostras.....	31
4.3 Análise da massa forrageira e do valor nutritivo da pastagem.....	31
4.4 Análise das imagens da pastagem.....	32
4.5 Análise Estatística.....	34
5. Resultados e Discussão .....	35
5.1 Valor nutritivo da pastagem.....	35
5.2 Análises de correlação.....	36
5.3 Coeficientes de determinação .....	43
6. Considerações Finais .....	59
7. Bibliografia .....	60

## Índice de Tabelas

Tabela 1 - Variação Sazonal do Valor Nutritivo da Pastagem (Média ± Desvio-Padrão), n=47 ..	35
Tabela 2 – Variação Espacial do Valor Nutritivo da Pastagem (Média ± Desvio-Padrão), n=4 ...	35
Tabela 3 - Análise descritiva das distribuições dos índices vegetativos.....	37
Tabela 4 - Matriz de correlações de Pearson dos índices vegetativos na colheita número 1, de 22 de abril.....	37
Tabela 5 - Matriz de correlações de Pearson dos índices vegetativos na colheita número 3, de 13 de maio.....	38
Tabela 6 - Matriz de correlações de Pearson dos índices vegetativos na colheita número 6, de 3 de junho .....	39
Tabela 7 - Matriz de correlações de Pearson dos índices vegetativos na colheita número 9, de 24 de junho .....	39

## Índice de Equações

$NDVI = (NIR - RED)/(NIR + RED)$ [Equação 1] .....	21
$((G)^2 - (R)^2)/((G)^2 + (R)^2)$ [Equação 2] .....	26
$(2G - R - B)/(2G + R + B)$ [Equação 3].....	26
$(G - R)/(G + R)$ [Equação 4].....	27
$(G - (B * RG))/((G)^2 + (B * R))$ [Equação 5].....	27
$2G - R - B$ [Equação 6] .....	28
$GRa \times B(1 - a)$ [Equação 7].....	29

## Índice de Figuras

Figura 1 - Régua.....	17
Figura 2 - Disco Medidor .....	18
Figura 3 - Monitorização da Produtividade das Pastagens: da Detecção Remota à utilização complementar de Sensores Próximos.....	21
Figura 4 - Sonda Grassmaster II.....	22
Figura 5 - Imagem Térmica.....	23
Figura 6 - Exemplo de Duas Imagens Digitais, Pano de Fundo Preto (a) e Pano de Fundo Branco (c), e suas Respetivas Imagens Binárias (b e d), Convertidas usando Técnicas de Análise de Vegetação de Imagens Digitais (DIVA) .....	24
Figura 7 - Parcela e pontos de amostragem do estudo .....	30
Figura 8 - Aro utilizado nas colheitas de amostras.....	31
Figura 9 - Análise da correlação do índice PB com os índices MGVRI e MPRI na colheita número 1.....	40
Figura 10 - Análise da correlação do índice Biomassa com o índice RGB greenness e do índice PB com o índice VEG na colheita número 3 .....	41
Figura 11 - Análise da correlação do índice Biomassa com o índice RGB greenness e do índice PB com o índice VEG na colheita número 6 .....	41



Figura 12 - Análise da correlação do índice Biomassa com o índice RGB greenness e do índice PB com o índice VEG na colheita número 9 .....	42
Figura 13 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo MGVRI por momento da colheita .....	44
Figura 14 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo GLI por momento da colheita.....	45
Figura 15 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo MPRI por momento da colheita.....	45
Figura 16 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo MPRI por momento da colheita.....	46
Figura 17 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo ExG por momento da colheita.....	46
Figura 18 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo VEG por momento da colheita.....	47
Figura 19 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo RGB Greenness por momento da colheita .....	47
Figura 20 - Regressões lineares do MO (% MS) explicado pelo MGVRI por momento da colheita .....	48
Figura 21 - Regressões lineares do MO (% MS) explicado pelo GLI por momento da colheita ..	48
Figura 22 - Regressões lineares do MO (% MS) explicado pelo MPRI por momento da colheita .....	49
Figura 23 - Regressões lineares do MO (% MS) explicado pelo RGVBI por momento da colheita .....	49
Figura 24 - Regressões lineares do MO (% MS) explicado pelo ExG por momento da colheita .	50
Figura 25 - Regressões lineares do MO (% MS) explicado pelo VEG por momento da colheita	50
Figura 26 - Regressões lineares do MO (% MS) explicado pelo VEG por momento da colheita	51
Figura 27 - Regressões lineares do PB (% MS) explicado pelo MGVRI por momento da colheita .....	51
Figura 28 - Regressões lineares do PB (% MS) explicado pelo GLI por momento da colheita ....	52
Figura 29 - Regressões lineares do PB (% MS) explicado pelo MPRI por momento da colheita	52
Figura 30 - Regressões lineares do PB (% MS) explicado pelo RGVBI por momento da colheita	53
Figura 31 - Regressões lineares do PB (% MS) explicado pelo ExG por momento da colheita...	53
Figura 32 - Regressões lineares do PB (% MS) explicado pelo VEG por momento da colheita ..	54
Figura 33 - Regressões lineares do PB (% MS) explicado pelo RGB Greenness por momento da colheita.....	54
Figura 34 - Regressões lineares do NDF (% MS) explicado pelo MGVRI por momento da colheita .....	55
Figura 35 - Regressões lineares do NDF (% MS) explicado pelo GLI por momento da colheita .	55
Figura 36 - Regressões lineares do NDF (% MS) explicado pelo MPRI por momento da colheita .....	56
Figura 37 - Regressões lineares do NDF (% MS) explicado pelo RGVBI por momento da colheita .....	56
Figura 38 - Regressões lineares do NDF (% MS) explicado pelo ExG por momento da colheita	57
Figura 39 - Regressões lineares do NDF (% MS) explicado pelo VEG por momento da colheita	57
Figura 40 - Regressões lineares do NDF (% MS) explicado pelo RGB Greenness por momento da colheita.....	58

## Lista de Abreviaturas, Acrónimos e Siglas

MS – Matéria Seca

$R^2$  - Coeficiente de determinação

$s^2$  - Desvio Padrão

CV - Coeficiente de Variação

P – Produção

X – Altura da Pastagem/ Unidade de Leitura do Equipamento

RS – Remote Sensing/ Sensores Remotos

NDVI - Normalized Difference Vegetation Index/ Índice de Vegetação de Diferença Normalizada

RED – Vermelho

NIR – Infra Vermelho Próximo

RED EDGE – Borda Vermelha

RGB – Espectro Visível

DIVA – Imagens Digitais para Análise de Vegetação

MGVRI – Modified Green Red Vegetation Index / Índice de Vegetação Verde Vermelho Modificado

GLI)– Green Leaf Index / Índice de Folha Verde

MPRI – Modified Photochemical Reflectance Index / Índice de Refletância Fotoquímica Modificado

RGVBI – Red Green Blue Vegetation Index / Índice de Vegetação Vermelho Verde Azul

ExG – Excess of green / Excesso de Verde

G (Green) – Verde

R (Red) – Vermelho

B (Blue) – Azul

GNSS - Global Navigation Satellite Systems/ Sistemas Globais de Navegação por Satélite

Image Name – Nome da Imagem

% Pixels - % de Pixels

Average Red – Vermelho Médio

StDev Red – Desvio-Padrão Vermelho

Average Green – Verde Médio

StDev Green – Desvio-Padrão Verde

Average Blue – Azul Médio

StDev Blue – Desvio-Padrão Azul

## 1. Introdução

Segundo Allen, et.al (2011), o termo pastagem refere toda a terra composta por vegetação e cujo potencial seja o pastoreio pelas mais diversas espécies animais. Mais concretamente, pastagens são comunidades de plantas, geralmente herbáceas forrageiras (gramíneas e leguminosas), aproveitadas predominantemente no próprio local em que se desenvolvem pelos animais em pastoreio, e, portanto, particularmente importantes em sistemas extensivos de produção animal (Moreira, 2002). A estrutura da pastagem altera-se ao longo da estação, bem como à medida que diferentes espécies de plantas com diferentes fenologias amadurecem, sendo a distribuição espacial da biomassa numa pastagem comumente expressa em quilogramas de matéria seca (MS) por hectare (kg MS/ha) (Carvalho et.al, 2008).

Nos últimos anos, os sistemas extensivos têm ganho relevância pois são uma valiosa ferramenta para o desenvolvimento sustentável do setor primário em Portugal, diminuindo os problemas ambientais, económicos e sociais que os modelos de exploração animal atuais acarretam (Correia, 2018). De facto, a rentabilidade das explorações agropecuárias depende, entre outros fatores, dos custos relacionados com a alimentação animal, sendo a pastagem um dos recursos utilizado por muitos agricultores. Isto significa que, se adotarmos estratégias adequadas no que respeita ao pastoreio, conseguiremos rentabilizar financeiramente as explorações (Van den Pol-van Dasselaar et.al, 2014). Tais estratégias teriam por base otimizar a ingestão do efetivo, sendo para isso importante a estimativa da massa forrageira disponível, preferencialmente através de métodos rápidos, fiáveis e reprodutíveis.

## **2. Métodos para estimar a massa forrageira**

Sabendo que a massa forrageira representa a quantidade de matéria seca ao nível do solo por cada unidade de área, é importante estimar o seu valor uma vez que irá determinar o sucesso da gestão e rentabilização das pastagens. Para tal, podemos recorrer a técnicas diretas baseadas no corte da pastagem e a técnicas indiretas. Nos métodos diretos, para podermos estimar a massa forrageira (kg MS/ha) é necessário recorrer ao corte da pastagem numa determinada área, com posterior cálculo da matéria seca. Este corte, se for possível a sua análise química, pode ainda fornecer informação sobre a qualidade da pastagem (Mannetje, 2000). É um método preciso, mas destrutivo, trabalhoso e demorado. Outra desvantagem é exigir um grande número de amostragens numa pastagem, de forma a que os resultados obtidos sejam representativos da variabilidade espacial existente na pastagem e, portanto, fiáveis (Mannetje, 2000).

Existem ainda, formas de estimar a massa forrageira das pastagens sem recorrer ao corte de pequenas porções das mesmas, designando-se por métodos indiretos (Silva & Cunha, 2003), que incluem técnicas não destrutivas, expeditas e comparativamente menos trabalhosas, mas cuja utilização se encontra dependente de calibrações e poderá gerar resultados menos precisos que as técnicas diretas. Nos vários métodos disponíveis para estimar a massa forrageira, a precisão da estimativa dependerá de diversos fatores como: técnica utilizada; espécie; idade; altura; época do ano (Dufloth et.al, 2015), pelo que a escolha do método mais adequado terá de ter em consideração a dimensão e especificidades da pastagem, o propósito da estimativa, a precisão necessária, bem como os recursos disponíveis (equipamentos e mão de obra) (Mannetje, 2000).

### **2.1 Métodos Diretos**

Os métodos diretos, utilizados para estimar a massa forrageira, envolvem o corte de uma área da pastagem em que, posteriormente, é realizada uma pesagem da amostra de pastagem recolhida (Mannetje, 2000). Visto que, estes métodos fazem uso do corte de uma amostra de pastagem são classificados como destrutivos, já que impossibilita

novas avaliações na área onde se colheu pastagem. A determinação da quantidade de pastagem residual (pastagem que permanece após o período de pastoreio) é determinada de maneira idêntica. Este método é considerado bastante fiável desde que, seja estabelecido um plano experimental que seja seguido, assim como um plano das áreas onde se irá proceder à recolha de pastagem (Mannetje, 2000).

São diversos os equipamentos que poderão ser utilizados para o corte da pastagem, podendo ser:

- Instrumentos de corte mecânico;
- Instrumentos de corte manual.

O tipo de equipamento a utilizar é escolhido de acordo com o tipo de pastagem (homogénea ou heterogénea) e com o relevo da área, mas o mais importante é o número de amostras que se recolhem.

As amostras recolhidas são posteriormente secas e pesadas e podem servir para outras análises químicas para cálculo de valor nutritivo. Tem que se ter especial atenção ao corte das amostras para que não contenham pequenas porções de terra ou de folhas de árvores. Caso o mesmo se verifique, irá haver uma deturpação dos resultados após feitas análises químicas às amostras (Edvan et.al, 2016).

Segundo Barnett (1974), não é recomendada a utilização deste método em grandes áreas de pastagem devido à maior probabilidade de ocorrência de erros e pelo facto de ser necessária uma mão-de-obra superior e, conseqüentemente, um maior gasto de tempo no processo de recolha de amostras. Devido às razões acima mencionadas, há uma necessidade de reduzir os custos associados à mão-de-obra e o tempo necessário para tal, pois uma recolha de um menor número de amostras da pastagem gerará, conseqüentemente, uma menor precisão e eficácia dos resultados obtidos.

## 2.2 Métodos Indiretos

De acordo com Silva & Cunha (2003), os métodos indiretos são considerados os mais adequados para estimar a massa forrageira de pastagens que estejam a ser pastoreadas devido, principalmente, à sua natureza não-destrutiva. Estes métodos foram surgindo devido à procura de métodos mais rápidos e eficazes, e baseiam-se no desenvolvimento de modelos preditivos da massa forrageira com base em diversas características das pastagens.

Os métodos indiretos apresentam várias vantagens sobre os métodos diretos, das quais podemos destacar, a menor necessidade de mão-de-obra e equipamentos, a necessidade de um período de tempo menor, menor custo, possibilidade de aplicação em zonas que estejam submetidas a pastoreio ou áreas de acesso mais restrito, possibilidade de aplicação em áreas mais reduzidas onde o uso de métodos que requerem o corte da pastagem podem não ser benéficos (Frame, 1981).

No entanto, o uso destes métodos gera uma menor precisão nos resultados obtidos quando comparados com os métodos diretos, uma vez que os resultados podem ser influenciados por diversas variáveis. Não obstante, pelo facto dos métodos indiretos exigirem menor dispêndio de tempo por observação e uma menor mão-de-obra, permitem que se efetuem um maior número de observações por unidade de tempo, rentabilizando desta forma a mão-de-obra disponível e uma recolha superior de número de amostras / área (Mannetje, 2000).

Geralmente, as técnicas não destrutivas envolvem a medição de um ou mais atributos da pastagem, antes e após o período de pastoreio, compilado com uma previsão de massa forrageira por unidade de área (kg MS / ha) e utilizando equações de regressão adequadas para cálculo da MS e/ou aferir relativamente à qualidade. Para tal, é necessário um número limitado de amostras de pastagem para que se possa correlacionar com as características da pastagem (Silva & Cunha, 2003). Das equações de regressão são definidos vários parâmetros, tais como, coeficientes de determinação ( $R^2$ ), desvio padrão ( $s^2$ ) e coeficiente de variação (CV) que permitirão escolher o método mais adequado. De acordo com Nagelkerke (1991), o coeficiente de determinação ( $R^2$ )

é considerado uma medida de sucesso dos modelos de regressão linear como modelos preditivos, sendo definido como a proporção de variância explicada pelo respetivo modelo de regressão. Os seus valores variam entre 0 e 1 sendo que, quanto mais próximo de 1 forem os valores apresentados mais robusto se torna o modelo.

De entre os métodos indiretos destacam-se dois:

- Régua, o qual se baseia na altura da pastagem;
- Disco medidor, o qual se baseia na densidade da pastagem.

### **2.2.1 Uso da Régua**

Consiste na medição da altura da pastagem utilizando uma régua graduada com uma escala correta (preferencialmente em cm) (Figura 1). Recorre-se ao uso de materiais transparentes e leves onde serão medidos dois pontos, o ponto mais alto e o ponto mais baixo da porção da pastagem em estudo, sendo a altura da pastagem a média aritmética desses dois pontos. São realizadas várias medições aleatórias de forma a integrar variações pontuais de altura e a média das alturas é calculada para posterior desenho da respetiva curva de calibração que permite relacionar a altura com a produção de massa forrageira (MS / ha) (Dufloth et.al, 2015). No entanto, as diferentes fenologias e estádios de desenvolvimento existentes das espécies das pastagens presentes na Bacia Mediterrânea, juntamente com as irregularidades do solo e existência de fauna, são fatores de variabilidade associados ao método que dificultam o estabelecimento de um valor médio (Dufloth et.al, 2015).





*Figura 1 - Régua*

**Fonte:** Rayburn & Lozier (2003)

### **2.2.2 Uso do Disco Medidor**

Tem por base a correlação existente entre a altura da pastagem e a sua densidade. Esta técnica inicia-se através da introdução da ponta da haste do disco medidor na pastagem, perpendicularmente à mesma (Figura 2). Ao longo da aplicação da técnica, o prato do disco medidor vai-se deslocando até que a haste atinja o solo e seja feita uma medição da altura do prato na escala da haste, até tocar na pastagem, que irá ser diretamente proporcional à densidade da pastagem. Posteriormente, à semelhança do método da régua, será utilizada uma equação de calibração de modo a quantificar a produção de massa forrageira (kg MS / ha) (Dufloth et.al, 2015).

A principal vantagem deste método é a rapidez da sua utilização, permitindo ao indivíduo recolher aproximadamente 50 leituras por cada 15 minutos (Cunha, 2002).



*Figura 2 - Disco Medidor*

**Fonte:** Rayburn & Lozier (2003)

Qualquer destes métodos exigem calibração anterior, o que é feito através do corte de amostras da pastagem.

Silva & Cunha (2003) avaliaram os dois métodos indiretos supramencionados ao longo de 12 meses em pastagens do género *Cynodon*, tendo verificado que, no que se refere à precisão de ambos os métodos, não se detetaram variações significativas, mas que o método do disco medidor permite a obtenção de resultados de um modo mais rápido. Realçaram ainda a necessidade de calibrações frequentes em ambos métodos de forma a assegurar a precisão dos resultados.

Dufloth et.al (2015) comparou também ambos métodos numa pastagem de *Axonopus*, tendo verificado diferenças nos coeficientes de determinação (Gráfico 1 e 2), o que permitiu seleccionar o método do disco como o mais adequado na previsão da produção da massa forrageira ( $R^2 = 0.73$  vs  $R^2 = 0.57$ ) nas condições em que foi realizado o trabalho.




Gráfico 1 - Gráfico de Regressão linear- Uso da Régua.

**Fonte:** Dufloth et.al, (2015)

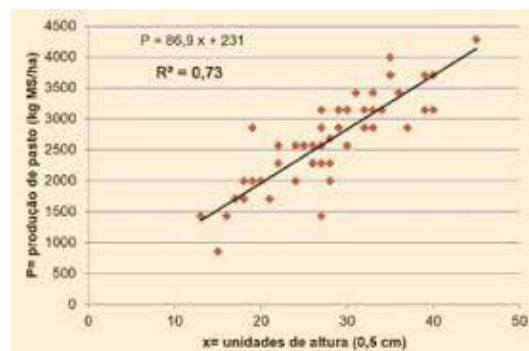


Gráfico 2 - Gráfico de Regressão linear- Uso do Disco Medidor.

**Fonte:** Dufloth et.al, (2015)

Apesar dos modestos valores de  $R^2$ , outros trabalhos reforçam também o uso do método do disco como o melhor método de predição da produção de massa forrageira (MS / ha), desde que devidamente calibrado (Cunha, 2002; Sanderson et al., 2001).

Para além dos métodos referidos, vários outros métodos não destrutivos (indiretos) foram revistos por Frame (1981) e Mannetje (1978), destacando-se:

- Estimativa visual;
- Medições por sensores de proximidade e remotos;
- Imagens de cobertura vegetal (remota ou ao nível do solo).

### 2.2.3 Estimativa Visual

O método de estimativa visual é realizado através de uma avaliação da pastagem existente na parcela que pretendemos quantificar que será comparada a uma avaliação realizada anteriormente, permitindo retirar conclusões quantitativas relativamente à pastagem (Edvan et.al, 2016). Embora este método permita um elevado número de observações / unidade de tempo tem que se ter em conta que o mesmo não é objetivo, uma vez que está fortemente dependente da eficácia e eficiência com que o indivíduo responsável realiza a estimativa visual e a correlaciona com os seus conhecimentos adquiridos em experiências anteriores. Além disso, as avaliações visuais podem ser

influenciadas por variações nas características da pastagem (como a densidade e altura) assim como por condições climáticas (teor de humidade). É de realçar que o indivíduo que realiza este método tem que ser experiente visto que, através de uma simples observação o indivíduo terá que correlacionar a pastagem apresentada como os conhecimentos adquiridos anteriormente (Frame, 1981).

No seu estudo, O'Donovan et.al (2002) comparou quatro métodos para estimar a massa forrageira numa pastagem (estimativa visual, disco medidor, estaca "Hill Farm Research organization" e o medidor de capacitância), tendo verificado uma melhor *performance* com o método de estimativa visual ao nível de precisão dos resultados, obtendo um modelo com  $R^2$  superior (0.95) aos restantes. Num outro estudo, a estimativa visual conseguiu também estimar com precisão a massa forrageira em pastagens de *Brachiaria decumbens* ( $R^2 = 0.83$ ) (Costa et. al, 2009).

Apesar da subjetividade inerente ao método, a estimativa visual pode ser pertinente em estudos preliminares ou como suporte de decisões técnicas, permitindo também um controlo / perceção do crescimento da pastagem (Mannetje, 2000; Frame, 1981).

#### **2.2.4 Sensores de Proximidade e Remotos**

Tem havido um uso crescente de recursos mais tecnológicos na agricultura que permitem digitalização. Os sensores remotos permitem obter imagens da cobertura vegetal das pastagens em estudo, sendo úteis para estudar áreas maiores, mas pelo facto de serem imagens aéreas, estão limitados pelo facto de não ser possível visualizar a vegetação que se encontra sob a canópia (Serrano et.al 2021). A sua utilização pode ser combinada com o uso de dispositivos de proximidade, que permitem leituras ao nível do solo (Figura 3). Da utilização destes dispositivos podem ser retirados parâmetros como:

- Índice de Vegetação de Diferença Normalizada (NDVI, do inglês *Normalized Difference Vegetation Index*) (Rouse et.al, 1974), que quantifica a vegetação através do cálculo da diferença entre a radiação do infra-vermelho próximo (*Near-Infrared*, NIR), que é refletida pelas clorofilas e do vermelho (RED), que é absorvida pelas plantas. Esta radiação emitida pelas plantas é captada nas

imagens obtidas pelos sensores e a vegetação pode ser quantificada pela fórmula:

$$NDVI = (NIR - RED)/(NIR + RED) \quad [Equação 1]$$

- Capacitância – propriedade de armazenar energia sob a forma de cargas elétricas. Zonas de pastagem possuem valores de capacitância superiores, pelo que a sua medição com capacitímetros (Figura 4) permite estimar a quantidade de massa forrageira (Serrano et.al, 2009).
- Temperatura – a temperatura das plantas está relacionada com a estrutura foliares interna, nomeadamente, conteúdo em água e nutricional (Costa et.al, 2013), pelo que a monitorização da temperatura utilizando câmaras térmicas de infravermelhos (Figura 5) permitirá avaliar o estado da vegetação, sendo, portanto, um método com várias aplicações na agricultura (Manickavasagan et.al, 2005).

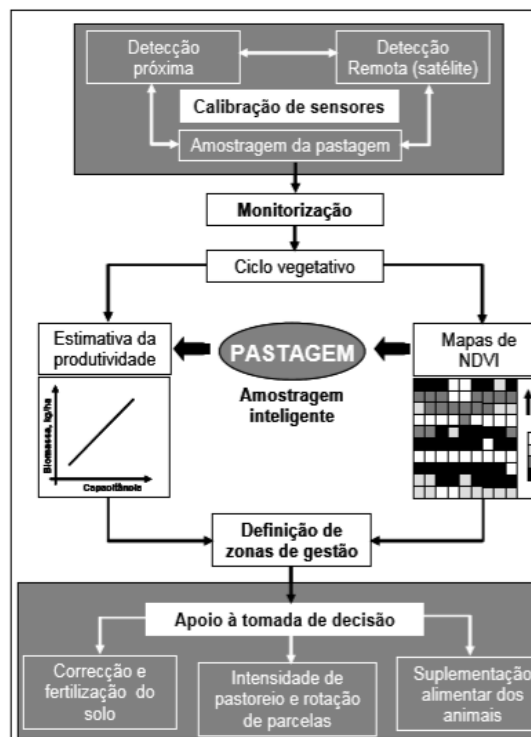


Figura 3 - Monitorização da Produtividade das Pastagens: da Detecção Remota à utilização complementar de Sensores Próximos

Fonte: Serrano et.al (2018)


A utilização isolada ou combinada destes parâmetros permite inferir qualitativa e quantitativamente sobre as características da pastagem. Carecem igualmente de calibração de forma a que as medições sejam representativas da pastagem avaliada. Por exemplo, Edirisinghe et.al (2011) desenvolveu um modelo ( $R^2 = 0.85$ ) baseado no NDVI obtido por imagens de satélite de alta resolução, que permite estimar quantitativamente a biomassa de pastagens.

Serrano et.al (2018) avaliou a utilização da capacitância como método para determinar a matéria verde e seca da pastagem em três parcelas do Alentejo compostas por diferentes espécies vegetais, tendo verificado que a sazonalidade climática e o estágio de desenvolvimento das pastagens pode por em causa a fiabilidade do método uma vez que apenas nos meses de Fevereiro e Março se encontraram fortes correlações entre as leituras obtidas e a produtividade da pastagem. Num outro estudo, a avaliação da produtividade da pastagem na mesma região foi feita utilizando medições de capacitância e NDVI, observando-se elevadas correlações entre ambos parâmetros e a matéria verde, apesar de não terem sido tão eficazes a estimar a matéria seca (Serrano et. al, 2016).



*Figura 4 - Sonda Grassmaster II*

**Fonte:** Serrano et.al (2018)



*Figura 5 - Imagem Térmica*


**Fonte:** Safa et.al (2019)

Apesar de promissores relativamente aos baixos custos e à facilidade e rapidez de utilização, os métodos indiretos comportam várias limitações, não havendo nenhum método universal que permita estimar de forma precisa e realista a produtividade das pastagens. Desta forma, são necessários mais estudos que permitam desenvolver e/ou melhorar este tipo de métodos.

### **3. Imagens Digitais e Determinação da Qualidade das Pastagens**

O uso de imagens digitais para aferir relativamente à qualidade das pastagens tem vindo a crescer dado que, de acordo com os estudos já realizados, é uma técnica precisa e que reduz os erros associados ao observador/ manipulador (Limb et.al, 2007) apesar de existirem erros associados que comprometem a sua interpretação e classificação. A presença de nuvens, as alterações sazonais da luz solar, a hora e até mesmo data, a heterogeneidade da pastagem e características técnicas da câmara ou sensibilidade do sensor a sombras e reflexos são fatores que poderão influenciar as imagens obtidas e afetar, conseqüentemente, a avaliação das pastagens (Barbosa et.al, 2016; Jorgensen et.al, 2013). Poderá ser possível tratar as imagens obtidas das pastagens recorrendo a *softwares* de tratamento imagem que permitam a correção de artefactos presentes nas mesmas ou a utilização de filtros e ajustes de parâmetros aquando da obtenção das imagens (Lukina et.al, 1999).

O princípio por trás desta metodologia centra-se na reflexão de luz em determinados comprimentos de onda pelas plantas devido à incidência da luz solar (refletância) e/ou na ocorrência de fluorescência (absorção de luz de um determinado comprimento de onda e posterior emissão num comprimento de onda maior) (Barbosa et.al, 2016). Relativamente ao tipo de radiação, devido à absorção de radiação pela clorofila durante o processo fotossintético, as plantas têm baixa refletância na região do espectro visível e uma refletância superior na região do infravermelho próximo, e refletâncias baixas na zona do vermelho devido à absorção de radiação pela água (Jensen et al., 2009). As câmaras digitais são capazes de detetar essas emissões de luz, resultando numa imagem onde cada *pixel* que a forma resulta da combinação das três cores primárias – Vermelho, Azul, Verde (sistema RGB - do inglês *Red, Green, Blue*) (Barbosa et.al, 2016). Para além da contagem de bandas do espectro, as imagens digitais permitem a contagem de pixels contido numa fotografia, produzindo uma estimativa digital relativamente à cobertura vegetal (Figura 6) (Jorgensen et.al, 2013; Barbosa et.al, 2016), que se usa para análise de vegetação (DIVA) e que está dependente do software utilizado.



*Figura 6 - Exemplo de Duas Imagens Digitais, Pano de Fundo Preto (a) e Pano de Fundo Branco (c), e suas Respetivas Imagens Binárias (b e d), Convertidas usando Técnicas de Análise de Vegetação de Imagens Digitais (DIVA)*

**Fonte:** Jorgensen et.al (2013)



Lukina et.al (1999) levaram a cabo um estudo de aplicação de imagens digitais para estimar a cobertura vegetal em campos de trigo (*Triticum aestivum*) através da correlação entre a percentagem de pixels correspondentes à cor da vegetação e a percentagem de cobertura vegetal, tendo inclusivamente obtido uma elevada correlação entre os valores de percentagem de cobertura vegetal obtidos com este método e o índice NDVI, falado anteriormente. No entanto, identificaram o tipo de solo como principal fator limitativo do método, sendo necessário efetuar vários ajustes de contraste, brilho e balanço das imagens em função das características do solo de determinada área.

Para além do NDVI, outro índice usado frequentemente é o índice de Área Foliar (IAF), obtido através do quociente entre a soma da área de uma das faces das folhas projetada sobre a área da superfície do solo, estando fortemente relacionado com a produtividade das pastagens, uma vez que o nível de atividade fotossintética depende da área foliar e da incidência da radiação solar (Watson, 1952). Softwares de determinação de áreas podem ser utilizados para determinar este índice e desenvolver modelos preditivos de áreas foliares (Ferreira et.al 2009). Por exemplo, foram desenvolvidos e validados modelos preditivos de área foliar ( $R^2 > 0.98$ ) em seis espécies diferentes de leguminosas forrageiras utilizando imagens digitais das folhas processadas com o software ImageJ do pacote R Leaf Area (Santana et.al, 2018). Num outro estudo, a área foliar foi determinada recorrendo a câmaras digitais mais acessíveis e económicas, como por exemplo, de telemóveis, câmaras web ou câmaras semiprofissionais, sem que a precisão dos dados obtidos seja afetada (Guerrero et.al, 2012). No entanto, estas imagens foram obtidas em laboratório, pelo que a sua utilização *in situ* teria de ser igualmente validada.

Outros índices podem ser obtidos a partir das imagens digitais, como resultado da combinação entre dois ou mais comprimentos de onda e que refletem características da cobertura vegetal da zona fotografada:

- Modified Green Red Vegetation Index (MGVRI);
- Green Leaf Index (GLI);
- Modified Photochemical Reflectance Index (MPRI);

- Red Green Blue Vegetation Index (RGVBI);
- Excess of green (ExG);
- Vegetativen (VEG).

### 3.1 Modified Green Red Vegetation Index (MGVRI)

O Índice de Vegetação Verde Vermelho Modificado (*Modified Green Red Vegetation Index* (MGVRI)), uma adaptação do índice de GVRI proposto por Tucker (1979), permite a distinção entre o solo e a vegetação (Bendig et.al, 2015). No entanto, as sombras produzidas pelas nuvens podem interferir com os resultados, levando a uma sobrestimação do grau de desenvolvimento da vegetação, pelo que a sua utilização terá de ser cuidadosamente avaliada (Barbosa et.al, 2019). O cálculo deste índice é feito utilizando os valores de refletâncias do verde (G) e vermelho (R) das imagens digitais conforme a fórmula:

$$((G)^2 - (R)^2) / ((G)^2 + (R)^2) \quad \text{Bendig et.al (2015) [Equação 2]}$$

### 3.2 Green Leaf Index (GLI)

O Índice de Folha Verde (Green Leaf Index (GLI)), proposto por Louhaichi et.al (2001) e cuja fórmula se encontra abaixo (Equação 3), é calculado utilizando a diferença normalizada das diferentes faixas espectrais (verde (G), vermelho (R) e azul (B)). Este índice pode assumir valores que oscilam entre 1 e -1 em que, os valores positivos são inerentes a área constituída por vegetação e os valores negativos representam áreas de solo.

$$(2G - R - B) / (2G + R + B) \quad \text{Louhaichi et.al (2001) [Equação 3]}$$

### 3.3 Modified Photochemical Reflectance Index (MPRI)

O Índice de Refletância Fotoquímica Modificado (MPRI, do inglês *Modified Photochemical Reflectance Index*) tem por objetivo a análise da diferença normalizada desencadeada na resposta espectral verde (G) em relação ao vermelho (R), tendo por base a ênfase da região verde da vegetação (Yang et.al, 2008). O seu cálculo pode ser realizado utilizando a seguinte fórmula:

$$(G - R) / (G + R) \text{ Yang et.al (2008) [Equação 4]}$$

Segundo o estudo de Barbosa et.al (2019), o MPRI é o índice que se adequa para classificar a variabilidade da vegetação e a cobertura do solo, uma vez que permite a distinção visual destes dois parâmetros e devido ao facto de ser menos afetado por sombras. Gonçalves et.al (2017) verificou também uma elevada correlação entre os valores de MPRI e presença de vegetação (*Axonopus affinis*) com um  $R^2 = 0.89$ , detentando uma variabilidade do índice em relação ao estágio de desenvolvimento da vegetação.

### 3.4 Red Green Blue Vegetation Index (RGVBI)

O Índice de vegetação Vermelho Verde e Azul (RGVBI, do inglês *Red Green Blue Vegetation Index*) foi proposto também por Bendig et.al (2015), sendo definido pela diferença normalizada do quadrado da refletância do verde (G) e o produto da refletância do azul (B) pelo vermelho (R), de acordo com a seguinte fórmula:

$$(G - (B * R)) / ((G)^2 + (B * R)) \text{ Bendig et.al (2015) [Equação 5]}$$

Os autores verificaram uma maior aplicabilidade deste índice para estados iniciais do desenvolvimento das culturas (no caso do estudo referido, culturas de cevada *Hordeum vulgare*), onde a distinção entre vegetação e solo foi mais eficaz, tendo obtido valores de  $R^2 = 0.82$  na estimativa da biomassa da cultura (Bendig et.al 2015).

### 3.5 Excess of green (ExG)

À semelhança dos índices referidos anteriormente, o Índice Excesso de Verde (ExG, do inglês *Excesso of Green*), proposto por Woebbecke et.al (1995), visa evidenciar e separar a vegetação do solo exibido, com a particularidade de distinguir igualmente os resíduos de vegetação em condições de sombra e elevada intensidade solar. Para tal, são consideradas as diferenças existentes nas intensidades de verde (G) e vermelho (R) e nos seus diferentes comportamentos na interação com o solo e com a vegetação (Souza, 2018).

Este índice é representado pela seguinte fórmula:

$$2G - R - B \text{ Woebbecke et.al (1995) } [Equação 6]$$

No seu trabalho, Barbosa et.al (2016) observou uma reduzida capacidade deste indicador de distinguir a vegetação do solo, avaliando erradamente o grau de desenvolvimento da vegetação de determinadas áreas. No entanto, tais resultados contrariam aqueles observados por Torres-Sánchez et.al (2015) em plantações de trigo, onde obtiveram precisões de 90% na deteção de vegetação, apesar de ocorrer sub e sobre estimacão dos valores em zonas onde o tamanho das plantas era inferior e superior à média, respetivamente.

### 3.6 Vegetativen (VEG)

O Índice *Vegetativen* é uma adaptacão de Hague et.al (2006) do índice desenvolvido por Marchant & Onyango (2000) para corrigir as sombras presentes em imagens obtidas com iluminacão solar, aplicando uma constante  $\alpha$  de valor 0.667 aos valores do vermelho (R) e azul (B), de acordo com a seguinte fórmula:

$$\frac{G}{R^a \times B^{(1-a)}} \quad \text{Hague et.al (2006)} \quad [\text{Equação 7}]$$

No seu trabalho, Hague et.al (2006) verificaram a eficácia deste índice em identificar a percentagem de componente vegetal de imagens de campos de cereais, obtendo uma boa correlação entre a metodologia automática e a manual. Noutro estudo, a aplicabilidade deste índice foi também analisada para determinar a cobertura vegetal em campos de feijão *Canavalia ensiformis* e da planta *Pennisetum glaucum*, tendo-se observado nível variável de eficácia do índice de acordo com a espécie analisada ( $R^2 = 0.84$  para *C. ensiformis* e  $R^2 = 0.46$  para *P. glaucum*) (Beniaich et.al 2019).

Os estudos referenciados permitem concluir que a aplicação de imagens digitais para avaliar a vegetação existente em pastagens, apesar de extremamente promissora, carece ainda de estudos que permitam ultrapassar as limitações existentes, de forma a que os resultados obtidos sejam robustos e com reduzida variabilidade relativamente às condições ambientais.

O objetivo deste estudo passa, principalmente, por conseguirmos obter um método expedito e que possa facilmente ser usado pelo agricultor. Pretendemos averiguar se, através de uma fotografia recolhida pelo agricultor da sua pastagem, se consegue aferir a sua qualidade e quantidade. A fotografia poderá ser tirada através de um smartphone, uma vez que nos dias que correm o seu uso é cada vez mais comum, assim como o acesso à internet que, segundo o estudo feito por Costa, et.al (2016), a nível mundial 3,4 bilhões de pessoas têm acesso e fazem uso desta.

É de realçar que, nas condições presentes na Bacia Mediterrânea, as pastagens são bastante heterogêneas ao nível da sua estrutura e densidade, o que irá influenciar a validação destas imagens digitais para determinar a qualidade e quantidade das pastagens.

## 4. Materiais e Métodos

### 4.1 Local dos ensaios

As colheitas de amostras foram realizadas numa parcela com cerca de 7 ha, localizada na Quinta da Silveira, (latitude 38,6218119° N; longitude 7,9462648° W) em Évora, Portugal. A monitorização da pastagem foi feita em quarenta e sete pontos de amostragem (Figura 7), que distavam 35 m uns dos outros, constituindo os pontos de amostragem uma grelha regular, em que cada quadrícula tinha 1,225m<sup>2</sup> de área. Os pontos de amostragem foram georreferenciados com GNSS de precisão (GPS Trimble RTK/ PP-4700, Trimble Navigation Limited, EUA), e reconhecíveis no terreno com pequenas estacas de ferro.

Nesses 47 pontos foram efetuadas colheitas de imagens e de pastagem em 4 datas distintas: 22 de abril, 13 de maio, 3 de junho e 24 de junho.



Figura 7 - Parcela e pontos de amostragem do estudo

Fonte: Adaptado de Serrano et.al, 2016

## 4.2 Recolha das amostras

Em cada ponto de amostragem foi utilizada um aro com 0,25m<sup>2</sup> (50cmX50cm) (Figura 8). Em cada ponto recolheram-se um mínimo de 2 fotografias, utilizando uma máquina fotográfica GoPro Hero 2, tendo como referência o centroide do aro e mantendo uma distância de 80cm na perpendicular. Após a captura das fotos, toda a pastagem que se encontrava no interior foi cortada com uma tesoura elétrica cerca de 2cm acima da superfície do solo. O material vegetal foi colocado em sacos de plásticos identificados e transportada para o Laboratório de Metabolismo e Nutrição da Universidade de Évora, onde se realizaram os procedimentos laboratoriais.

## 4.3 Análise da massa forrageira e do valor nutritivo da pastagem

No laboratório as amostras do material vegetal foram pesadas para determinação, da massa forrageira em verde (kg MV/ha). Seguidamente eram secas na estufa durante 72h a 65°C e pesadas novamente par determinar a quantidade de matéria Seca ((kg MS/ha). As amostras secas foram moídas e utilizadas para determinar a matéria seca residual (para poder expressar os parâmetros analíticos em % de MS, ISSO 6496:1999). Foram ainda determinadas as cinzas totais para cálculo da matéria orgânica (MO), a proteína bruta (PB, método Dumas, ISO 16634–1;2008) e a fibra insolúvel em detergente neutro (NDF, ISO 16472:2006).



*Figura 8 - Aro utilizado nas colheitas de amostras*

**Fonte:** Autor

A matéria seca residual foi feita secando as amostras a 105 °C durante 24h. As cinzas totais foram obtidas após inceneração na mufla a 550°C durante 3 horas, seguido de uma hora em estufa a 150°C. A determinação de PB foi realizada pelo método Dumas por detecção da condutividade térmica do azoto libertado por combustão a altas temperaturas em oxigénio puro (LECO), convertido em proteína bruta usando o fator 6,25. A determinação da fibra foi feita segundo o método de Van Soest (Fibretherm) usando detergente neutro.

#### **4.4 Análise das imagens da pastagem**

Para procedermos à análise da qualidade da pastagem é necessário recorrer à instalação do software ADI, desenvolvido pela empresa Analog Devices, Inc.

Antes da utilização do Software as fotografias originais foram recortadas, de forma a conseguir remover a área em torno do aro e o mais próximo possível do mesmo para que consigamos selecionar a sua área interna (evitando ao máximo deturpações e incluir extremidades do aro o que iria afetar as leituras de cor).

Descrevemos seguidamente a ações efetuadas para o tratamento das imagens de forma a obtenção automática dos canais de RED, GREEN e BLUE e qu podem ser observadas na Figura 9.

- 1 - Selecionar a opção “Spatial Analysis”;
- 2 - Selecionar a imagem cuja pastagem pretendemos analisar;
- 3 - Na opção “Select Measurement Tool” e optar pela opção “Rectangle Tool”;
- 4 – Selecionar a área dentro do frame e com  $\pm 7000$ pixels;
- 5 – Opção “Save Measurement”.



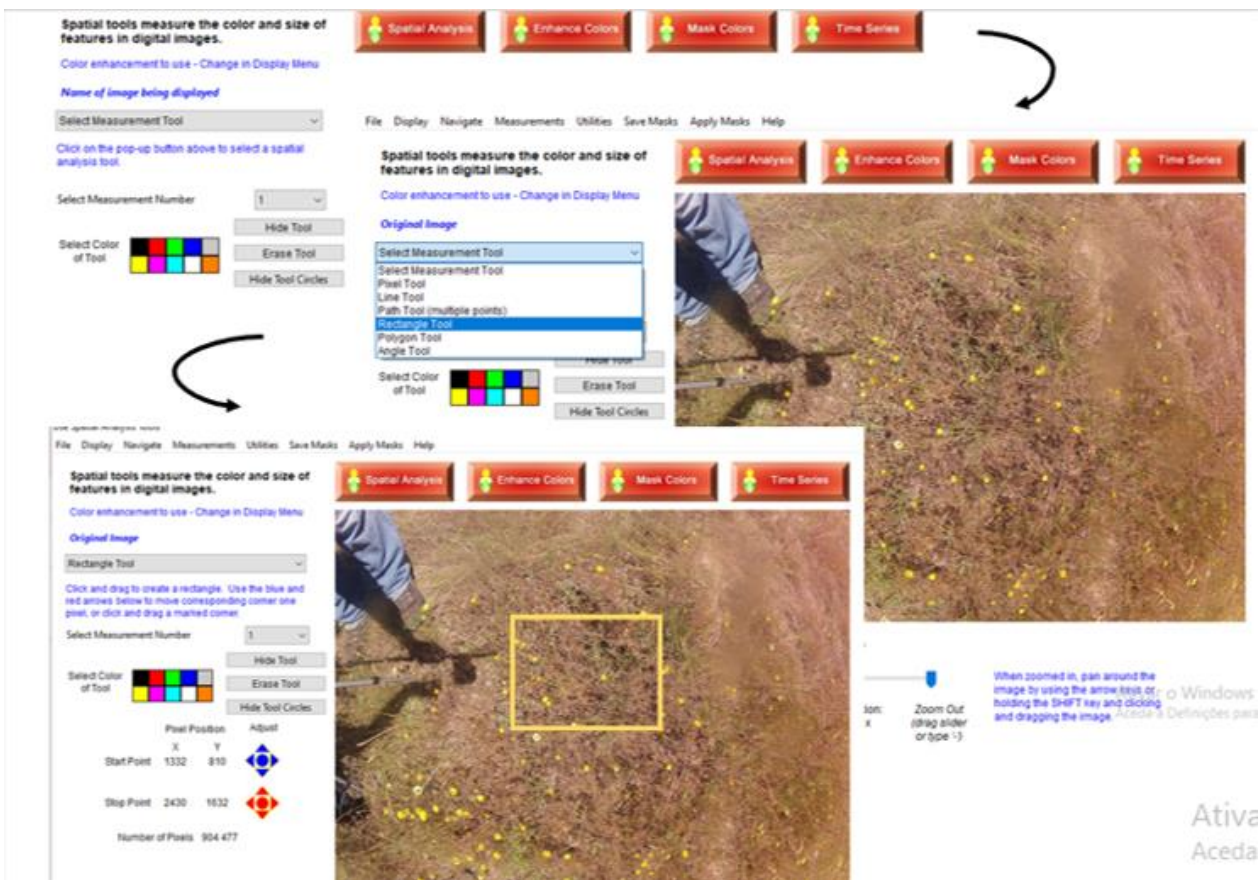


Figura 9 - Ecrãs do ADI Software durante o tratamento das imagens

Fonte: Autor

Após este processo, obtinha-se um ficheiro em formato “.txt” (Fig.10) com a compilação dos resultados obtidos após a análise das fotografias inerentes a um determinado ponto.

Image Name	Scaling Factor	Scaling Unit	Image Width	Image Height	User Data	User Comments	Analysis Type	Length/Area	Number of Pixels
GOPR4084.JPG	-1	732 918	Rectangle	-1 70290	-1 345	148 557	477 RGB	55,637 100,001 14,902	
% Pixels Masked	X1 Y1	X2 Y2	Color Scheme	Average Red	Max Red Min Red StDev Red	Average Green	Max Green Min Green StDev G		
15,372 52,246 100,001 10,980	15,043 11,023 75,295 0,000	9,016							

Figura 10 - Dados Obtidos do Software ADI

Fonte: Autor

Posteriormente procedeu-se à elaboração de uma folha de excel (Fig.11) onde constam os dados acima mencionados e a partir dos quais pudemos calcular as média e desvio-padrão de cada ponto salientando que, para cada ponto existem 2 fotografias.

Ponto	Image Name	Number of Pixels	Average Red	StDev Red	Média	Desvio-Padrão	Average Green	StDev Green	Média	Desvio-Padrão	Average Blue	StDev Blue	Média	Desvio-Padrão
1	GOPR0012.JPG	70246	41,337	13,936			39,966	14,002			39,357	12,502		
1	GOPR0013.JPG	70238	38,977	12,443	40,157	1,668772004	37,788	12,47	38,877	1,540078569	38,513	11,445	38,935	0,596798123
2	GOPR0016.JPG	70246	45,216	19,404			36,656	19,112			29,161	16,423		
2	GOPR0017.JPG	70176	48,996	18,902	47,106	2,672863633	38,316	18,496	37,486	1,173797257	30,806	16,301	29,9835	1,163190655
3	GOPR0020.JPG	70097	61,826	15,8			47,169	15,631			31,013	13,521		
3	GOPR0021.JPG	70048	62,591	13,068	62,2085	0,540936688	46,111	12,938	46,64	0,748118974	25,033	10,523	28,023	4,228498551
4	GOPR0024.JPG	70091	57,885	17,726			46,922	17,444			23,617	13,661		
4	GOPR0025.JPG	70149	48,668	17,758	53,2765	6,517403202	43,003	17,503	44,9625	2,771151475	21,817	13,379	22,717	1,272792206
5	GOPR0026.JPG	70247	46,169	13,149			42,673	13,029			36,886	11,057		
5	GOPR0027.JPG	70290	43,3	12,162	44,7345	2,028689355	41,503	12,115	42,088	0,827314934	38,205	10,697	37,5455	0,932673844
6	GOPR0186.JPG	70414	58,345	10,162			48,017	10,478			29,313	8,48		
6	GOPR0187.JPG	70143	58,865	10,616	58,605	0,367695526	48,225	10,986	48,121	0,14707821	28,466	8,948	28,8895	0,598919444
7	GOPR0190.JPG	70000	51,726	13,598			44,268	12,966			29,053	10,558		
7	GOPR0191.JPG	70048	54,519	13,575	53,1225	1,97494924	45,169	12,891	44,7185	0,63710321	28,154	10,215	28,6035	0,635688996
8	GOPR0042.JPG	70263	22,614	10,729			23,589	10,88			24,78	9,832		
8	GOPR0043.JPG	70196	22,716	10,969	22,665	0,072124892	23,367	10,905	23,478	0,156977705	24,541	9,835	24,6605	0,168998521
9	GOPR0038.JPG	70172	61,634	13,882			44,852	13,745			22,297	10,781		
9	GOPR0039.JPG	70092	60,923	13,872	61,2785	0,502752921	44,197	13,7	44,5245	0,463154942	21,393	10,632	21,845	0,63922453
10	GOPR0034.JPG	70048	59,762	11,589			46,78	11,594			32,03	10,11		
10	GOPR0035.JPG	70092	61,242	12,561	60,502	1,046518036	46,625	12,53	46,7025	0,109601551	29,089	10,885	30,5595	2,079601043

Figura 11- Folha de Excel para Tratamento dos Dados

Fonte: Autor

Com os valores médios dos vários canais para cada fotografia foram calculados vários índices RGB, nomeadamente usando as equações 2, 3, 4, 5, 6 e 7, descritas na revisão bibliográfica.

#### 4.5 Análise Estatística

A análise de dados foi conduzida com o programa SPSS, (IBM, versão 26). Na descrição de variáveis foram utilizadas médias (M), desvios padrões (DP), medianas (Mdn) e percentis/ quartis (P25-P75). Na avaliação da distribuição das variáveis foram utilizados os coeficientes de assimetria e curtose. Os coeficientes de correlação Pearson e Spearman foram utilizados para avaliar a associação entre os índices vegetativos laboratoriais e de imagens digitais, conforme foi ou não detetada proximidade à normalidade das distribuições. A regressão linear foi utilizada para avaliar a qualidade preditiva das imagens digitais, pelo cálculo do coeficiente de determinação ( $R^2$ ).

## 5. Resultados e Discussão

### 5.1 Valor nutritivo da pastagem

Tabela 1 - Variação Sazonal do Valor Nutritivo da Pastagem (Média ± Desvio-Padrão), n=47

Datas	Biomassa (kgMSTotal/ha)		MO (%MS)		PB (%MS)		NDF (%MS)	
	Média	Desvio-Padrão	Média	Desvio-Padrão	Média	Desvio-Padrão	Média	Desvio-Padrão
<b>Colheita 1 (22/04)</b>	1387,00	700,75	85,50	35,31	14,00	3,68	54,00	6,74
<b>Colheita 3 (13/05)</b>	1528,87	884,39	90,97	2,53	13,25	3,36	56,27	6,40
<b>Colheita 6 (03/06)</b>	1569,95	1042,36	92,57	1,48	10,23	2,36	59,37	6,17
<b>Colheita 9 (24/06)</b>	911,19	878,98	93,19	2,04	8,16	2,15	68,32	4,47

Tabela 2 – Variação Espacial do Valor Nutritivo da Pastagem (Média ± Desvio-Padrão), n=4

Ponto	Biomassa (kgMSTotal/ha)		MO (%MS)		PB (%MS)		NDF (%MS)	
	Média	Desvio-Padrão	Média	Desvio-Padrão	Média	Desvio-Padrão	Média	Desvio-Padrão
1	1478,67	569,76	91,23	2,62	14,94	5,14	52,17	11,10
2	3022,73	1257,50	89,98	2,03	14,61	3,28	56,05	9,89
3	730,44	376,94	92,15	1,67	9,89	2,03	63,59	8,48
4	1461,01	543,92	92,21	2,04	10,49	3,10	63,54	6,48
5	971,11	532,26	92,41	2,32	9,32	2,44	61,05	6,37
6	1036,03	495,72	89,01	6,22	10,00	1,86	61,99	5,04
7	1476,70	930,63	86,06	11,73	10,80	2,04	63,03	4,93
8	1491,61	619,54	87,19	2,73	13,37	2,82	54,26	10,13
9	1475,43	313,04	93,49	0,54	8,64	1,50	63,03	3,47
10	1449,38	572,83	88,86	5,21	16,07	3,45	55,08	8,14
11	1483,63	947,29	89,76	4,74	11,51	2,73	57,60	5,55
12	2479,28	944,16	89,56	2,39	15,81	1,95	55,94	4,54
13	1884,21	1122,51	86,30	11,65	12,89	1,50	55,47	3,72
14	684,78	336,08	91,31	3,83	11,27	2,82	57,79	9,12
15	1251,15	290,77	91,13	3,83	8,79	1,91	58,88	9,89
16	928,44	302,07	91,91	2,47	11,88	4,36	60,78	6,69
17	1292,43	366,98	89,67	6,40	9,38	2,46	67,70	2,67

18	2527,77	1367,52	89,30	2,57	17,11	5,83	53,16	8,48
19	1947,06	619,69	82,95	14,79	10,04	1,94	65,06	4,70
20	506,23	442,37	91,19	3,41	11,19	3,30	54,13	8,53
21	910,90	679,00	85,09	11,33	11,86	1,37	54,03	1,93
22	1078,31	318,73	91,87	3,00	10,78	3,24	57,35	10,75
23	640,33	350,34	92,49	1,50	9,28	1,66	55,54	6,42
24	1184,95	488,87	85,81	13,63	8,95	1,80	62,43	6,84
25	1334,48	443,28	91,41	2,17	11,24	3,97	58,85	9,63
26	1890,33	478,45	86,66	3,47	14,47	2,57	57,51	4,24
27	3728,70	1024,90	87,08	5,18	14,25	3,10	53,90	6,97
28	759,11	370,67	86,49	12,70	10,04	1,57	60,17	4,44
29	1292,90	259,88	87,24	8,09	12,23	3,33	61,49	7,60
30	2142,14	877,83	89,31	4,76	17,19	4,49	52,22	5,75
31	1421,64	297,07	86,37	11,88	12,43	2,53	57,51	5,13
32	865,42	181,58	87,35	8,76	11,35	2,95	57,12	6,28
33	697,01	225,18	91,70	1,67	10,57	2,30	59,63	5,89
34	1246,76	142,35	89,49	4,43	10,83	2,66	59,25	5,53
35	586,26	311,98	93,31	2,13	7,17	1,32	65,80	4,76
36	535,41	233,78	91,80	1,97	10,92	2,02	56,95	9,76
37	454,35	205,30	90,94	3,37	8,77	1,74	59,43	5,50
38	1810,46	762,60	86,22	11,44	9,41	1,59	65,49	4,23
39	1054,71	419,09	89,61	6,83	9,90	1,95	61,08	7,14
40	460,14	122,42	90,44	5,44	8,03	2,18	62,34	10,86
41	656,42	298,77	89,34	10,06	7,01	1,19	64,12	6,42
42	873,27	549,95	89,09	7,19	9,87	1,81	59,68	5,74
43	1115,29	563,06	90,10	2,11	11,67	4,01	62,14	5,56
44	2089,13	826,43	90,20	0,44	10,08	1,35	66,49	4,21
45	1570,22	748,13	143,28	97,67	12,90	1,68	63,89	4,25
46	2290,33	665,49	85,94	4,21	16,98	3,25	54,84	10,37
47	881,85	264,36	92,08	1,07	9,84	1,26	62,44	2,52

## 5.2 Análises de correlação

Na Tabela 3 são apresentados os resultados descritivos das variáveis analisadas. As distribuições das variáveis foram avaliadas pelos coeficientes de assimetria e curtose. Quando próximos do enquadramento [-1; 1] foram calculadas médias (M) e desvios padrão (DP). Fora desse intervalo foram observadas as variáveis Biomassa (kgMSTotal/ha) e MO (% MO), para as quais foram calculadas medianas (Mdn) e percentis (P25 e P75).

Tabela 3 - Análise descritiva das distribuições dos índices vegetativos

	<b>Assimetria</b>	<b>Curtose</b>	<b>M</b>	<b>DP</b>	<b>P25</b>	<b>Mdn</b>	<b>P75</b>
MGVRI	0.74	-0.16	<b>-0.03</b>	<b>0.21</b>	-0.20	-0.07	0.12
GLI	0.51	-0.75	<b>0.14</b>	<b>0.12</b>	0.04	0.13	0.23
MPRI	0.80	0.06	<b>-0.01</b>	<b>0.11</b>	-0.10	-0.03	0.06
RGVBI	0.16	-1.19	<b>-0.31</b>	<b>0.12</b>	-0.42	-0.32	-0.20
ExG	0.49	-0.76	<b>22.13</b>	<b>18.32</b>	6.69	20.10	35.56
VEG	1.05	0.70	<b>1.34</b>	<b>0.38</b>	1.02	1.24	1.56
RGB greenness	0.49	-0.76	<b>22.13</b>	<b>18.32</b>	6.69	20.10	35.56
Biomassa (kgMSTotal/ha)	1.38	2.25	1356.02	926.48	<b>680.40</b>	<b>1187.60</b>	<b>1743.00</b>
MO (% MS)	10.37	130.44	90.55	17.95	<b>88.59</b>	<b>92.28</b>	<b>93.36</b>
PB (% MS)	0.84	0.61	<b>11.44</b>	<b>3.78</b>	8.85	10.73	13.46
NDF (% MS)	-0.12	-0.70	<b>59.44</b>	<b>8.08</b>	53.28	59.70	65.38

Nas Tabelas 4, 5, 6 e 7 são apresentadas as matrizes de correlações entre dos índices vegetativos nos momentos de colheita número 1 (22 de abril), colheita número 3 (13 de maio), colheita número 6 (3 de junho) e colheita número 9 (24 de junho). O objetivo centra-se nas correlações dos índices MGVRI, GLI, MPRI, RGVBI, ExG, VEG e RGB Greenness (imagens digitais) com os índices de Biomassa (kgMSTotal/ha), MO (% na MS), PB (% na MS) e NDF (% na MS). As correlações entre os índices e as análises laboratoriais da pastagem estão destacadas a cinzento nessas tabelas.

Na colheita de 22 de abril, as correlações mais fortes foram encontradas com o índice PB (% MS), particularmente com MGVRI ( $r=.704$ ,  $p<.01$ ) e MPRI ( $r=.701$ ,  $p<.01$ ). Foram ainda identificadas correlações positivas moderadas [0.3; 0.7] do índice PB (% MS) com os restantes índices. O índice NDF associou-se de forma negativa moderada [-0.7; -0.3] com o MGVRI, GLI, MPRI, VEG e RGB greenness.

Tabela 4 - Matriz de correlações de Pearson dos índices vegetativos na colheita número 1, de 22 de abril

	Imagens digitais (1:7)						Análise laboratorial (8:11)				
	1	2	3	4	5	6	7	8	9	10	11
1 MGVRI	1	.784**	.999**	.530**	.640**	.746**	.664**	.017	.224	.704**	-.481**
2 GLI		1	.775**	.932**	.903**	.978**	.842**	.020	.144	.563**	-.319*
3 MPRI			1	.518**	.625**	.739**	.654**	.007	.218	.701**	-.476**
4 RGVBI				1	.870**	.917**	.820**	.060	.076	.399**	-.205
5 ExG					1	.880**	1,000**	.087	-.008	.562**	-.294
6 VEG						1	.852**	.054	.102	.571**	-.330*
7 RGB greenness							1	.087	.047	.523**	-.315*

8 Biomassa (kgMSTotal/ha)	1	-.305*	0.250	-0.002
9 MO (% MS)		1	.093	.042
10 PB (% MS)			1	-.784**
11 NDF (% MS)				1

\*p<.05; \*\*p<.01; Correlações envolvendo as variáveis Biomassa (KgMSTotal/ha) e MO (% MS) calculadas com o coeficiente de correlação de Spearman

Na colheita de 13 de maio não foram detetadas correlações fortes. Contudo, foram observadas correlações positivas, com valores entre  $r=.446$  e  $r=.608$  da Biomassa (kgMSTotal/ha) com os restantes índices. Neste particular, a principal correlação foi com o RGB greenness ( $r=.608$ ,  $p<.01$ ). Foram também observadas correlações moderadas negativas entre o índice MO (% na MS) e os restantes índices, com mínimo de  $r=-.292$ ,  $p<.05$  (RGVBI) e máximo de MPRI ( $r=-.542$ ,  $p<.01$ ). O índice PB (% MS) obteve correlações positivas moderadas com os restantes índices considerados, nomeadamente  $r=.471$  (RGVBI) e  $r=.586$  (VEG), mínimo e máximo respetivamente.

Tabela 5 - Matriz de correlações de Pearson dos índices vegetativos na colheita número 3, de 13 de maio

	Imagens digitais (1:7)							Análise laboratorial (8:11)			
	1	2	3	4	5	6	7	8	9	10	11
1 MGVRI	1	.510**	.999**	.131	.411**	.464**	.473**	.473**	-.533**	.529**	-.308*
2 GLI		1	.503**	.889**	.897**	.970**	.406**	.449**	-.466**	.567**	-.235
3 MPRI			1	.125	.411**	.460**	.892**	.566**	-.542**	.537**	-.310*
4 RGVBI				1	.783**	.916**	.411**	.446**	-.292*	.471**	-.184
5 ExG					1	.849**	.822**	.487**	-.416**	.523**	-.176
6 VEG						1	1.000**	.473**	-.482**	.586**	-.269
7 RGB greenness							1	.608**	-.408**	.515**	-.139
8 Biomassa (kgMSTotal/ha)								1	-.518**	.628**	-.357*
9 MO (% MS)									1	-.685**	.521**
10 PB (% MS)										1	-.650**
11 NDF (% MS)											1

\*p<.05; \*\*p<.01; Correlações envolvendo as variáveis Biomassa (KgMSTotal/ha) e MO (% MS) calculadas com o coeficiente de correlação de Spearman

Na colheita número 6, de 3 de junho, também não foram detetadas correlações fortes. Contudo, foram observadas maiores diferenças de correlação entre os índices com correlações positivas moderadas variando entre  $r=.383$  (GLI) e  $r=.628$  (MPRI) para o parâmetro Biomassa (kgMSTotal/ha). Em detalhe, as principais correlações foram com o MPRI ( $r=.628$ ,  $p<.01$ ), MGVRI ( $r=.617$ ,  $p<.01$ ) e RGB greenness ( $r=.617$ ,  $p<.01$ ). Foram também observadas correlações moderadas negativas entre o índice MO (% MS) e os restantes índices, com mínimo de  $r=-.438$ ,  $p<.01$  (RGVBI) e máximo de VEG ( $r=-.569$ ,  $p<.01$ ). O índice PB (% MS) obteve correlações positivas moderadas com os restantes índices considerados, nomeadamente  $r=.399$ ,  $p<.01$  (RGB greenness) e  $r=.596$ ,  $p<.01$

(VEG), mínimo e máximo respetivamente.

Tabela 6 - Matriz de correlações de Pearson dos índices vegetativos na colheita número 6, de 3 de junho

	Imagens digitais (1:7)							Análise laboratorial (8:11)			
	1	2	3	4	5	6	7	8	9	10	11
1 MGVRI	1	.633**	.999**	.438**	.578**	.739**	.617**	.617**	-.438**	.441**	-.081
2 GLI		1	.634**	.966**	.984**	.979**	.487**	.383**	-.564**	.570**	-.089
3 MPRI			1	.440**	.581**	.739**	.994**	.628**	-.446**	.447**	-.080
4 RGVBI				1	.967**	.918**	.501**	.390**	-.520**	.521**	-.084
5 ExG					1	.954**	.975**	.579**	-.563**	.554**	-.094
6 VEG						1	1.000**	.617**	-.569**	.596**	-.134
7 RGB greenness							1	.601**	-.510**	.399**	-.008
8 Biomassa (kgMSTotal/ha)								1	-.579**	.512**	-.054
9 MO (% MS)									1	-.649**	.068
10 PB (% MS)										1	-.318*
11 NDF (% MS)											1

\* $p < .05$ ; \*\* $p < .01$ ; Correlações envolvendo as variáveis Biomassa (KgMSTotal/ha) e MO (% MS) calculadas com o coeficiente de correlação de Spearman

Na colheita número 9, de 24 de junho, as correlações obtidas foram entre a Biomassa (kgMSTotal/ha) e os índices MGVRI ( $r = .529$ ,  $p < .01$ ), MPRI ( $r = .525$ ,  $p < .01$ ), ExG ( $r = .560$ ,  $p < .01$ ), VEG ( $r = .529$ ,  $p < .01$ ) e RGB greenness ( $r = .510$ ,  $p < .01$ ), todas positivas e moderadas. O índice MO (% MS) correlacionou-se de forma moderada e negativa com todos os restantes índices de interesse, variando entre  $r = -.375$  ( $p < .01$ ) e  $r = -.485$ .

Tabela 7 - Matriz de correlações de Pearson dos índices vegetativos na colheita número 9, de 24 de junho

	Imagens digitais (1:7)							Análise laboratorial (8:11)			
	1	2	3	4	5	6	7	8	9	10	11
1 MGVRI	1	.402**	.998**	.194	.307*	.535**	.529**	.529**	-.385*	.200	-.197
2 GLI		1	.404**	.964**	.966**	.979**	.030	.157	-.485**	.150	-.064
3 MPRI			1	.195	.312*	.536**	.988**	.525**	-.375*	.189	-.197
4 RGVBI				1	.954**	.923**	.035	.192	-.448**	.103	-.012
5 ExG					1	.926**	.953**	.560**	-.426**	.099	.022
6 VEG						1	1.000**	.529**	-.481**	.155	-.102
7 RGB greenness							1	.510**	-.382*	.017	.138
8 Biomassa (kgMSTotal/ha)								1	-.498**	.237	-.023
9 MO (% MS)									1	-.470**	.227
10 PB (% MS)										1	-.508**
11 NDF (% MS)											1

\* $p < .05$ ; \*\* $p < .01$ ; Correlações envolvendo as variáveis Biomassa (KgMSTotal/ha) e MO (% MS) calculadas com o coeficiente de correlação de Spearman

De seguida procedeu-se à avaliação das medidas com correlação mais elevada em cada colheita (Figuras 9, 10, 11 e 12).

Na colheita número 1 destacaram-se as medidas de imagens digitais MGVRI ( $r=.704$ ,  $p<.01$ ) e MPRI ( $r=.701$ ,  $p<.01$ ) na associação com o índice PB (% MS). Os coeficientes de determinação, que estimam o poder explicativo (%) da variável independente sobre a variável dependente apontaram para 49.6% no MGVRI e 49.2% no MPRI, i.e. valores muito próximos.

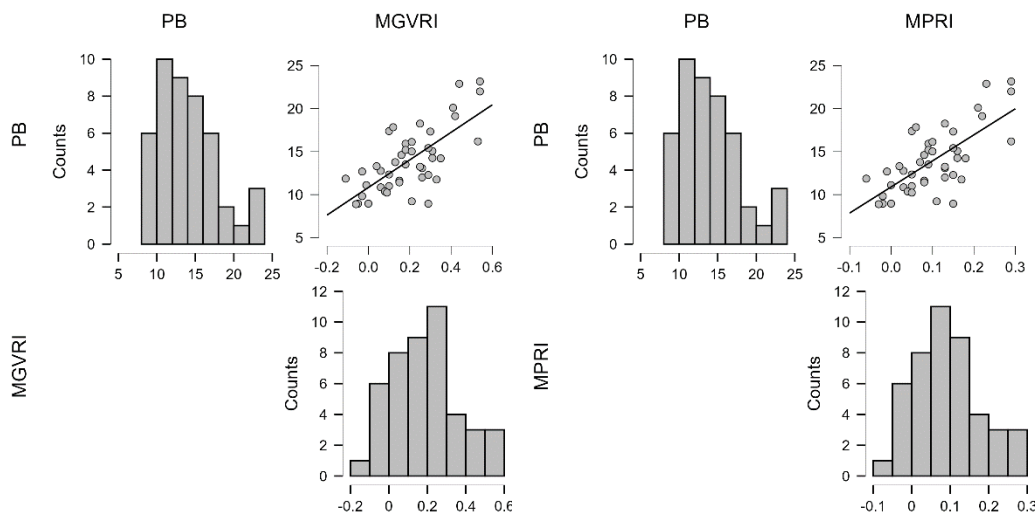


Figura 9 - Análise da correlação do índice PB com os índices MGVRI e MPRI na colheita número 1

Na colheita número 3 (Figura 10) destacaram-se as medidas de imagens digitais RGB greenness ( $r=.608$ ,  $p<.01$ ) e VEG ( $r=.567$ ,  $p<.01$ ) na associação com os índices Biomassa (kgMSTotal/ha) e PB (% MS), respetivamente. Os coeficientes de determinação, que estimam o poder explicativo (%) da variável independente sobre a variável dependente apontaram para 21.1% na associação do RGB greenness com a Biomassa e 34.3% no MPRI, i.e. valores idênticos.



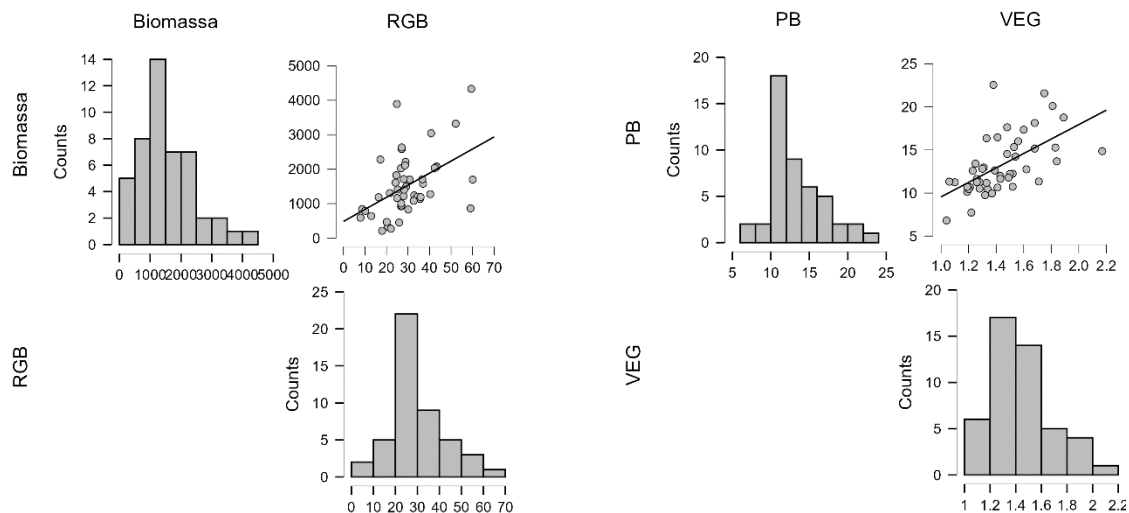


Figura 10 - Análise da correlação do índice Biomassa com o índice RGB greenness e do índice PB com o índice VEG na colheita número 3

Na colheita número 6 (Figura 11) destacaram-se as medidas de imagens digitais MGVRT (r=.617, p<.01) e VEG (r=.617, p<.01) na associação com o índice Biomassa (kgMSTotal/ha). Os coeficientes de determinação, que estimam o poder explicativo (%) da variável independente sobre a variável dependente apontaram para 25.5% na associação do MGVRT com a Biomassa e 22.5% na associação do VEG com a biomassa.

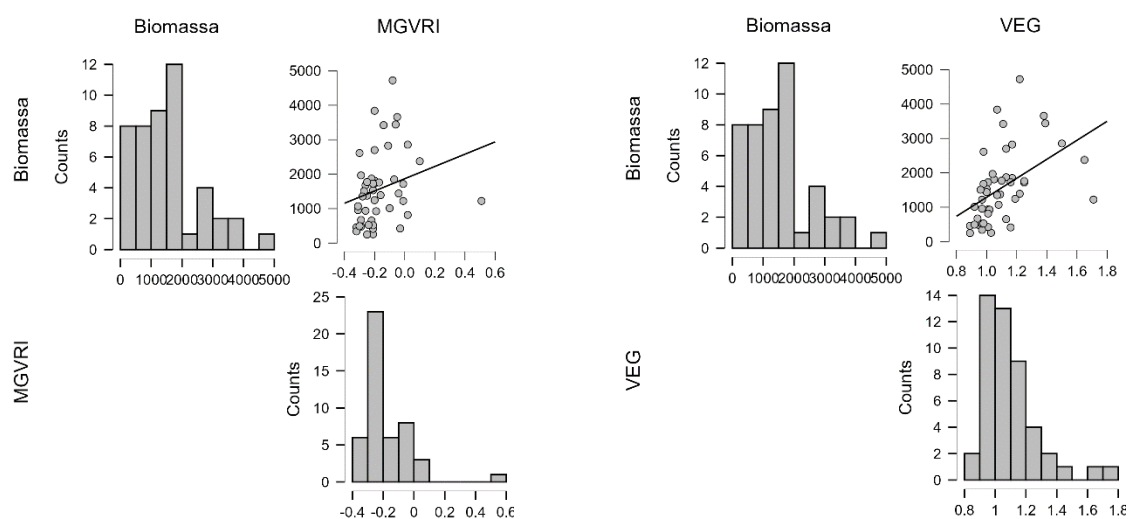


Figura 11 - Análise da correlação do índice Biomassa com o índice RGB greenness e do índice PB com o índice VEG na colheita número 6

Na colheita número 9 (Figura 12) destacaram-se as medidas de imagens digitais ExG ( $r=.560$ ,  $p<.01$ ) MGVR1 ( $r=.529$ ,  $p<.01$ ) e VEG ( $r=.529$ ,  $p<.01$ ) na associação com o índice Biomassa (kgMSTotal/ha). Os coeficientes de determinação, que estimam o poder explicativo (%) da variável independente sobre a variável dependente apontaram para 59.3% na associação do ExG com a Biomassa 13.8% na associação do MGVR1 com a Biomassa e 63.4% na associação do VEG com a biomassa.

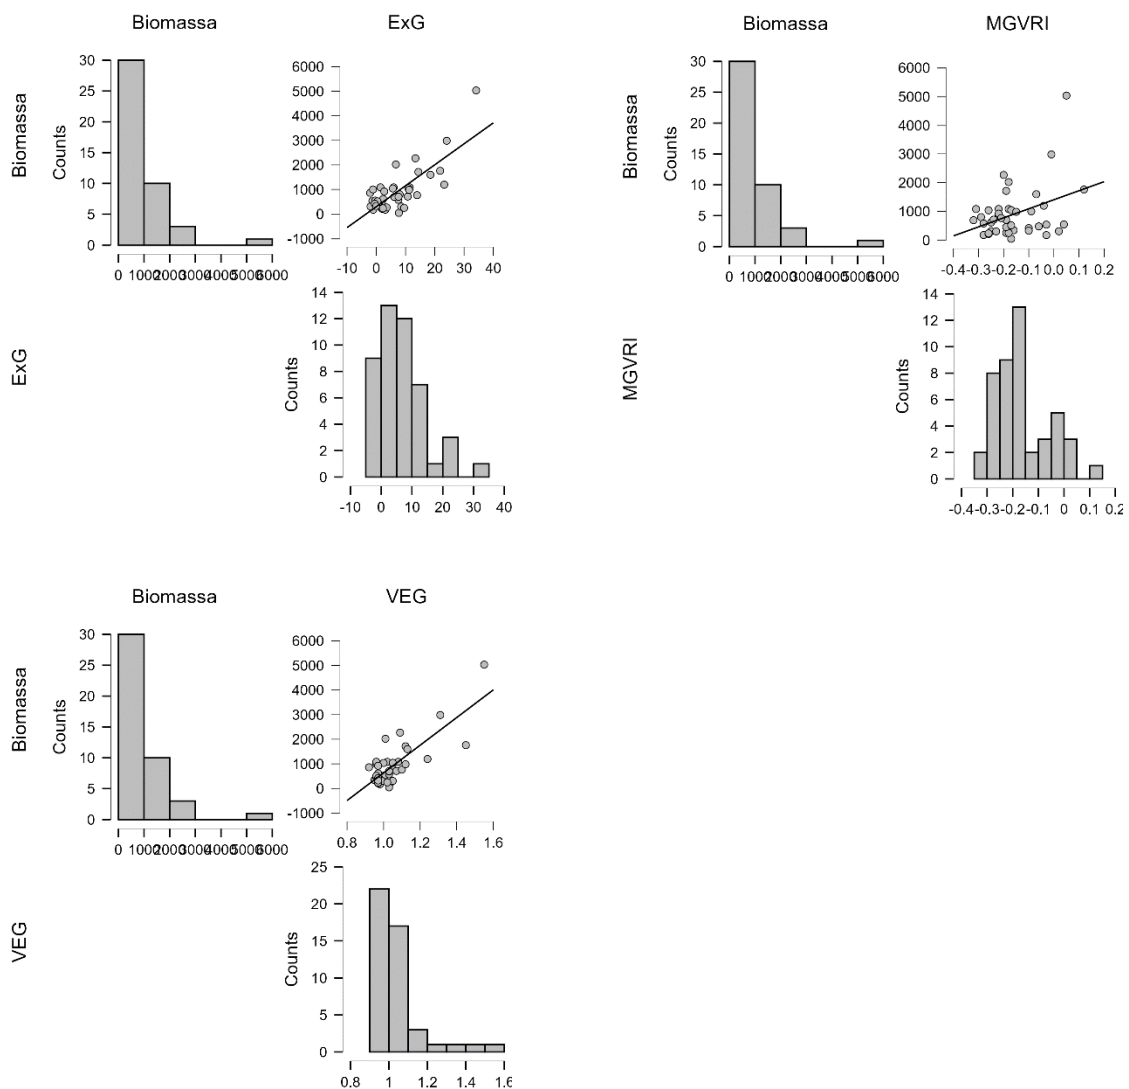


Figura 12 - Análise da correlação do índice Biomassa com o índice RGB greenness e do índice PB com o índice VEG na colheita número 9

### 5.3 Coeficientes de determinação

Nas Figuras 13 à 40 são apresentados os resultados da associação dos índices obtidos em laboratório com os obtidos pelas imagens digitais. Relativamente ao índice de Biomassa (kgMSTotal/ha), a primeira colheita não fornece informação relevante nas imagens digitais. Foi observada uma tendência para melhoria da capacidade preditiva sobre a biomassa ao longo das colheitas. Os melhores índices para avaliar a qualidade das pastagens relativamente à biomassa foram o RGBI na colheita número 9 ( $R^2=0.548$ ), ExG, na colheita número 9 ( $R^2=0.593$ ), VEG na colheita número 9 ( $R^2=0.634$ ) e RGB Greenness, também na colheita número 9 ( $R^2=0.593$ ).

As associações das imagens digitais com o índice MO (% na MS) não foram relevantes ( $0.000 < R^2 < 0.323$ ), concluindo-se as imagens digitais não são um bom método para avaliar a qualidade das pastagens baseada no MO.

Ao avaliar os resultados das imagens digitais em associação com o índice PB (% na MS) conclui-se que a colheita número 9 é o pior momento para encontrar associações das imagens digitais com esta medida. Os melhores índices para avaliar a qualidade das pastagens relativamente ao PB foram o MGVRI na colheita número 1 ( $R^2=0.496$ ) e MPRI na colheita número 1 ( $R^2=0.492$ ).

As associações das imagens digitais com o índice NDF (% na MS) não foram relevantes ( $0.000 < R^2 < 0.227$ ), concluindo-se as imagens digitais não são um bom método para avaliar a qualidade das pastagens baseada no NDF.

Em suma, o melhor índice baseado em imagens digitais para prever os índices obtidos em laboratório foram o VEG na colheita número 9, com 63.4% de poder explicativo sobre a biomassa. A biomassa foi o único índice laboratorial cujas associações com imagens digitais obteve capacidade preditiva superior a 50%, RGBI ( $R^2=54.8\%$ ), ExG, ( $R^2=59.3\%$ ), VEG ( $R^2=63.4\%$ ) e RGB Greenness ( $R^2=59.3\%$ ), mas apenas na colheita número 9. Foi ainda observada alguma capacidade preditiva, próxima de 50%, das imagens digitais MGVRI na colheita número 1 ( $R^2=49.6\%$ ) e MPRI na colheita número 1 ( $R^2=49.2\%$ ) para com o índice PB (% MS).

As associações das imagens digitais com os índices MO (% MS) e NDF (% MS) não foram relevantes pelo que não se aconselha este método para avaliar a qualidade das pastagens, com referência a estes índices.




Figura 13 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo MGVRTI por momento da colheita




Figura 14 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo GLI por momento da colheita




Figura 15 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo MPRI por momento da colheita

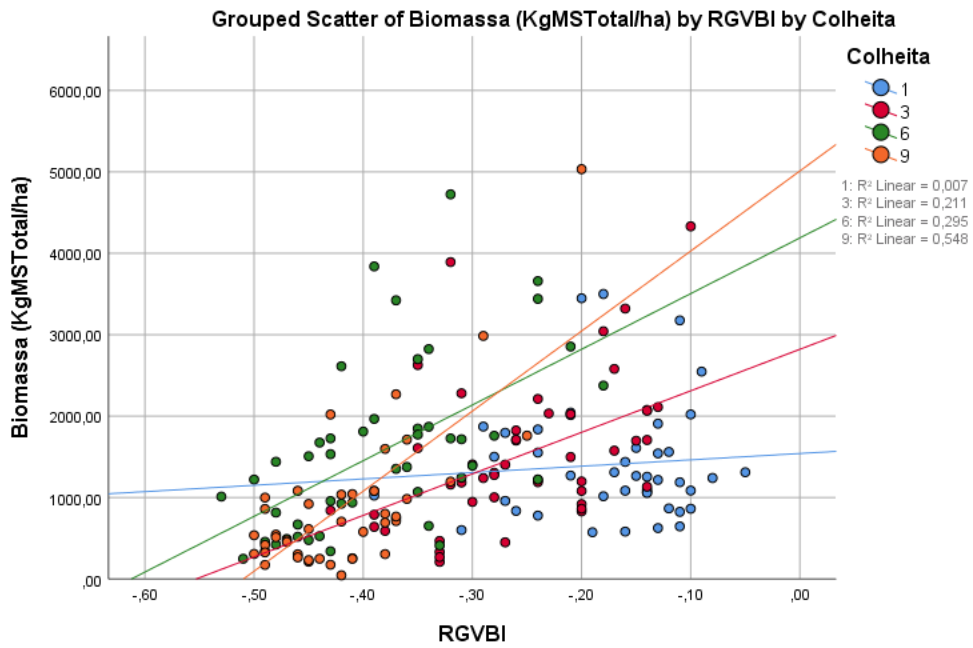


Figura 16 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo MPRI por momento da colheita

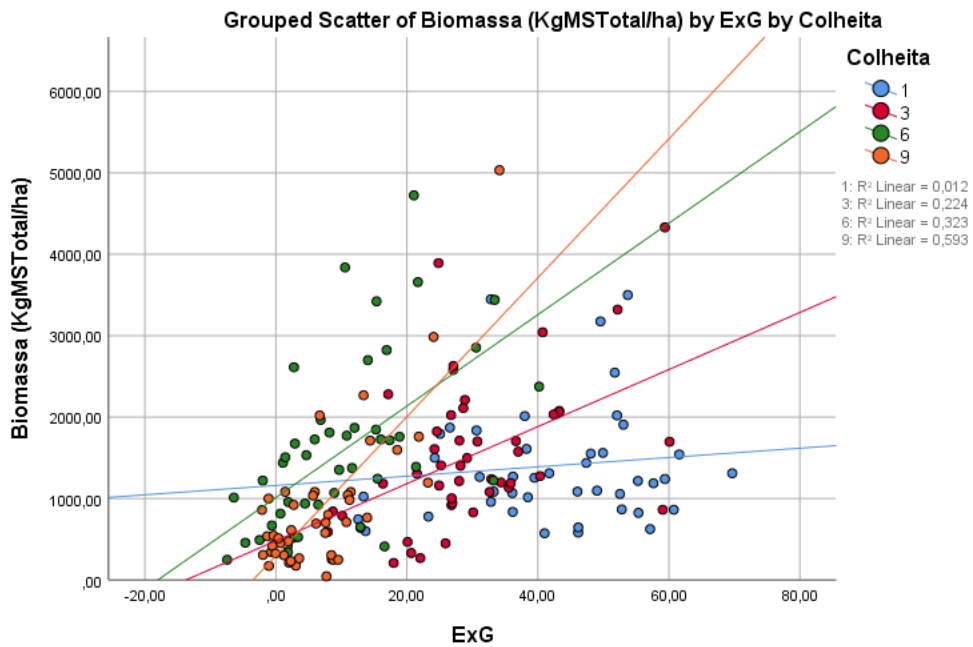


Figura 17 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo ExG por momento da colheita




Figura 18 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo VEG por momento da colheita




Figura 19 - Regressões lineares da Biomassa (kgMSTotal/ha) explicada pelo RGB Greenness por momento da colheita




Figura 20 - Regressões lineares do MO (% MS) explicado pelo MGVRT por momento da colheita

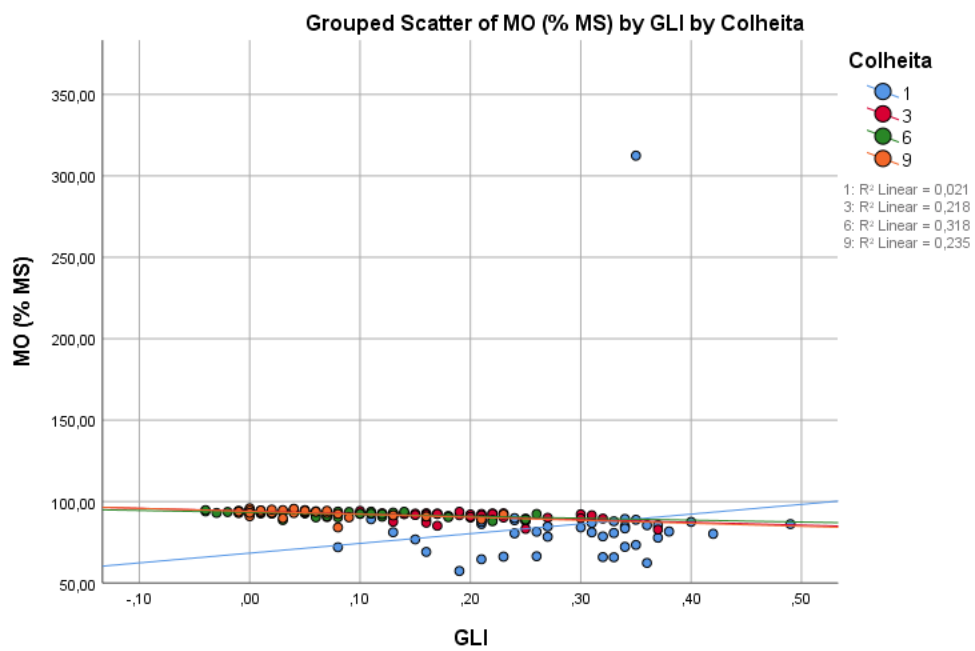


Figura 21 - Regressões lineares do MO (% MS) explicado pelo GLI por momento da colheita



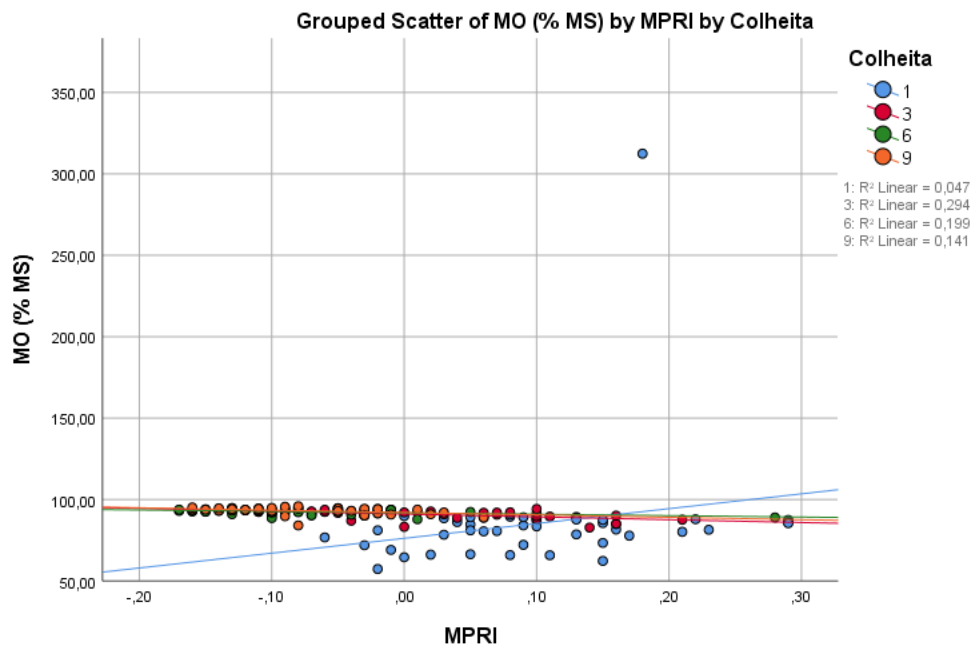


Figura 22 - Regressões lineares do MO (% MS) explicado pelo MPRI por momento da colheita

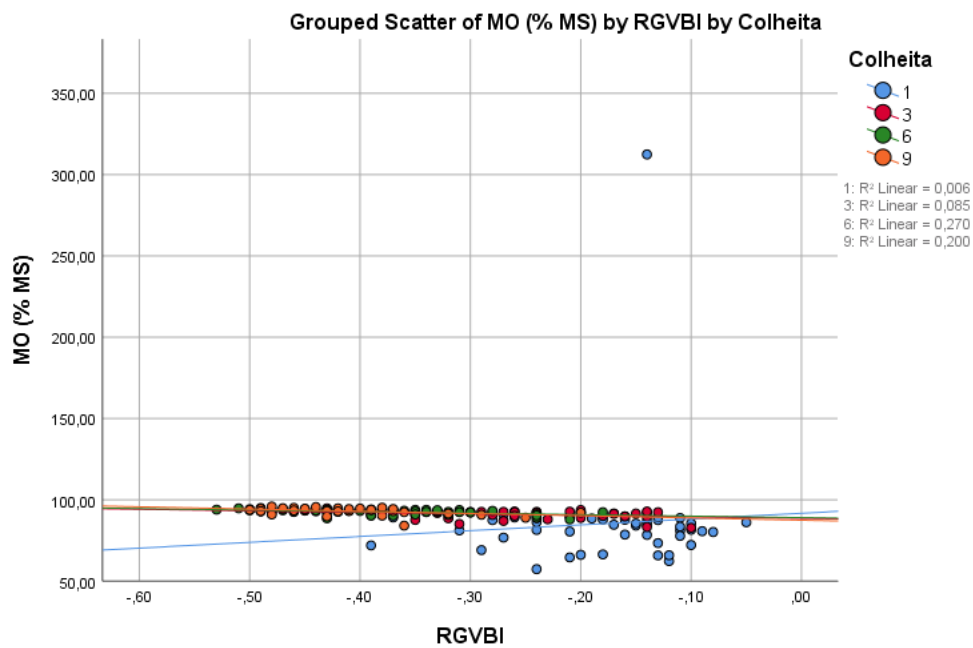


Figura 23 - Regressões lineares do MO (% MS) explicado pelo RGVBI por momento da colheita

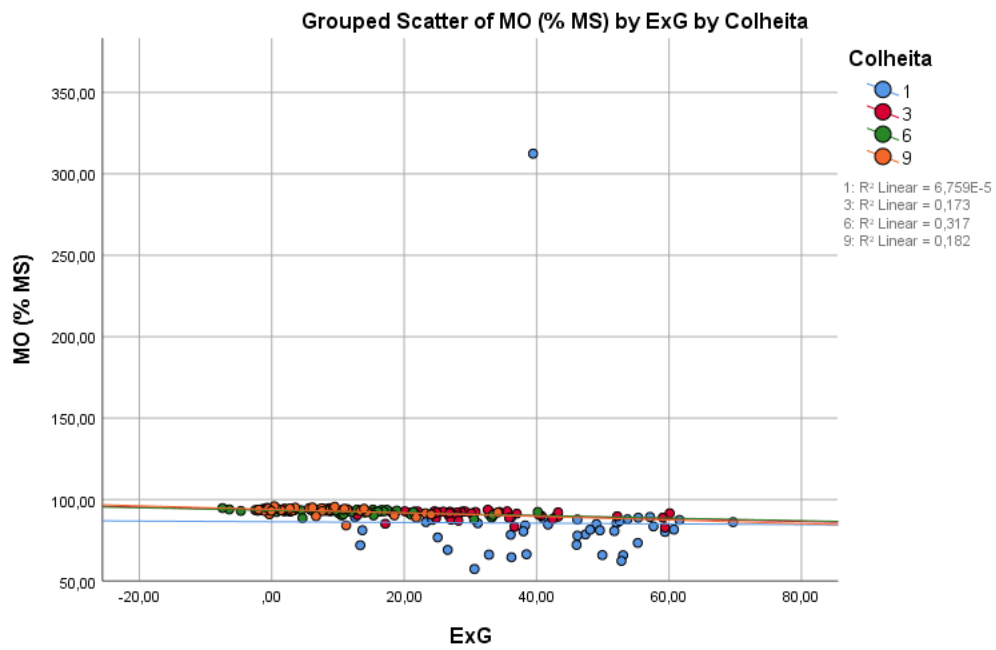


Figura 24 - Regressões lineares do MO (% MS) explicado pelo ExG por momento da colheita

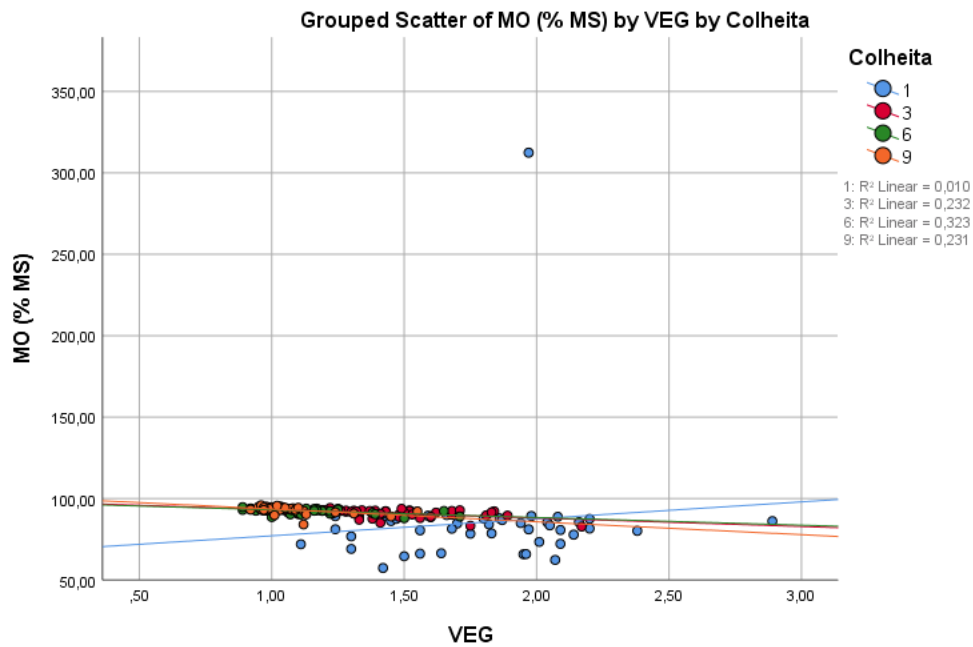


Figura 25 - Regressões lineares do MO (% MS) explicado pelo VEG por momento da colheita




Figura 26 - Regressões lineares do MO (% MS) explicado pelo VEG por momento da colheita




Figura 27 - Regressões lineares do PB (% MS) explicado pelo MGVRT por momento da colheita

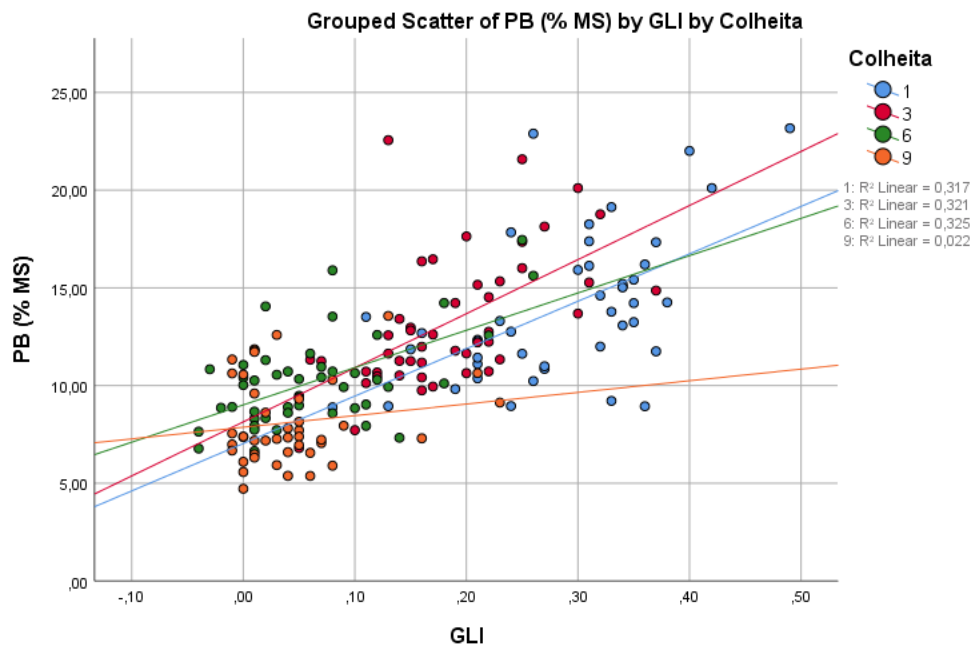


Figura 28 - Regressões lineares do PB (% MS) explicado pelo GLI por momento da colheita

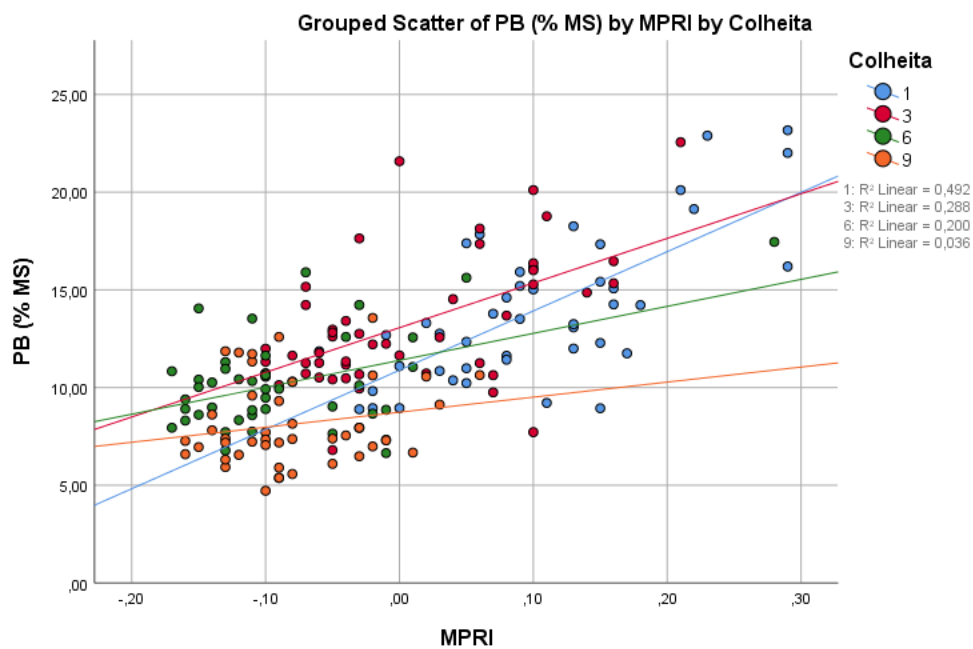


Figura 29 - Regressões lineares do PB (% MS) explicado pelo MPRI por momento da colheita

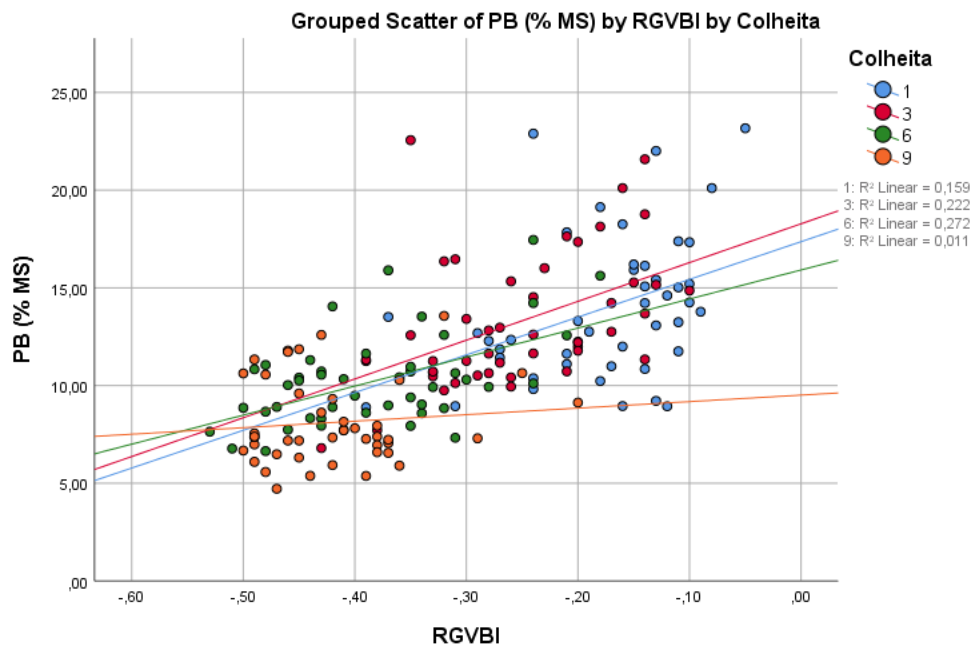


Figura 30 - Regressões lineares do PB (% MS) explicado pelo RGVBI por momento da colheita

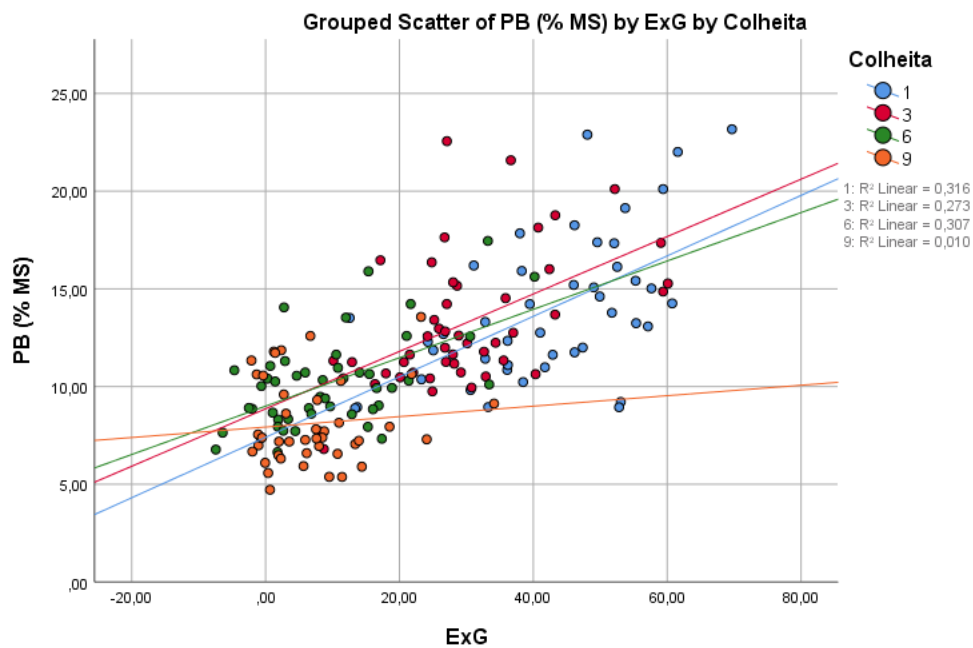


Figura 31 - Regressões lineares do PB (% MS) explicado pelo ExG por momento da colheita

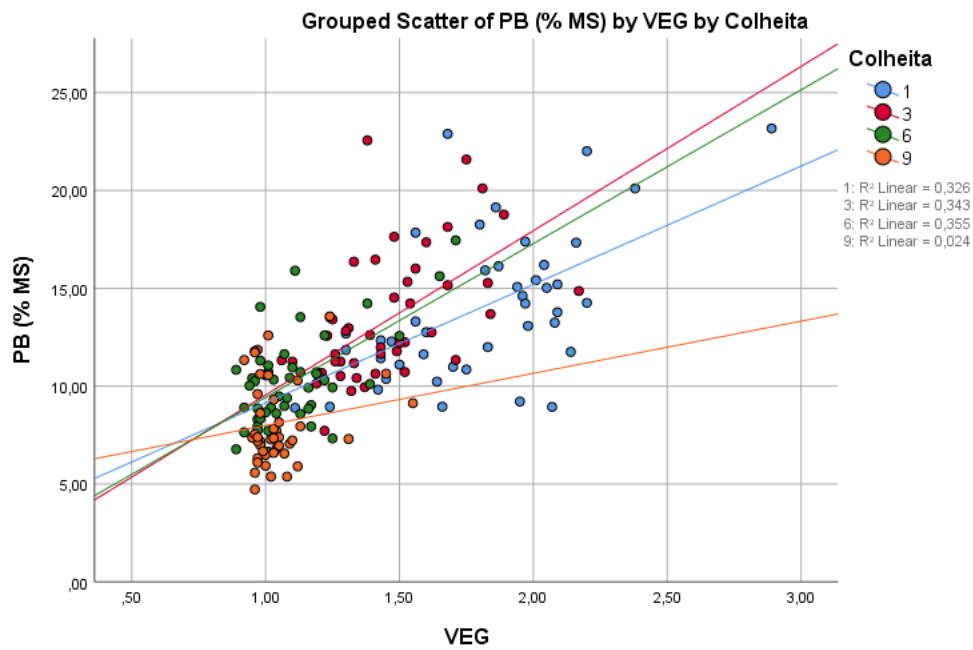


Figura 32 - Regressões lineares do PB (% MS) explicado pelo VEG por momento da colheita

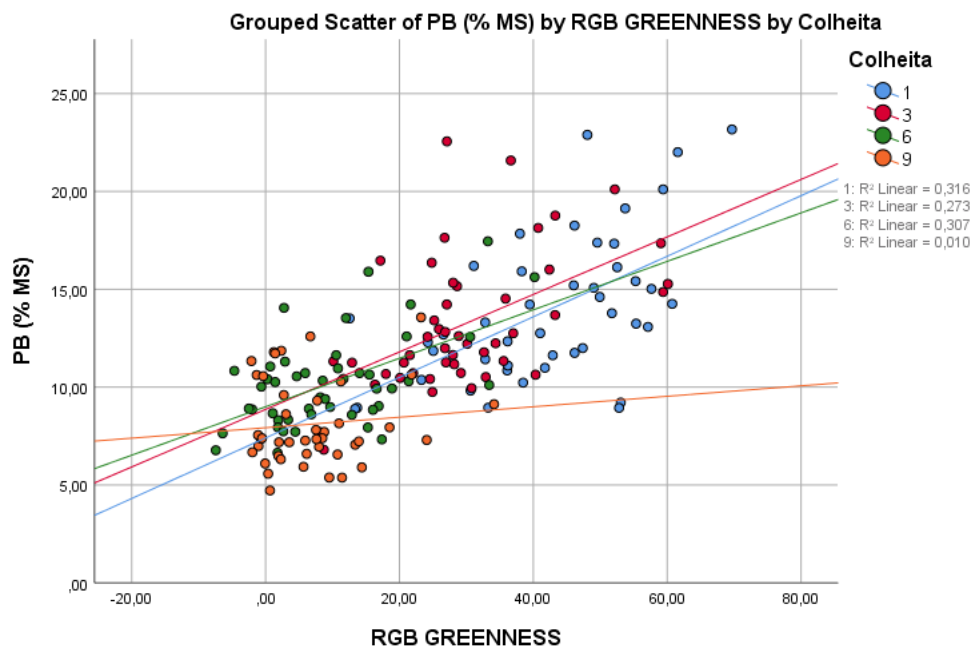


Figura 33 - Regressões lineares do PB (% MS) explicado pelo RGB Greenness por momento da colheita

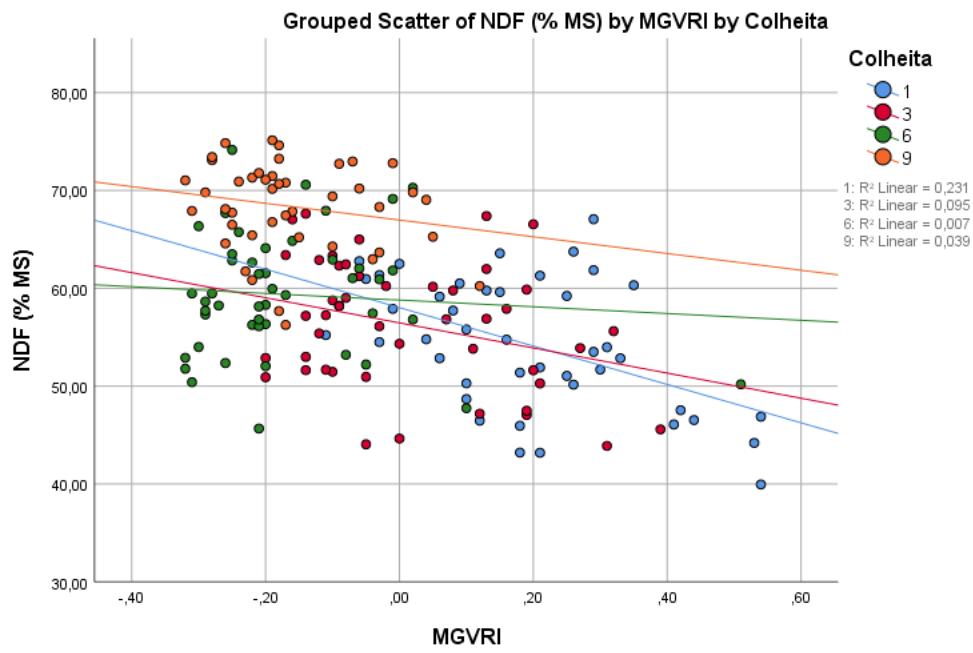


Figura 34 - Regressões lineares do NDF (% MS) explicado pelo MGVRT por momento da colheita

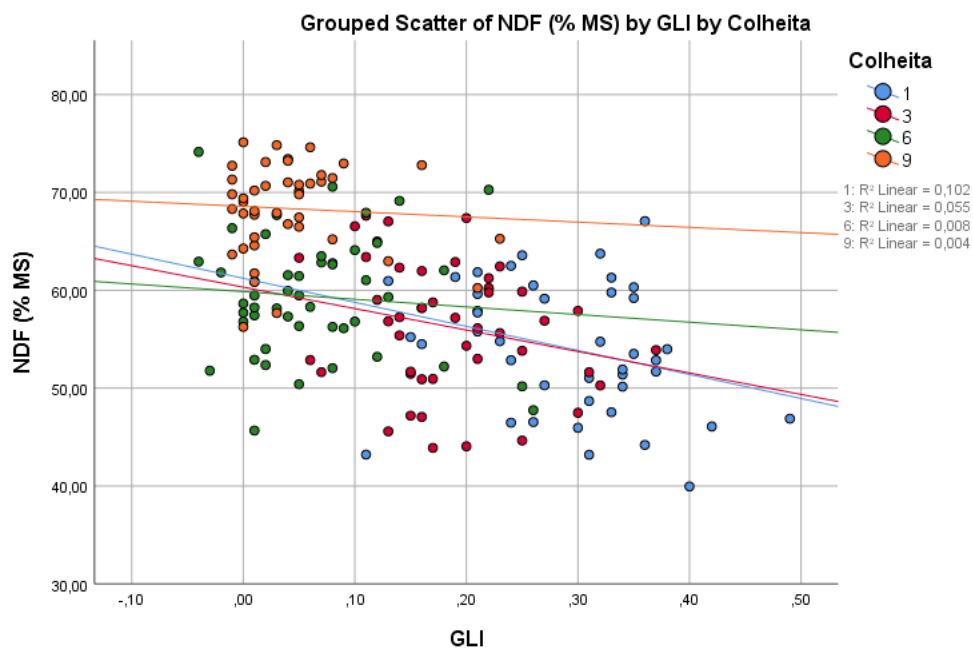


Figura 35 - Regressões lineares do NDF (% MS) explicado pelo GLI por momento da colheita

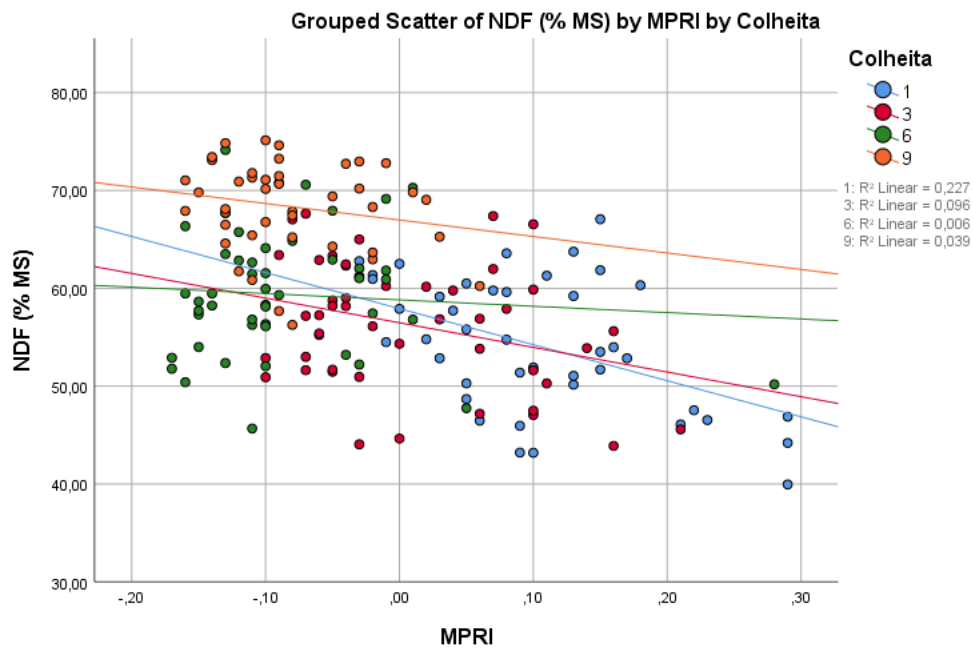


Figura 36 - Regressões lineares do NDF (% MS) explicado pelo MPRI por momento da colheita

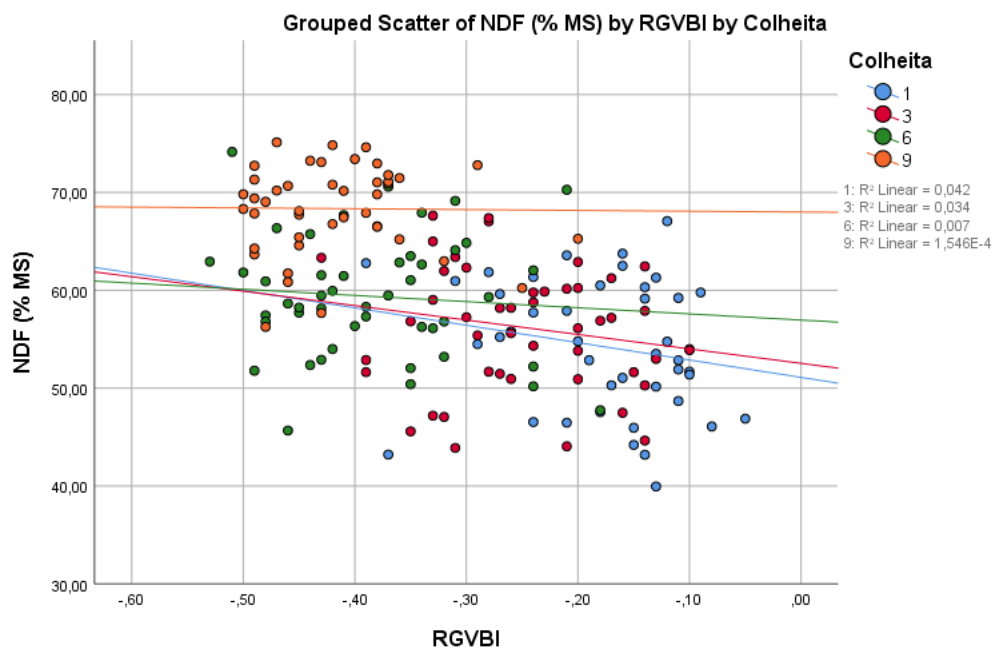


Figura 37 - Regressões lineares do NDF (% MS) explicado pelo RGVBI por momento da colheita






Figura 38 - Regressões lineares do NDF (% MS) explicado pelo ExG por momento da colheita

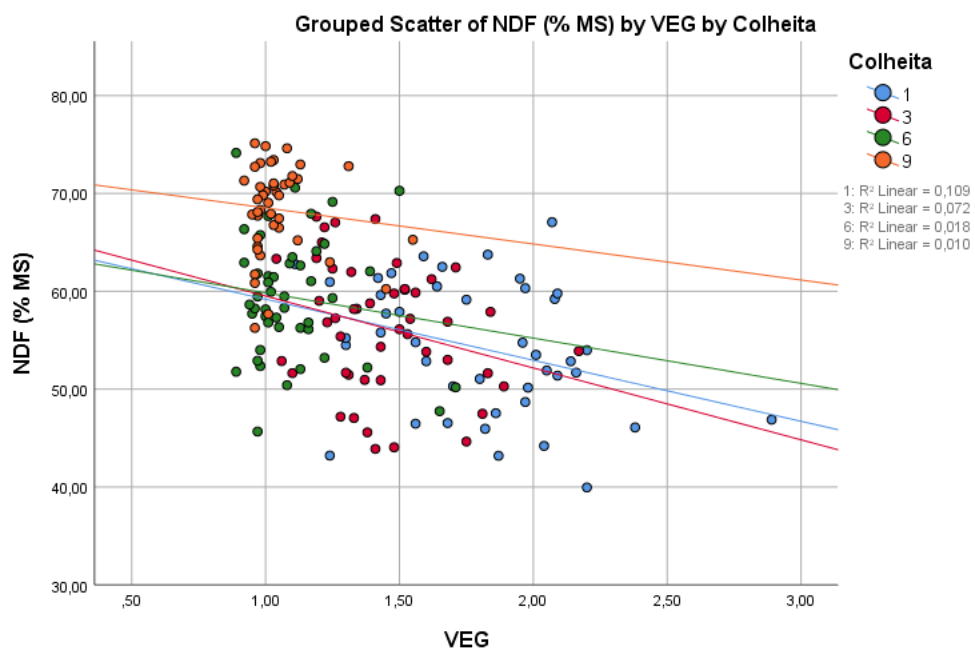



Figura 39 - Regressões lineares do NDF (% MS) explicado pelo VEG por momento da colheita



*Figura 40 - Regressões lineares do NDF (% MS) explicado pelo RGB Greenness por momento da colheita*

## 6. Considerações Finais

Nas pastagens presentes na Bacia Mediterrânea estamos perante pastagens de elevada heterogeneidade quer em termos de estrutura quer de densidade o que irá dificultar a validação de imagens digitais para que possamos aferir relativamente à quantidade e qualidade das pastagens.

Essa heterogeneidade foi evidente no presente estudo, encontrando-se diferenças de valor nutritivo entre vários pontos da pastagem, e diferenças ao longo do tempo. De destacar que os índices testados tiveram melhores associações quando o parâmetro em estudo tinha valores mais altos, nomeadamente melhor predição da massa forrageira na última colheita de junho, quando os valores são mais altos e melhor predição da proteína em abril, igualmente quando os valores são mais altos.

Com o nosso estudo concluímos que a metodologia baseada em imagens digitais, relaciona-se sobretudo com a biomassa e a proteína bruta, e que não existe um único índice que consiga correlacionar-se fortemente com todos os parâmetros de valor nutritivo e de quantidade disponível. Mas a explicação de cerca de 50% da variação é promissora e os modelos deverão ser melhorados. Por exemplo, os índices testados não se comportaram todos da mesma maneira. Destacamos como mais promissores o MGVRT e o VEG porque não sendo sempre os mais explicativos em cada colheita tiveram em termos gerais previsões próximas de 50% nas várias colheitas ao longo do tempo, e relacionaram-se bem com parâmetros quer quantitativos (biomassa) quer qualitativos (PB). Mas é possível que o uso de diferentes índices mais adaptados às características da pastagem no momento consigam melhorar as previsões.

Sendo um método de fácil execução, é possível que a sua utilização se venha a intensificar, e o presente estudo contribui para a seleção dos índices que deverão ser mais aprofundados.

## 7. Bibliografia

Allen, V. G., Batello, C., Berretta, E. J., Hodgson, J., Kothmann, M., Li, X., Mclvor, J., Milne, J., Morris, C., Peeters, A., & Sanderson, M. (2011). An international terminology for grazing lands and grazing animals. *Grass and forage science*, 66, 2-28.

Barbosa, B. D. S., Ferraz, G. A. S., Gonçalves, L. M., Marin, D. B., Maciel, D. T., Ferraz, P. F. P., & Rossi, G. (2019). RGB vegetation indices applied to grass monitoring: a qualitative analysis. *Agronomy Research*, 17(2), 349-357.

Barbosa, J. Z., Consalter, R., Pauletti, V., & Motta, A. C. (2016). Uso de imagens digitais obtidas com câmeras para analisar plantas. *Revista de Ciências Agrárias*, 39(1), 15-24.

Barnett, V. (1974). *Elements of sampling theory*. Routledge.

Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., & Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79-87.

Beniaich, A., Naves Silva, M. L., Avalos, F. A. P., Menezes, M. D., & Candido, B. M. (2019). Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera. *Semina-Ciencias Agrarias*, 40(1), 49-66.

Carvalho, P. D. F., Gonda, H. L., Wade, M. H., Mezzalira, J. C., Amaral, M. D., Gonçalves, E. N. Santos, D.T., Nadin, L. & Poli, C.H.E.S.C (2008). Características estruturais do pasto e o consumo de forragem: o quê pastar, quanto pastar e como se mover para encontrar o pasto. *IV Simpósio sobre Manejo Estratégico da Pastagem*, 101-130.

Correia, C. F. S. (2018). Produção extensiva de animais: uma ferramenta de gestão de território. (Tese de Mestrado). Faculdade de Economia, Universidade do Porto.

Costa, B.M. da, Ledo, C.A.S., Silva, M.C, Teixeira, V.I. (2009). Estimativa da produção de

forragens em pastagem de *Brachiaria decumbens*. *Archivos de zootecnia*, 58(221), 141-144.

Costa, J. J., Matos, A. P., Rosario, M. D. P., Ceu Salvador, M. D., Luz Vale-Dias, M. D., & Zenha-Rela, M. (2016). Evaluating use and attitudes towards social media and ICT for Portuguese youth: The MTUAS-PY scale. *In: 2nd International Conference on Health and Health Psychology*.

Costa, J. M., Grant, O. M., & Chaves, M. M. (2013). Thermography to explore plant–environment interactions. *Journal of experimental botany*, 64(13), 3937-3949.

Cunha, W.F. (2002). Métodos Indiretos para Estimativa de Massa de Forragens em Pastagens de *Cynodon* spp. (Tese de Doutorado). Escola Superior de Agricultura Luiz de Queiroz. Estado de São Paulo, Brasil.

Dufloth, J.H., Back, A.J., & Passos, R. (2015). Estimativa da produção de pasto através de dois métodos indiretos: Régua (altura) e Disco Medidor (densidade). *Agropecuária Catarinense*, 28(1), 83-86.

Edirisinghe, A., Hill, M. J., Donald, G. E., & Hyder, M. (2011). Quantitative mapping of pasture biomass using satellite imagery. *International Journal of Remote Sensing*, 32(10), 2699-2724.

Edvan, R.L., Bezerra, L.R., Marques, C.A., Carneiro, M.S.S., Oliveira, R.L., & Ferreira, R.R. (2016). Methods for estimating forage mass in pastures in a tropical climate. *Revista de Ciências Agrárias*, 39(1), 36-45.

Ferreira, O. G. L., Rossi, F. D., & Andrighetto, C. (2009). Determinação de área foliar, índice de área foliar e área de olho de lombo através de imagens digitais. *Reunião Anual da Sociedade Brasileira de Zootecnia*, 46.

Frame, J. H. (1981). *Herbage mass*. In *Sward Measurement Handbook*. British Grassland

Society Publication, Berkshire, U.K.

Gonçalves, L., Barbosa, B., Ferraz, G., Maciel, D., & Santos, H. (2017). Variabilidade espacial e temporal do índice de vegetação MPRI aplicado às imagens de grama São Carlos obtida por aeronave remotamente pilotada. *Brazilian Journal of Biosystems Engineering*, 11(4), 340-349.

Guerrero, N. R., Quintero, M. A. O., & Naranjo, J. C. P. (2012). Determinación del área foliar en fotografías tomadas con una cámara web, un teléfono celular o una cámara semiprofesional. *Revista Facultad Nacional de Agronomía Medellín*, 65(1), 6399-6405.

Hague, T., Tillett, N. D., & Wheeler, H. (2006). Automated crop and weed monitoring in widely spaced cereals. *Precision Agriculture*, 7(1), 21-32.

International Organization for Standardization. (1999). Animal Feeding Stuffs. Determination of moisture and other volatile matter content (ISO 6496:1999).

International Organization for Standardization. (2008). Animal Feeding Stuffs. Determination of the total nitrogen content by combustion according to the Dumas principle and calculation of the crude protein content—Part 1: Oilseeds and animal feeding stuffs. (ISO 16634–1:2008). PMID: 18942543

International Organization for Standardization. (2008). Animal Feeding Stuffs. Determination of amylase-treated neutral detergent fibre content (aNDF). (ISO 16472:2006). PMID: 18942543

Jensen, J. R., & Epiphany, J. C. N. (2009). *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. São José dos Campos: Parêntese Editora, 598-598.

Jorgensen, C.F., Stutzman, R.J., Anderson, L.C., Decker, S., Powell, L.A, Schacht, W.H., & Fontaine, J.J. (2013). Choosing a DIVA: a comparison of emerging digital imagery vegetation analysis techniques. *Applied vegetation science*, 16(4), 552-560.

Limb, R.F., Hickman, K.R., Engle, D.M., Norland, J.E., & Fuhlendorf, S.D. (2007). Digital Photography: Reduced Investigator Variation in Visual Obstruction. *Rangeland Ecology & Management*, 60(5), 548-552.

Louhaichi, M., Borman, M.M., & Johnson, D.E. (2001). Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. *Geocarto International*, 16(1), 65-70.

Louhaichi, M., Hassan, S., Clifton, K., & Johnson, D. E. (2018). A reliable and non-destructive method for estimating forage shrub cover and biomass in arid environments using digital vegetation charting technique. *Agroforestry Systems*, 92(5), 1341-1352.

Lukina, E. V., Stone, M. L., & Raun, W. R. (1999). Estimating vegetation coverage in wheat using digital images. *Journal of Plant Nutrition*, 22(2), 341-350.

Manickavasagan, A., Jayas, D. S., White, N. D., & Paliwal, J. (2005). Applications of thermal imaging in agriculture—a review. In *Proceedings of the CSAE/SCGR 2005 Meeting*, Winnipeg, MB, Canada, pp. 26-29.

Mannetje, L. (1978) *Measurement of grassland vegetation and animal production*. Farnham Royal (UK) Commonwealth Agricultural Bureaux.

Mannetje, L. (2000). Measuring biomass of grassland vegetation. In L. Mannetje, & R. M. Jones (Ed.) *Field and laboratory methods for grassland and animal production research*, Chap. 7, pp. 151-177.

Marchant, J. A., & Onyango, C. M. (2000). Shadow-invariant classification for scenes illuminated by daylight. *Journal of the Optical Society of America A*, 17(11), 1952-1961.

Moreira, N. (2002). *Agronomia das Pastagens e Forragens*. Vila Real: UTAD.

Nagelkerke, N. J. (1991). A note on a general definition of the coefficient of

determination. *Biometrika*, 78(3), 691-692.

O'Donovan, M., Dillon, P., Rath, M., & Stakelum, G. (2002). A comparison of four methods of herbage mass estimation. *Irish Journal of Agricultural and Food Research*, 41, 17 - 27.

Rayburn, E., & Lozier, J. (2003). Estimating pasture forage mass from pasture height. *Fact Sheet. October*.

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA special publication*, 351(1974), 309.

Safa, M., Martin, K. E., Kc, B., Khadka, R., & Maxwell, T. M. (2019). Modelling nitrogen content of pasture herbage using thermal images and artificial neural networks. *Thermal Science and Engineering Progress*, 11, 283-288.

Sanderson, M.A, Rotz, C.A, Fultz, S.W., Rayburn, E. B. (2001). Estimate forage mass with a commercial capacitance meter, rising plate meter and a pasture ruler. *Agronomy Journal*, 93, 1281-1286

Santana, H. A., Rezende, B. R., Santos, W. V. D., & Silva, A. R. D. (2018). Models for prediction of individual leaf area of forage legumes. *Revista Ceres*, 65, 204-209.

Serrano, J. M., Peça, J. O., Palma, P., Silva, J. R., & Carvalho, M. (2009). Calibração e validação de um medidor de capacitância num projecto de agricultura de precisão em pastagens. *Revista de Ciências Agrárias*, 32(2), 85-96.

Serrano, J. M., Shahidian, S., & Da Silva, J. R. M. (2016). Monitoring pasture variability: optical OptRx® crop sensor versus Grassmaster II capacitance probe. *Environmental monitoring and assessment*, 188(2), 117.

Serrano, J., Carreira, E., Fonseca, A., Shahidian, S., & Silva, J. (2018). Avaliação da sonda



Grassmaster II como ferramenta para estimativa da produtividade de pastagens de sequeiro no Alentejo. *Revista de Ciências Agrárias*, 41(4), 871-880.

Serrano, J., Sales-Baptista, E., Shahidian, S., Silva, J.M., Oliveira, I.F., Castro, J.L., Pereira, A., d'Abreu, M.C., & Carvalho, M. (2021). Proximal sensors for monitoring seasonal changes of feeding sites selected by grazing ewes. *Agroforestry Systems*, 95, 55-69.

Silva, S.C.D., & Cunha, W.F.D. (2003). Métodos indiretos para estimar a massa de forragem em pastos de *Cynodon* spp. *Pesquisa Agropecuária Brasileira*, 38, 981-989.

Souza, M. (2018). Estimativa de massa forrageira (Kg MS) de trigo usando imagens de alta resolução espacial a partir de veículo aéreo não tripulado. (Tese de Mestrado). Escola de Engenharia, Universidade Federal do Rio Grande do Sul.

Torres-Sánchez, J., López-Granados, F., & Peña, J. M. (2015). An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, 114, 43-52.

Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.

Van den Pol-van Dasselaar, A., Philipsen, A. P., & De Haan, M. H. A. (2014). Economics of grazing. *Grassland Science in Europa*, 19, 662-664.

Watson, D. J. (1952). The physiological basis of variation in yield. *Advances in agronomy*, 101-145.

Woebbecke, D., Meyer, G., Von Bargen, K., & Mortensen, D. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259-269.

Yang, Z., Willis, P., & Mueller, R. (2008). Impact of band-ratio enhanced AWIFS image to

crop classification accuracy. *Pecora*, 17(1), 1-11.