



Aprendizado de máquina com base na resposta espectral de imagens aéreas obtidas por VANTs e aplicado no manejo de pastagens



**Empresa Brasileira de Pesquisa Agropecuária
Embrapa Pecuária Sul
Ministério da Agricultura, Pecuária e Abastecimento**

**BOLETIM DE PESQUISA
E DESENVOLVIMENTO
51**

**Aprendizado de máquina com base
na resposta espectral de imagens
aéreas obtidas por VANTs e aplicado
no manejo de pastagens**

*Márcia Cristina Teixeira da Silveira
Pedro Henrique Araújo de Almeida
Cláudio Vinícius Pedroso de Azevedo Andrade
Manoel Ricardo de Albuquerque Filho
Carolina Bremm
Flávia Cristina dos Santos*

Embrapa Pecuária Sul
Embrapa Pecuária Sul
EBR 153, Km 632,9. Caixa postal 242
796401-970 - Bagé - RS
Fax: 55.53.3240-4650
www.embrapa.br/pecuaria-sul
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações
da Embrapa Pecuária Sul

Presidente
Marcos Flávio Silva Borba

Secretário-Executivo
Gustavo Trentin

Membros
*Gustavo Martins da Silva, Graciela Olivella
Oliveira, Marco Antonio Karam Lucas, Ana
Cristina Mazzocato, João Carlos Pinto Oliveira,
Magda Vieira Benavides, Márcia Cristina
Teixeira da Silveira, Lisiane Bassols Brisolara*

Suplentes
*Emanuelle Baldo Gaspar e Jorge Luiz
Sant'Anna dos Santos*

Supervisão editorial
Lisiane Bassols Brisolara

Revisão de texto
Fernando Goss

Normalização bibliográfica
Graciela Olivella Oliveira

Tratamento das ilustrações
Daniela Garcia Collares

Projeto gráfico da coleção
Carlos Eduardo Felice Barbeiro

Editoração eletrônica
Daniela Garcia Collarest

Fotos da capa
Allan Figueiredo

1ª edição
Publicação digital (2022): PDF

Todos os direitos reservados

A reprodução não autorizada desta publicação, no todo ou em parte,
constitui violação dos direitos autorais (Lei nº 9.610).

Dados Internacionais de Catalogação na Publicação (CIP)

Nome da unidade catalogadora

Aprendizado de máquina com base na resposta espectral de imagens aéreas obtidas por
VANTs e aplicado no manejo de pastagens / Márcia Cristina Teixeira da Silveira ... [et al.]. —
Bagé: Embrapa Pecuária Sul, 2022.
PDF (59 p.). — (Boletim de pesquisa e desenvolvimento / Embrapa Pecuária Sul, ISSN
1983-0467 ; 51)

1. Pastagem. 2. Manejo. 3. Aerofotogrametria. I. Silveira, Márcia Cristina Teixeira da. II.
Almeida, Pedro Henrique Araújo de. III. Andrade, Cláudio Vinícius Pedroso de Azevedo. IV.
Albuquerque Filho, Manoel Ricardo de. V. Bremm, Carolina. VI. Santos, Flávia Cristina dos.
VII. Título. VIII. Série.

CDD (21. ed.) 631.4

Graciela O. Oliveira (CRB-10/1434)

© Embrapa, 2022

Sumário

Resumo	4
Abstract	6
Introdução.....	8
Material e Métodos	10
Resultados e Discussão	17
Considerações.....	24
Agradecimentos.....	24
Referências	25
Literatura Recomendada	26
Apêndice.....	27

Aprendizado de máquina com base na resposta espectral de imagens aéreas obtidas por VANTs e aplicado no manejo de pastagens

Márcia Cristina Teixeira da Silveira¹

Pedro Henrique Araújo de Almeida²

Cláudio Vinícius Pedroso de Azevedo Andrade³

Manoel Ricardo de Albuquerque Filho⁴

Carolina Bremm⁵

Flávia Cristina dos Santos⁶

Resumo – O monitoramento de áreas agrícolas tem sido beneficiado com a evolução das novas tecnologias de sensoriamento remoto. O advento dos veículos aéreos não tripulados (VANTs) revolucionou o mundo do sensoriamento remoto nos últimos anos. Progressivamente, o custo dos equipamentos está se tornando mais acessível, permitindo aos profissionais ampliar a sua gama de atuação e fornecer produtos de melhor qualidade para escalas maiores. Essas novas tecnologias aliadas a técnicas tradicionais de monitoramento de pastagens podem prover ganhos do ponto de vista operacional ao produtor rural. Sendo assim, o objetivo do presente trabalho foi avaliar o uso de imagens de VANT para estimar e monitorar a cobertura e altura do pasto. As imagens utilizadas foram capturadas na área experimental da Fazenda Trijunção, localizada em Cocos, Bahia.

¹Doutora, pesquisadora, Embrapa Pecuária Sul

²Mestre, doutorando, Universidade Federal de Viçosa

³Mestre, doutorando, Universidade Federal de Viçosa

⁴Doutor, pesquisador, Embrapa Milho e Sorgo

⁵Doutora, pesquisadora, Secretaria da Agricultura, Pecuária e Desenvolvimento Rural do Rio Grande do Sul

⁶Doutora, pesquisadora, Embrapa Milho e Sorgo

Relacionou-se o comportamento espectral de imagens RGB com 3 classes de cobertura do solo em áreas sob pastejo (pré-pastejo, em pastejo e pós-pastejo), além de uma classe de solo exposto, em diferentes épocas, durante dois anos. Adicionalmente relacionou-se a altura de planta medida em campo com as bandas da imagem RGB. No software R Studio o banco de dados foi dividido em conjuntos de treinamento e validação, com a relação de 75% e 25%, respectivamente. Considerando todo o conjunto de dados, o modelo ajustado alcançou 66% de exatidão e índice Kappa 0,53 na predição das 4 classes, sendo 3 dessas relativas às classes de manejo de pastagem e 1 de solo exposto. Quando avaliado apenas as imagens do período seco do ano, o modelo ajustado alcançou 68% de exatidão e índice Kappa de 0,56. Já o conjunto de dados do período chuvoso apresentou 70% de exatidão e índice Kappa de 0,58. Ao aplicar o modelo em novos conjuntos de imagens observou-se índice de assertividade satisfatório ao analisar as classes de manejo com base na cobertura do solo e a altura do dossel medidas em campo. Os resultados demonstram o potencial da rotina de processamento implantada para o processamento em imagens de VANT, via aprendizado de máquina, como ferramenta auxiliar no manejo de pastagens. Proporciona também uma solução em tempo reduzido para a avaliação e manejo de áreas de pastagens de diferentes dimensões.

Termos de indexação: Pastagem, monitoramento, VANT, random forest, aprendizado de máquina.

Machine learning based on the spectral response of aerial images obtained by UAVs and applied to pasture management

Abstract – The monitoring of agricultural areas has benefited from the evolution of new remote sensing technologies. The advent of unmanned aerial vehicles (UAVs) has revolutionized the world of remote sensing in recent years. Progressively, the cost of equipment is becoming more accessible, allowing professionals to expand their range of activities and provide better quality products for larger scales. These new technologies allied to traditional techniques of monitoring pastures can operationally provide gains to the rural producer. Therefore, the objective of this work was to evaluate the use of UAV images to estimate and monitor the coverage and height of the pasture. The images used were captured in the experimental area of Fazenda Trijunção, located in the southwest of the state of Bahia, Brazil. The spectral behavior of RGB images was related to three land cover classes in areas under pasture (pre-grazing, in-grazing and post-grazing), in addition to the use of an exposed soil class, at different times, for two years. Additionally, the plant height measured in the field was related to the bands of the RGB image. In the R Studio software, the database was divided into training and validation sets, with a ratio of 75% and 25%, respectively. Considering the entire data set, the adjusted model reached 66% accuracy and Kappa index 0.53 in the prediction of the four classes; three of them related to pasture management classes and one to exposed soil. When only the images of the dry period of the year were evaluated, the adjusted model reached 68% of accuracy and Kappa index of 0.56. On the other hand, the data set of the rainy season presented 70% of accuracy and Kappa index of 0.58. When applying the model to new sets of images, a good assertiveness index was observed when analyzing management classes based on soil cover and canopy height measured in the field.

The results demonstrated the potential of the processing routine implemented for processing UAV images, via machine learning, as an auxiliary tool in pasture management. It also provides a time saving solution for evaluating and managing pasture areas of different sizes.

Index terms: Pasture, monitoring, UAV, random forest, machine learning.

Introdução

Quando se pensa em produção animal a pasto, o planejamento e o manejo adequado do pastejo devem ser os primeiros passos a serem observados no intuito de se buscar alcançar resultados produtivos satisfatórios. O planejamento e manejo nada mais são do que estratégias que os produtores podem se valer no sentido de buscar um equilíbrio entre oferta e demanda de alimento para os animais.

Pensando na produção animal em sistemas pastoris, um dos pontos-chave do manejo está em disponibilizar forragem em quantidade e qualidade adequadas, que satisfaça às exigências de manutenção e produção dos animais em pastejo. Também se almeja que as plantas tenham condições de persistência, o que passa pela necessidade de manutenção de quantidade de folhas suficientes para garantir rebrotação rápida e vigorosa.

Neste contexto, o momento ideal para pastejo considerando limites eco-fisiológicos de crescimento e desenvolvimento é quando o dossel forrageiro está entre 90 e 95% de interceptação luminosa (IL). Ponto onde estudos mostram ser possível otimizar o acúmulo de folhas e favorecer o consumo de forragem pelos animais.

Estes valores de IL são condizentes com recomendações de altura que são específicas para cada planta forrageira (Barrios et al., 2019). Assim, a altura pode ser utilizada como critério prático para definir o momento ideal de pastejo, bem como permite identificar a necessidade ou não de realização de ajustes de carga animal, visando estabelecer condições ótimas de utilização do pasto mediante os principais processos envolvidos no crescimento e utilização das plantas forrageiras sob pastejo, sendo hoje considerado um método seguro para auxiliar o produtor no manejo do pasto da propriedade (Genro; Silveira, 2018).

Para que essas recomendações de altura possam ser respeitadas faz-se necessário o monitoramento das áreas de pastagem com maior frequência, no sentido de tomar decisões de ajuste de carga e/ou rotação dos animais entre as áreas de forma mais efetiva. Logo, a utilização de técnicas de monitoramento como o sensoriamento remoto apresentam-se como ferramentas promissoras no auxílio às tomadas de decisão referentes ao manejo de pastagens, sobretudo em áreas que possam demandar longos períodos de caminhamento e mensuração.

Nesse sentido, os Veículos Aéreos Não Tripulados (VANTs) surgem como uma alternativa interessante, por conta do seu baixo custo, além da possibilidade de utilização de diferentes sensores como câmeras hiperespectrais, gerando resultados em curto intervalo de tempo. Hott et al. (2019) apresentam diversas vantagens para a utilização dessa tecnologia, como a possibilidade de analisar os estágios de crescimento e desenvolvimento das lavouras e das pastagens, a partir da correlação de índices de vegetação com a produção de biomassa, na identificação de falha de plantio, além de pragas e doenças. Freeman e Freeland (2015) afirmam que após o desenvolvimento de pesquisas e técnicas de análise, poderão ser estabelecidas expectativas realistas sobre o uso de VANTs nos sistemas agropecuários, gerando assim maior demanda de utilização dos mesmos.

De acordo com Anziliero (2021), um dos principais problemas para o uso de forma mais ampla seria a falta de automação, algo que pode ser incrementado a partir da utilização de ferramentas de machine learning, possibilitando dar mais autonomia para os VANTs e agilidade na obtenção dos resultados. Diante do exposto, o objetivo deste trabalho foi avaliar o uso de imagens de VANTs para estimar e monitorar a cobertura e altura do pasto mediante um conjunto de procedimentos sistematizados e padronizados na forma de um script de processamento.

Esta publicação contribui com o Objetivo de Desenvolvimento Sustentável 2.4 (ODS 2) contido na Agenda 2030, proposta pela Organização das Nações Unidas. Este objetivo visa “garantir sistemas sustentáveis de produção de alimentos e implementar práticas agrícolas resilientes, que aumentem a produtividade e a produção, que ajudem a manter os ecossistemas, que fortaleçam a capacidade de adaptação às mudanças climáticas, às condições meteorológicas extremas, secas, inundações e outros desastres, e que melhorem progressivamente a qualidade da terra e do solo”.

Materiais e Métodos

A condução do trabalho se deu na Fazenda Santa Luzia, pertencente à matrícula principal Fazenda Trijunção, localizada em Cocos-BA, Brasil. A área monitorada possui 85 hectares, dividida em 4 piquetes (identificados como A1, A2, D1 e D2), formados com a espécie forrageira *Urochloa brizantha* cv. BRS Piatã. Para reduzir o efeito de bordadura, eliminou-se uma faixa de 25 metros em torno dos piquetes, de forma que cada um ficou com área útil de 16 hectares.

O clima da região é do tipo Aw, pela classificação de Köppen e Geiger, caracterizando-se como quente e seco, com chuvas concentradas no verão e temperatura média de 24 °C. A altitude local é de 933 m e a precipitação média anual varia de 700 a 1.400 mm, com déficit hídrico pronunciado do final de abril a outubro. Na Figura 1 é apresentado o balanço hídrico mensal que foi calculado em planilha eletrônica de Sentelhas et al. (1999), cujos valores de ETo originalmente de Thornthwaite e Mather foram substituídos pelos de Penman-Monteith, utilizando-se uma CAD de 25 mm. Observa-se a caracterização de duas épocas características da região com verão quente e chuvoso e inverno seco.

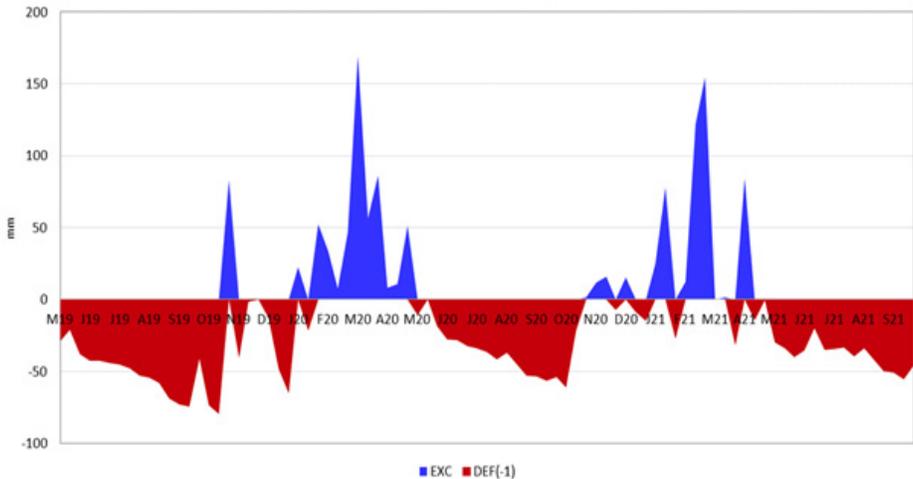


Figura 1. Balanço hídrico mensal (mm) de maio de 2019 a setembro de 2021 na Fazenda Trijunção.

Os pastos foram manejados sob pastejo rotacionado mediante critério de altura (Barrios et al., 2019) com recomendação de entrada dos animais a 30-40 cm. Nesta amplitude de altura, as plantas apresentam maior concentração de folhas em relação a colmos e material morto. O momento de saída do gado (pós-pastejo) ideal é de 20 cm, para respeitar os limites ecofisiológicos de rebrotação da planta e otimizar os ganhos de peso dos animais em pastejo. O monitoramento de altura foi realizado semanalmente durante o verão e quinzenalmente no inverno, períodos de menor crescimento do pasto, com auxílio de régua graduada adotando-se caminhamento em zig-zag e amostrando-se cerca de 100 pontos por piquete.

Em períodos pré-determinados no ano (águas, transição águas-seca, seca e transição seca-águas) foram realizadas avaliações in loco da cobertura do solo pela forragem, altura do pasto e da massa de forragem em todos os piquetes e realizada a classificação da condição do pasto de cada piquete no momento de avaliação (em pastejo, pré-pastejo ou pós-pastejo).

Dez pontos georreferenciados por piquete foram amostrados (Figura 2), utilizando-se uma moldura de ferro de 1m x 1m. Dentro desta moldura foi realizada a avaliação visual da cobertura do solo pelo pasto, por pelo menos três pessoas devidamente treinadas, sendo atribuídas notas de 0 a 100% de cobertura. Adicionalmente, em cada um dos vértices do quadrado e na região central deste, foi medida a altura do pasto (5 pontos), sendo essas as alturas utilizadas para caracterização nos momentos de avaliação por período. Após estas avaliações foi realizado o corte de toda a forragem disponível dentro da área delimitada pelo quadro, rente ao solo.

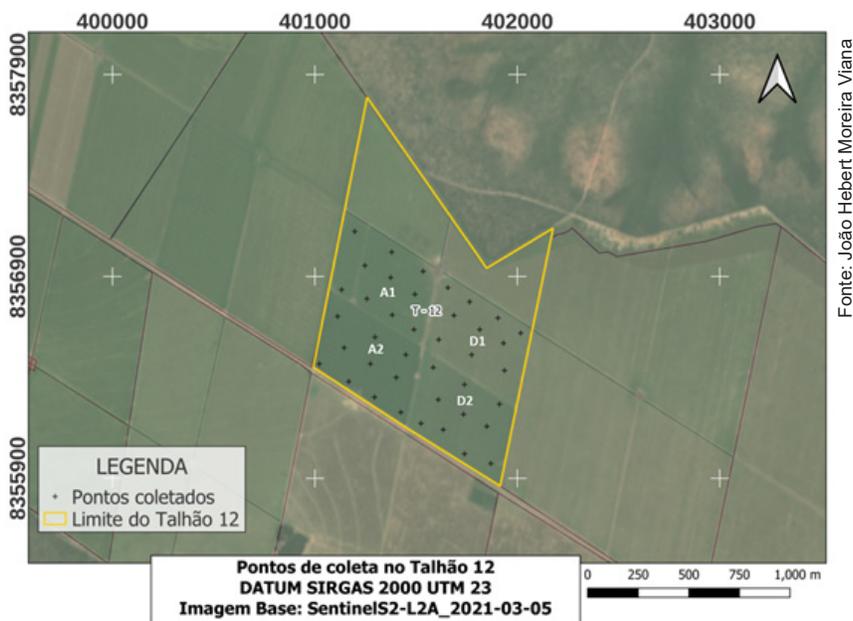


Figura 2. Gride/pontos georreferenciados para coleta de informações de cobertura, massa de forragem e altura nos quatro piquetes sob pastejo rotacionado, do talhão 12 na fazenda Santa Luzia, Cocos-BA.

Visando gerar as informações necessárias ao objetivo do trabalho, sempre que foram realizados os monitoramentos de campo nos períodos pré-determinados, também foram feitos os monitoramentos de imagem via VANT, o que possibilitou gerar um banco de dados equivalente a oito levantamentos de imagens entre 2019 e 2021.

Para a obtenção das imagens aéreas utilizou-se aeronave remotamente pilotada de baixo custo de aquisição e operação, modelos Phantom 4 pro e Mavic pro, ambos fabricados pela empresa DJI. Foram executados voos orientados por um plano previamente concebido, onde a melhor execução foi observada com o modelo Phanton 4 Pro a 70 m de altura, principalmente nos quesitos estabilidade em voo, autonomia e número de fotografias por área. Foi respeitada uma sobreposição entre fotos de 75% frontal e 70% lateral. Para correção posicional das imagens foram utilizados em média 15 pontos de controle.

Para a aquisição de pontos recorreu-se à utilização de um par de receptores GNSS RTK (Real Time Kinematic) modelo CHC X91+. O transporte de coordenadas foi realizado através do serviço online para pós-processamento de dados do IBGE (2021).

Posteriormente, as imagens foram processadas utilizando a técnica de estereoscopia em software computacional. Nessa etapa as imagens individuais são transformadas em nuvem de pontos tridimensional, além de realizar a aquisição do mosaico de imagens aéreas. Para a correta avaliação temporal do conjunto de dados, foram identificados os erros de processamento na etapa de correção geométrica e posicional das imagens.

De posse das imagens, utilizou-se de ambiente GIS para o estabelecimento de pontos amostrais a serem utilizados na classificação das imagens, recortes dos efeitos de borda, determinação dos limites dos piquetes e demais elementos significativos na área de estudo.

Ainda nessa etapa, foram obtidas as informações espectrais referentes às bandas RGB das imagens, utilizando o conjunto de pontos amostrais estabelecido. Para a obtenção dos pontos de amostragem, foram gerados polígonos de 10 m², próximos aos locais de coleta de dados em campo. Ao todo foram gerados 40 polígonos, sendo 10 em cada piquete. Posteriormente foi realizada a conversão dos polígonos em pontos, sendo gerados 46 pontos por polígono.

Este processo foi necessário para a obtenção de amostras para treinamento, onde os pontos não poderiam ser gerados de forma randômica, mas sim respeitando uma distância constante dentro de uma área representada pelas observações de campo constatadas pelo método de manejo convencional por altura.

A partir da informação de manejo por altura, para a forrageira em questão, apontada por Barrios et al. (2019), e com base no monitoramento de campo foram criadas quatro classes de cobertura do solo pela vegetação.

Para realizar a predição de classes de cobertura foram atribuídos códigos numéricos aos atributos categóricos. Na Tabela 1, são apresentadas as classes de manejo e altura adotadas para o pasto de capim-piatã, e seus respectivos códigos.

Tabela 1. Classes de manejo adotadas e altura recomendada para o manejo do capim-piatã.

Classe	Código	Altura de planta
Pré-pastejo	1	30 a 40 cm
Em pastejo	2	20 a 30 cm
Pós-pastejo	3	Próximo de 20 cm
Solo exposto	4	Sem vegetação

Essas informações de classes de cobertura obtidas em ambiente GIS foram concatenadas com as condições de manejo e altura de plantas obtidas por mensurações in loco. Ao final, o banco de dados foi exportado para o formato “csv.”, além das bandas RGB segmentadas do ortomosaico, contabilizando um conjunto amostral de 18909 pontos.

No software R (RStudio..., 2020) utilizou-se o classificador Random Forest (Breiman, 1996, 2001; Blas, 2021) para a execução das etapas de classificação e predição da cobertura do solo e altura do dossel.

Optou-se pela utilização da linguagem de programação R de forma a possibilitar o livre acesso ao código ou script. Esse algoritmo de aprendizagem de máquina é comumente utilizado para problemas de classificação e regressão, combinando a saída de múltiplas árvores de decisão para alcançar um único resultado.

Portanto, no classificador Random Forest, o método de tomada de decisão demonstrado por Breiman (2001) foi escolhido pela sua finalidade de conceber a diferenciação das respostas em espectros das imagens obtidas em campo, além de posteriormente utilizar as demais variáveis, onde mais de uma árvore de decisão é utilizada.

Como exemplo desse método de diferenciação das respostas, na Figura 3 é possível observar que a árvore de decisão começa com um único nó ($b3_img < 119.5$), que se divide em possíveis resultados. Cada um desses resultados leva a nós adicionais, que se ramificam em outras possibilidades, até a tomada de decisão, que nesse trabalho é representada pelas classes de manejo do pasto.

Árvore de decisão

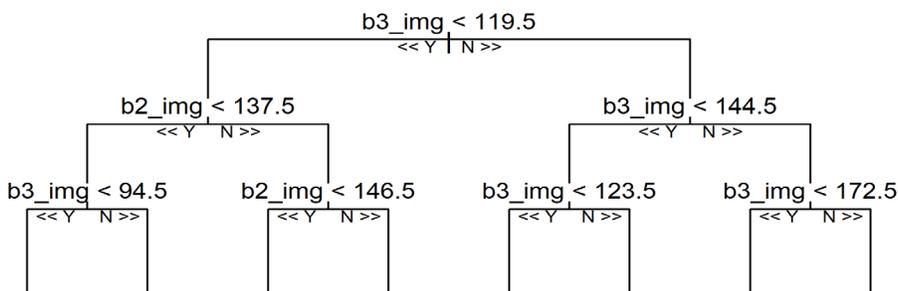


Figura 3. Exemplo de árvore de decisão demonstrando como foi realizada a separação das 4 classes de manejo a partir da condição apresentada em cada nó.

O treinamento do algoritmo foi realizado através da separação dos conjuntos amostrais de treinamento e validação, sendo atribuído 75% dos dados das classes para o conjunto de treinamento e 25% dos dados para o conjunto de validação.

A fórmula aplicada combinou as diferentes bandas da imagem para prever a classe de cobertura e altura do dossel. A avaliação da precisão do modelo foi realizada a partir da análise da matriz de confusão e da matriz de acerto. Para realizar a predição de altura, utilizou-se o mesmo algoritmo, sendo aplicada uma regressão a partir dos dados obtidos em campo.

Rotina de inserção de base de dados para processamento de ortofotomosaicos

A rotina elaborada foi concebida para reduzir a necessidade de interferência por parte do usuário, sendo descrito no script as etapas necessárias para a correta utilização (Anexo 2). Esse script nada mais é do que um código com instruções de programação na forma de um texto a ser executado. Portanto, para início do processamento, o usuário deverá alterar ou criar um diretório de trabalho, e salvar as imagens separadas por banda no mesmo diretório.

Para executar o código proposto é necessário carregar os pacotes discriminados no script, caso o usuário não possua os pacotes instalados, é possível realizar a instalação a partir da barra de tarefas “packages” do software R.

Posteriormente é direcionado o diretório de trabalho. Para isso é necessário alterar o diretório de acordo com cada usuário, copiando e alterando no passo “2” do script. Com estas etapas concluídas é feita a leitura dos dados e carregada a base de dados contendo as variáveis descritas na Tabela 2.

Tabela 2. Códigos utilizados para as variáveis de treinamento do modelo.

Significado	Código
Classe de manejo	class
Estação do ano	estacao
Altura medida em campo	altura_ca
Polígono	id
Banda R da imagem	b1_img
Banda G da imagem	b2_img
Banda B da imagem	b3_img

À medida que o código é executado, são retornados os resultados em forma de tabela, além de arquivos em formato .TIF com o resultado da classificação e espacialização da altura de planta.

Resultados e Discussão

Treinamento do modelo

Em relação ao conjunto de dados de treinamento do modelo, a exatidão e o Índice Kappa foram de 70% e 0,58 para o período chuvoso, de 68% e 0,56 para o período seco, respectivamente. Considerando todo o conjunto de treinamento, a exatidão e o Índice Kappa foram de 66% e 0,53, dentro de um recorte de monitoramento de 2 anos, que contemplou dois períodos secos (estação de inverno e período de transição secas-águas) e dois chuvosos (estação de verão e período de transição águas-secas).

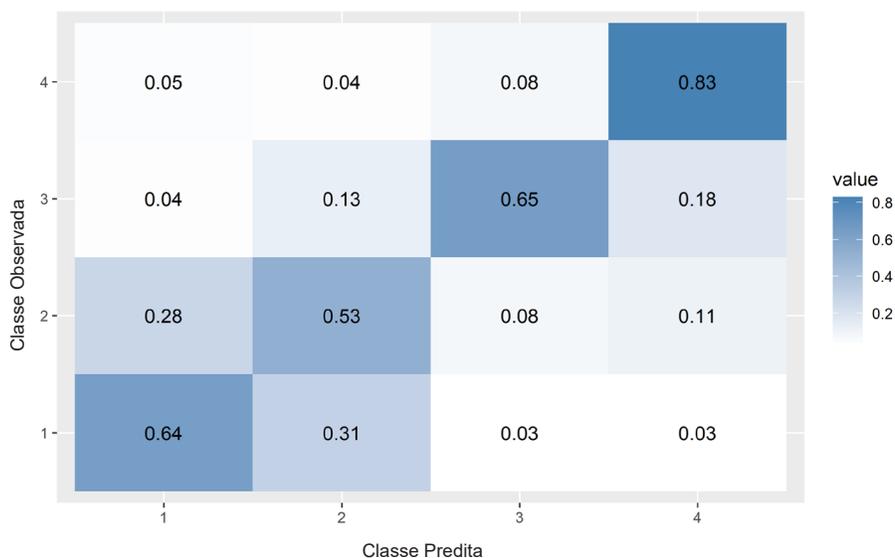


Figura 5. Matriz de acerto, onde é avaliada a relação entre as classes preditas e observadas pelo modelo. Representa a porcentagem de acerto referente ao conjunto de validação.

Foram observados maiores erros de classificação entre a classe 1 (Pré-pastejo) e a classe 2 (Em pastejo). Este comportamento já era esperado devido serem estas classes relacionadas a presença de considerável cobertura vegetal. Portanto, a semelhança da resposta espectral influencia no erro de divisão entre as classes, principalmente em período chuvoso, quando mesmo com a pastagem em altura reduzida, o favorecimento da produção de biomassa e a rebrotação propiciam uma maior resposta da cor verde.

O mesmo ocorre entre as classes 3 (Pós-pastejo) e classe 4 (Solo Exposto), onde ambas apresentam como principal característica a presença, em maior proporção, de solo exposto, embutindo maior erro de classificação devido à proximidade da reflectância do solo exposto com material senescente presente na base das touceiras no pós-pastejo. Esse confundimento mostrou-se maior em relação ao pasto nos períodos de menor crescimento e maior presença de material senescente na base das touceiras, ou seja, principalmente na estação seca do ano.

Resultados da predição em um novo conjunto de dados

Após a constatação da viabilidade de aplicação da técnica proposta, foi utilizado o algoritmo Random Forest para a classificação de um novo conjunto de imagens coletadas em janeiro de 2021. Os resultados são apresentados nas Tabelas 3 e 4.

Tabela 3. Resultado final da classificação de um novo conjunto de dados mediante aplicação do algoritmo Random Forest para as classes de cobertura do solo.

Piquetes	In loco		Predito		
	Condição observada em campo	Pré-pastejo (%)	Pré-pastejo (%)	Pré-pastejo (%)	Solo exposto (%)
A1	Em pastejo	60,89	37,97	0,15	0,97
A2	Pré-pastejo	59,39	40,17	0,02	0,40
D1	Pré-pastejo	66,00	30,84	0,61	2,54
D2	Pós-pastejo	2,78	11,73	64,99	20,50

Na Tabela 3 a coluna “Piquetes” indica a área trabalhada, enquanto a coluna In loco apresenta a condição de campo no momento da aquisição do ortofotomosaico, e nas demais colunas a porcentagem de pixels separados para cada classe proposta pelo modelo.

No piquete A1, que se encontrava na condição in loco “Em pastejo”, observou-se um erro de classificação do algoritmo entre as condições de pré-pastejo (60,89% dos pixels) e em pastejo (37,97% dos pixels). Ressalta-se que nesse piquete esse comportamento pode estar relacionado ao início do pastejo dos animais na área, caracterizando uma maior resposta à presença de forragem, onde a condição era próxima à caracterização de pré-pastejo. A altura média de campo e predita apresentada na Tabela 4 para este piquete demonstra que o rebaixamento do pasto estava apenas iniciando, concordando com a predição das classes de cobertura desse conjunto de dados.

No piquete A2, no momento da aquisição dos dados, a condição era de pré-pastejo, concordando com 59,39% da predição. Vale ressaltar que somando as classes Pré e Em pastejo obteve-se 99,56% dos pixels, sendo essas as classes que demonstram condição de maior cobertura do solo pelas plantas.

O mesmo comportamento foi observado para o piquete D1, que apresentou 66% dos pixels na predição da condição de pré-pastejo e 96,84% dos pixels entre as classes Pré e Em pastejo. Já o piquete D2, que se encontrava na condição de Pós-pastejo, teve 64,99% dos pixels classificados assertivamente, e 20,50% classificados com uma resposta espectral que indicava solo exposto. Assim, é possível observar uma concordância geral entre o manejo adotado a campo e a predição proposta pelo processo de classificação/previsão.

É válido ressaltar que a classe “Em pastejo” pode demonstrar diferentes condições em campo, isso quer dizer que, caso o pastejo tenha sido iniciado a pouco, a resposta espectral pode estar próxima da condição de “Pré-pastejo”, ou caso a biomassa já tenha sido largamente consumida na área em questão, a resposta do espectro de cores pode se aproximar da condição de “Pós-pastejo” ou até mesmo de “Solo exposto”.

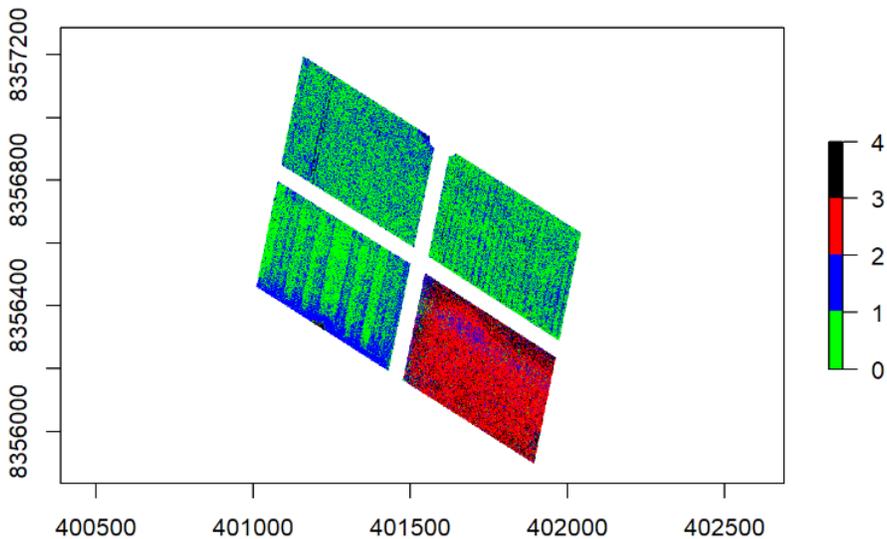


Figura 6. Resposta da classificação do espectro de cores dos quatro piquetes sob monitoramento para as classes de pastejo estipuladas onde, “0-1” - Pré-pastejo, “1-2” - Em pastejo, “2-3” - Pós-pastejo e “3-4” - referente às áreas de solo descoberto.

Na Figura 6 é possível observar a consonância dos dados com a Tabela 3, ambas provenientes da classificação, onde é clara a condição de resposta do piquete na condição de pós-pastejo. É válido ressaltar a disposição espacial da classificação dos pixels das imagens, sendo observado que na região central de cada piquete são encontradas as maiores alturas de plantas. As menores alturas identificadas em talhões classificados como “Em pastejo” e “Pré-pastejo” encontram-se nas bordas dos piquetes, além dos locais utilizados como trilhas do gado próximos aos comedores e locais de passagem de implementos agrícolas utilizados para realizar a adubação dos piquetes, fornecimento de sal ou proteinado. Logo, no piquete A2, a parte inferior azul reflete justamente essa área de acesso e trânsito de maquinário e implementos ao talhão.

Na Tabela 4 são apresentados os resultados da predição de altura dos pastos. No geral, observa-se valores semelhantes entre a altura média predita e a altura média observada em campo.

Tabela 4. Resultado final da classificação do conjunto de imagens mediante aplicação do algoritmo Random Forest para altura média do dossel.

Piquete	Classe de pastejo adotada em campo	Altura média observada em campo (cm)	Altura média predita (cm)	Diferença (%)
A1	Em pastejo	49,00	39,20	20
A2	Pré-pastejo	40,00	36,30	9,3
D1	Pré-pastejo	48,00	35,10	26,9
D2	Pós-pastejo	31,00	24,80	20

É possível observar maior erro de classificação no piquete D1, em relação aos demais piquetes, onde a diferença entre os valores de altura medidos a campo e preditos é de 26,9% (12,9 cm). Essa diferença observada pode estar relacionada ao método de coleta, sendo o método de campo realizado por amostragem, representando um total de 10 m² em cada piquete, totalizando 0,0040 m² em toda área. Essa amostragem de certa forma representa a condição do pasto próxima aos pontos de amostragem. Já a avaliação a partir dos produtos do VANT é realizada na área como um todo, representando por completo toda a área, inclusive aqueles pontos com baixa cobertura do solo ou inexistência de vegetação, possibilitando representar uma área total de 64,7 hectares.

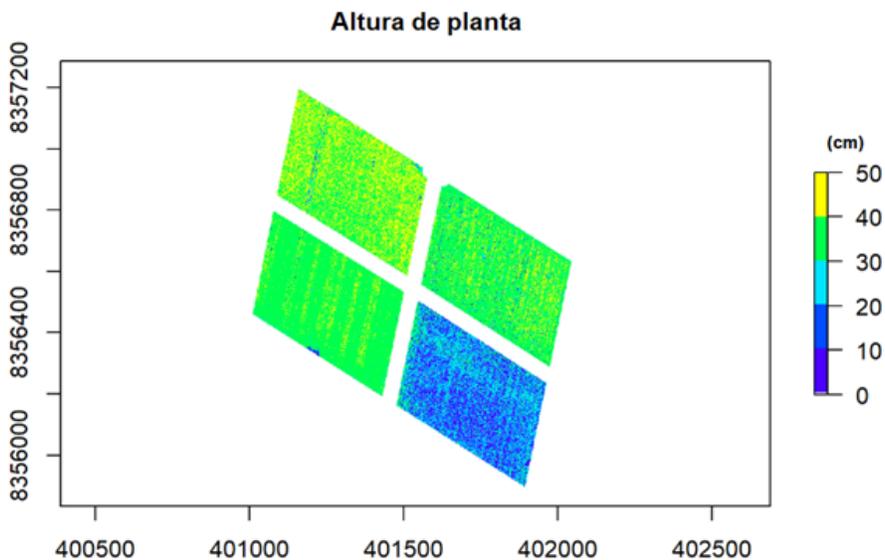


Figura 7. Resposta preditiva da altura média de plantas, proposta pelo algoritmo em questão.

É possível observar também a consonância dos dados da Figura 6 relativa às classes de pastejo e da Figura 7 no tocante à altura de plantas, onde apesar da altura média predita ter sido menor que a mensurada em campo, é possível ver que diversas observações respeitaram o comportamento das informações coletadas in loco.

Considerações finais

Neste estudo testou-se um maior detalhamento da cobertura do solo, para conhecer as possibilidades do método perante a limitação de dados espectrais. Mesmo com um modelo simples de VANT, com restrições como resolução espectral (dados somente na região do visível-RGB), foi possível obter classificações satisfatórias para o manejo do capim-piatã sob pastejo rotacionado.

Assim, o script de processamento, para a aplicação em ortomosaicos de imagens obtidos com o uso de VANT de baixo custo, possibilita o uso da tecnologia como ferramenta auxiliar no manejo do pastejo.

Para resultados confiáveis em relação ao método padrão de avaliação a campo, são necessários ajustes em função da localidade de utilização, por meio de métodos convencionais, para correções relacionadas às limitações do equipamento (somente imagens na região do visível).

Por fim, a aplicação do aprendizado de máquina com base na resposta espectral de imagens aéreas obtidas por VANTs em outras espécies e/ou cultivares forrageiras se faz necessária para dados conclusivos do uso do modelo de forma mais ampla.

Agradecimentos

À Fazenda Trijunção, pelo financiamento e parceria na realização do trabalho. Ao gerente da Fazenda Trijunção Allan Figueiredo, Virgínio Gonçalves e Magno Falcão, aos estagiários e toda equipe da Fazenda por apoiar e possibilitar a execução deste trabalho.

Referências

- ANZILIERO, D. As técnicas de monitoramento por VANT: uma revisão dos resultados obtidos na agricultura. In: FARIAS, H. P. S. de. (org.). **Diversidade, meio ambiente e o processo interdisciplinar na contemporaneidade**. Rio de Janeiro: Epitaya, 2021. p. 34-47.
- BARRIOS, S. C. L.; CARROMEU, C.; MATSUBARA, E. T.; CRIVELLARO, L. L.; SILVA, M. A. I. da; VALLE, C. B. do; SANTOS, M. F.; JANK, L. **Pasto Certo - versão 2.0®**: aplicativo para dispositivos móveis e desktop sobre forrageiras tropicais. Campo Grande, MS: Gado de Corte, 2019. 13 p. (Embrapa Gado de Corte. Comunicado técnico, 148).
- BLAS, B. **SpatialRF**: CRAN v 1.1.3. 2021. DOI: 10.5281/zenodo.4745208.
- BREIMAN, L. Bagging predictors. **Machine Learning**, v. 24, p. 123-140, 1996.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5-32, Oct. 2001.
- FREEMAN, P. K.; FREELAND, R. S. Agricultural UAVs in the U.S.: potential, policy, and hype. **Remote Sensing Applications: Society and Environment**, v. 2, p. 35-43, Dec. 2015.
- GENRO, T. C. M.; SILVEIRA, M. C. T. da. **Uso da altura para ajuste de carga em pastagens**. Bagé: Embrapa Pecuária Sul, 2018. 17 p. (Embrapa Pecuária Sul. Comunicado técnico, 101).
- HOTT, M. C.; ANDRADE, R. G.; MAGALHAES JUNIOR, W. C. P. de; BENITES, F. R. G. Uso de veículo aéreo não tripulado (VANT) para estimativa de vigor e de correlações agrônômicas em genótipos de capim *Cynodon*. In: SILVA, H. C. da (org.). **Engenharia sanitária e ambiental**. Ponta Grossa: Atena, 2019. p. 235-244.
- IBGE. **Serviço online para pós-processamento de dados GNSS**. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-sobre-posicionamento-geodesico/servicos-para-posicionamento-geodesico/16334-servico-online-para-pos-processamento-de-dados-gnss-ibge-ppp.html?=&t=o-que-e>. Acesso em: 17 set. 2021.
- RSTUDIO: integrated development for R. Boston: PBC, 2020. Disponível em: <http://www.rstudio.com/> Acesso em: 21 out. 2021.
- RODRIGUES, M. T., POLLO, R. A., RODRIGUES, B. T., MALHEIROS, J. M., & CAMPOS, S.. Sensoriamento remoto e geoprocessamento aplicado ao uso da terra para avaliação entre classificadores a partir do índice Kappa. **Revista Científica Eletrônica de Engenharia Florestal**, 23(1), p. 60-70, 2014.
- SENTELHAS, P. C.; PEREIRA, A. R.; ANGELOCCI, L. R. **Meteorologia agrícola**. Piracicaba: Universidade de São Paulo, 1999. 125 p.

Literatura recomendada

CUNLIFFE, A. M.; BRAZIER, R.E.; ANDERSON, K. Ultra-fine grain landscape-scale quantification of dryland vegetation structure with drone-acquired structure-from-motion photogrammetry. **Remote Sensing of Environment**, v. 183, p. 129-143, Sept. 2016.

LU, B.; HE, Y. Species classification using Unmanned Aerial Vehicle (UAV)-acquired high spatial resolution imagery in a heterogeneous grassland. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 128, p. 73-85, June 2017.

MAFANYA, M.; TSELE, P.; BOTAI, J.; MANYAMA, P.; SWART, B.; MONATE, T. Evaluating pixel and object based image classification techniques for mapping plant invasions from UAV derived aerial imagery: *Harrisia pomanensis* as a case study. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 129, p. 1-11, July 2017.

OSCO, L. P.; RAMOS, A. P. M.; PEREIRA, D. R.; MORIYA, E. A. S.; IMAI, N. N.; MATSUBARA, E. T.; ESTRABIS, N.; SOUZA, M. de; MARCATO JUNIOR, J.; GONÇALVES, W. N.; LI, J.; LIESENBERG, V.; CRESTE, J. E. Predicting canopy nitrogen content in citrus-trees using Random Forest algorithm associated to spectral vegetation indices from UAV-imagery. **Remote Sensing**, v. 11, n. 24, p. 2925, Dec. 2019.

SANKEY, T.; DONAGER, J.; MCVAY, J.; SANKEY, J. B. UAV lidar and hyperspectral fusion for forest monitoring in the southwestern USA. **Remote Sensing of Environment**, v. 195, p. 30-43, June 2017.

SENTHILNATH, J.; KANDUKURI, M.; DOKANIA, A.; RAMESH, K.N. Application of UAV imaging platform for vegetation analysis based on spectral-spatial methods. **Computers and Electronics in Agriculture**, v. 140, p. 8-24, Aug. 2017.

UYSAL, M.; TOPRAK, A. S.; POLAT, N. DEM generation with UAV Photogrammetry and accuracy analysis in Sahitler hil. **Measurement**, v. 73, p. 539-543, Sept. 2015.

WRIGHT, M. N.; ZIEGLER, A. Ranger: a fast implementation of random forests for high dimensional data in C++ and R. **Journal of Statistical Software**, v. 77, n. 1, p. 1-17, Mar. 2017. DOI: 10.18637/jss.v077.i01.

Apêndice

Código completo, arquivo tipo RMarkdown

****Rotina de processamento de imagem de aeronaves remotamente pilotadas:****

O código abaixo está descrito em etapas. É imprescindível que o usuário altere o diretório de trabalho e salve as imagens separadas por banda no diretório de trabalho.

```
![_Figura 1__ - Diretório de trabalho e imagens utilizadas](Diretorio.jpg)
```

****1.**** Para executar o código proposto é necessário Carregar os pacotes discriminados a seguir. Caso o usuário não possua os pacotes instalados, é possível realizar a instalação a partir da barra de tarefas “packages”.

```
```{r, message=FALSE, warning=FALSE}
```

```
library(knitr)
```

```
library(rmarkdown)
```

```
library(raster)
```

```
library(marmap)
```

```
library(randomForest)
```

```
library(caret)
```

```
library(doParallel)library(corrplot)
```

```
library(cluster)
```

```
library(Hmisc)
```

```
library(GGally)
```

```
library(dplyr)
```

```
library(knitr)
```

```
library(rgdal)
library(sf)
library(ggplot2)
inicio = Sys.time()
...
```

**\*\*2.\*\*** Nessa etapa é direcionado o diretório de trabalho. É necessário alterar o diretório de trabalho de acordo com cada usuário. Copiar o diretório e alterar no código abaixo. Atentar-se para alterar a barra para “/”.

```
``{r, message=FALSE, warning=FALSE}
setwd (“C:/0_EMBRAPA/R/Script”)
...
```

**\*\*3.\*\*** Nessa etapa é feita a leitura dos dados. A Tabela utilizada foi obtida a partir da coleta de pontos nas imagens de treinamento, sendo concatenada a informação de dados de campo (**\*\*Classe de manejo\*\*** e **\*\*Altura de planta\*\***) e os dados obtidos a partir da extração de valores de imagens RGB obtidas pelo imageamento aéreo. Visando aumentar as covariáveis foram criadas relações entre as bandas RGB, conforme as fórmulas a seguir:

$$RG = \frac{R}{G}$$

$$RB = \frac{R}{B}$$

$$GB = \frac{G}{B}$$

$$RG_{\text{normalizado}} = \frac{R-G}{R+G}$$

$$RB_{\text{normalizado}} = \frac{R-B}{R+B}$$

$$GB_{\text{normalizado}} = \frac{G-B}{G+B}$$

**\*\*4.\*\*** Nesse procedimento é feita a leitura do banco de dados com as amostras que serão utilizadas para treinamento e validação do modelo preditivo.

```
``{r, warning=FALSE}
```

```
d = read.csv("C:/0_EMBRAPA/R/asc2/Amostras_v4.csv",sep = ";")
d$rg = d$b1_img/d$b2_img
d$rb = d$b1_img/d$b3_img
d$gb = d$b2_img/d$b3_img
Criar relações de bandas
d$rg_ = (d$b1_img-d$b2_img)/(d$b1_img+d$b2_img)
d$rb_ = (d$b1_img-d$b3_img)/(d$b1_img+d$b3_img)
d$gb_ = (d$b1_img-d$b3_img)/(d$b2_img+d$b3_img)
names(d)
...
```

**\*\*5.\*\*** Nesse procedimento é feita eliminação de colunas no conjunto amostral (se necessário) .

```
```{r}
d$OBJECTID_12 = NULL
d$OBJECTID_1 = NULL
d$OBJECTID = NULL
names(d)
```

****6.**** Nesse procedimento é apresentada a distribuição do conjunto de dados e a correlação entre as variáveis.

```
```{r}
#ggpairs(d)
d %>% ggpairs(.,
 mapping = ggplot2::aes(colour=estacao),
 lower = list(continuous = wrap("smooth", alpha = 0.3, size=0.1)))
...
```

**\*\*7.\*\*** A seguir é apresentada a estrutura do banco de dados. O conjunto de dados foi obtido a partir de coleta de amostras em ambiente GIS. Essa etapa é necessária para correlacionar as classes de manejo e altura de planta, com a resposta espectral da imagem. Para a obtenção dos pontos de amostragem, foram gerados polígonos de 10 m<sup>2</sup> próximos aos locais de coleta de dados em campo. Ao todo foram gerados 40 polígonos, sendo 10 em cada talhão. Posteriormente foi realizada a conversão dos polígonos em pontos, sendo gerados 46 pontos por polígono. Adicionalmente foram coletadas amostras de solo exposto, sendo contabilizado um conjunto amostral de 18909 pontos. Em ambiente GIS foram carregadas as bandas R (Vermelho), G (Verde) e B (Azul), e extraída a informação para cada ponto do conjunto amostral.

\_\_Tabela 1\_\_: Estrutura do banco de dados

```
```\{r, echo=FALSE, message=FALSE, warning=FALSE}

library(knitr)

kable(head(d),digits = 2,align = "c")

...

```

****8.**** A tabela abaixo apresenta as variáveis utilizadas no trabalho. Visando aumentar o conjunto de covariáveis, e assim aumentar a performance do classificador, foram criados índices a partir das informações RGB. A seguir são descritos o significado e o código utilizado.

__Tabela 2__: Variáveis utilizadas no trabalho

```
```\{r, echo=FALSE, message=FALSE, warning=FALSE}

library(knitr)

classes. = c("Classe de manejo", "Estação do ano", "Altura medida em
campo", "Poligono", "Banda R da imagem", "Banda G da imagem", "Banda B
da imagem")

indice. = c("class", "estacao", "Altura_Ca", "ORIG_FID", "b1_img", "b2_
img", "b3_img")

```

```

tab.classes = cbind(classes., indice.)

tab.classes = as.data.frame(row.names = c("Significado", "Codigo"), tab.
classes)

names(tab.classes) = c("Significado", "Codigo")

#kable(tab.classes, caption = " __Tabela 2 - Variaveis utilizadas no traba-
lho__",align = "c", digits = 2)
...

```

**\*\*9.\*\*** A partir dos índices apontados por Barrios et al. (2019), foram utilizados os resultados do trabalho de monitoramento já realizado e criadas classes de manejo de pastagens. Para realizar a predição de classes de manejo é necessário atribuir códigos aos atributos categóricos.

```

__Tabela 3__: Classes de manejo utilizadas
```{r, echo=FALSE, message=FALSE, warning=FALSE}
library(knitr)

classes. = c("Pre-Pastejo", "Em pastejo", "Pós pastejo", "Solo exposto")

indice. = c(1, 2, 3, 4)

Altura. = c("30 a 40 cm", "20 a 30 cm", "Abaixo de 20 cm", "Sem vegetação")

tab.classes = cbind(classes., indice.,Altura.)

tab.classes = as.data.frame(row.names = c("Classe", "Código", "Altura de
planta"), tab.classes)

names(tab.classes) = c("Classe", "Código", "Altura de planta")

#kable(tab.classes, caption = " __Tabela 3 - Classes de manejo utiliza-
das__",align = "c", digits = 2)
...

```

****10.**** Nessa etapa é realizada algumas transformações dos cabeçalhos do banco de dados. Nessa etapa os atributos categóricos são convertidos para fator, sendo realizada também a troca do nome dos atributos utilizados. Como resultado, é obtido um novo conjunto de dados, denominado "df".

```
``{r, warning=FALSE}
```

```
df = d %>% mutate(classe = as.factor(class), poligono = as.factor(ORIG_
FID), estacao = as.factor(estacao) ) %>%
```

```
  select(classe, poligono, everything(), -ORIG_FID, -class) %>% na.omit()
  names (df)
```

```
...
```

****11.**** Nessa etapa é realizada a seleção das variáveis a serem utilizadas no treinamento do modelo, sendo criado um dataframe denominado “dclassifica”.

```
``{r, message=FALSE, warning=FALSE}
```

```
dclassifica = select(df,classe,Altura_Ca,poligono,estacao,b1_img,b2_im
g,b3_img)
```

```
...
```

****12.**** Nessa etapa é selecionada a época do ano de análise, considerando as épocas *seca* e *chuva*. Para selecionar a época de interesse, alterar no campo de seleção *estação*. Posteriormente é criado um conjunto de dados para a época selecionada, sendo criado um dataframe denominado “dclassifica_epoca”.

```
``{r, message=FALSE, warning=FALSE}
```

```
dclassifica_epoca = dclassifica %>% filter(estacao == 'chuva') # Alterar
aqui para estação seca ou chuvosa
```

```
dclassifica = dclassifica_epoca
```

****13.**** Nessa etapa é apresentada a distribuição dos dados e classes correspondentes.

```
``{r, message=FALSE, warning=FALSE}
```

```
dclassifica$classe = as.numeric(dclassifica$classe)
```

```
hist(dclassifica$classe, col = "wheat", main = paste("Histograma - Pixels
por Classe"), xlab = "Classe", ylab = "Frequência")
```

```
  abline(v = 20, lwd = 4, col = "magenta")
```

```
...
```

****14.**** É realizada a separação dos conjuntos amostrais de treinamento e validação, sendo atribuído 75 % dos dados das classes para o conjunto de treinamento e 25% dos dados para o conjunto de validação. Foram dois conjuntos amostrais, sendo o de treinamento do modelo denominado “treino” e o de validação do modelo denominado “valida”.

```
``{r, message=FALSE, warning=FALSE}
set.seed(100)

intrain = createDataPartition(dclassifica$classe, p = 0.75, list = FALSE)
treino = dclassifica[intrain,]
valida = dclassifica[-intrain,]

treino$classe = as.factor(treino$classe)
valida$classe = as.factor(valida$classe)
```

****15.**** Agora é realizado o treinamento do classificador, utilizando o algoritmo Random Forest. Abaixo foi aplicada a fórmula combinando as diferentes bandas da imagem para prever a classe de manejo para realizar uma classificação da imagem. Para realizar a predição de altura, é realiza a troca na fórmula pela coluna `Altura_Ca`.

Uma matriz de classificação é criada, classificando-se todos os casos do modelo em categorias, determinando se o valor previsto correspondeu ao valor real. Todos os casos em cada categoria são contabilizados e os totais são exibidos na matriz.

Somando os valores das células que são diagonalmente adjacentes, pode-se determinar a exatidão geral do modelo.

Nesta parte do processo o classificador tende a ter um erro menor, pois a validação do classificador utiliza o conjunto amostral do treinamento.

```
``{r, message=FALSE, warning=FALSE}
set.seed(100)

formula = as.formula(classe ~ b1_img + b2_img + b3_img)
fit.rf = randomForest(formula,data = treino, ntree = 50)

fit.rf
``
```

****16.**** Nessa etapa é verificada a importância das variáveis:

```
```{r}
varImpPlot(fit.rf)
```

**\*\*17.\*\*** Predizendo as amostras de validação e calculando o kappa. Nesse procedimento é realizada a validação utilizando o conjunto de validação. Este conjunto não havia sido apresentado ao classificador.

Nesse procedimento é gerada a matriz confusão, onde: v = valor predito e valida\$classe = valor real

```
```{r}
v = predict(fit.rf,valida)
cm = confusionMatrix(v,valida$classe)
cm
...
```
```

O índice Kappa é uma medida de concordância interobservador e mede o grau de concordância além do que seria esperado tão somente pelo acaso. Esta medida de concordância tem como valor máximo o 1, onde este valor 1 representa total concordância e os valores próximos e até abaixo de 0, indicam nenhuma concordância, ou a concordância foi exatamente a esperada pelo acaso.

**\*\*18.\*\*** Plotando a matriz de acertos, onde: v = valor predito e valida\$classe = valor real.

```
```{r}
library(reshape2)
cf = data.frame(round(prop.table(table(v,valida$classe),1),2))
melted_cf <- melt(cf)
...
```{r, message=FALSE, warning=FALSE}
library(ggplot2)
```

```
ggplot(data = melted_cf, aes(y=v, x=Var2, fill=value)) +
 geom_tile() +
 geom_text(aes(x=Var2, y=v, label = value), color = "black", size = 4) +
 scale_fill_gradient(low = "white", high = "steelblue")
...
__Predição para novo raster__
```

**\*\*19.\*\*** Nessa etapa é realizada a leitura das imagens a serem preditas. Para realizar a predição para um novo conjunto amostral basta copiar as imagens das respectivas bandas e colar na pasta de trabalho. Esse procedimento visa carregar os rasters de covariáveis a serem preditas.

```
` `{r}
getwd()

lista = names(dclassifica) #Lista o nome das covariáveis do conjunto de
dados com a finalidade de importar os rasters com o mesmo nome

lista

lista = lista[-c(1:4)] #Elimina dessa lista as 4 primeiras colunas, de variá-
veis categóricas.

lista

lista = paste(lista, ".tif", sep = "") #Irá importar todos os arquivos na pasta a
partir dos nomes e formato .tif

lista
...

20. Nesse procedimento são carregados os rasters de interesse.

` `{r}

getwd() # Apresenta o nome da pasta de trabalho (local onde os rasters
estão salvos)

rasters.selec <- stack(lista)
```

`res(rasters.selec)` #Apresenta a resolução do raster. Quanto maior a resolução do raster, maior será o detalhamento, porém com maior exigência de processamento e tempo

...

# Plota o resultado da classificação para todos talhões

`brk <- c(0,1, 2, 3, 4)`

`plot(talhoes, col=c("green", "blue", "red", "black"), breaks=brk, main="Talhão 12 classificado")`

...

**\*\*22.\*\*** Calcula as estatísticas (classes) por talhão (Piquetes) - Talhão A1

```
```{r echo=TRUE, message=FALSE, warning=FALSE}
```

```
library(dplyr)
```

```
options(digits = 3)
```

```
#Aplicar o filtro por talhão selecionado a partir do shapefile
```

```
talhaoa1 = talhao %>% filter(Talhao == 'A1')
```

```
#Aplica a máscara por talhão selecionado
```

```
talhaoa1_r = raster::mask(r1, talhaoa1) # Talhão classificado
```

```
rgb_a1_r = raster::mask(rgb_, talhaoa1) # Talhão ortofoto
```

```
# Salva o raster classificado no caminho indicado
```

```
writeRaster(talhaoa1_r, "C:/0_EMBRAPA/R/asc2/dclassifica_talhao_a1.tif", overwrite = TRUE )
```

```
# Para calcular a estatística (Frequência - %), primeiro transforma o raster em data frame
```

```
talhaoa1_d = as.data.frame(talhaoa1_r)
```

```
# Excluir dados faltantes
```

```
talhaoa1_d = na.omit(talhaoa1_d)
```

```
# Calcula a estatística - Contagem de pixels por classe
freq_a1 <- table(talhaoa1_d$dclassifica)
print ("Frequency count")
print (freq_a1)
# Calcula a estatística - Frequência relativa
prob_a1 <- prop.table(freq_a1)
freq_a1 = (prob_a1*100)
freq_a1
# Transforma em data frame para gerar a tabela final
freq_a1 = as.data.frame(freq_a1)
freq_a1 = t(freq_a1 )
freq_a1 = as.data.frame(freq_a1)
freq_a1 = freq_a1 [-1,]
# Adiciona à tabela a informação do número do talhão e a classe de manejo de acordo com classificação de campo para validação
freq_a1$Talhao = "Talhao A1"
freq_a1$Manejo = "Em pastejo"
freq_a1 <- freq_a1 %>% rename("Pre pastejo (%)" = V1)
freq_a1 <- freq_a1 %>% rename("Em pastejo (%)" = V2)
freq_a1 <- freq_a1 %>% rename("Pos pastejo (%)" = V3)
freq_a1 <- freq_a1 %>% rename("Solo exposto (%)" = V4)
freq_a1 = freq_a1 %>% select(Talhao, Manejo, everything())
# Plota o resultado da classificação para o talhão selecionado
brk <- c(0,1, 2, 3, 4)
```

```
plot(talhaoa1_r, col=c("green", "blue", "red", "black"), breaks=brk, main="-
Talhao A1 classificado", xlim=c(401000,401600), ylim=c(8356580, 8357250))
```

```
...
```

****23.**** Apresenta os resultados da classificação para o Talhão (piquetes) A1 e a ortofoto

```
``{r, fig.width=10, fig.height=8, echo=FALSE}
par(mfrow= c(1,2))
brk <- c(0,1, 2, 3, 4)
plot(talhaoa1_r, col=c("green", "blue", "red", "black"), breaks=brk, main="-
Talhao A1 classificado", xlim=c(401000,401600), ylim=c(8356580, 8357250))
ext_a1 <- list(x=c(401000,401600), y=c(8356580, 8357250))
plotRGB(rgb_a1_r, main="Ortofotomosaico", ext= ext_a1)
...
```

****24.**** Calcula as estatísticas (classes) por talhão (piquetes) - Talhão A2

```
``{r}
library(dplyr)
options(digits = 3)
#Aplicar o filtro por talhão selecionado a partir do shapefile
talhaoa2 = talhao %>% filter(Talhao == 'A2')
#Aplica a máscara por talhão selecionado
talhaoa2_r = raster::mask(r1, talhaoa2) # Talhão classificado
rgb_a2_r = raster::mask(rgb_, talhaoa2) # Talhão ortofoto
```

```
# Salva o raster classificado no caminho indicado
writeRaster(talhaoa2_r, "C:/0_EMBRAPA/R/asc2/dclassifica_talhao_a2.tif", overwrite = TRUE )

# Para calcular a estatística (Frequência %), primeiro transforma o raster em data frame
talhaoa2_d = as.data.frame(talhaoa2_r)

# Excluir dados faltantes
talhaoa2_d = na.omit(talhaoa2_d)

# Calcula a estatística - Contagem de pixels por classe
freq_a2 <- table(talhaoa2_d$dclassifica)
print (freq_a2)

# Calcula a estatística - Frequência relativa
prob_a2 <- prop.table(freq_a2)
freq_a2 = (prob_a2*100)
freq_a2

# Transforma em data frame para gerar a tabela final
freq_a2 = as.data.frame(freq_a2)
freq_a2 = t(freq_a2 )
freq_a2 = as.data.frame(freq_a2)
freq_a2 = freq_a2 [-1,]

# Adiciona à tabela a informação do número do talhão e a classe de manejo de acordo com classificação de campo para validação
freq_a2$Talhao = "Talhao A2"
freq_a2$Manejo = "Pre pastejo"

# Altera os nomes das colunas
freq_a2 <- freq_a2 %>% rename("Pre pastejo (%)") = V1)
freq_a2 <- freq_a2 %>% rename("Em pastejo (%)") = V2)
```

```

freq_a2 <- freq_a2 %>% rename("Pos pastejo (%)" = V3)
freq_a2 <- freq_a2 %>% rename("Solo exposto (%)" = V4)
# Reordenar as colunas
freq_a2 = freq_a2 %>% select(Talhao, Manejo, everything())
# Plotar o resultado final
brk <- c(0,1, 2, 3, 4)

plot(talhaoa2_r, col=c("green", "blue", "red", "black"), breaks=brk, main="Talho A2 classificado", xlim=c(401000,401500), ylim=c(8356180, 8356800))

**25.** Apresenta os resultados da classificação para o Talhão (piquete) A2 e a ortofoto
```{r, fig.width=10, fig.height=8, echo=FALSE}
par(mfrow= c(1,2))

plot(talhaoa2_r, col=c("green", "blue", "red", "black"), breaks=brk, main="Talho A2 classificado", xlim=c(401000,401500), ylim=c(8356180, 8356800))

ext_a2 <- list(x=c(401000,401500), y=c(8356180, 8356800))

plotRGB(rgb_a2_r, main="Ortofotomosaico", ext= ext_a2)
...
...

26. Calcula as estatísticas (classes) por talhão (piquete)- Talhão D1
```{r}

library(dplyr)

options(digits = 3)

#Aplicar o filtro por talhão selecionado a partir do shapefile
talhaod1 = talhao %>% filter(Talhao == 'D1')

#Aplica a máscara por talhão selecionado
talhaod1_r = raster::mask(r1, talhaod1) # Talhão classificado
rgb_d1_r = raster::mask(rgb_, talhaod1) # Talhão ortofoto

```

```
# Salva o raster classificado no caminho indicado
writeRaster(talhaod1_r, "C:/0_EMBRAPA/R/asc2/dclassifica_talhao_d1.tif", overwrite = TRUE )

# Para calcular a estatística (Frequência %), primeiro transforma o raster em data frame
talhaod1_d = as.data.frame(talhaod1_r)
# Excluir dados faltantes
talhaod1_d = na.omit(talhaod1_d)
# Calcula a estatística - Contagem de pixels por classe
freq_d1 <- table(talhaod1_d$dclassifica)
print (freq_d1)
# Calcula a estatística - Frequência relativa
prob_d1 <- prop.table(freq_d1)
freq_d1 = (prob_d1*100)
freq_d1
# Transforma em data frame para gerar a tabela final
freq_d1 = as.data.frame(freq_d1)
freq_d1 = t(freq_d1 )
freq_d1 = as.data.frame(freq_d1)
freq_d1 = freq_d1 [-1,]

# Adiciona à tabela a informação do número do talhão e a classe de manejo de acordo com classificação de campo para validação
freq_d1$Talhao = "Talhao D1"
freq_d1$Manejo = "Pre Pastejo"
```

```

# Altera o nome das colunas
freq_d1 <- freq_d1 %>% rename("Pre pastejo (%)" = V1)
freq_d1 <- freq_d1 %>% rename("Em pastejo (%)" = V2)
freq_d1 <- freq_d1 %>% rename("Pos pastejo (%)" = V3)
freq_d1 <- freq_d1 %>% rename("Solo exposto (%)" = V4)
# Reordenar as colunas
freq_d1 = freq_d1 %>% select(Talhao, Manejo, everything())
# Plotar o resultado final
brk <- c(0,1, 2, 3, 4)

plot(talhaod1_r, col=c("green", "blue", "red", "black"), breaks=brk, main="-
Talhao D1 classificado", xlim=c(401500, 402050), ylim=c(8356250, 8356900))
...

plot(talhaod1_r, col=c("green", "blue", "red", "black"), breaks=brk, main="-
Talhao D1 classificado", xlim=c(401500, 402050), ylim=c(8356250, 8356900))
...

**27.** Apresenta os resultados da classificação para o Talhão (piquete)
D1 e a ortofoto
```{r, fig.width=10, fig.height=8, echo=FALSE}
par(mfrow= c(1,2))

plot(talhaod1_r, col=c("green", "blue", "red", "black"), breaks=brk, main="-
Talhao D1 classificado", xlim=c(401500, 402050), ylim=c(8356250, 8356900))
ext_d1 <- list(x=c(401500, 402050), y=c(8356250, 8356900))
plotRGB(rgb_d1_r, main="Ortofotomosaico", ext= ext_d1)

28. Calcula as estatísticas (classes) por talhão (piquete) - Talhão D2
```{r}

library(dplyr)

options(digits = 3)

```

```
#Aplicar o filtro por talhão selecionado a partir do shapefile
talhaod2 = talhao %>% filter(Talhao == 'D2')

#Aplica a máscara por talhão selecionado

talhaod2_r = raster::mask(r1, talhaod2) # Talhão classificado

rgb_d2_r = raster::mask(rgb_, talhaod2) # Talhão ortofoto

# Salva o raster classificado no caminho indicado

writeRaster(talhaod2_r, "C:/0_EMBRAPA/R/asc2/dclassifica_talhao_d2.tif",overwrite = TRUE )

# Para calcular a estatística (Frequência %), primeiro transforma o raster
em data frame

talhaod2_d = as.data.frame(talhaod2_r)

# Excluir dados faltantes

talhaod2_d = na.omit(talhaod2_d)

# Excluir dados faltantes

talhaod2_d = na.omit(talhaod2_d)

# Calcula a estatística - Frequência relativa

freq_d2 <- table(talhaod2_d$dclassifica)

print (freq_d2)

# Calcula a estatística - Frequência relativa

prob <- prop.table(freq_d2)

freq_d2 = (prob*100)

freq_d2
```

```

# Transforma em data frame para gerar a tabela final
freq_d2 = as.data.frame(freq_d2)
freq_d2 = t(freq_d2 )
freq_d2 = as.data.frame(freq_d2)
freq_d2 = freq_d2 [-1,]

# Adiciona à tabela a informação do número do talhão e a classe de ma-
nejo de acordo com classificação de campo para validação
freq_d2$Talhao = "Talhao D2"
freq_d2$Manejo = "Pos Pastejo"

# Altera o nome das colunas
freq_d2 <- freq_d2 %>% rename("Pre pastejo (%)" = V1)
freq_d2 <- freq_d2 %>% rename("Em pastejo (%)" = V2)
freq_d2 <- freq_d2 %>% rename("Pos pastejo (%)" = V3)
freq_d2 <- freq_d2 %>% rename("Solo exposto (%)" = V4)

# Reordenar as colunas
freq_d2 = freq_d2 %>% select(Talhao, Manejo, everything())

# Plotar resultado final
brk <- c(0,1, 2, 3, 4)

plot(talhaod2_r, col=c("green", "blue", "red", "black"), breaks=brk, main="-
Talhao D2 classificado", xlim=c(401400, 402050), ylim=c(8355800, 8356550))

**29.** Apresenta os resultados da classificação para o Talhão (piquete)
D2 e a ortofoto

``{r, fig.width=10, fig.height=8, echo=FALSE}
par(mfrow= c(1,2))

```

```

plot(talhaod2_r, col=c("green", "blue", "red", "black"), breaks=brk, main="-
Talhao D2 classificado", xlim=c(401400, 402050), ylim=c(8355800, 8356550))
ext_d2 <- list(x=c(401400, 402050), y=c(8355800, 8356550))
plotRGB(rgb_d2_r, main="Ortofotomosaico", ext= ext_d2)
...

```

__Resultado final da classificação__

****30.**** A seguir são apresentados os resultados finais obtidos para os talhões (piquetes) investigados.

```

```{r}
Plota o resultado da classificação para todos talhões
...

```

```
brk <- c(0,1, 2, 3, 4)
```

```
plot(talhoes, col=c("green", "blue", "red", "black"), breaks=brk, main="Talha
o 12 classificado")
```

**\*\*31.\*\*** Abaixo é apresentada uma tabela com o resumo da classificação por talhão, sendo os resultados apresentados em porcentagem da classe predita. A partir do resultado dessa tabela será possível determinar o manejo da pastagem mais adequada conforme a qualidade e quantidade de pastagem ofertada.

\_\_Tabela 4\_\_ : Resultado final da classificação

```
```{r, echo=FALSE, message=FALSE, warning=FALSE}
```

```
library(knitr)
```

```
tabela_final = rbind(freq_a1, freq_a2, freq_d1, freq_d2)
```

```
kable(head(tabela_final),digits = 2,align = "c")
```

****32.**** A seguir são selecionados os resultados da classificação. (Kappa e Acurácia)

```

```{r}
cm2 = as.data.frame(cm$overall)

```

```

cm2 = t(cm2)
cm2 = as.data.frame(cm2)
cm2 = cm2[,-c(3:7)]
...

```

####\_Realizar a predição de altura de planta aplicando-se uma regressão com o algoritmo Random Forest\_\_

**\*\*33.\*\*** Nessa etapa é realizada a seleção das variáveis a serem utilizadas no treinamento do modelo, sendo criado dataframe denominado “dclassifica”.

```

```{r, message=FALSE, warning=FALSE}
dclassifica = select(df,classe,Altura_Ca,estacao,b1_img,b2_img,b3_img)
...

```

****34.**** Nessa etapa é realizada a separação dos conjuntos amostrais de treinamento e validação, sendo atribuído 75 % dos dados das classes para o conjunto de treinamento e 25% dos dados para o conjunto de validação. Foram dois conjuntos amostrais, o de treinamento do modelo denominado “treino” e o de validação do modelo denominado “valida”.

```

```{r, message=FALSE, warning=FALSE}
set.seed(100)
intrain = createDataPartition(dclassifica$classe, p = 0.75, list = FALSE)
treino = dclassifica[intrain,]
valida = dclassifica[-intrain,]

```

**\*\*35.\*\*** Agora é realizado o treinamento do classificador, utilizando o algoritmo Random Forest. Esse algoritmo de aprendizagem de máquina é comumente usado para problemas de classificação e regressão, combinando a saída de múltiplas árvores de decisão para alcançar um único resultado (Breiman, 2001.). Sendo também um método de escolha amplamente empregado em classificação e monitoramento agrícola, de aspectos biofísicos de plantas, condição nutricional, hídrico, biomassa (PRADO-OSCO et al., 2019).

Abaixo foi aplicada a fórmula combinando as diferentes bandas da imagem para prever a classe de manejo para realizar uma classificação da imagem. Para realizar a predição de altura, é realiza a troca na fórmula pela coluna Altura\_Ca.

Uma matriz de classificação é criada classificando-se todos os casos do modelo em categorias, determinando se o valor previsto correspondeu ao valor real. Todos os casos em cada categoria são contabilizados e os totais são exibidos na matriz.

Somando os valores das células que são diagonalmente adjacentes, pode-se determinar a exatidão geral do modelo.

Nesta parte do processo o classificador tende a ter um erro menor, pois a validação do classificador utiliza o conjunto amostral do treinamento.

```

`r, message=FALSE, warning=FALSE}
set.seed(100)

formula = as.formula(Altura_Ca ~ b1_img + b2_img + b3_img)
fit.rf = randomForest(formula,data = treino, ntree = 50)

fit.rf
...

__Predição para novo raster__

36. Nesta etapa é verificada a importância das variáveis:

`r}

varImpPlot(fit.rf)
...

```

**37.** Predizendo as amostras do conjunto de validação e calculando o kappa. Nesse procedimento é realizada a validação utilizando o conjunto de validação. Este conjunto não havia sido apresentado ao classificador.

Nesse procedimento é gerada a matriz confusão, onde: v = valor predito e valida\$classe = valor real

```

`r}

```

Nesse procedimento é gerada a matriz confusão, onde:  $v$  = valor predito e  $v_{classe}$  = valor real

```
``{r}
```

```
#ADICIONAR ALGUM PARAMETRO PARA AVALIAR A ACURACIA DA
REGRESSAO
```

```
...
```

O índice Kappa é uma medida de concordância interobservador e mede o grau de concordância além do que seria esperado tão somente pelo acaso. Esta medida de concordância tem como valor máximo o 1, onde este valor 1 representa total concordância e os valores próximos e até abaixo de 0, indicam nenhuma concordância, ou a concordância foi exatamente a esperada pelo acaso (Rodrigues et al., 2014).

**\*\*38.\*\*** Nessa etapa é realizada a leitura das imagens a serem preditas. Para realizar a predição para um novo conjunto amostral basta copiar as imagens das respectivas bandas e colar na pasta de trabalho. Esse procedimento visa carregar os rasters de covariáveis a serem preditas.

```
``{r}
```

```
getwd()
```

```
lista = names(dclassifica) #Lista o nome das covariáveis do conjunto de
dados com a finalidade de importar os rasters com o mesmo nome
```

```
lista
```

```
lista = lista[-c(1:3)] #Elimina dessa lista as 4 primeiras colunas, de variá-
veis categóricas.
```

```
lista
```

```
lista = paste(lista, ".tif", sep = "") #Irá importar todos os arquivos na pasta a
partir dos nomes e formato .tif
```

```
lista
```

```
...
```

**\*\*39.\*\*** Nesse procedimento são carregados os rasters de interesse.

```
``{r}
```

```
getwd() # Apresenta o nome da pasta de trabalho (local onde os rasters
estão salvos)
```

```
rasters.selec <- stack(lista)
```

```
res(rasters.selec) #Apresenta a resolução do raster. Quanto maior a reso-
lução do raster, maior será o detalhamento, porém com maior exigência de
processamento e tempo
```

```
...
```

**\*\*40.\*\*** Fazendo a predição para toda a área e salvando como raster tif. e gera o mapa com o resultado da classificação (classes)

```
``{r, message=FALSE, warning=FALSE}
```

```
Realiza a predição e salva o raster classificado no caminho indicado
```

```
r2 = predict(rasters.selec, fit.rf, filename = "C:/0_EMBRAPA/R/asc2/dclas-
sifica_altura.tif", na.rm = TRUE, overwrite = TRUE, type = "response")
```

```
Importar a imagem RGB para comparação
```

```
rgb_ <- stack("Mosaico_2020_Jan_T12.tif")
```

```
Importa o shapefile dos talhões correspondentes
```

```
talhao = st_read(dsn = "talhoes.shp")
```

```
Faz o recorte do raster classificado com o limite dos talhões
```

```
talhoes = raster::mask(r2, talhao)
```

```
Plota o resultado da classificação para todos talhões
```

```
Plota o resultado da classificação para todos talhões
```

```
brk <- c(0, 10, 20, 30, 40, 50)
```

```
plot(talhoes, col= topo.colors(5), breaks=brk, main="Talhao 12
classificado")
```

```
...
```

**\*\*41.\*\*** Calcula as estatísticas (média de altura) por talhão (piquete) - Talhão A1

```
```{r echo=TRUE, message=FALSE, warning=FALSE}

library(dplyr)

options(digits = 3)

#Aplicar o filtro por talhão selecionado a partir do shapefile

talhaoa1 = talhao %>% filter(Talhao == 'A1')

#Aplica a máscara por talhão selecionado

talhaoa1_alt = raster::mask(r2, talhaoa1) # Talhão classificado

# Salva o raster classificado no caminho indicado

writeRaster(talhaoa1_alt,      "C:/0_EMBRAPA/R/asc2/dclassifica_alt_tal-
hao_a1.tif",overwrite = TRUE )

# Para calcular a estatística (Frequência - %), primeiro transforma o raster
em data frame

talhaoa1_d_alt = as.data.frame(talhaoa1_alt)

# Excluir dados faltantes

talhaoa1_d_alt2 = na.omit(talhaoa1_d_alt)

##Eliminar o 0 apenas

talhaoa1_d_alt3  =  talhaoa1_d_alt2[(talhaoa1_d_alt2$dclassifica_altu-
ra>15), ]

talhaoa1_d_alt3 = as.data.frame(talhaoa1_d_alt3)
```

```
# Extrair estatística

sumario_a1 = summary(talhaoa1_d_alt3)

sumario_a1 = as.data.frame(sumario_a1)

sumario_a1$Talhao = "Talhao A1"

sumario_a1$Manejo = "Em pastejo"

sumario_a1$Media_Campo = "49"

sumario_a1 = sumario_a1[4,]

# Plota o resultado da classificação para o talhão selecionado

brk <- c(0, 10, 20, 30, 40, 50)

plot(talhaoa1_alt, col=topo.colors(6), breaks=brk, main="Talhao A1 classi-
ficado", xlim=c(401000,401600), ylim=c(8356580, 8357250))

# Apresenta a distribuição de dados

library(knitr)

kable(head(sumario_a1), digits = 2, caption = " __Tabela X - Estatística
descritiva - Altura de plantas (cm)__", align = "c")

# Gera um boxplot

boxplot(talhaoa1_d_alt3, col = "brown", main = "Boxplot - Altura de planta
(cm)", xlab = "Talhão A1", ylab = "Altura (cm)")

#abline(h = 20, lwd = 4, col = "magenta")

# Gera histograma

hist(talhaoa1_d_alt3, col = "wheat")

#abline(v = 20, lwd = 4, col = "magenta")
```

****42.**** Apresenta os resultados da classificação para o Talhão (piquete) A1 e a ortofoto

```
```{r, fig.width=10, fig.height=8, echo=FALSE}
par(mfrow= c(1,2))
brk <- c(0, 10, 20, 30, 40, 50)

plot(talhaoa1_alt, col=topo.colors(6), breaks=brk, main="Talhao A1 - Altura
de planta (cm)", xlim=c(401000,401600), ylim=c(8356580, 8357250))
ext_ <- list(x=c(401000,401600), y=c(8356580, 8357250))
plotRGB(rgb_a1_r, main="Ortofotomosaico", ext= ext_)
...`
```

**\*\*43.\*\*** Calcula as estatísticas (média de altura) por talhão (piquete) - Talhão A2

```
```{r echo=TRUE, message=FALSE, warning=FALSE}
library(dplyr)
options(digits = 3)
#Aplicar o filtro por talhão selecionado a partir do shapefile
talhaoa2 = talhao %>% filter(Talhao == 'A2')
#Aplica a máscara por talhão selecionado
talhaoa2_alt = raster::mask(r2, talhaoa2) # Talhão classificado
# Salva o raster classificado no caminho indicado
writeRaster(talhaoa2_alt, "C:/0_EMBRAPA/R/asc2/dclassifica_alt_talhao_a2.tif", overwrite = TRUE )
# Para calcular a estatística (Frequência - %), primeiro transforma o raster em data frame
talhaoa2_d_alt = as.data.frame(talhaoa2_alt)
# Para calcular a estatística (Frequência - %), primeiro transforma o raster em data frame
talhaoa2_d_alt = as.data.frame(talhaoa2_alt)`
```

```
# Excluir dados faltantes
talhaoa2_d_alt2 = na.omit(talhaoa2_d_alt)
##Eliminar o 0 apenas
talhaoa2_d_alt3 = talhaoa2_d_alt2[(talhaoa2_d_alt2$dclassifica_altu-
ra>15), ]
talhaoa2_d_alt3 = as.data.frame(talhaoa2_d_alt3)
# Extrair estatística
sumario_a2 = summary(talhaoa2_d_alt3)
sumario_a2 = as.data.frame(sumario_a2)
sumario_a2$Talhao = "Talhao A2"
sumario_a2$Manejo = "Pre pastejo"
sumario_a2$Media_Campo = "40"
sumario_a2 = sumario_a2[4,]
# Plota o resultado da classificação para o talhão selecionado
brk <- c(0, 10, 20, 30, 40, 50)
plot(talhaoa2_alt, col=topo.colors(6), breaks=brk, main="Talhao A2 classi-
ficado", xlim=c(401000,401500), ylim=c(8356180, 8356800))
# Apresenta a distribuição de dados
library(knitr)
kable(head(sumario_a2), digits = 2, caption = " __Tabela X - Estatística
descritiva - Altura de plantas (cm)__", align = "c")
# Gera um boxplot
boxplot(talhaoa2_d_alt3, col = "brown", main = "Boxplot - Altura de planta
(cm)", xlab = "Talhão A2", ylab = "Altura (cm)")
abline(h = 20, lwd = 4, col = "magenta")
```

```
# Gera histograma
hist(talhaoa2_d_alt3, col = "wheat")
abline(v = 20, lwd = 4, col = "magenta")
...
```

****44.**** Apresenta os resultados da classificação para o Talhão (piquete) A2 e a ortofoto

```
```${r, fig.width=10, fig.height=8, echo=FALSE}
par(mfrow= c(1,2))
brk <- c(0, 10, 20, 30, 40, 50)
plot(talhaoa2_alt, col=topo.colors(6), breaks=brk, main="Talhao A2 - Altura
de planta (cm)", xlim=c(401000,401500), ylim=c(8356180, 8356800))
ext_ <- list(x=c(401000,401500), y=c(8356180, 8356800))
plotRGB(rgb_a2_r, main="Ortofotomosaico", ext= ext_)
...`
```

**\*\*45.\*\*** Calcula as estatísticas (média de altura) por talhão (piquete) - Talhão D1

```
```${r echo=TRUE, message=FALSE, warning=FALSE}
library(dplyr)
options(digits = 3)
#Aplicar o filtro por talhão selecionado a partir do shapefile
talhaod1 = talhao %>% filter(Talhao == 'D1')
#Aplica a máscara por talhão selecionado
talhaod1_alt = raster::mask(r2, talhaod1) # Talhão classificado
# Salva o raster classificado no caminho indicado
writeRaster(talhaod1_alt, "C:/0_EMBRAPA/R/asc2/dclassifica_alt_tal-
hao_d1.tif", overwrite = TRUE )`
```

Para calcular a estatística (Frequência - %), primeiro transforma o raster em data frame

```
talhaod1_d_alt = as.data.frame(talhaod1_alt)
```

```
# Excluir dados faltantes
```

```
talhaod1_d_alt2 = na.omit(talhaod1_d_alt)
```

```
##Eliminar o 0 apenas
```

```
talhaod1_d_alt3 = talhaod1_d_alt2[(talhaod1_d_alt2$dclassifica_altura>15), ]
```

```
talhaod1_d_alt3 = as.data.frame(talhaod1_d_alt3)
```

```
# Extrair estatística
```

```
sumario_d1 = summary(talhaod1_d_alt3)
```

```
sumario_d1 = as.data.frame(sumario_d1)
```

```
sumario_d1$Talhao = "Talhao D1"
```

```
sumario_d1$Manejo = "Pre pastejo"
```

```
sumario_d1$Media_Campo = "48"
```

```
sumario_d1 = sumario_d1[4,]
```

```
# Plota o resultado da classificação para o talhão selecionado
```

```
brk <- c(0, 10, 20, 30, 40, 50)
```

```
plot(talhaod1_alt, col=topo.colors(6), breaks=brk, main="Talhao D1 classificado", xlim=c(401500, 402050), ylim=c(8356250, 8356900))
```

```
# Apresenta a distribuição de dados
```

```
library(knitr)
```

```
kable(head(sumario_d1), digits = 2, caption = " __Tabela X - Estatística descritiva - Altura de plantas (cm)__", align = "c")
```

```
# Gera um boxplot
```

```
boxplot(talhaod1_d_alt3, col = "brown", main = "Boxplot - Altura de planta (cm)", xlab = "Talhão D1", ylab = "Altura (cm)")
```

```
abline(h = 20, lwd = 4, col = "magenta")
```

```

# Gera histograma
hist(talhaod1_d_alt3, col = "wheat")
abline(v = 20, lwd = 4, col = "magenta")
...

**46.** Apresenta os resultados da classificação para o Talhão (piquete)
D1 e a ortofoto
```{r, fig.width=10, fig.height=8, echo=FALSE}
par(mfrow= c(1,2))
brk <- c(0, 10, 20, 30, 40, 50)
plot(talhaod1_alt, col=topo.colors(6), breaks=brk, main="Talhao D1 -
Altura de planta (cm)", xlim=c(401500, 402050), ylim=c(8356250, 8356900))
ext_ <- list(x=c(401500, 402050), y=c(8356250, 8356900))
plotRGB(rgb_d1_r, main="Ortofotomosaico", ext= ext_)
...

47. Calcula as estatísticas (média de altura) por talhão (piquete) -
Talhão D2
```{r echo=TRUE, message=FALSE, warning=FALSE}
library(dplyr)
options(digits = 3)
#Aplicar o filtro por talhão selecionado a partir do shapefile
talhaod2 = talhao %>% filter(Talhao == 'D2')
#Aplica a máscara por talhão selecionado
talhaod2_alt = raster::mask(r2, talhaod2) # Talhão classificado
# Salva o raster classificado no caminho indicado
writeRaster(talhaod2_alt, "C:/0_EMBRAPA/R/asc2/dclassifica_alt_talhao_d2.tif", overwrite = TRUE )

```

Para calcular a estatística (Frequência - %), primeiro transforma o raster em data frame

```
talhaod2_d_alt = as.data.frame(talhaod2_alt)
```

```
# Excluir dados faltantes
```

```
talhaod2_d_alt2 = na.omit(talhaod2_d_alt)
```

```
##Eliminar o 0 apenas
```

```
talhaod2_d_alt3 = talhaod2_d_alt2[(talhaod2_d_alt2$dclassifica_altura>15), ]
```

```
talhaod2_d_alt3 = as.data.frame(talhaod2_d_alt3)
```

```
# Extrair estatística
```

```
sumario_d2 = summary(talhaod2_d_alt3)
```

```
sumario_d2 = as.data.frame(sumario_d2)
```

```
sumario_d2$Talhao = "Talhao D2"
```

```
sumario_d2$Manejo = "Pos pastejo"
```

```
sumario_d2$Media_Campo = "31"
```

```
sumario_d2 = sumario_d2[4,]
```

#sumario_d2\$AE = Porcentagem de cobertura efetiva para cálculo de lotação. Pega a área total e elimina a classe de solo exposto

```
# Plota o resultado da classificação para o talhão selecionado
```

```
brk <- c(0, 10, 20, 30, 40, 50)
```

```
plot(talhaod2_alt, col=topo.colors(6), breaks=brk, main="Talhao D2 classificado", xlim=c(401400, 402050), ylim=c(8355800, 8356550))
```

```
# Apresenta a distribuição de dados
```

```
library(knitr)
```

```
kable(head(sumario_d2), digits = 2, caption = " __Tabela X - Estatística descritiva - Altura de plantas (cm)__", align = "c")
```

```
...
```

****48.**** Apresenta o histograma de frequência e o gráfico boxplot.

```
``{r, fig.width=8, fig.height=4, echo=FALSE}
par(mfrow= c(1,2))
# Gera boxplot
boxplot(talhaod2_d_alt3, col = "brown", main = "Boxplot - Altura de planta
(cm)", xlab = "Talhão D2", ylab = "Altura (cm)")
abline(h = 20, lwd = 4, col = "magenta")
# Gera histograma
hist(talhaod2_d_alt3, col = "wheat", main = paste("Histograma - Altura de
planta (cm)", talhaod2_d_alt), xlab = "Altura (cm)", ylab = "Frequência")
abline(v = 20, lwd = 4, col = "magenta")
...

```

****49.**** Apresenta os resultados da classificação para o Talhão (piquete) D2 e a ortofoto

```
``{r, fig.width=10, fig.height=8, echo=FALSE}
par(mfrow= c(1,2))
brk <- c(0, 10, 20, 30, 40, 50)
plot(talhaod2_alt, col=topo.colors(6), breaks=brk, main="Talhao D2 -
Altura de planta (cm)", xlim=c(401400, 402050), ylim=c(8355800, 8356550))
ext_ <- list(x=c(401400, 402050), y=c(8355800, 8356550))
plotRGB(rgb_d2_r, main="Ortofotomosaico", ext= ext_)
...

```

O modelo aqui apresentado como exemplo alcançou exatidão global e índice Kappa apresentados na tabela abaixo:

__Tabela 5__: Resultado final da classificação

```
```\{r, echo=FALSE, message=FALSE, warning=FALSE}
```

```
library(knitr)
```

```
kable(head(cm2),digits = 2,align = "c")
```

```
...
```

**\*\*50** De acordo com a qualidade e quantidade de pastagem ofertada.

\_\_Tabela 6\_\_: Resultado final da classificação

```
```\{r, echo=FALSE, message=FALSE, warning=FALSE}
```

```
library(knitr)
```

```
tabela_final = rbind(freq_a1, freq_a2, freq_d1, freq_d2)
```

```
kable(head(tabela_final),digits = 2,align = "c")
```

```
...
```

__Tabela 7__: Resultado final da altura de plantas

```
```\{r, echo=FALSE, message=FALSE, warning=FALSE}
```

```
library(knitr)
```

```
tabela_final_altura = rbind(sumario_a1, sumario_a2, sumario_d1,
sumario_d2)
```

```
kable(head(tabela_final_altura),digits = 2,align = "c")
```

```
...
```

**\*\*51.\*\*** Apresenta o tempo de processamento

```
```\{r}
```

```
fim = Sys.time()
```

```
tempo = fim - inicio
```

```
# Tempo gasto para rodar
```

```
tempo
```

```
...
```

Embrapa

Pecuária Sul



MINISTÉRIO DA
AGRICULTURA, PECUÁRIA
E ABASTECIMENTO

CGPE 017914