

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

RAFAELA SOUZA MARTINS

AVALIAÇÃO DO POTENCIAL DE IMAGENS PARA DETECÇÃO DE FALHAS
DE PLANTIO NA CULTURA DA CANA-DE-AÇÚCAR

Monte Carmelo

2020

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

RAFAELA SOUZA MARTINS

AVALIAÇÃO DO POTENCIAL DE IMAGENS PARA DETECÇÃO DE FALHAS
DE PLANTIO NA CULTURA DA CANA-DE-AÇÚCAR

Trabalho de Conclusão de Curso
apresentado ao curso de Agronomia
da Universidade Federal de
Uberlândia, Campus Monte Carmelo,
como requisito necessário para a
obtenção do grau de Engenheira
Agrônoma.

Orientador: Prof. Dr. George Deroco
Martins

Monte Carmelo

2020

RAFAELA SOUZA MARTINS

AVALIAÇÃO DO POTENCIAL DE IMAGENS PARA DETECÇÃO DE FALHAS
DE PLANTIO NA CULTURA DA CANA-DE-AÇÚCAR

Trabalho de Conclusão de Curso
apresentado ao curso de Agronomia da
Universidade Federal de Uberlândia,
Campus Monte Carmelo, como requisito
necessário para a obtenção do grau de
Engenheira Agrônoma.

Monte Carmelo, 14 de agosto de 2020.

Prof. Dr. George Deroco Martins, FECIV/UFU

Prof. Dr. Edson Aparecido dos Santos, ICIAG/UFU

Prof. Dr. Rodrigo Bezerra de Araújo Gallis, IG/UFU

Monte Carmelo

2020

Ao meu eterno e querido,

Avô Elpídio (in memoriam).

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me concedido força, saúde, sabedoria e fé, para encarar e alcançar todas as etapas do curso, até chegar neste momento.

Ao meu falecido avô Élpidio, que não está mais presente comigo nesse mundo, mas de alguma forma está honrado de ver tudo o que conquistei, ele que sempre acreditava em mim e no meu potencial, demonstrando muito orgulho por ter uma neta engenheira. À minha avó Luzia, sempre me apoiando em todas as decisões, por mais difíceis e dolorosas que eram.

Aos meus pais, que sempre se preocuparam comigo a quilômetros de distância de casa e faziam de tudo para me ver bem e feliz. Aos meus amigos, por estarem vivenciando comigo a rotina de faculdade e entender tudo o que foi passado.

A todos os professores, em especial meu orientador, George Deroco, por ter aceitado a me ajudar neste trabalho e ter dado o maior suporte para que os resultados saíssem como previstos.

À Usina São Martinho e aos funcionários, Rafael Monteiro e Welton, por disponibilizarem uma área e dedicar um tempo para que todo esse experimento fosse feito e tivesse bons recursos.

E por fim, à Universidade Federal de Uberlândia, campus Monte Carmelo, por ensinar aos alunos os valores humanos, e de forma direta agir no crescimento e habilidade profissional.

RESUMO

A cada época, a demanda por novas tecnologias vem crescendo, os produtores estão na busca da melhor capacidade produtiva e rentabilidade nas lavouras, desejando aplicações ágeis e qualidade na produção de cana-de-açúcar, com o objetivo principalmente de lucrar com menos custos na implantação. Com o uso das Aeronaves Remotamente Pilotadas (ARPs), é possível obter informações em tempo recorde, auxiliando nas tomadas de decisões da cultura. Objetivou-se com o trabalho avaliar o potencial de imagens no mapeamento de falhas da cultura de cana-de-açúcar. Para tanto, a variável altura de planta também é objeto de estudo, uma vez que essa variável é importante para definir o momento que as falhas já são detectadas. Em uma área cedida pela Usina São Martinho, próximo à região de Guariba-SP, foi mapeado o local onde ocorreu a análise. Foram utilizadas imagens de ARP e softwares comerciais para o processamento das imagens gerando dados de fácil visualização e interpretação da região com falhas para as diversas alturas. Com base nas imagens, analisou a quantidade de perdas decorrente dessas falhas, com ênfase na melhor altura disponível para sobrevoar o local e conseguir uma visualização ampla da maioria das falhas presentes, interpolando com os dados manuais em campo, para ter uma alta acurácia. A melhor resposta para detectar a maioria das falhas de plantio foi por meio da classificação supervisionada por redes neurais, que obteve uma média de apenas 17% de omissão entre os dados manuais e os processados na imagem. Em segundo momento, para o parâmetro altura, a banda que teve maior correlação foi a do TGI, gerando uma equação de regressão linear capaz estimar a altura das plantas de com um erro médio quadrático de 19,95%, onde a variabilidade das medidas de altura variou entre 1,1 e 1,4 metros.

Palavras-chaves: Cana-de-açúcar, imagens de baixo custo, mapa de falhas, predição de alturas.

Sumário

1 INTRODUÇÃO.....	8
2 JUSTIFICATIVA	9
3.OBJETIVOS.....	11
3.1 Objetivo geral	11
3.2 Objetivos específicos	11
4 REVISÃO DA LITERATURA	11
4.1 Importância da cana-de-açúcar	11
4.2 Falhas na linha de plantio e manejo da cana-de-açúcar	13
4.3 Sensoriamento remoto na agricultura	14
4.4 Imagens aéreas na Agricultura.....	16
4.5 Processamento digital da imagem.....	16
4.5.1 Classificação da imagem	17
4.5.2 Cálculo do índice de vegetação.....	19
4.5.3 Correlação e Modelos de regressão	20
5 MATERIAL E MÉTODOS.....	21
5.1 Caracterização da área de estudo	21
5.3 Experimento 1: Análise da acurácia do mapeamento do número e comprimento de falhas de plantio a partir de imagens	26
5.4 Experimento 2: Análise da acurácia de modelos de predição de altura de plantas de cana-de-açúcar	28
6 RESULTADOS E DISCUSSÕES.....	29
7 CONSIDERAÇÕES FINAIS	39
REFERÊNCIAS	40

1 INTRODUÇÃO

A cana-de-açúcar é vista como uma das principais culturas do mundo, sendo no meio rural uma importante fonte econômica, cultivada em mais de 100 países. A produção de açúcar deverá atingir 31,8 milhões de toneladas, crescimento de 9,5% ao produzido na safra 2018/19 (CONAB, 2019).

A crescente produção se deu em 1975 com o desenvolvimento do Programa Nacional do Álcool (Proálcool) e também com o aumento das exportações de açúcar, logo após houve uma queda gerada pela crise do setor, mas, em 2003, a demanda pela produção voltou a crescer, pelo uso de veículos flex fuel, sendo ela até os dias de hoje uma das principais fontes de etanol.

No campo, uma das principais complicações na cultura ocorre quando muitos brotos consecutivos param de germinar e o cultivo falha. As falhas ocorrem em muitos canaviais e interferem diretamente na rentabilidade da atividade.

A metodologia clássica de identificação e mensuração de falhas é feita por levantamento manual, no campo. A amostragem é realizada a partir de 90 dias após o plantio, no momento que a cultura já está estabelecida. Sabe-se que falhas são descontinuidades das fileiras de cana-de-açúcar plantada maiores que 50 cm (STOLF et al., 2016).

A quantificação da porcentagem e a identificação das falhas nas lavouras de cana-de-açúcar são importantes por vários fatores, como: calcular as perdas significativas, verificar a germinação da muda ou tolete, uniformização da área, avaliar definição da necessidade do replantio etc.

Boa parte das falhas no plantio da cana-de-açúcar se deve ao plantio mecanizado. Nessa etapa, ocorrem danos às gemas que impedem a germinação uniforme das linhas. Erros relacionados à distribuição das mudas e até o pisoteio na linha também influenciam o baixo estande na lavoura. Uma alternativa, nessas situações, é a utilização de mudas pré-brotadas (MPB).

Dentre as ferramentas para melhora das operações de manejo do plantio de cana-de-açúcar destacam-se os estudos do sensoriamento remoto, que consiste ser a técnica

de obter informações de um objeto sem ter contato direto (NOVO, 2008). Sendo a imagem a forma mais utilizada, capturadas por sensores ópticos. Através do mapeamento das variações das estimativas de produção, utilizados na agricultura de precisão, ajudando produtores nas estratégias em campo.

A frequência de informações que o sensoriamento remoto oferece disponibiliza serviços de acompanhamento das safras, otimiza as averiguações do uso de satélites em resultados de pesquisa e desenvolve uma iniciativa para gestão de equipes em campo.

Atualmente, com o uso de equipamentos operacionais, como a Aeronave Remotamente Pilotada (ARPs), que apresenta câmeras de alta resolução e algoritmos especializados no processamento de dado, é possível obter informações em tempo recorde, auxiliando tomadas de decisões importantes dentro da cultura, onde é possível elaborar voos para a obtenção de imagens automáticas, que posteriormente os dados serão processados por um software em que detecta as falhas e linhas de plantio totais encontrados.

Para a indústria da cana-de-açúcar, os ARPs são uma das alternativas viáveis na obtenção de dados de sensoriamento remoto, pois podem combinar tempos de resposta mais curtos com recursos de mapeamento de linhas de falha mais amplos, sem o contato direto com o objeto de estudo, permitindo que os agricultores façam correções rápidas, tendo um indicador da qualidade do plantio e subsídio para avaliar se o replantio é necessário, elevando a produtividade nos sucessivos ciclos e postergar a reforma dos canaviais, diluindo o custo de implantação e aumentando o retorno econômico das áreas de produção.

2 JUSTIFICATIVA

No processo de produção de cana-de-açúcar, a geotecnologias vem tendo uma grande importância, no intuito de aperfeiçoar os custos e também incrementar na produtividade da lavoura com técnicas mais eficientes do que as convencionais (MANEGATT et al, 2006).

Em boa parte das culturas de interesse agrícola a avaliação de falhas no plantio, que consiste em espaços alocados maiores que 0,5 m, se dá de forma manual. Em virtude do tamanho das áreas, tal prática é onerosa e morosa e leva a diversos erros na gestão do plantio.

Em situações recentes alguns agricultores têm trabalhado com imagens de satélites, porém, as estimativas ainda apresentam grande número de erro em relação ao que realmente acontece no campo, apresentando desvantagens por meio da resolução temporal e espacial, além do alto custo para aquisição (MANEGATT et al, 2006).

Uma sugestão para a avaliação de falhas no plantio é a utilização das Aeronaves Remotamente Pilotáveis (ARP) em que o piloto não está a bordo, mas pilota o equipamento através de uma interface (estação remota) (BRASIL, 2010). Em comparação com a verificação manual das falhas, em que ainda se utiliza a trena como ferramenta de mensuração, sendo um trabalho mais árduo no campo.

O uso da tecnologia de imagens coletadas por ARPs, além de fornecer imagens de alta resolução, o custo é mais baixo em relação aos inúmeros fatores que a partir da imagem pode-se interpretar, tendo um acompanhamento regular em toda extensão da lavoura, comparado com um serviço manual.

Com isto, seu uso vem sendo mais procurado nos últimos anos, para diversos setores e aplicações, revolucionando vários segmentos, além de oferecer informações mais seguras, o rendimento de trabalho vai ser maior, consequentemente o produtor atingirá uma maior gratificação.

Apresentado resultados satisfatórios para a agricultura de precisão, proporcionado um rápido retorno no investimento, o uso das tecnologias já é realidade em muitas propriedades no Brasil, principalmente para diagnósticos mais rápidos e precisos, com precisão de até 99%, podendo mapear áreas de 4000 há em um único voo (AGROLINK, 2020). Em que há necessidade de avaliar a precisão desta detecção, para que os produtores busquem alternativas para compensar a produção, para que cada vez mais se integrem de forma benéfica na tomada de decisão.

Logo, este trabalho justifica-se por apresentar uma análise de dados rápida e reprodutível, pela necessidade de avaliar as principais técnicas e algoritmos disponíveis

para mapear falhas na linha de plantio, estimando parâmetros agronômicos e trazendo um maior rendimento para os produtores que buscam gerar inovações e obter conhecimento das tecnologias em sua lavoura.

3.OBJETIVOS

3.1 Objetivo geral

Mapear as falhas na linha de plantio na cultura da cana-de-açúcar e estimar parâmetros agronômicos a partir das imagens tomadas por ARPs.

3.2 Objetivos específicos

- Avaliar a acurácia do mapeamento de falhas na cultura da cana-de-açúcar a partir de imagens tomadas por ARPs;
- Avaliar o potencial dos principais softwares comerciais em estimar o comprimento de falhas na cultura da cana-de-açúcar;
- Avaliar a acurácia de modelos espectrais na estimativa da altura de plantas.

4 REVISÃO DA LITERATURA

4.1 Importância da cana-de-açúcar

A Cana-de-açúcar (*Saccharum* spp.) é um grupo de espécies nativas do sul da Ásia e da Melanésia, uma cultura usada para produção de açúcar, etanol e energia. A cana pertence à família Poaceae, essencial para a agricultura brasileira (CHAVES, 2012).

Quatro são os principais estádios de desenvolvimento da cana-de-açúcar: plantio à brotação das gemas, da brotação das gemas até o fim do perfilhamento, do final do perfilhamento ao começo da acumulação de açúcar e do início da acumulação à maturidade (KRUTMAN, 1966).

A germinação de brotos ocorre entre três e cinco semanas após o plantio, dependendo de vários fatores, incluindo dominância apical, estado nutricional da amostra, posição dos brotos no caule, posição dos brotos no sulco, método de prevenção de doenças, variedade e mudança climática e a fase de perfilhamento deve-se iniciar de forma intensa para que todos os perfilhos se desenvolvam com a mesma idade.

O máximo perfilhamento ocorre aproximadamente aos quatro meses o plantio das mudas de cana-de-açúcar. Nesse estágio, as plantas são extremamente sensíveis a fatores edafoclimáticos e às práticas realizadas pelos agricultores (Casagrande, 1991).

Ao longo do tempo, no setor sucroenergético, pode-se atingir um alto grau de sustentabilidade, considerando um dos mais prósperos na estratégia de desenvolvimento econômico (NASTARI, 2012). A usina de cana-de-açúcar utiliza quase tudo da planta. Após a remoção do caldo da cana, o restante é chamado de bagaço. E hoje em dia, as grandes indústrias utilizam para gerar eletricidade e produzir biogás em menor grau.

Pesquisas promissoras mostraram que esse bagaço também pode ser transformado em álcool, o famoso etanol de celulose. Segundo a revista Nova Cana, as melhores plantas de destilação produzem cerca de 85 litros de etanol absoluto por tonelada de cana-de-açúcar e para cada tonelada de cana processada nessas usinas, são produzidos cerca de 71 kg de açúcar e 42 litros de etanol.

No Brasil, a cana-de-açúcar é destaque por ser a terceira cultura temporária em termos de ocupação de área, bem atrás das culturas de soja e de milho, devido à

excelente eficiência de conversão fotossintética, que permite uma produtividade excepcional, em torno de 75 t/ha em média.

Para atender à demanda por etanol, a expansão da área de cana-de-açúcar em São Paulo garantiu que a safra seja proeminente na situação agrícola nacional. Entretanto, questões socioeconômicas e ambientais levantaram preocupações sociais sobre a cultura de cana-de-açúcar (LOPES; RIBEIRO, 2006; MORAES, 2007).

No território nacional, a cultura da cana-de-açúcar, está presente em 1,2% da área, localizada principalmente nos estados do Centro-Sul e Nordeste, gerando emprego, renda e desenvolvimento em cerca de 30% dos municípios brasileiros e fazendo parte de muitos produtores. (ÚNICA, 2019).

4.2 Falhas na linha de plantio e manejo da cana-de-açúcar

Descrevem-se como falhas, espaços sem colmos, que variam em tamanho e número, podendo diminuir ou aumentar conforme o manejo que será utilizado nas linhas da plantio. As falhas interferem diretamente na produtividade da área (STOLF et al, 1991).

Os campos de cana-de-açúcar são inerentemente falhos, toda a extensão é composta por falhas de tamanhos variados. Quando são muito pequenas e geralmente levam a quase nenhuma falha, são quando a projeção à distância entre 2 colmos quase se sobrepõe. Considerando que as maiores falhas são indesejáveis, e se houver mais falhas em relação a outro campo de cana, o campo irá apresentar maiores perdas. (STOLF., 1986).

Pode-se evitar em torno de 14% de perdas na lavoura, executando a quantificação e identificação das linhas com falhas. Há correlação de 3:1 entre falhas e perdas, respectivamente, por exemplo, a cada 10% de falhas idealiza 3,2% de perda no rendimento, dependendo do tamanho da propriedade. A perda de produtividade está diretamente relacionada com o manejo mecanizado, principalmente condigno á falta de controle do tráfego na área, quando o trator invade as linhas de plantio e não segue as

entrelinhas, tráfegando assim em vários lugares, além disso, o pisoteio por máquinas na colheita compactando o solo, evitando a emergência da planta (GEOAGRI, 2019).

Acompanhar o desenvolvimento cultural é cada vez mais importante para a tomada de decisões. Pode-se ajustar o tratamento, a irrigação e até o replantio, detectando falhas na colheita ou diferenças no desenvolvimento.

O plantio de cana-de-açúcar no Brasil está sendo mais proveitoso e produtivo, apesar da redução de 1,3% da área plantada, segundo dados da Conab, o que significa um bom uso da tecnologia por parte de profissionais no campo. O crescimento atual do uso de drones tem se tornado para esse parâmetro uma ferramenta destaque, não influenciando em si no plantio da cana-de-açúcar, mas na geração de informações que impactam na produção (MAPPA, 2020).

Atualmente as imagens de alta resolução fornecem esses dados e ajuda a monitorar o desenvolvimento de campos de cultivo, onde os defeitos e diferenças de padrão podem ser claramente constatados (JORGE et al., 2002).

Com a entrada da tecnologia no campo, o cultivo da cana-de-açúcar brasileira tornou-se cada vez mais automatizado e atingiu um novo nível de produtividade. Especialmente nessa cultura, analisar a linha de produção ao seu estado original e verificar a falha no plantio é uma excelente maneira de gerenciar o trabalho, em que anteriormente as medições eram feitas de forma manual. (MAPPA., 2020).

4.3 Sensoriamento remoto na agricultura

A tecnologia de geoprocessamento e sensoriamento remoto usados de maneira correta pode tornar a previsão de lavoura e monitoramentos de calendários agrícolas mais eficazes. Na agricultura, esse novo mundo tecnológico é realizado através do uso de tecnologia sofisticada e de uma ideologia de maior competitividade (VENTURA *et al.*, 2018).

O sensoriamento remoto pode ser definido como a aquisição de dados físicos de um objeto sem tocar ou entrar em contato (LINTZ; SIMONETT, 1976). Pesquisadores

vêm estudando há mais de 35 anos o potencial de seu uso aplicado à agricultura. Os Pesquisadores da Agricultural Reserch Service (ARS) do United States Department of Agriculture (USDA), nas décadas de 60 e 70 investigavam as características morfológicas de culturas e suas propriedades espectrais (ALLEN *et al.*, 1969; GAUSMAN *et al.*, 1969).

A identificação de falhas e outras anomalias nas culturas em extensões agrícolas em larga escala torna difícil o monitoramento, por isso, o sensoriamento remoto é uma ferramenta primordial para a detecção. A detecção remota pode ser realizada nos diferentes níveis do solo, suborbital e orbital, sendo o nível sub-orbital de mais destaque. O nível sub-orbital diz respeito às fotografias aéreas, usadas principalmente para a elaboração de mapas temáticos (GALVÃO *et al.*, 2015).

Essa tecnologia fornece informações espaço-temporais detalhadas sobre o comportamento das culturas nos ambientes. Vários estudos mostraram o potencial do uso de tecnologia de sensoriamento remoto na agricultura, como mapeamento e monitoramento das culturas (MASELLI; REMBOLD, 2001; PELLEGRINO, 2001; DORAISWAMY *et al.*, 2003; RUDORFF, 2005; ROCHA, 2006; ESQUERDO, 2007).

A agricultura de precisão, com essa nova aplicação de estratégias e técnicas, visa diminuir erros através do uso de GPS's e elaborar um projeto mais eficiente das variáveis que afetam a produção, conseqüentemente, variando o nível de tecnologia de cada uma das propriedades e assim estabelecendo um padrão (NASCIMENTO *et al.*, 2012).

Além de fornecer uma visão resumida das áreas agrícolas, o sensoriamento remoto tem a capacidade de monitorar temporariamente o estágio de desenvolvimento da cultura em uma grande área. Com essa implantação do SR promoveram e facilitaram as aplicações tecnológicas neste setor, como a necessidade de reduzir os custos de aplicação e principalmente diminuir o tamanho dos equipamentos utilizados. (JORGE *et al.*, 2014). Apesar do grande potencial de aplicação na cana-de-açúcar, poucos estudos ainda foram realizados usando os sensores ópticos (FRASSON *et al.*, 2007).

4.4 Imagens aéreas na Agricultura

Capturar uma imagem de uma referência acima do solo tem muitas vantagens para a visualização e mapeamento da área. Para projetos que precisam ser visualizados de cima e com muitos detalhes, o amplo espectro de visão fornecido pela fotografia aérea pode ser bem rico em detalhes. Segundo Gonçalves (2006), a fotogrametria no mapeamento aéreo explica uma técnica considerando medições, registros e análises das fotografias obtendo informações geométricas dos objetos detectados.

Primeiro, a imagem aérea era tirada por uma câmera montada no balão. Posteriormente, para auxiliar no processo de obtenção dessas imagens, foram usados aviões e helicópteros e seguido, utilizados os satélites e ARP, reduzindo os custos e tempos operacionais.

Sendo assim, as Aeronaves Remotamente Pilotadas (ARPs) mais conhecidos como “drones”, é aquela em que o piloto não está a bordo, mas controla aeronave remotamente por meio de uma interface a certa distância. (HIPARC GEOTECNOLOGIA, 2015). Que facilita suas aplicações na área agrícola, principalmente pelo tamanho do avião, definido como uma pequena aeronave capaz de executar várias funções, desde que não haja contato físico direto entre a plataforma de aquisição e o alvo.

Na implementação de projetos de fotogrametria aérea, é essencial que sejam tomadas medidas para ajudar nas decisões, em que se fortalece o trabalho, como o desenvolvimento de planos de voo, que é uma etapa importante para o cálculo e a elaboração do mapa, orientando o usuário sobre a cobertura fotografada. (DALMOLIN, 2005).

4.5 Processamento digital da imagem

Imagens aéreas são cada vez mais usadas para mapear e monitorar mudanças de crescimento e estimativas de rendimento agrícola. Seu uso tornou-se uma opção importante para a aplicação de novos conhecimentos nas áreas rurais e ajudou os agricultores a desenvolver estratégias na gestão agrícola (ALONÇO *et al.*, 2005).

A tecnologia usada para analisar dados multidimensionais obtidos por vários tipos de sensores é chamada de processamento digital de imagens, que é a manipulação de imagens por um computador, para que a entrada e a saída do processo sejam imagens, ou seja, é um conjunto de tecnologias usado para processar imagens digitais para fácil extração de informação. Essas tecnologias podem explorar detalhes inacessíveis, métodos tradicionais e permitir destacar áreas específicas de interesse (MACIEL *et al.*, 2015).

Os métodos de processamento digital de imagens, além de permitirem analisar uma cena nas várias regiões do espectro eletromagnético, também possibilitam a integração de vários tipos de dados, devidamente georeferenciados. Depois que uma imagem é capturada por um processo de digitalização, é necessária uma representação apropriada para o processamento do computador, envolvendo muitas tarefas, todas interconectadas. (ESQUEF *et al.*, 2003).

Essas tecnologias permitem o acesso em tempo real a informações precisas sobre o status de crescimento da colheita e o potencial de produção, também podem servir como um suporte importante para a análise consistente dos dados coletados por métodos convencionais (FRASSON *et al.*, 2007).

4.5.1 Classificação da imagem

Classificação é o processo de recopilar informações de imagens para identificar objetos homogêneos para especificar as áreas da superfície da terra correspondentes ao material de interesse. Os resultados da classificação digital são representados por categorias espectrais semelhantes. É composto por mapas de "pixel" representados e catalogados por cores ou símbolos gráfico. Com isso o processo de classificação digital

converte níveis de cinza em cada banda espectral em um pequeno número de categorias para formar uma única imagem. (SPRING, 2006).

A classificação pode ser fragmentada em supervisionada e não supervisionada, com base no algoritmo que será aplicado. Ambas classificações demandam dois passos: a do treinamento e a da classificação. (MOREIRA, 2003)

A classificação supervisionada é um processo de identificação de regiões espectralmente semelhantes em uma imagem, em que os usuários podem identificar inicialmente regiões de interesse conhecidas na superfície da Terra e podem extrapolar esses recursos espectrais selecionados para áreas de outra imagem. (CASTILLEJO-GONZÁLEZ *et al.*, 2009). Entre os métodos supervisionados de classificação de imagens, o algoritmo de máxima verossimilhança (Maxver) é um dos métodos mais amplamente utilizados para a caracterização, medição e monitoramento de florestas e áreas agrícolas (AMARAL *et al.*, 2009; MORIERA *et al.*, 2010; RAMIREZ *et al.*, 2010).

Outro método de classificação de imagem notável são as redes neurais artificiais (RNA), que consiste em vários neurônios distribuídos em camadas: a primeira é a de entrada e tem função de armazenar os dados, a camada média é a qual vai ocorrer o processamento das redes, e a última, que é a camada de saída, recebe os valores que foram processados. (TAFNER *et. al.*, 1995).

Visando estudar a possibilidade de usar modelos matemáticos para simular um comportamento inteligente baseado no cérebro humano. O número de neurônios em cada camada, o número de camadas em cada rede e os pesos são chamados de arquitetura de rede neural (ITO, *et. al.* 2000). Escolher a melhor arquitetura das redes neurais é uma grande dificuldade, os dados de amostra devem estar distribuídos eventualmente e devem ser inerentes para cada classe determinada na imagem (BENEDIKTSSON *et. al.* 1990). Segundo Kavzoglu e Vieira (1998), a capacidade de aprender, generalizar e reconhecer padrões torna as redes neurais artificiais úteis para a classificação supervisionada de dados detectados remotamente.

Quando um usuário usa um algoritmo para identificar a categoria presente na imagem, ela é considerada não supervisionada, onde a área deve ser heterogênea para

que garantisse que todas as categorias e variabilidades sejam incluídas, não atentando com a homogeneidade dessa área (FREITAS *et al.*, sd).

Os dois tipos de classificação têm regras de definição, portanto, o classificador associa um determinado pixel a uma determinada categoria ou uma área com níveis de cinza semelhantes (FREITAS *et al.*, sd).

4.5.2 Cálculo do índice de vegetação

Quando a radiação eletromagnética é focada e interage com as plantas, ela pode ser dividida em três partes: reflexão, absorção e transmissão. A resposta espectral da refletividade da vegetação refere-se à capacidade das culturas de refletir a radiação eletromagnética em comprimentos de onda no espectro. Com a proposta de facilitar a interpretação dos dados gerados pelos sensores óticos surgiram os índices de vegetação (IVs). Segundo Moreira (2001), o IV foi criado para destacar padrões de mudança de vegetação relacionados ao solo e outras metas de terra. Essas são transformações lineares dos coeficientes de reflexão obtidos a partir das bandas espectrais de dois ou mais sensores e envolvem operações matemáticas como soma, diferença, razão ou qualquer outra operação (WIEGANG *et al.*, 1991).

O índice de vegetação é calculado a partir de dados espectrais em diferentes faixas de frequência. (LIMA *et al.*, 2013). Onde as bandas espectrais refletidas pela vegetação estão relacionadas à atividade fotossintética, ao teor de clorofila e ao estado de maturidade das plantas. As imagens do espectro visível são compostas por uma combinação de três bandas (RGB- Red, Green e Blue). Considera-se que existe uma correlação entre a atividade fotossintética das plantas e o teor de clorofila. No processo de fotossíntese, a planta absorve as faixas vermelha e azul, mas em menor grau. No entanto, a faixa verde não é absorvida, mas refletida. Isso permite que utilizemos equipamentos fotográficos para coleta das informações necessárias para os cálculos.

O índice de vegetação, chamado de TGI (Triangular Greenness Index), do português Índice de Verde Triangular, sendo um índice que possui a capacidade de obter informações durante todo o período de crescimento da planta (HUNT, 2011).

Foi produzido com base na área triangular envolvendo as características espectrais da clorofila. Quando a refletividade do verde é maior que a linha entre os vértices vermelho e azul, ou seja, para a vegetação verde, o valor de TGI é positivo. Quando a refletância verde é menor que a linha vermelho e azul, o TGI é negativo.

O índice TGI possui a unidade de comprimento de onda \times refletância, podendo mudar a refletância de fracionada para a percentual, sem afetar o resultado com a conversão de unidades (HUNT, 2011).

Ao aplicar o IV à abordagem de sensoriamento remoto, variáveis relacionadas à cobertura vegetal podem ser medidas indiretamente a partir das imagens adquiridas, porque os dados de refletância estão diretamente relacionados às características das plantas.

4.5.3 Correlação e Modelos de regressão

Entre os poucos problemas nos mais diversos campos, é preciso verificar se duas ou mais variáveis estão relacionadas, o que é crucial para estabelecer modelos matemáticos para verificar seu comportamento e ajudar a entender como certos aspectos afetam outros tão importantes.

É importante construir um modelo matemático, onde a correlação verifica o relacionamento entre as duas variáveis, determinando se ambas apresentam uma variabilidade. E a modelagem chamada de regressão, ajuda a entender como certas variáveis afetam outras variáveis, ou seja, analisa como o comportamento de uma variável altera o comportamento de outra. (PORTAL ACTION, 2019)

São dois os modelos gerados de regressão: o simples e multivariado, a diferença entre eles é quantidade de variável que envolve, sendo mais de duas variáveis, utilizado o modelo multivariado, e o simples quando envolve uma relação entre apenas duas variáveis. Realizando previsões sobre o comportamento futuro de algum fenômeno da realidade. (VANTAGE, 2019).

Os modelos (simples ou multivariados) simulam relacionamentos entre as variáveis, podendo ser do tipo linear (equação da reta) ou não linear (equação geométrica ou exponencial) (USP, sd).

5 MATERIAL E MÉTODOS

5.1 Caracterização da área de estudo

O trabalho foi realizado em área cedida pela Usina São Martinho, na região de Guariba-SP, fazenda Santa Bárbara (Figura 1). O talhão de localização próxima às coordenadas UTM E 229580 N 7930445, fuso 23S, constituído de cana variedade RB975952 e com 168 dias após a emergência. A cultura foi implantada mecanizada em espaçamentos de 1,5 m entre as fileiras. Os dados de estágio fisiológicos e espaçamentos foram fornecidos pelo corpo técnico da usina. Neste experimento foi delimitados quatro blocos aleatórios e heterogêneos de 40 metros de comprimento por 12 metros de largura, totalizando uma área de 480m², com oito linhas de plantio para cada bloco e 1.920m² de área total estudada.

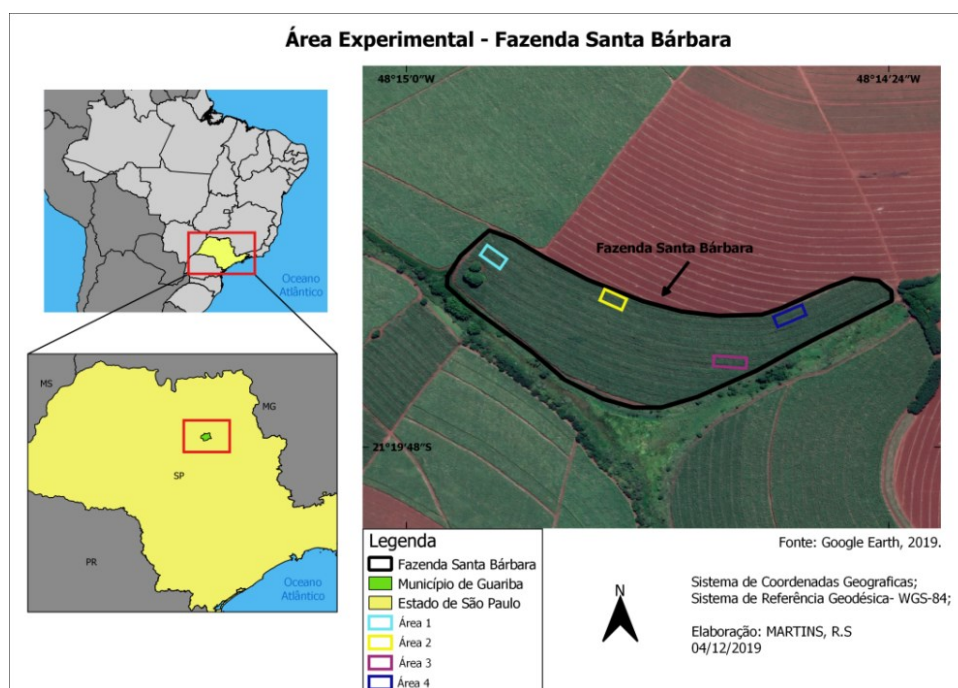


Figura 1. Localização do experimento.

Fonte: Autoria própria.

Em termos gerais, os experimentos desenvolvidos neste trabalho foram definidos com intuito de avaliar o potencial de ferramentas remotas no mapeamento de falhas da cultura da cana de açúcar. Nesse contexto, considera-se uma série de medidas métricas em campo como potenciais variáveis significativas para testar a acurácia dos produtos gerados neste estudo, tais como: número de falhas, comprimento de falhas e altura de plantas. Assim, neste estudo, são apresentados um conjunto de métodos baseados na combinação de softwares, algoritmos e modelos estatísticos para detecção e predição de tais variáveis-chaves.

Para tanto, para que o desempenho de tais metodologias fosse aferido, foi necessário realizar aerolevantamentos e dois momentos distintos sobre talhões agrícolas por meio de uma ARP. De forma concomitante a este processo, também foi realizado um levantamento convencional (*in situ*) de falhas sobre a mesma área conforme classificação de Stolf (1986), ou seja, com uso de trenas a 0,5 m em nível de solo.

Vale ressaltar que, para as quatro áreas e os dois momentos, conforme apresentado na figura 1, as medidas das variáveis métricas foram realizadas de forma manual e georreferenciadas. O georreferenciamento se fez necessário, para analisar a acurácia dos produtos gerados. A posição das variáveis medidas em campo torna-se um importante indicativo do que foi mapeado ou até mesmo predito se realmente reflete a situação real em que a variável medida se encontrava em estado natural de campo.

Salienta-se de que quando, neste manuscrito, este autor remete que as medidas foram realizadas em dois momentos, significa-se que o trabalho foi realizado no período de dois meses de monitoramento, sendo realizados em cada mês, em apenas um dia, análises de leitura de dados em campo e o levantamento aéreo das imagens.

Na figura 2 observa-se uma sequência de etapas necessárias para validar o potencial de produtos gerados por processos remotos na detecção das variáveis métricas relacionadas às falhas da cultura. As etapas são definidas como preparatórias e experimentais. Dentre as preparatórias têm-se: 1- Definição da Área de Estudos; 2- Aquisição de dados remotos e de campo e; 3- Processamento de dados remotos. As duas

últimas etapas estão diretamente relacionadas com os experimentos desenvolvidos, sendo elas: 4- Geração de mapas; 5- Análise da acurácia dos produtos.

Aqui vale enfatizar que a etapa 4, sobre a geração de mapas, foi dividida em dois experimentos e assim nomeada, pois os produtos gerados são apresentados na forma de mapas.

Para um melhor entendimento e organização metodológica, os experimentos foram dispostos com os seguintes propósitos:

Experimento 1: Análise da acurácia do mapeamento do número e comprimento de falhas de plantio a partir de imagens;

Experimento 2: Análise da acurácia de modelos de predição de altura de plantas de cana-de-açúcar.

Na figura 2, apresenta as etapas em sequência para execução deste trabalho.

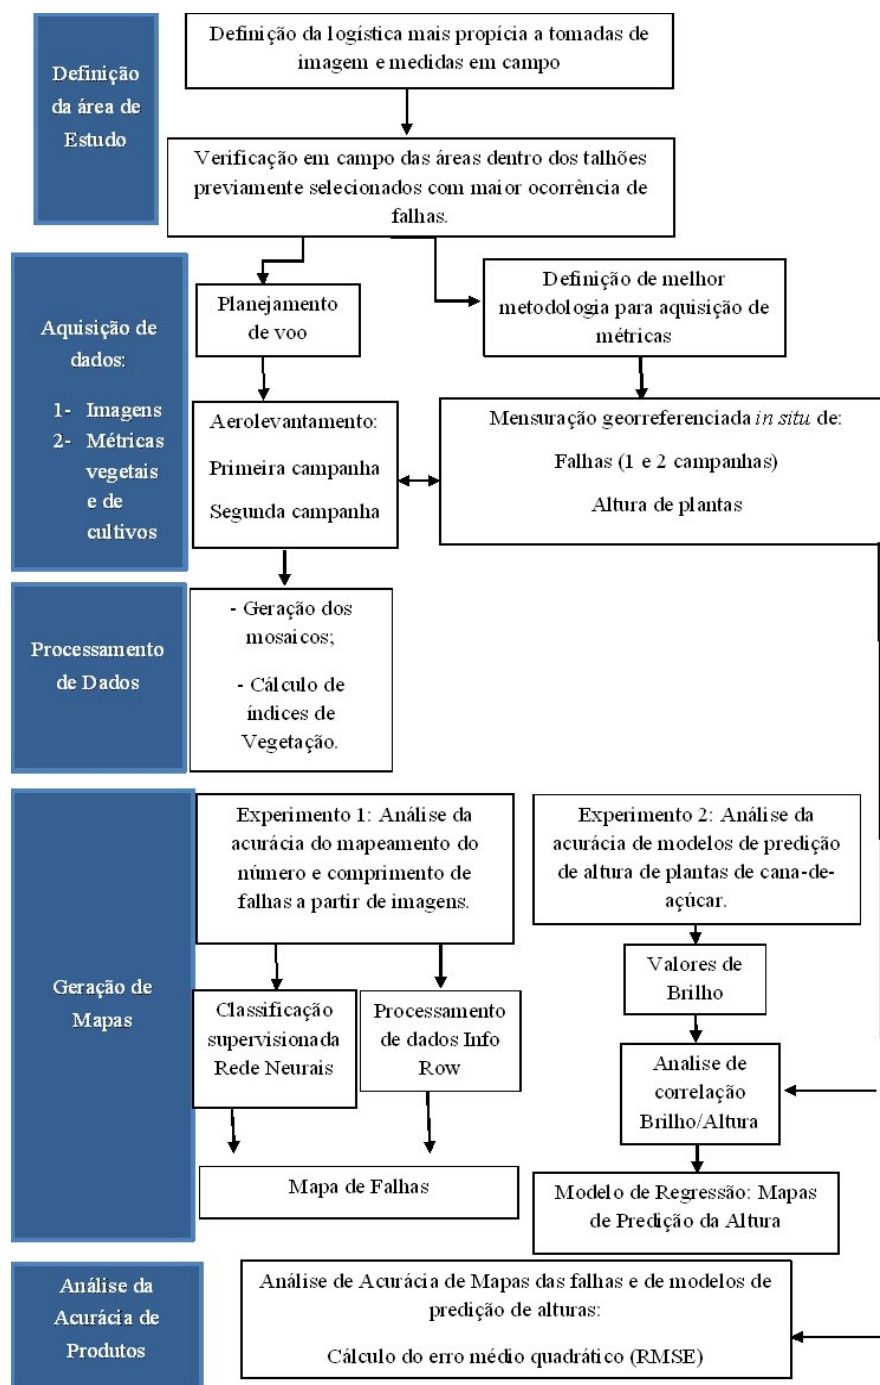


Figura 2. Fluxograma das principais etapas do trabalho.

Fonte: Autoria Própria.

5.2 Aquisições dos dados: Imagens e métricas vegetais e de cultivos

O levantamento das falhas de plantio em cana-de-açúcar nos experimentos foi realizado conforme padrão classificado por Stolf (1986) como “Levantamento manual”, conforme as normas da ABNT 156:000. 00 - 005 - Cana-de-açúcar – Determinação da Qualidade. Onde é considerado como falha a distância entre duas plantas ao longo da linha, medida de centro a centro dos colmos ao nível do solo, em uma distância maior que 0,5m.

A medição das falhas na linha de plantio da cana-de-açúcar fora realizada utilizando uma trena, em que se limita o centro do colmo de uma planta até o centro do colmo da próxima planta, em que se certifiquem valores acima de 0,5 m, para serem incluídas como falhas. As devidas alturas foram mensuradas também utilizando a trena, mas delineando a distância da base do colmo até o “colarinho” da folha mais nova. Os valores de altura considerados são de apenas 24 plantas por área, mensuradas alturas aleatórias de plantas sequenciais, sendo todas georreferenciadas por um receptor GPSmap 76CSx Garmin.

Esse procedimento resultou igualmente em duas campanhas, sendo na primeira, o plano de voo que aconteceu no período de outubro e na segunda, em novembro de 2019.

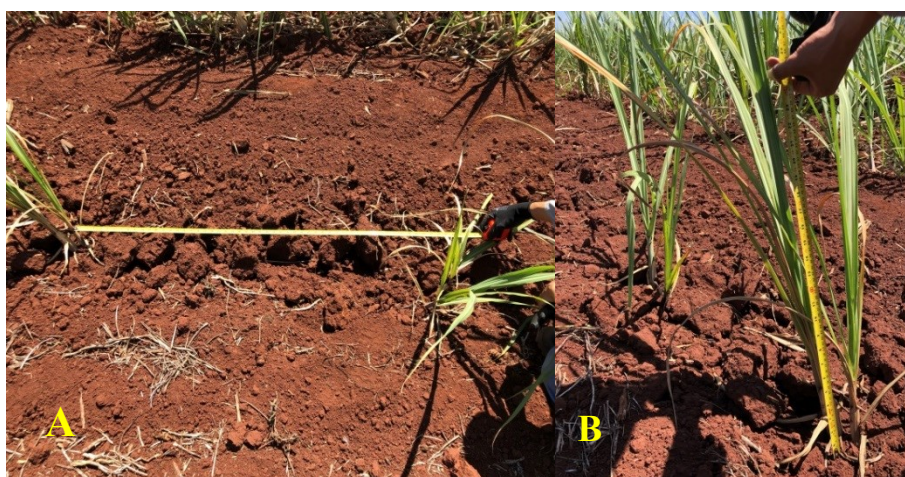


Figura 3. Realização das medidas manuais de falhas (A) e altura (B) na linha de plantio da cana-de-açúcar utilizando uma trena.

Fonte: Autoria Própria.

No levantamento aerofotogramétrico, o planejamento de voo feito de forma automática para a captura das imagens, envolvendo todos os blocos de interesse, criado via aplicativo *DroneDeploy* e precisou apenas de alguns minutos e uma pessoa para acompanhar o voo e orientar-se em campo. O voo aconteceu em horário entre 11h00 e 12h00, para evitar que a incidência de raios solares e que não influenciasse na imagem. Utilizou-se uma ARP modelo DJI Phantom 4 (figura 4), com câmera de 4.3 cm/pixel, voando a 100 m de altura, com velocidade de 11 m ⁻¹s O equipamento foi programado para capturar as imagens com sobreposição frontal de 75% e lateral de 65%.



Figura 4. ARP utilizada para o mapeamento da área.

Fonte: Tech Advisor

5.3 Experimento 1: Análise da acurácia do mapeamento do número e comprimento de falhas de plantio a partir de imagens

O intuito foi gerar mapas de falhas, por meio de duas estratégias. A primeira foi com o software Info Row e a segunda a partir da classificação supervisionada por Redes Neurais. Para tantos os processos serão detalhados neste capítulo.

Primeiramente, a geração do ortomosaico foi realizada pelo *software Pix4D mapper*, que consiste em um processo de fototriangulação, que efetua um cálculo e ajusta as coordenadas na hora de cada imagem fotografada compondo um bloco,

determinando as coordenadas tridimensionais dos pontos de interesse, a partir desses pontos homólogos entre as imagens sobrepostas, gera-se o mosaico.

E o processamento da imagem, objetivou extrair e aprimorar as informações específicas, com isso alguns erros podem ser inseridos na hora da captura e causar uma radiosidade e degradação geométrica, por isso é feito um pré-processamento em que se trata a imagem digital com o intuito de corrigir alguns desses nuances.

O *software Envi Class* além de fornecer a análise da imagem, ofereceu a extração das informações necessárias para agregar valor no experimento, auxiliando posteriormente na tomada de decisão. No software aplicou-se uma equação no qual a imagem RGB recebia um índice TGI descrita pela fórmula (1), para melhorar a interpretação dos dados e destacar o comportamento espectral das plantas, verificando assim o índice dessa vegetação com a resposta as bandas se estariam relacionadas. Além disso, no mesmo software atribuiu a classificação supervisionada da imagem por redes neurais, dando significado aos pixels em função de suas propriedades geográficas, recebendo os dados das regiões de interesse, solo exposto e cana-de-açúcar, de onde está o foco do experimento.

$$TGI = GREEN - 0.39 * RED - 0.61 * BLUE \quad (1)$$

Para a geração dos resultados das falhas, testou-se o software comercial *Info-row*, que tem a função de distinguir a vegetação (cana-de-açúcar) do solo, mostrando os números e comprimentos de falhas desejados, sendo maiores que 0,5m em cada linha de plantio.

Na avaliação da acurácia, houve um comparativo entre as metodologias capazes de gerar os mapas ilustrativos de falhas, em que exhibe a imagem original RGB, a imagem aplicada à classificação supervisionada por redes neurais e outra com a demonstração do software comercial *Info-Row*, onde foram analisados os números de falhas e o comprimento de cada uma. Isto efetuado também nas duas campanhas, integralmente ao método de aquisição de dados manuais, sendo importante para discriminar as hipóteses de uma planta de cana-de-açúcar ser mais tardia do que a outra para desenvolver a brotação, isto é, a falha ocorre quando um grande número de gemas consecutivas deixa de brotar, ou também considerando o fato de que a planta, se muito alta, os seus perfilhos podem afetar a visualização dessas falhas presentes.

Convalidando os arquivos digitais relacionados com os valores de comprimentos de falhas que fossem maiores que 0,5m, com auxílio do critério de Stolf (1986), eram medidos e dado o tamanho de cada uma, isso repetido ao longo da área, nas quatro áreas experimentais, verificando através de uma omissão, a quantidade de pontos que foram mapeados corretamente.

Na busca para demonstrar os erros encarados nas análises dos comprimentos das falhas nas imagens e para validar a credibilidade do mapeamento, os dados foram dispostos á avaliação da acurácia pela medida de erro mais comumente usada para averiguar a qualidade do ajuste de um modelo que é a raiz do erro médio quadrático (RMSE), que é a raiz do erro médio quadrático da diferença entre a predição e o valor real.

A RMSE foi calculada pela equação:

$$RMSE (\%) = \sqrt{\sum_{i=1}^n \frac{(x_o - x_i)^2}{n}} * \frac{(100 * n)}{(\sum_{i=1}^n x_o)}$$

Onde:

- x_o é a quantidade de café seco observado;
- x_i é o valor calculado pela equação;
- n é a quantidade da amostra.

Os valores de RMSE mais próximos de zero, são os que tendem a apresentar as menores diferenças entre si.

5.4 Experimento 2: Análise da acurácia de modelos de predição de altura de plantas de cana-de-açúcar

O intuito nesse experimento é avaliar a acurácia dos modelos de predição das alturas das plantas de cana-de-açúcar, através da correlação da refletância da vegetação com os valores de campo.

A correlação da refletância da vegetação, a partir da variável da altura de plantas, foi gerada a partir das medidas manuais das 24 plantas em cada área experimental, totalizando em 96 valores de altura em cada campanha, anexando juntamente os valores das bandas das imagens, que são a banda do vermelho, verde e azul e mais o índice TGI.

Para verificar a confiabilidade da acurácia, produziram-se modelos de regressão linear, pelo software *MiniTab*, empregando a variável TGI, que apresentou a maior resposta de correlação entre valores mensurados manualmente.

Operando com 80% dos valores de altura e mais os valores das bandas RGB e o índice TGI, que foi a qual apresentou o melhor resultado, que baseia em valores de refletância em comprimentos de onda visíveis, sendo uma boa para calcular áreas com alta cobertura foliar.

Estabelecendo o modelo de regressão linear com valores de alturas aleatórios, denota-se uma equação de regressão simples, permitindo inferir a relação de uma variável dependente de outra, onde será aplicada para os valores de TGI da imagem.

Essa análise de regressão pode ser usada como um método descritivo de análise de dados sem fazer nenhuma suposição sobre o processo que permite que os dados sejam gerados, designando uma equação matemática que descreva a relação entre as variáveis.

Portanto, aplicou-se essa equação nos 20% dos valores restantes, para avaliar a acurácia desses modelos na estimativa da altura. Conseguindo calcular o RMSE, por meio da discrepância da altura mensurada manualmente e os valores da altura estimada pela equação.

O modelo que apresentar uma melhor acurácia no mapeamento e um RMSE menor, a equação de altura de plantas será padronizada, com isso podendo identificar a maior porcentagem de falhas na linha de plantio da cana-de-açúcar em época correta.

6 RESULTADOS E DISCUSSÕES

Os resultados evidenciam os meios de comparação que a imagem foi disposta, sendo utilizados o software *Info-Row* e a classificação supervisionada pelo método de redes neurais, o qual pelos comparativos das imagens são mostrados pontos de interesse, como as falhas de plantio e as plantas de cana-de-açúcar.

Pelo software *Info-Row*, a imagem consegue distinguir os tamanhos de falhas e o comprimento das linhas, de maneira automática, onde podem ser estimadas as porcentagens de perda na produção daquela área e também a capacidade de replantio, caso venha obter uma extensa faixa sem indícios de emergência das plantas, em áreas com porcentagem superior 20% de falhas, notificado pelo corpo técnico da usina.

Na classificação por Redes Neurais, a ilustração se dá através de ferramentas utilizadas no software *Enviclass*, em que alicia regiões de interesse discriminando o solo exposto das vegetações, anexando um valor nessa imagem e modificando as cores para uma fácil e ampla visualização na hora em que for mensurar as falhas, utilizando a ferramenta “régua” do software *Qgis*.

6.1 Resultados experimento 1

Percebe-se visualmente a concentração de falhas quase no centro das imagens, onde ocorrem pouco crescimento e desenvolvimento de plantas (figura 5 e 6), podendo notificar que canaviais que são construídos com sistema de plantio do tipo Meiosi, aparentam ser representados dessa forma, pois as mudas que são elaboradas a partir da fileira mãe são distribuídas em média quatro linhas para a direita e quatro linhas para a esquerda e muitas das vezes faltam mudas para serem plantadas, onde vai apresentar uma faixa de solo exposto mais ampla, maior que 0,5m e assim ordenadas como falhas. (BARCELOS, 1984).

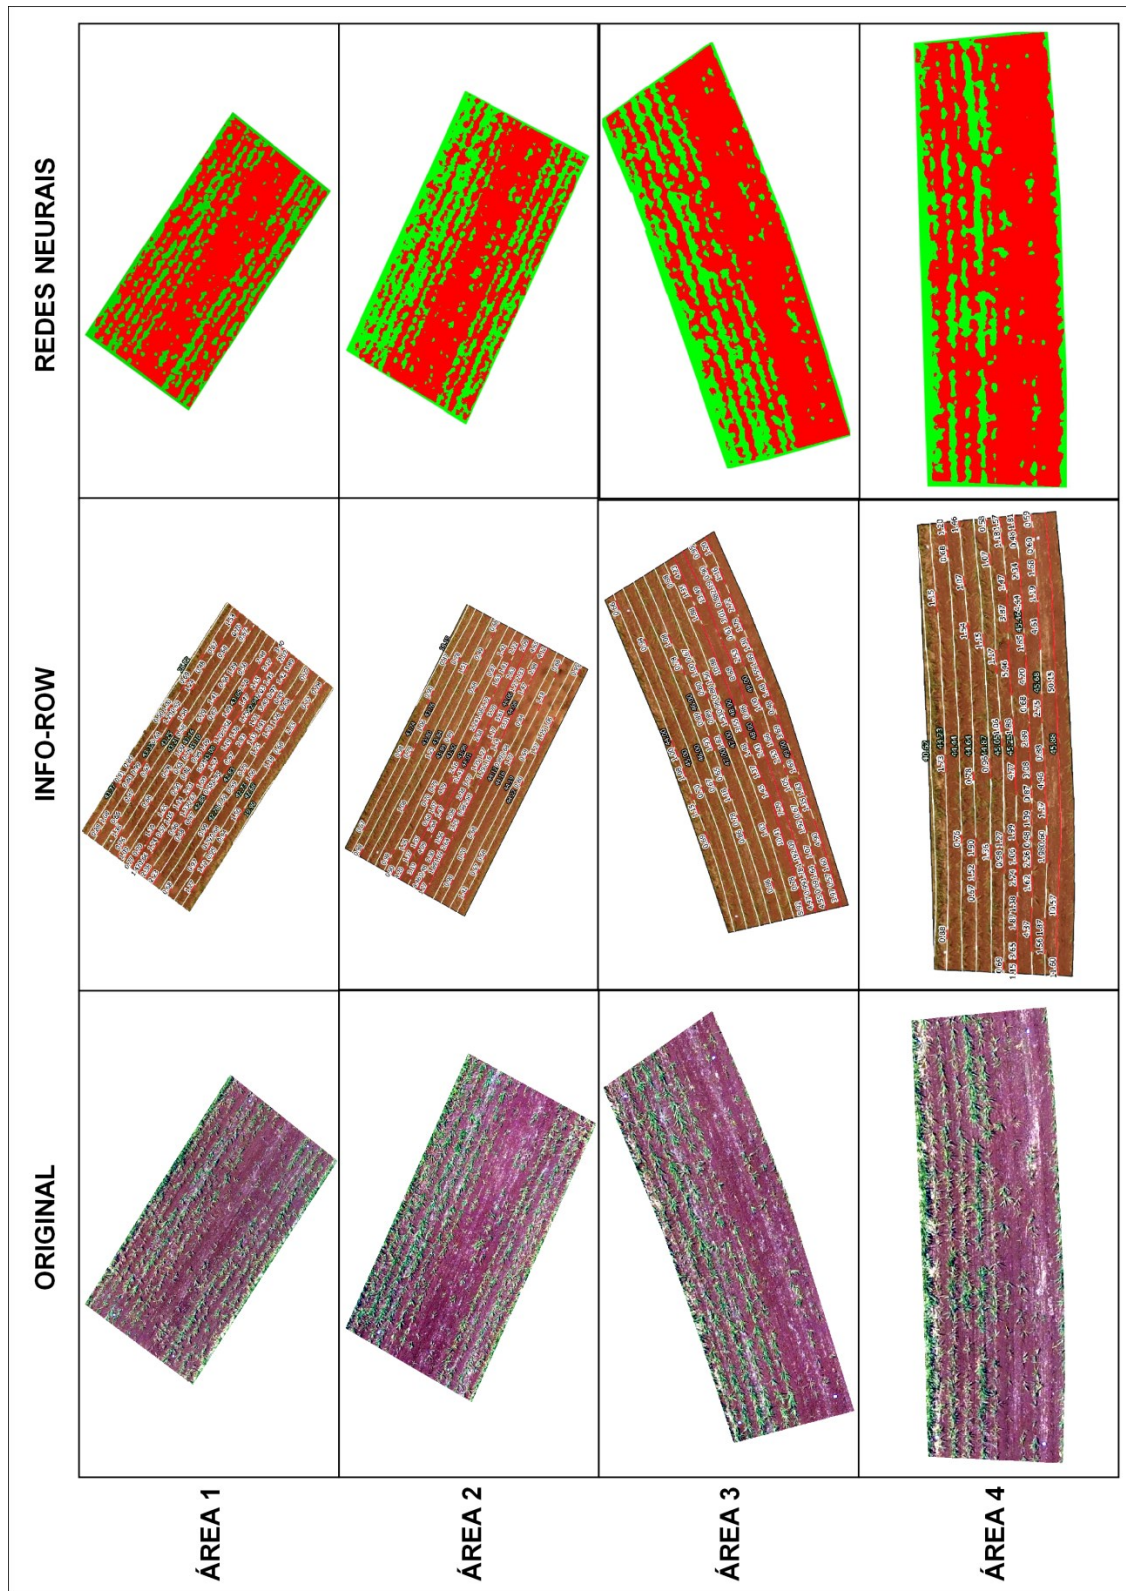


Figura 5. Resultados ilustrativos das áreas experimentais na primeira campanha.

Fonte: Autoria Própria.

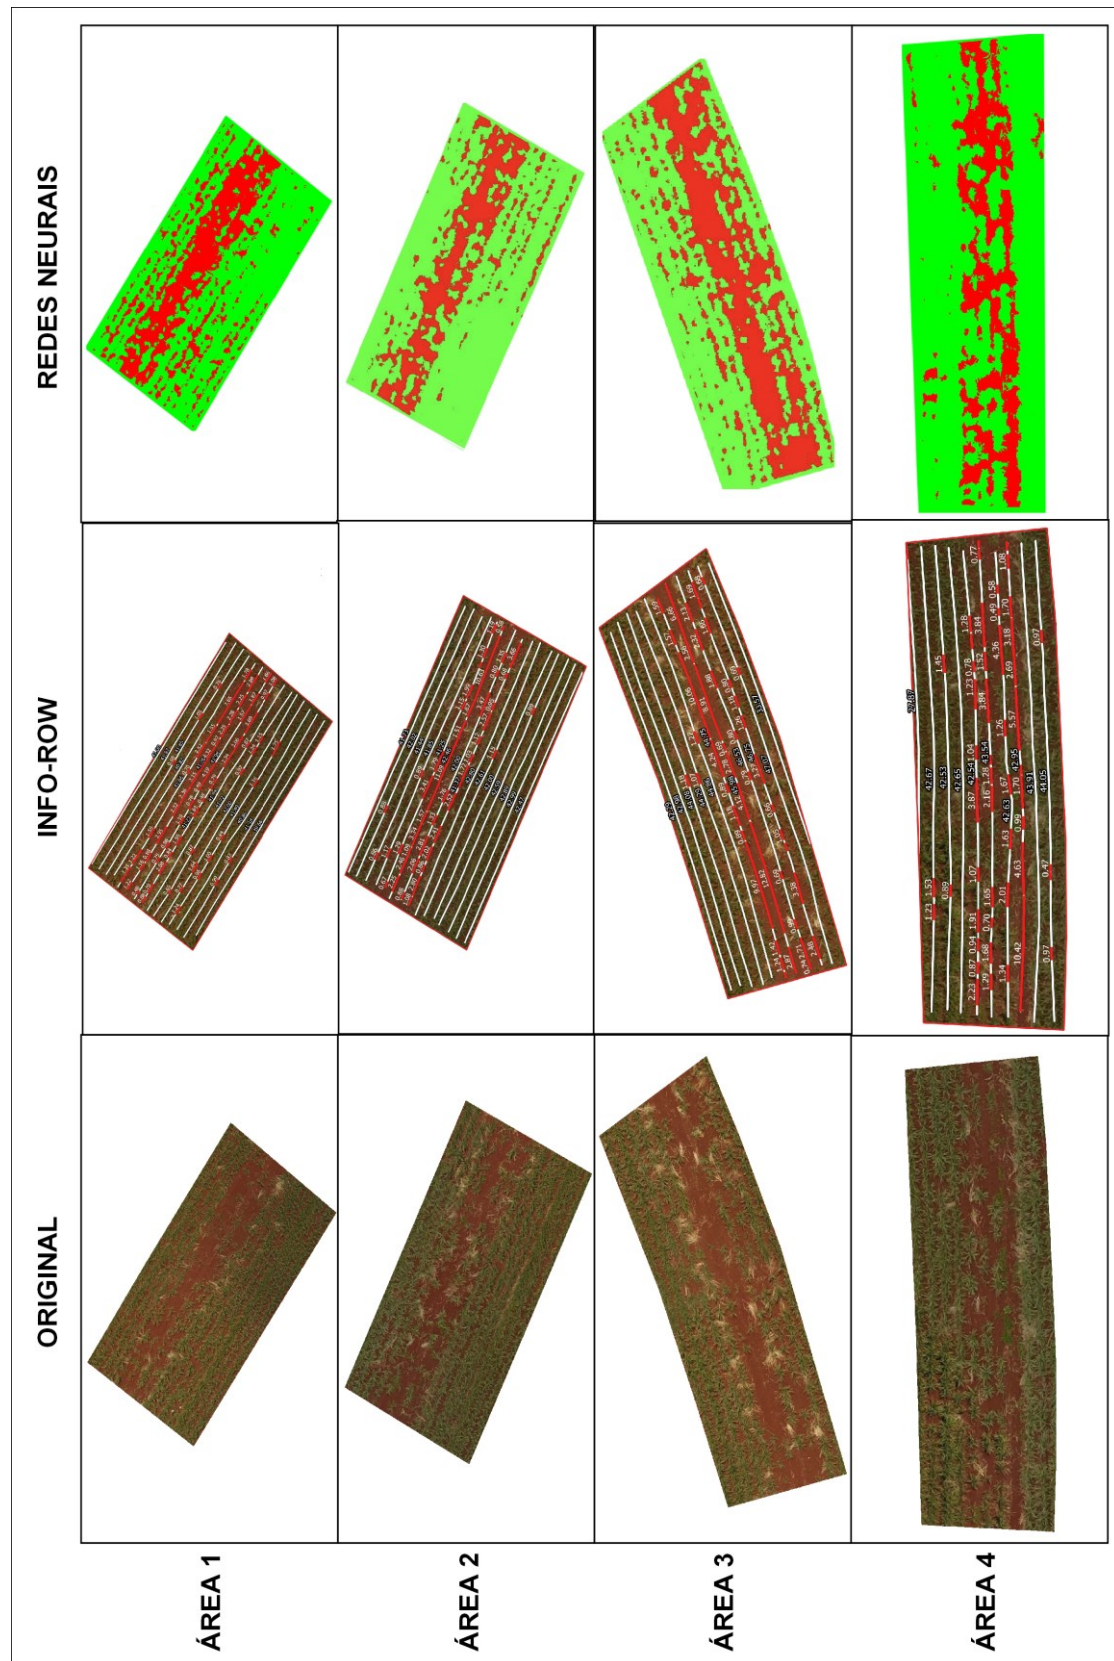


Figura 6. Resultados ilustrativos das áreas experimentais na segunda campanha.

Fonte: Autoria Própria.

Com isso, a manutenção do canavial pode ser feito com MPB (mudas pré-brotadas), por ser um método rápido e mais prático que leva pouco tempo de trabalho e mão-de-obra, pois com a tecnologia dos drones fica fácil a observação das áreas que apontam uma concentração maior de falhas no plantio.

O comparativo dos valores de números de falhas de plantio entre as medidas mensuradas manualmente, pelo software *Info-Row* e pela classificação por redes neurais (tabela 1), identificam-se no cotejo das medições manuais e do *Info-Row* uma menor omissão, no primeiro voo de 38% e 51% no segundo voo. Esse mesmo parâmetro foi comparado com a classificação por redes neurais, verificando também a menor omissão de 17% e 43% no primeiro e segundo voo, respectivamente, sendo esses valores o resultado de uma média das omissões das quatro áreas testadas.

Tabela 1. Números brutos de falhas de plantio na cana-de-açúcar em cada área estudada, comparando números encontrados no levantamento em campo, pelo *software Info-Row* e pela Classificação por Redes Neurais.

Área	Med. Manual Voo 1	Med. Info-Row	Omissão (%)	Med. Manual Voo 2	Med. Info-Row	Omissão (%)
1	125	58	53,6	100	52	48
2	90	56	37,7	83	42	49,4
3	79	55	30,38	71	33	53,52
4	75	52	30,66	86	39	54,65

Área	Med. Manual Voo 1	Med. Redes Neurais	Omissão (%)	Med. Manual Voo2	Med. Redes Neurais	Omissão (%)
1	125	81	35,2	100	52	48
2	90	85	5,5	83	42	49,4
3	79	65	17,72	71	57	19,72
4	75	82	9,3	86	40	53,49

Analisando os números da tabela acima, a mensuração dada pelo software *Info-Row* foi mais precisa e próxima do real no primeiro momento na área 3, onde omitiu 30,38% e em segundo momento na área 1, de 48%. Na classificação supervisionada por redes neurais apresentou um ótimo valor de apenas 5,5% no primeiro momento na área 2 e de 19,72% no segundo momento na área 3.

Atentando o qual o processo por meio da classificação supervisionada se destacou por mostrar uma omissão menor (5,5%), relacionada ou outro método de classe. Segundo Atkinson e Tatnall (1997) apontam um crescimento vertiginoso na utilização de RNA's, destacando-se ao sensoriamento remoto, por sua maior precisão quando comparada com outras estratégias, como os classificadores estatísticos, quando os traços não são linearmente separáveis ou as classes tem distribuições estatísticas diferentes.

Outro fator estudado por Benediktsson et al (1990) é uma agilidade superior depois de treinada na habilidade para incorporação dos tipos de dados, facilitando as interpretações e uma maior capacidade de demonstrar ótimos resultados.

Além do comparativo com os números de falhas, foi executado também com os comprimentos dessas falhas presentes e calculando a RMSE (erro médio quadrático) para verificar a acurácia do mapeamento na estimativa das falhas (tabela 2).

Os resultados de porcentagem de erro, na maioria das áreas, foram considerados altos neste parâmetro. A média dos erros foi próxima tanto com o software testado quanto também para a classificação supervisionada, mas destacando um valor alto de RMSE de 0,85 no segundo voo classificado por redes neurais. Ainda assim, a classificação comparada ao software comercial, teve proeminência, apresentando erros menores.

Tabela 2. Erro médio dos comprimentos das falhas de plantio na cana-de-açúcar observados do levantamento em campo, pelo *software Info-Row* e pela Classificação por Redes Neurais.

Área	INFO-ROW RMSE VOO1	ERRO (%)	INFO-ROW RMSE VOO2	ERRO (%)
1	0,36	45,12	0,84	76,36
2	0,65	41,31	0,67	60,9
3	0,55	51,43	0,77	76,57
4	0,62	51,23	0,53	55,2

Área	REDES NEURAIIS RMSE VOO1	ERRO (%)	REDES NEURAIIS RMSE VOO2	ERRO (%)
1	0,58	71	0,85	85,5
2	0,68	45,9	0,76	56,58
3	0,59	55,7	0,43	47,58
4	0,74	60	0,85	88,2

Mather (2004) cita que a avaliação da acurácia da classificação supervisionada é dependente de dois parâmetros: a representatividade das estimativas das classes e a natureza estatística da informação das classes recordadas nos dados da imagem e a suposição dessas classes, assente na técnica de classificação escolhida.

Pois segundo Correa (2012), indica que, dentro das parcelas analisadas, a eficiência do método de medição com sensores ópticos e a imagem obtida pela câmera do drone são tão eficazes quanto o método de levantamento manual. De acordo com Marchiori *et al.*, (2017), devido à precisão do sistema de informações geográficas, pode-se considerar que a precisão dos levantamentos de campo é baixa devido às dificuldades visuais típicas que os trabalhadores que analisam podem enfrentar.

6.2 Resultados experimento 2

A partir da correlação feita entre os valores das bandas RGB (Red, Green e Blue) e TGI (Triangular Greenness Index) da imagem com a altura manual (tabela 3 e 4), que a banda que mais houve correlação com os valores de altura, foi o de TGI, apresentando um p-value menor que 0,05, sendo significativo (GLANTZ, 2002), tanto no primeiro momento, como também no segundo.

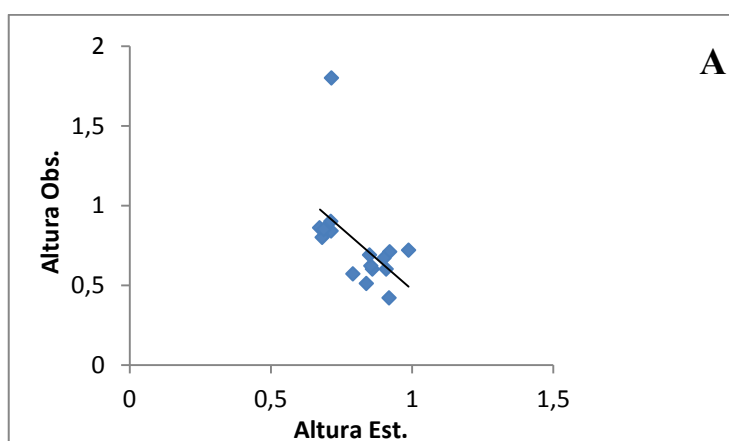
Tabela 3. Correlação de Pearson entre altura das plantas de cana-de-açúcar e bandas originais do sensor e do índice TGI no primeiro voo.

Bandas	Correlação	P-value
B1-Vermelho	0,179	0,113
B2-Verde	0,34	0,002
B3-Azul	0,312	0,005
TGI	0,383	0

Tabela 4. Correlação de Pearson entre altura das plantas de cana-de-açúcar e bandas originais do sensor e do índice TGI no segundo voo.

Bandas	Correlação	P-value
B1-Vermelho	0,052	0,648
B2-Verde	0,245	0,028
B3-Azul	0,232	0,038
TGI	0,315	0,004

Com o valor significativo entre a altura observada em campo e a altura estimada da imagem TGI, foi possível produzir modelos empíricos de regressão. (Figura 7).



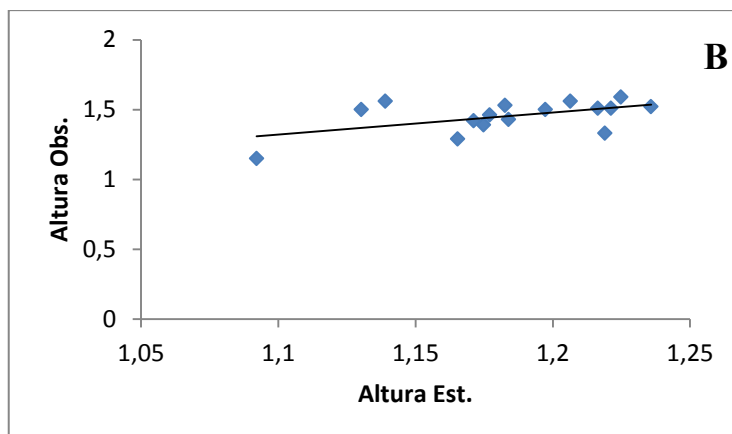


Figura 7. Gráficos de regressão da correlação entre valores observados em campo das alturas da cana-de-açúcar e valores estimados da imagem com índice TGI. (A) Primeira campanha. (B) Segunda campanha.

Fonte: Autoria Própria.

Posteriormente à correlação, elaborou-se a regressão linear entre o índice TGI e os valores de altura manuais, concebendo equações simples (tabela 5). Para uma melhor avaliação do potencial estimativo de cada equação, foi feita a troca da equação, utilizando assim a equação do modelo 1 no modelo 2 e vice-versa, demonstrando também os resultados do RMSE para cada método descrito.

Tabela 5. Modelos estimativos de regressão

Método	Modelo	RMSE (%)
1ºvoo	$Alt=0,230309+0,00642378*TGI$	47,36
1ºvoo (alterada)	$Alt=0,695757+0,00628263*TGI$	81,57
2ºvoo	$Alt=0,695757+0,00628263*TGI$	19,95
2ºvoo (alterada)	$Alt=0,230309+0,00642378*TGI$	50,23

O modelo de equação que apresenta um menor erro médio quadrático é o da segunda campanha, com um valor de 19,95%, sendo ele o mais próximo do real. Então, foi possível inseri-lo em *Band Math*, no *software Envi Classic*, gerando o produto final. (figura 8).

Isso prova que a aplicação de drones na agricultura e o uso de imagens aéreas podem ajudar a tomar decisões relacionadas a culturas, amostrando uma porção bem mais significativa do terreno que a indicada pela amostragem manual, sendo mais assertivas e minimizando a subestimação que os métodos de amostragem podem causar.

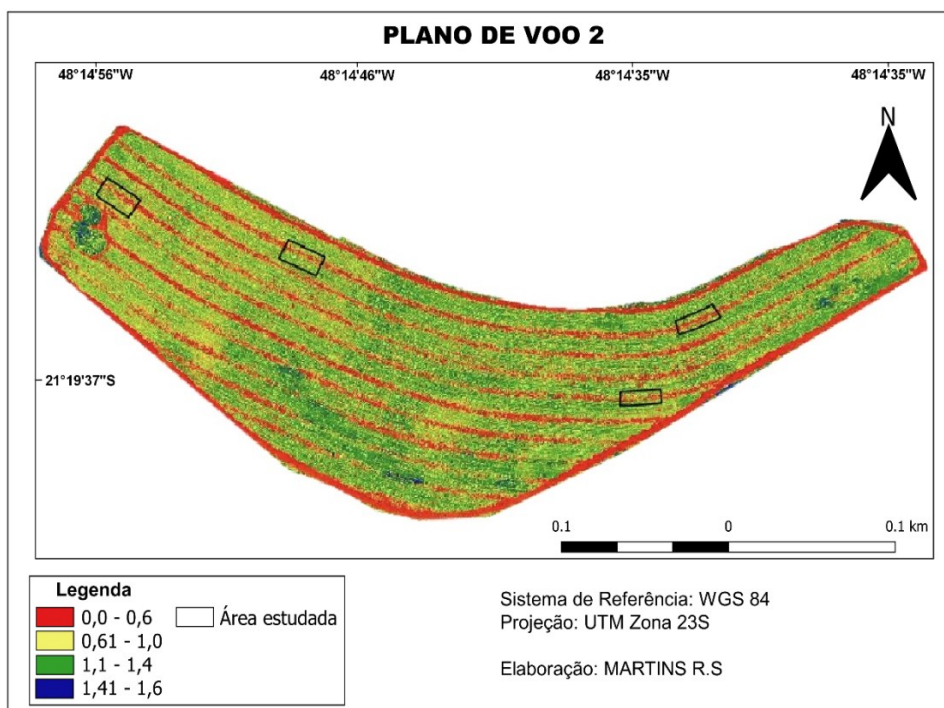
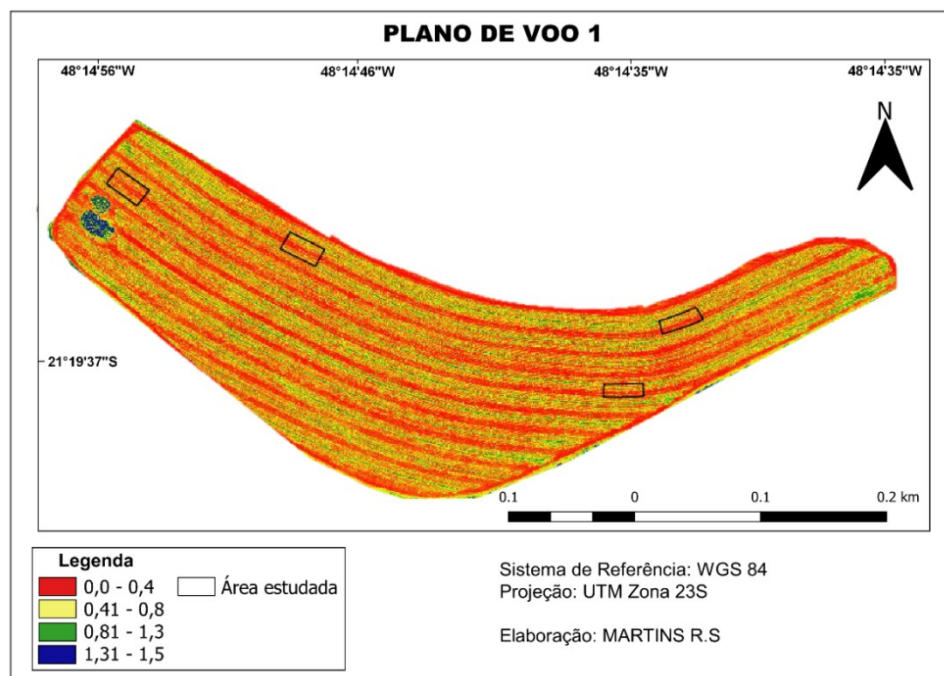


Figura 8. Mapa temático da área total obtido a partir da equação do modelo de regressão estimando os valores de altura de plantas da cana-de-açúcar em metros.

Fonte: Autoria Própria.

O desenvolvimento de veículos aéreos não tripulados é uma opção importante para a agricultura de precisão, com potencial para auxiliar os produtores rurais na determinação de estratégias para melhorar a eficiência do manejo agrícola, maximizar a rentabilidade das culturas e tornar o agronegócio mais competitivo (Medeiros et al. 2008).

Baseado na melhor equação e analisando os mapas de predição, pode-se concluir que os valores ótimos de altura estão em maiores proporções entre 1,1 e 1,4m, onde consegue dizer que a leituras das falhas no plantio ficam mais explícitas.

7 CONSIDERAÇÕES FINAIS

O uso de ARPs para o monitoramento de falhas de plantio na cultura da cana-de-açúcar é um método eficaz e representa a situação real dos campos, além de avaliar uma grande extensão de áreas, como também analisar o desenvolvimento da planta, onde possibilitou discriminar a vegetação das falhas na linha de plantio.

A melhor acurácia para o mapeamento do número das falhas de plantio se deu pela classificação supervisionada por redes neurais, chegando mais próxima do real e avaliando o potencial em estimar o tamanho dessas falhas.

Com base no parâmetro da altura de plantas, a banda de melhor correlação foi a do TGI, com uma equação de regressão simples, que obteve apenas uma RMSE de 19,95%, indiciando que a melhor altura se encontra entre 1,1 e 1,4 metros para conseguir analisar de forma mais clara as falhas na linha de plantio.

REFERÊNCIAS

- AERO SENSORIAMENTO REMOTO. **Identificação de Falhas em Linhas de Plantio- Aplicação dos Drones no Setor Sucroenergético**. 2017. Disponível em: <<https://www.aerodronebrasil.com/2017/11/20/falhas-em-linha-de-plantio/>> Acesso em: 10 de Out. de 2019.
- AGRO LINK. Agricultura de Precisão. 2020. Disponível em: <https://www.agrolink.com.br/georreferenciamento/agricultura-de-precisao_361504.html> Acesso em: 17 de Ago. de 2020.
- ALLEN, W.A. et al. Interaction of isotropic light with a compact plant leaf. **Journal of the Optical Society of America**, v.59 n.10, p.1376-1390, 1969.
- ALONÇO, A. dos S. Desenvolvimento de um veículo aéreo não tripulado (VANT) para utilização em atividades inerentes à agricultura de precisão. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 35., 2005, Jaboticabal. **Anais...** Jaboticabal: Associação Brasileira de Engenharia Agrícola, 2005. 1 CD-ROM.
- AMARAL, M. V. F. et al. Avaliação e comparação de métodos de classificação de imagens de satélite para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, v.33, n.3, p.575-582, 2009.
- ATKINSON, P.M. & TATNALL, A.R.L. Neural Networks in Remote Sensing. **International Journal of Remote Sensing**, v.18, p.699-709, 1997.
- BARBOSA, J.Z. et al. Uso de imagens digitais obtidas com câmeras para analisar plantas. **Revista de Ciências Agrárias**, v.39, n.1, p.15-24, 2016.
- BARCELOS, J.E.T. “Meiosi - Cana e Alimentos” Método inter-rotacional ocorrendo simultaneamente. **SACCHARUM** (Revista Tecnológica da indústria açucareira alcooleira). Ano VII, Número 31. Março/ abril 1984.
- BENEDIKTSSON, J. A; SWAIN, P. H; ERSOY, O. K. Neural Network approaches versus statistical methods in classification of multisource Remote Sensing data. **IEEE Transactions on Geoscience and Remote Sensing**, v.28, n.4, 1990.
- BRASIL. Comando da Aeronáutica. Departamento de Controle do Espaço Aéreo. AIC-N 21/10: veículos aéreos não tripulados. Rio de Janeiro, 2010. Disponível em: <http://publicacoes.decea.gov.br/?i=publicacao&id=3499>. Acesso em: 16 ago. 2020.
- CALVÃO, T.; PESSOA, M. Remote sensing in food production – A review. **Emirates Journal of Food and Agriculture**, **Helsinki**, v. 27, n. 2, p. 138-151, 2015.
- CASAGRANDE, A.A. **Tópicos de morfologia e fisiologia da cana-de-açúcar**. Jaboticabal: FUNEP, 1991. 157 p.
- CASTILLEJO-GONZÁLEZ, I.L. et al. Object - and pixel-based analysis for mapping crops and their agroenvironmental associated measures using QuickBird imagery. **Computers and Electronics in Agriculture**. v.68, p. 207-215, 2009.

- CHAVES, Bruno Edson. **ASPECTOS ANATÔMICOS DA RAIZ E LÂMINA FOLIAR DE *Saccharum L. (POACEAE)* NATIVAS DO BRASIL**. 2012. 260 f. Dissertação (Mestrado) - Curso de Botânica, Universidade de Brasília, Brasília, 2012.
- CONAB. **Acompanhamento da safra brasileira de Cana-de-açúcar, safra 2018/2019, n.2- Segundo Levantamento**, Brasília, p.1-62, 2019. Disponível em: <<https://www.conab.gov.br/ultimas-noticias/3017-producao-total-de-etanol-deve-ficar-em-31-6-bilhoes-de-litros>> Acesso em: 10 de Out. de 2019.
- CORREA, J. G. **Levantamento de falhas de brotação em cana-de-açúcar utilizando sensores e VANT**. 2012. 20 p. Trabalho de Conclusão de Curso (Graduação em Engenharia Agrônômica) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2012.
- DALMOLIN, Q. Projeto fotogramétrico. Curitiba: **Imprensa Universitária da UFPR**, 2005.
- DORAISWAMY, P.C. et al. Crop Yield Assessment from Remote Sensing. **Photogrammetric Engineering & Remote Sensing**, v.69, n.6, p.665-674, 2003.
- ESQUERDO, J.C.D.M. **Utilização de perfis multi-temporais do NDVI/AVHRR no acompanhamento da safra de soja no oeste do Paraná**. Campinas, SP. 186p. Tese (Doutorado em Engenharia Agrícola). UNICAMP, 2007.
- FERNANDES, J.L. **Monitoramento da Cultura de Cana-De-Açúcar no Estado de São Paulo por Meio de Imagens Spot Vegetation e Dados Meteorológicos**. 144p. Tese (Mestrado em Engenharia Agrícola). UNICAMP, 2009.
- FIGUEREDO, D. Conceitos Básicos de Sensoriamento Remoto. **Companha Nacional do Abastecimento**. Brasil, 2005.
- FRASSON, F.R. *et al.* Quantificação de falhas de plantio em cana-de-açúcar utilizando um sensor ótico ativo. In: XIII Simpósio Brasileiro de Sensoriamento Remoto, 7., 2007, Florianópolis. **Anais...** NPE, 2007.
- FREITAS, M.I.C.; PANCHER, A.M. Classificação De Imagens. **Unesp**, SD.
- GLANTZ SA. *Primer in Biostatistics*, 5th ed. New York: McGraw-Hill; 2002.
- GONÇALVES, G.R. Elementos da fotogrametria analítica. Coimbra: **Departamento de Matemática da FCTUC**, 2006.
- HIPARC GEOTECNOLOGIA. Alerta de segurança operacional ASO-05-2015-Pag 1; 08 Jun.15.
- HUNT, E. R. EITEL, J.; DAUGHTRY, C.; LONG, D. Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. *Agronomy Journal*, [s.l.], v. 103, n. 4, p.1090-1099, maio 2011.
- ITO, Y; HOSOKAMA, M. LEE, H; LIU, J. G. Extraction of damaged regions using SAR data and neural networks. Amsterdam, *IntelRNAational Archives of Photogrammetric Engineering and Remote Sensing*, v.33, 2000.

JORGE, L. A. de C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. In: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; INAMASU, R. Y. (Eds.). **Agricultura de precisão: resultados de um novo olhar**. Brasília: Embrapa, 2014. p. 109-134.

JORGE, L.A. De C.; TRINDADE Junior, O. Metodologia para Utilização de Aeromodelos em Monitoramento Aéreo. Ministério da Agricultura, Pecuária e Abastecimento, **Circular Técnica nº 15**, São Carlos, SP, outubro, 2002.

KAVZOGLU, T.; VIEIRA, C. A. O. An analysis of artificial neural network pruning algorithms in relation to land cover classification accuracy. In: REMOTE SENSING STUDENTS CONFERENCE, 1998, **Proceedings...** Oxford: p.53-58, 1998.

KRUTMAN, S. Do Grande período de variedades de cana. **Pesquisa Agropecuária Brasileira**. Brasília, v. 11. p. 395-400, 1966.

LIMA, G.C. *et al.* Avaliação da cobertura vegetal pelo índice de vegetação por diferença normalizada (IVDN). **Revista Ambiente e água**, v.8, n.2, p.202-214, 2013.

LINTZ, J.; SIMONETT, D.S. Remote Sensing of environment. **Readig**, MA: AddisonWesley, 1976.

LOPES, F.S.; RIBEIRO, H. Mapeamento de internações hospitalares por problemas respiratórios e possíveis associações à exposição humana aos produtos da queima da palha de cana-de-açúcar no Estado de São Paulo. **Revista Brasileira de Epidemiologia, São Paulo**, v.9, n.2, p.215-225, 2006.

MACIEL, A.M. *et al.* Aplicação de técnicas de processamento digital de imagens usando a extensão espacial PostGIS Raster em imagens de sensoriamento remoto. In: XVII Simpósio Brasileiro de Sensoriamento Remoto. 11., 2015, João Pessoa. **Anais...** SBSR, 2015.

MENEGATT, L. A.; MOLIN, J. P.; GÓES, S. L.; KORNDORFER, G. H.; SOARES, R. A. B.; LIMA, E. A. Benefícios econômicos e agrônômicos da adoção de agricultura de precisão em usinas de açúcar. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2º. São Pedro, SP: ESALQ/USP, 2006.

MARCHIORI, L. F. S.; TREVISAN, H. M.; BERNARDES, M. S. Levantamento de índice de falhas em cana-de-açúcar por veículo aéreo não tripulado (VANT). In: WORKSHOP AGROENERGIA E MATÉRIAS-PRIMAS. 11., 2017, Ribeirão Preto. **Anais...** Ribeirão Preto: Instituto Agrônomo de Campinas (IAC), 2017. 1 CD-ROM.

MATHER, P.M. Computer processing of remote sensed images: an introduction. Chichester: Wiley, 1987.

MASELLI, F.; REMBOLD, F. Analysis of GAC NDVI Data for Cropland Identification and Yield Forecasting in Mediterranean African Countries. **Photogrammetric Engineering & Remote Sensing**, v.67, n.5, p.593-602, 2001.

MEDEIROS, F. A.; ALONÇO, A. S.; BALESTRA, M. R. G.; DIAS, V. O.; JÚNIOR, M. L. L. Utilização de um veículo aéreo não tripulado em atividades de imageamento georreferenciado. **Ciência Rural, Santa Maria**, v. 38, n. 8, p. 2375-2378, 2008.

- MOLIN, J.P. et al. Spatial variability of sugarcane row gaps: measurement and mapping. **Ciência e Agrotecnologia**, v.40, n.3, p.347-355, 2016.
- MOREIRA, M A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 1ª ed. São José dos Campos: INPE, 2001.
- MOREIRA, M.A. **Fundamentos de Sensoriamento Remoto e Metodologias de Aplicação**. 2ª ed. Viçosa, UFV, 2003
- MOREIRA, M. A. et al. Geotecnologias para mapear lavouras de café nos estados de Minas Gerais e São Paulo. **Engenharia Agrícola**, v. 30, n. 6, p. 1123-1135, 2010.
- NASTARI, P.M. Produção Sustentável: A importância do Setor Sucroenergético no Brasil. **Agroanalysis**, p.16-17, 2012.
- NASCIMENTO, H.R. et al. Geração de informações sobre a agricultura de energia por meio das geotecnologias. **Interações** , v.13, n.2, p.181-189, 2012.
- NOVO, E. M. L. M. Sensoriamento Remoto: Princípios e Aplicações. São Paulo: Blucher, 2008.
- PELLEGRINO, G.Q. **Utilização de dados espectrais do satélite NOAA14/AVHRR como fonte de dados para modelos matemáticos de estimativa da fitomassa da cana-de-açúcar**. 116p. Tese (Doutorado em Engenharia Agrícola) - Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas - SP. 2001.
- RAMIREZ, G. M. et al. Comparação de dados dos satélites Ikonos-II e Landsat/ETM+ no estudo de áreas cafeeiras. **Pesquisa Agropecuária Brasileira**, v.41, n.4, p.661-666, 2010.
- ROCHA, J.V. Crop monitoring in South America (MERCOSUR + Bolivia). Bulletin no. 7/2006 (August, 2006). **Ispra**, Italy: JRC (Joint Research Centre), 2006.
- RUDORFF, B.F.T. et al. Imagens de satélite no mapeamento e estimativa de área de cana-de-açúcar em São Paulo: ano-safra 2003/04. **Agricultura em São Paulo**, v.52, n.1, p.21-39, 2005.
- SOLIE, J.B. *et al.* Real-time sensing and N fertilization with a field scale GreenSeeker applicator. In: 7th **International Conference on Precision Agriculture**, 2002.
- SPRING. **Manuais: Tutorial de Geoprocessamento**, 2006. Disponível em: <<http://www.dpi.inpe.br/spring/portugues/tutorial/classific.html>>. Acesso em: 10 Nov. de 2019.
- SPRING. **Teoria: Processamento de imagens**, 2006. Disponível em: <<http://www.dpi.inpe.br/spring/teoria/realce/realce.htm>>. Acesso em: 10 Nov. de 2019.
- STOLF, R; GARCIA, T. B.; NERIS, L. O.; TRINDADE JUNIOR, O.; REICHARDT, K. Avaliação de falhas em cana de açúcar segundo o método de Stolf utilizando imagens aéreas de alta precisão obtidas por VANT. **STAB – Março/Abril 2016**, v. 34, n. 4.
- STOLF, R. Metodologia de avaliação de falhas nas linhas de cana de açúcar. **STAB. Açúcar, Alcool e Subprodutos**, Piracicaba, v. 4, n. 6, p. 22-36, 1986.

STOLF, R. Teoria e teste experimental de fórmulas de transformação dos dados de penetrômetro de impacto em resistência do solo. *Revista Brasileira de Ciência do Solo*, Campinas, v.15, p.229-235, 1991.

TAFNER, M. A; XEREZ, M; RODRIGUES, I. W. F. *Redes Neurais Artificiais: introdução e princípios de neurocomputação*. Blumenau. Editora da FURB, 1995.

USP. *Análise de Regressão: Notas de Aula*. USP, sd.

VANTAGE. **Falhas De Plantio e o Processamento de Imagens**, 2019. Disponível em: <<https://www.geoagri.com.br/blog/agricultura-de-precisao/falhas-de-plantio-e-o-processamento-de-imagens>> Acesso em: 04 de Nov. 2019.

VENTURA, M. V. A.; LIMA, A, T, A.; CHAGAS, J. F. R.; COSTA, M. E.; ARANTES, B. T.; SANTOS, G. dos. Efeito de fungicidas em castanhas de caju comum e anão no sul de Tocantins. In: SEMANA AGRONÔMICA, 8., 2018, Goianésia. **Anais...** Goianésia: Faculdade Evangélica de Goianésia, 2018. 1 CD-ROM.

VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. 2000. 323 f. Thesis (Ph. D.) – University of Nottingham, Nottingham, 2000.

WIEGAND, G.L.; RICHARDSON, A.J.; ESCOBAR, D.E. Vegetation indices in crop assessment. **Remote Sensing of Environment**, v.35, n.2, p.105-119, 1991.