



Identificação do modo de colheita da cana-de-açúcar em imagens multitemporais landsat-like

Identification of sugarcane harvest in multi-temporal Landsat-like images

*Bruna Aparecida Silva Dias*¹

*Bruno Schultz*²

*Ieda Del'Arco Sanches*²

*Isaque Daniel Eberhardt*³

*Jussara dos Santos Rosendo*¹

Recebido em agosto de 2017.

Aprovado em abril de 2018.

RESUMO

O Brasil é o principal produtor mundial da cana-de-açúcar, no entanto, um ponto crítico na produção dessa cultura é a prática da queima para facilitar a colheita manual, que resulta em impactos ambientais, sociais e econômicos. Visando conhecer e minimizar estes impactos, o uso de sensoriamento remoto é bastante indicado para o monitoramento da cana-de-açúcar, incluindo a identificação do modo de colheita. Nesse contexto, o presente trabalho teve como objetivo mapear e identificar o modo de colheita da cana-de-açúcar na mesorregião do Triângulo Mineiro e Alto Paranaíba (TM), em Minas Gerais, durante um período de sete meses (abril a outubro de 2015) empregando imagens multitemporais. Os seguintes passos foram adotados: 1) mapeamento das áreas cultivadas com cana-de-açúcar; 2) identificação da época de colheita da cana; e 3) do modo de colheita (corte mecanizado ou com emprego do fogo). A metodologia consistiu na utilização de imagens multitemporais dos sensores OLI/Landast-8, ETM+/Landsat-7 e AWiFS/ResourceSat-2 na composição colorida RGB NIR-SWIR-Red. As técnicas de pré-processamento adotadas incluíram correção geométrica (AWiFS), preenchimento de falhas (ETM+) e normalização por Aparência Equalizada (todas as imagens). Foram gerados dois mapas de cana-de-açúcar por classificação automática utilizando os classificadores J48 e Random Forest (RF). Uma referência de campo foi obtida com base nos dados do mapeamento de cana de 2013 do INPE, os quais foram atualizados para o ano 2015 por um intérprete experiente.

¹Universidade Federal de Uberlândia-UFU, Programa de Pós-graduação em Geografia do Pontal, Ituiutaba, Brasil. E-mail: brunadiasgeo@gmail.com; jussara.rosendo@ufu.br

²Instituto Nacional de Pesquisas Espaciais-INPE, Divisão de Sensoriamento Remoto (DSR), São José dos Campos, Brasil. E-mail: ieda.sanches@inpe.br, schultz@dsr.inpe.br

³Universidade de Brasília-UNB, Programa de Pós-Graduação em Transportes, Brasília, Brasil. E-mail: isaquedanielre@hotmail.com

Essa referência serviu para validação dos mapas temáticos gerados. Comparando os dois métodos de classificação automáticos adotados, o melhor resultado de mapeamento de cana foi obtido com o RF. A análise do perfil espectro-temporal dos talhões de cana-de-açúcar em imagens Landsat-like permitiu identificar com eficiência o período e modo de colheita dessa cultura. Os resultados obtidos mostram que em 2015, no TM, os meses de maior intensificação da colheita da cana foram setembro e outubro, sendo que, 75,13% da área total destinada ao cultivo da cana-de-açúcar foi colhido por meio do sistema mecanizado e 24,87% utilizaram o uso da queima na pré-colheita.

PALAVRAS-CHAVE: Classificação automática. Composição colorida RGB NIR-SWIR-Red, Cana crua. Cana queimada.

ABSTRACT

Brazil is the world's leading producer of sugarcane, however, a critical point in the production of this culture is the practice of burning to facilitate manual harvest, resulting in environmental, social and economic impacts. Aiming to know and minimize these impacts, the use of remote sensing is well suited for monitoring of sugarcane, including the identification of the harvest mode. In this context, this study aimed to map and identify the crop to the sugarcane in the middle region of Triângulo Mineiro and Alto Paranaíba (TM) for a period of seven months (April-October 2015) using Landsat sensor images -like (sensors with characteristics similar to the Landsat series). The steps of this work were: 1) map the sugarcane fields; detect 2) the time of the sugarcane harvest; 3) and the type of harvest (with or without pre-harvest burning). The methodology consisted in the use of multi-temporal images of OLI/ Landsat-8, ETM+ / Landsat-7 and AwiFIS / ResourceSat-2 in NIR-SWIR-Red RGB color composition. The adopted preprocessing techniques included geometric correction (AwiFS), gap filling (ET +) and a normalization procedure (Appearance Equalized - ApEq). Two maps of sugarcane were generated by automatic classification using J48 and Random Forest (RF) classifiers. A field reference was obtained based on the 2013 sugarcane mapping data from INPE, which have been updated for 2015 by an experienced interpreter. This reference was used to validate the thematic maps generated. Comparing the two automatic classification methods tested, the best cane mapping result was obtained with RF. The analysis of the spectrum-temporal profile of the sugarcane fields in Landsat-like images allowed to identify with efficiency the period and mode of harvest of this culture. The results show that the months of greatest intensification of harvest were September and October, being that 75.13% of the total area cultivated with sugarcane was harvested using the mechanized system and 24.87% adopted the pre-harvest burning.

KEYWORDS: Automatic classification. RGB NIR-SWIR-Red composition. Green harvest sugarcane. Pre harvest burning sugarcane.

* *

Introdução

A cana-de-açúcar representa 17,37% da área plantada com agricultura do estado de Minas Gerais (MG), com participação de 9,5% da produção nacional. A cadeia produtiva e econômica dessa cultura é responsável por 15,5% do PIB agrícola do estado (AGÊNCIA MINAS, 2016). A mesorregião do Triângulo Mineiro e Alto Paranaíba (TM) é, entre as 12 mesorregiões do estado, a maior produtora de cana-de-açúcar em MG; em 2015, a área plantada foi de 632.163 hectares (ha) (IBGE, 2015). No TM, o plantio de cana-de-açúcar teve um incremento de 608% no período compreendido entre 1990 e 2015 (IBGE, 2015). Tais dados demonstram a necessidade de acompanhamento periódico dessa cultura e do seu modo de colheita por meio do corte mecanizado da cana crua ou manual após queimada na região.

Para monitorar a área ocupada com culturas agrícolas, podem ser empregados métodos subjetivos (e.g. dados obtidos de informantes qualificados) ou objetivos (e.g. estatística amostral probabilística). No Brasil, as estatísticas agrícolas oficiais são geradas pelo Instituto Brasileiro de Geografia e Estatística (IBGE), de forma subjetiva. Apesar de ser um dado de suma importância e de grande utilidade, a metodologia não permite que um erro seja associado ao dado reportado. Dessa forma, existe a necessidade de desenvolver e aprimorar metodologias objetivas que sejam empregadas de forma rotineira e que sejam capazes de informar a área das culturas (e.g. cana-de-açúcar) em tempo quase real, apresentar o erro de mensuração e informar a localização espacial dos talhões em determinada região geográfica. Nesse contexto, o sensoriamento remoto tem muito a contribuir (RUDORFF et al., 2010; SCHULTZ et al., 2015; LUIZ et al., 2015).

O projeto CANASAT - Monitoramento da cana-de-açúcar via imagens de satélite (RUDORFF et al, 2010), desenvolvido no Instituto Nacional de Pesquisas Espaciais (INPE), mapeou as áreas de cana-de-açúcar da região centro-sul do Brasil nas safras 2003/2004 a 2013/2014 com base em interpretação visual de imagens de sensores orbitais. Outro dado importante

sobre a cana-de-açúcar obtido por imagens de sensoriamento remoto refere-se ao modo de colheita (crua ou queimada) (AGUIAR et al., 2008; 2011:). Tal informação também foi disponibilizada pelo CANASAT, para o estado de São Paulo, para as safras 2006/2007 a 2012/2013. Informações confiáveis sobre o modo de colheita da cana-de-açúcar foram obtidas por AGUIAR et al. (2011), com base em imagens de precipitação do *Tropical Rainfall* multitemporais de satélites Landsat-like, de *Measuring Mission* (TRMM) e de declividade do *Shuttle Radar Topography Mission* (SRTM).

Atualmente, alguns fatores contribuem para a adoção do sensoriamento remoto no monitoramento da cana-de-açúcar e seu modo de colheita, como a facilidade de obtenção de dados multissensores e o desenvolvimento de novos procedimentos de pré-processamento de dados. Dentre esses métodos, destaca-se o da Aparência Equalizada (ApEq), que tem por objetivo tornar o contraste semelhante entre imagens multissensores, e, assim, normalizar a cor dos alvos nessas imagens de diferentes fontes (SCHULTZ et al., 2016b). Essa técnica é essencial quando se deseja fazer a interpretação visual das imagens, pois a cor que cada alvo assume em determinada composição colorida contém informações sobre ele (SANCHES et al., 2005). Além disso, a ApEq mostra-se atrativa para o desenvolvimento de um sistema rotineiro para identificação automática de áreas com cana-de-açúcar e do modo de sua colheita (SCHULTZ et al., 2016).

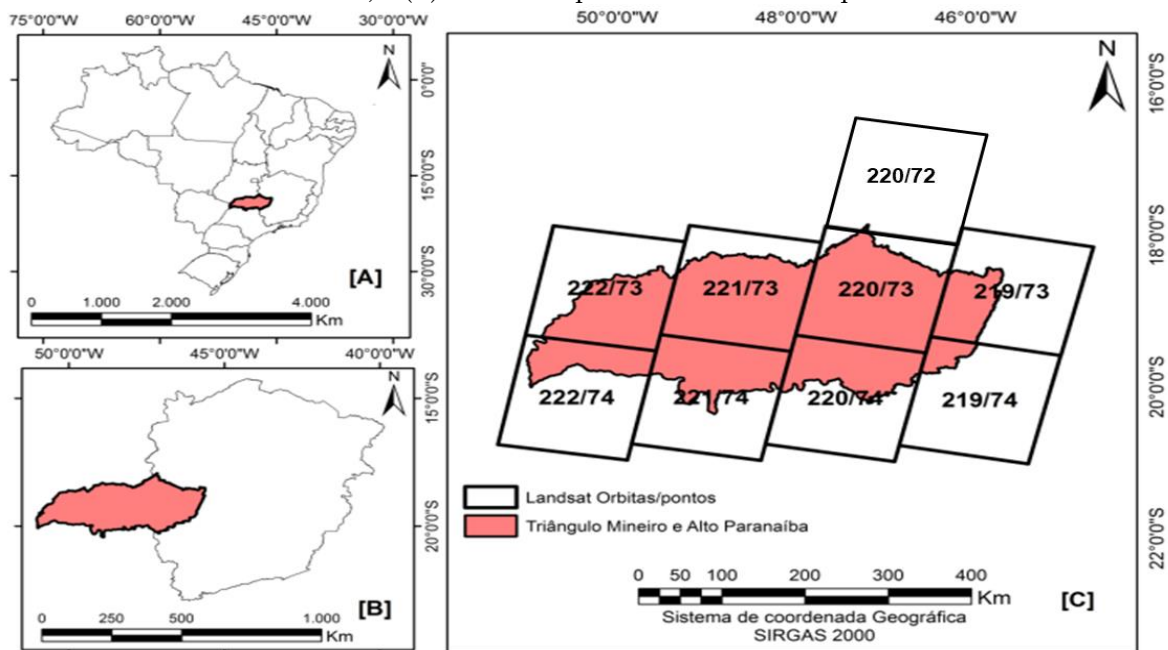
Nesse contexto, o presente trabalho tem como objetivo mapear e identificar o modo de colheita da cana-de-açúcar na mesorregião do Triângulo Mineiro e Alto Paranaíba (TM) durante um período de sete meses (abril a outubro de 2015) empregando imagens multitemporais. Para concluir tal objetivo, as seguintes etapas foram definidas: (a) mapear as áreas de cana-de-açúcar da área de estudo; (b) identificar o período da colheita dos talhões mapeados; e (c) identificar o modo da colheita aplicado sobre os talhões (crua ou queimada).

2 Materiais e Métodos

2.1 Área de estudo e cultivo da cana-de-açúcar

A mesorregião do Triângulo Mineiro e Alto Paranaíba (TM) localiza-se aproximadamente entre os paralelos $17^{\circ} 55' 12''$ e $20^{\circ} 41' 30''$ S Equador e os meridianos $45^{\circ} 33' 30''$ e $51^{\circ} 02' 18''$ W Greenwich, a oeste do estado de Minas Geras, região Sudeste do Brasil, e possui uma área territorial de 9.054.005 ha. A localização geográfica da área de estudo é mostrada na Figura 1:

Figura 1 – Localização do Triângulo Mineiro e Alto Paranaíba no mapa (A) do Brasil e (B) do estado de Minas Gerais, e (C) as órbitas/pontos do Landsat-8 que recobrem a área.

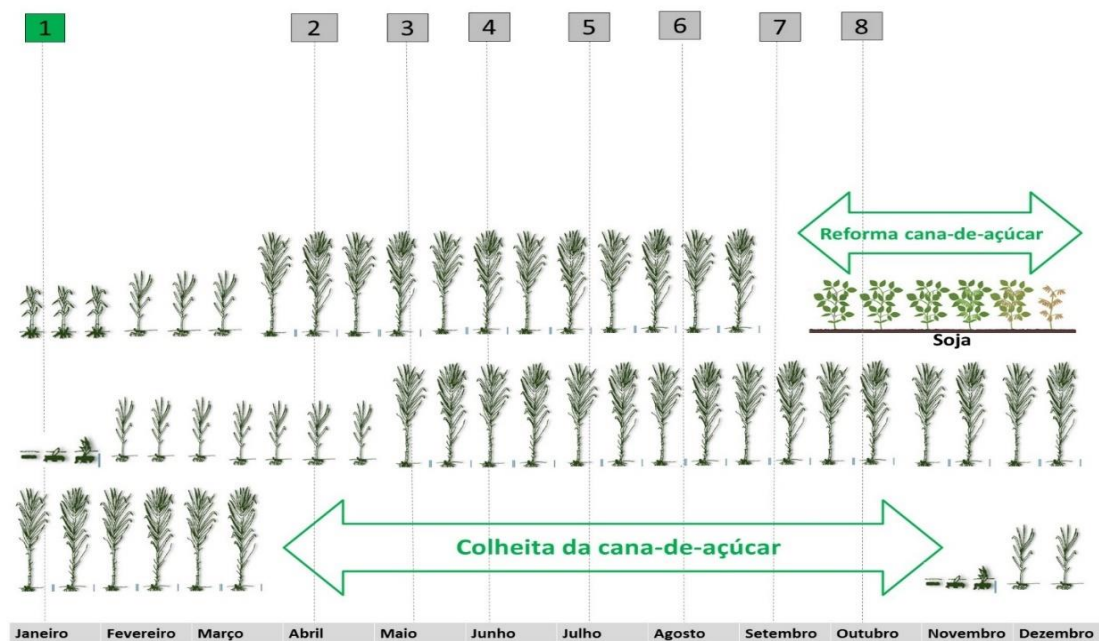


Fonte: INPE, IBGE (2016).

De acordo com o IBGE (2015), as principais culturas agrícolas plantadas na mesorregião do TM são a soja (715.796 mil ha), a cana-de-açúcar (632.163 mil ha) e o milho (411.412 mil ha). Na área de pesquisa, a cana-de-açúcar é normalmente plantada em novembro e colhida nos meses de abril a outubro. O sistema de manejo adotado no processo de colheita é realizado mecanicamente (cana crua) ou por meio da queimada (cana queimada). Após cinco a sete sucessivas colheitas (socas), o talhão de cana-de-açúcar é

reformado com culturas leguminosas (e.g. soja e amendoim) e subsequentemente renovado com um novo plantio de cana, na área de estudo, isso ocorre frequentemente nos meses de setembro a novembro. A Figura 2 ilustra didaticamente alguns exemplos de períodos com colheita e renovação observados nos talhões de cana-de-açúcar. Em alguns casos, ocorre o adiamento da colheita da cana que permanece no solo até a próxima safra (cana bisada).

Figura 2 – Esquema ilustrando diferentes ciclos de colheita e renovação da cana-de-açúcar. Os números de 1 a 8 representam os meses dos mosaicos multisensores usados no presente estudo.



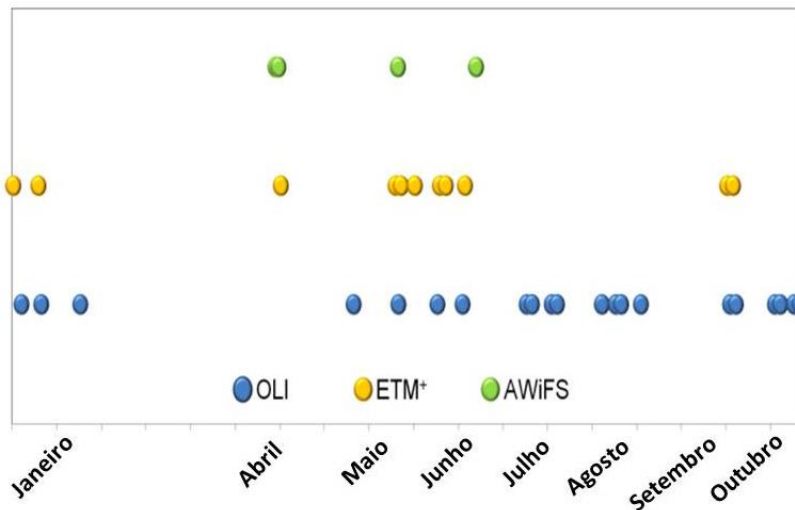
Fonte: elaborada pelos autores.

2.2 Imagens de sensoriamento remoto

As imagens utilizadas no presente estudo foram adquiridas do catálogo do INPE (Resourcesat-2) e do site do Serviço Geológico dos Estados Unidos (USGS) (Landsat-7 e -8). As datas das imagens utilizadas compreenderam o período de colheita da cana-de-açúcar na mesorregião do TM (abril a outubro de 2015), conforme demonstra a Figura 3. Além disso, imagens de janeiro de

2015 foram usadas no processamento dos dados e confecção da referência (ver tópicos 3.4 e 3.5).

Figura 3- Data de passagem das imagens multitemporais adquiridas no trabalho. Foram usadas 37 imagens OLI/Landsat-8, 17 ETM+/Landsat-7 e 10 AWiFS/ResourceSat-2.



Fonte: elaborada pelos autores.

É importante ressaltar que primeiramente, foi feita uma busca por imagens do sensor *Operational Land Imager* (OLI) do Landsat-8 livre de nuvens em nível 1 de processamento (reflectância da superfície). Para aquelas imagens com mais de 10% de nuvem, foram alternativamente baixadas imagens do sensor *Enhanced Thematic Mapper Plus* (ETM+) do Landsat-7. Num terceiro momento, para as datas que ainda não tinham imagens livres de nuvens, foram baixadas imagens do sensor *Advanced Wide Field Sensor* (AWiFS) do ResourceSat-2 (Tabela 1).

Tabela 1 – Características básicas dos sensores *Operational Land Imager* (OLI/Landsat-8), *Enhanced Thematic Mapper Plus* (ETM+/Landsat-7) e *Advanced Wide Field Sensor* (AWiFS/ResourcSat-2).

Descrição do sensor	OLI	ETM ⁺	AWiFS
Nome do sensor	<i>Operational Land Imager</i>	<i>Enhanced Thematic Mapper Plus</i>	<i>Advanced Wide Field Sensor</i>
Passagem no equador	± 11:00	± 10:10	± 10:30
Resolução radiométrica (bits)	16	8	12
Resolução espacial (m)	30	30	56
Bandas espectrais (nm)			
Red	0,63-0,68	0,63-0,69	0,62-0,68
NIR (Infravermelho)	0,85-0,89	0,76-0,90	0,77-0,86
SWIR (Infravermelho de ondas curtas)	1,56-1,66	1,55-1,75	1,55-1,70

Fonte: INPE (2016).

2.3 Pré-processamento dos dados de sensoriamento remoto

Como a cana-de-açúcar possui uma janela de colheita muito larga (abril a outubro) optou-se pela obtenção de mosaicos mensais da área de estudo. Dessa forma, o pré-processamento dos dados consistiu na obtenção de mosaicos equalizados, com 30 m de resolução espacial e com menor cobertura de nuvem no período de um mês.

Para isso, cinco passos de pré-processamento foram executados: (i) correção geométrica; (ii) preenchimento das falhas das imagens ETM⁺; (iii) reamostragem da resolução espacial para 30 m; (iv) detecção de nuvens; e (v) normalização das imagens por meio da aplicação da aparência equalizada (ApEq). Ao todo, oito mosaicos foram confeccionados: (1) janeiro, (2) abril, (3) maio, (4) junho, (5) julho, (6) agosto, (7) setembro e (8) outubro de 2015, todos em composição colorida falsa cor RGB NIR-SWIR-Red (Figura 4).

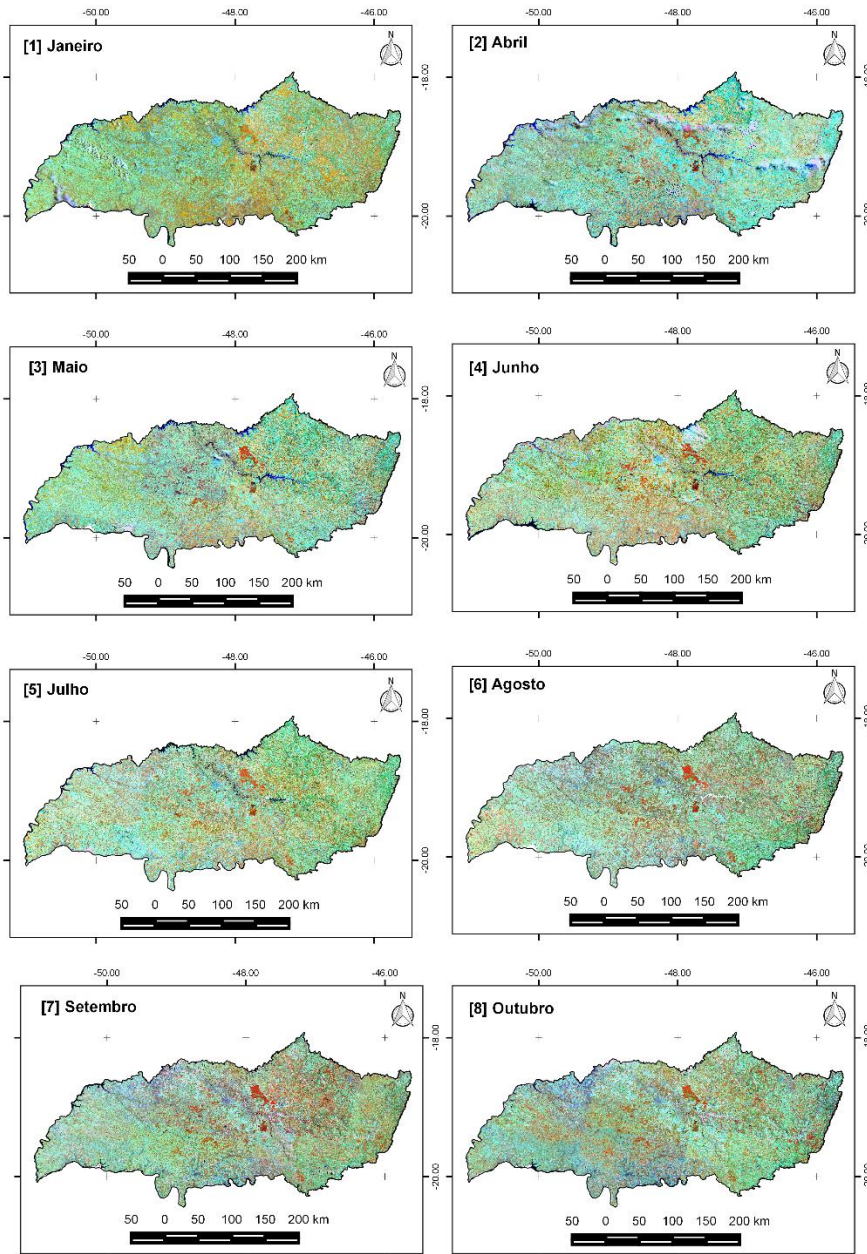
(i) A correção geométrica foi aplicada nas imagens AWiFS usando os dados Landsat do GLS- *Global Land Survey* (GUTMAN et al., 2013). O erro de tolerância adotado no processo foi de 40 m. As imagens Landsat-7 e -8 foram adquiridas já com correção geométrica.

(ii) O preenchimento das falhas (gaps) das linhas das imagens do sensor ETM+ foi corrigido usando filtro passa baixa, como sugerido por Schultz et al. (2016b) em script Phyton.

(iii) A reamostragem das imagens AWiFS de 56 m para 30 m foi realizada pelo algoritmo cubic B-spline (PARKER, 1983). Esse procedimento foi necessário para deixar todas as imagens na mesma resolução espacial. As imagens LISS-3/ResorceSat-2 não foram usadas no presente estudo devido à indisponibilidade das imagens para área estudada;

(iv) Para a detecção de nuvens das imagens AwiFS, foi utilizado o *cloud-detection* tool desenvolvido por Abreu et al. (2013). Para as imagens OLI e ETM+, o produto *cf_mask* foi utilizado.

Figura 4- Mosaicos em composição colorida falsa cor RGB NIR-SWIR-Red no período de colheita da cana-de-açúcar (abril a outubro) e o mês de janeiro utilizado para atualização da referência e processamento.



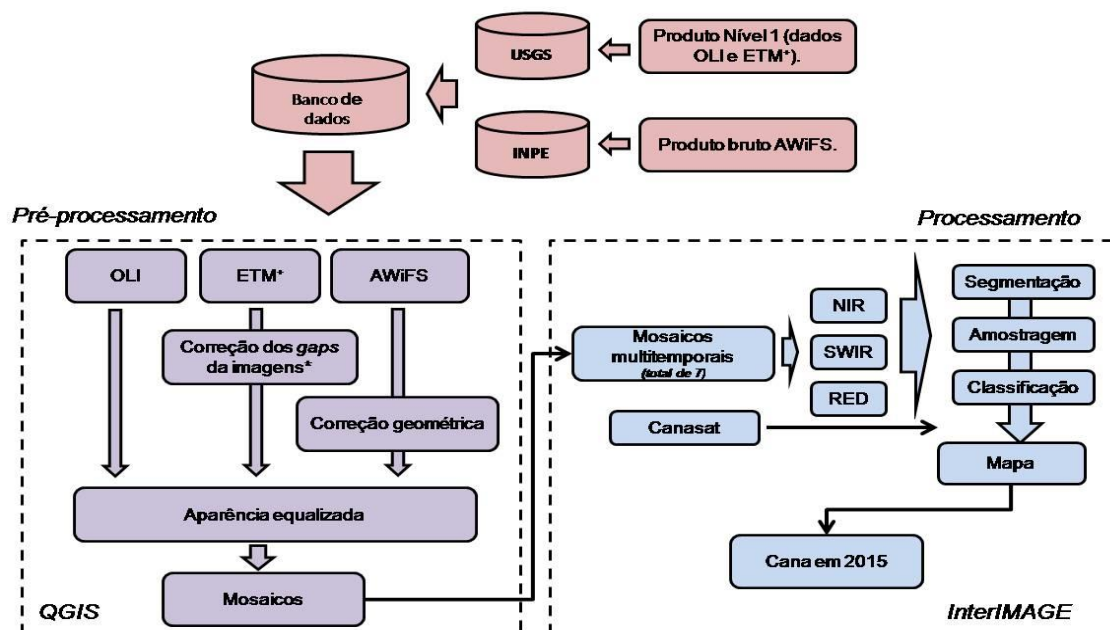
Fonte: elaborada pelos autores.

(v) Após todas as imagens estarem com a mesma resolução espacial, a imagem 221/074 do mês de abril do sensor OLI foi escolhida como imagem base (IB) para aplicação da ApEq e as demais foram consideradas imagens de conversão (IC). Pela ApEq, a cor das imagens em composição colorida RGB

NIR-SWIR-Red foi normalizada com base nos pixels de floresta. Após o processo de equalização pela ApEq, todas as imagens foram salvas em 8 bits (256 níveis de cinza).

A Figura 5 ilustra o fluxograma das atividades desenvolvidas no pré-processamento dos mosaicos multitemporais e multissensores. Além do pré-processamento, é possível observar os passos seguintes executados como processamento e obtenção de resultados.

Figura 5 – Fluxograma da metodologia aplicada no desenvolvimento do trabalho.



Fonte: elaborada pelos autores.

2.4 Processamento dos dados de sensoriamento remoto

As imagens foram equalizadas e depois foi criado um mosaico que cobriu toda área de estudo (Figura 4). Em seguida, os dados espectrais das bandas do NIR, SWIR e Red dos mosaicos 1, 2, 3, 4, 5, 6, 7 e 8 foram inseridos no programa *Ecognition* e os parâmetros de segmentação foram definidos seguindo as recomendações de Schultz et al. (2016). As imagens foram segmentadas levando em consideração o mesmo peso (p) para as três bandas

($p = 1$) e os atributos (28 no total) foram extraídos. Os atributos médios das bandas ($n = 3$) de cada data de imagem ($n = 7 \times 3$) e o NDVI de cada uma das datas ($n = 7$) foram selecionados.

Foram utilizadas 1.000 amostras de cana-de-açúcar (classe cana) e 3.000 amostras de outros alvos (classe outros) para treinamento dos modelos de classificação. Essas amostras (segmentos) foram obtidas do processo de segmentação e usadas para treinar os algoritmos J48 e RF. O número de 4.000 segmentos foi definido como aceitável para realizar o trabalho de interpretação visual em um espaço de tempo razoável.

Os modelos de classificação e a identificação final dos segmentos foram gerados no programa WEKA (BOUCKAERT, 2010). No WEKA, para o algoritmo RF foram definidos dois parâmetros de entrada dos dados: número de árvores ($n = 250$) e número de elementos de entrada (28 atributos). Para o algoritmo J48 foram definidos 28 elementos de entrada e a amostra foi dividida e testada 10 vezes. Esses valores foram definidos conforme Schultz et al. (2015) e Peña et al. (2014). Por fim, foram gerados dois mapas temáticos:

- a) RF_mapa_cana_2015;
- b) J48_mapa_cana_2015.

O modo de colheita da cana-de-açúcar foi definido como cana crua ou cana queimada e avaliado no programa QGIS. Essas duas variáveis foram analisadas quanto aos valores resultantes das médias das bandas NIR, SWIR e Red dos segmentos classificados como cana-de-açúcar. Os valores médios dos segmentos foram extraídos para cada uma das três bandas no programa Ecognition em formato matricial TIFF. Foram montados três diferentes *rasters* virtuais no QGIS com sete TIFs: (b) abril, (c) maio, (d) junho, (e) julho, (f) agosto, (g) setembro e (h) outubro. O *plugin Spectral Profile* desenvolvido (por QGIS, 2016) foi usado para observar a variação temporal do espectro de cada segmento de cana no tempo, isto é, no período de colheita da cana-de-açúcar na mesorregião do TM (de abril a outubro de 2015).

Para se avaliar o modo de colheita da cana-de-açúcar, foram observados os valores dos níveis digitais (NDs) (256 níveis) dos talhões no tempo (nos

mosaicos das imagens multitemporais equalizadas). Limiares de NDs foram definidos para cada banda, por análises a priori dos dados, baseado na interpretação visual das imagens em composição RGB NIR-SWIR-Red. As regras foram inseridas no programa R (VENABLES et al, 2016).

- a) NIR: Essa banda é mais sensível à reflectância da biomassa verde, e seus altos valores estão relacionados à presença de cana verde no talhão. Esses valores são superiores a 200 e obtidos quando a cana, está em período de vigor vegetativo (vegetação fotossinteticamente ativa absorve muita energia no Red e reflete muito no NIR);
- b) SWIR: Essa banda é mais sensível à quantidade de água nas plantas, e seus altos valores (superiores a 200) representam a colheita com cana crua (vegetação seca – palhada – absorve pouco no Red e reflete muito no SWIR);
- c) Red: Essa banda é mais sensível à exposição do solo descoberto, e seus altos valores (superiores a 200) representam a colheita com queima (solo exposto com presença de cinzas).

2.5 Validação do mapa temático e do modo de colheita

Para a validação dos mapas temáticos, foi elaborado um mapa de referência pela atualização dos vetores de cana-de-açúcar de um mapeamento realizado em 2013 e disponibilizado pelo projeto CANASAT (INPE). Os mapas do CANASAT foram validados de acordo com metodologia proposta por Adami et al. (2012). Esse dado em formato de vetor foi atualizado por intérprete treinado em classificação de cana-de-açúcar em dados multitemporais. O intérprete classificou a área ocupada com cana-de-açúcar em pleno vigor vegetativo em janeiro de 2015 (Mosaico 1), tendo como base o mapeamento dos talhões de cana-de-açúcar de 2013, no qual foram adicionadas as áreas de expansão da cana.

Os mapas produzidos pela classificação automática dos modelos J48 e RF foram comparados com o mapa de referência. O resultado foi obtido pixel-a-pixel (30 m) por matriz de confusão conforme Mello et al. (2010). A exatidão global e índice Kappa foram as estatísticas obtidas pela comparação entre os dados (CONGALTON, 1991). Além disso, os erros cometidos entre a sobreposição dos dados de referência e classificados (RF e J48) foram computados em número de pixels e avaliados em quadrículas de 15 x 15 km conforme Torbick et al. (2016). Essas quadrículas tiveram como objetivo mostrar a fração de erro cometido por cada um dos classificadores avaliados.

O modo de colheita da cana-de-açúcar foi avaliado com base em dados de interpretação visual de imagens e em dados coletados em trabalho de campo realizado nos dias 9 e 10 de setembro de 2015, em vários municípios da mesorregião do TM (e.g. Uberlândia, Uberaba, Delta, Ituiutaba, Canápolis, Capinópolis e Conquista, MG). Foram obtidos pontos com a localização espacial (lat/long) dos talhões de cana crua (20) e cana queimada (20). Foram gerados mais 100 pontos pela classificação visual: cana crua (59) e cana queimada (41) no mosaico (7), correspondente ao mês de setembro/2015, totalizando 60 amostras para cada modo de colheita. A avaliação do resultado foi também realizada por matriz de confusão, formada entre os dados automaticamente classificados e os dados de referência.

3 Resultados e discussão

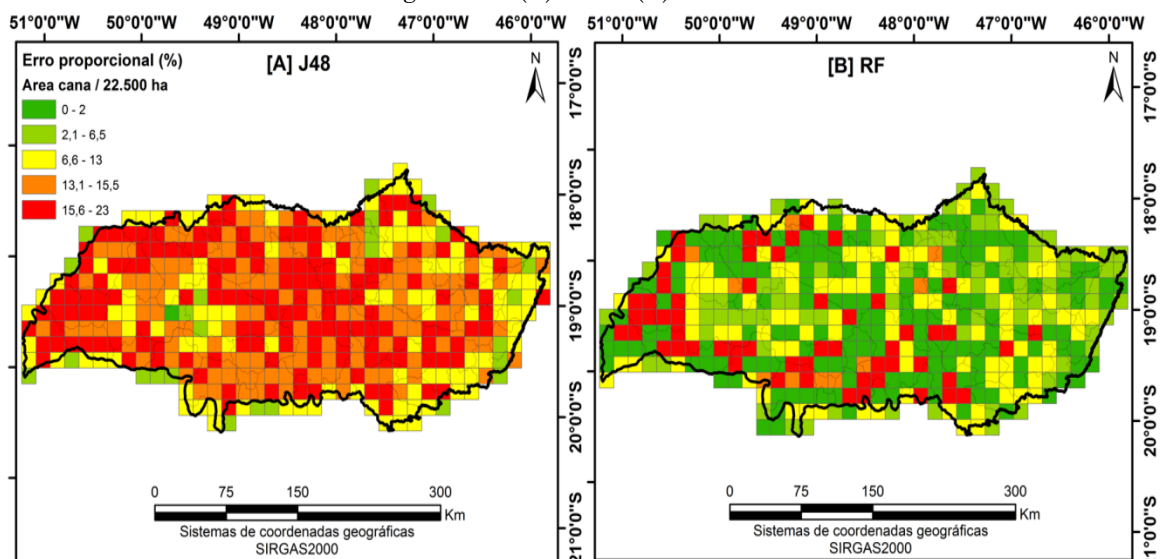
Os resultados foram apresentados das seguintes formas:

- a) Resultados dos mapeamentos da cana-de-açúcar no TM gerados pelos dois modelos de classificação automática (J48 e RF);
- b) Avaliação do perfil espectro-temporal dos talhões de cana para se identificar o modo de colheita dessa cultura (crua ou queimada);
- c) Identificação do modo e do mês de colheita da cana-de-açúcar na mesorregião do TM.

3.1 Avaliação dos mapas temáticos de cana

A Figura 6 ilustra a proporção (%) de área erroneamente classificada pelo algoritmo J48 (A) e RF (B) por quadrícula (15 x 15 km). Sua análise permite verificar maior presença de quadrículas em vermelho e laranja na Figura 6A (J48) se comparada à Figura 6B (RF). Isso significa que o modelo RF teve melhor desempenho na classificação das áreas de cana-de-açúcar em comparação ao J48. Isso pode ter ocorrido por não existir uma seleção, a priori, de atributos utilizados na formação do modelo de conhecimento do classificador. O sobreajuste causado pela presença de muitos atributos pode resultar na diminuição da taxa de acerto de algoritmos como o J48. O mesmo pode acontecer com o RF, no entanto, no RF mais de uma árvore de decisão é treinada com os dados de treinamento, fato que dilui a probabilidade de seleção de dados ruidosos (SCHULTZ et al., 2016) e, assim, segundo Immitzer et al. (2016), melhora o resultado da classificação final.

Figura 6- Mapa de Erro Proporcional das classificações automáticas geradas pelos algoritmos (A) J48 e (B) RF.



Fonte: elaborada pelos autores.

A diferença do classificador utilizado (RF ou J48) para identificação do modo de colheita da cana pode resultar em uma divergência de 76 mil ha em erros de classificação. O erro é maior para o J48 (erro: 69 mil ha) e menor para RF (erro = 23 mil ha).

Os resultados de Índice Kappa, Exatidão Global e erros de inclusão e omissão resultantes para cada modelo de classificação são apresentados na Tabela 2. Na análise da exatidão dos resultados, verificou-se que o modelo de classificação RF alcançou os melhores resultados, com o Índice Kappa de 0,82 e Exatidão Global de 0,97 quando comparado ao modelo J48, com Índice Kappa 0,60 e Exatidão Global 0,91.

Tabela 2 – Matrizes de confusão geradas pela comparação pixel-a-pixel entre os dados de referência e os classificados pelos modelos de classificação automática J48 e RF.

Valores em Ha	Referência			Exatidão do Usuário	Erro de inclusão	
	Cana-de-açúcar (ha)	Outros (ha)	Soma (ha)			
J48	Cana-de-açúcar	699.652	747.771	1.447.423	48,34	51,66
	Outros	22.347	7.584.235	7.606.582	99,71	0,29
	Soma	721.990	8.332.006	9.054.005		
Exatidão do Produtor	96,91	91,03				
Erro de omissão	3,09	8,97				

Índice Kappa = 0,60 e Exatidão Global = 0,91

Valores em Ha	Referência			Exatidão do Usuário	Erro de inclusão	
	Cana-de-açúcar (ha)	Outros (ha)	Soma (ha)			
RF	Cana-de-açúcar	639.422	172.567	811.990	78,75	21,25
	Outros	82.576	8.159.439	8.242.015	99,00	1,00
	Soma	721.990	8.332.006	9.054.005		
Exatidão do Produtor	88,56	97,93				
Erro de omissão	11,44	2,07				

Índice Kappa = 0,82 e Exatidão Global = 0,97.

Fonte: elaborada pelos autores.

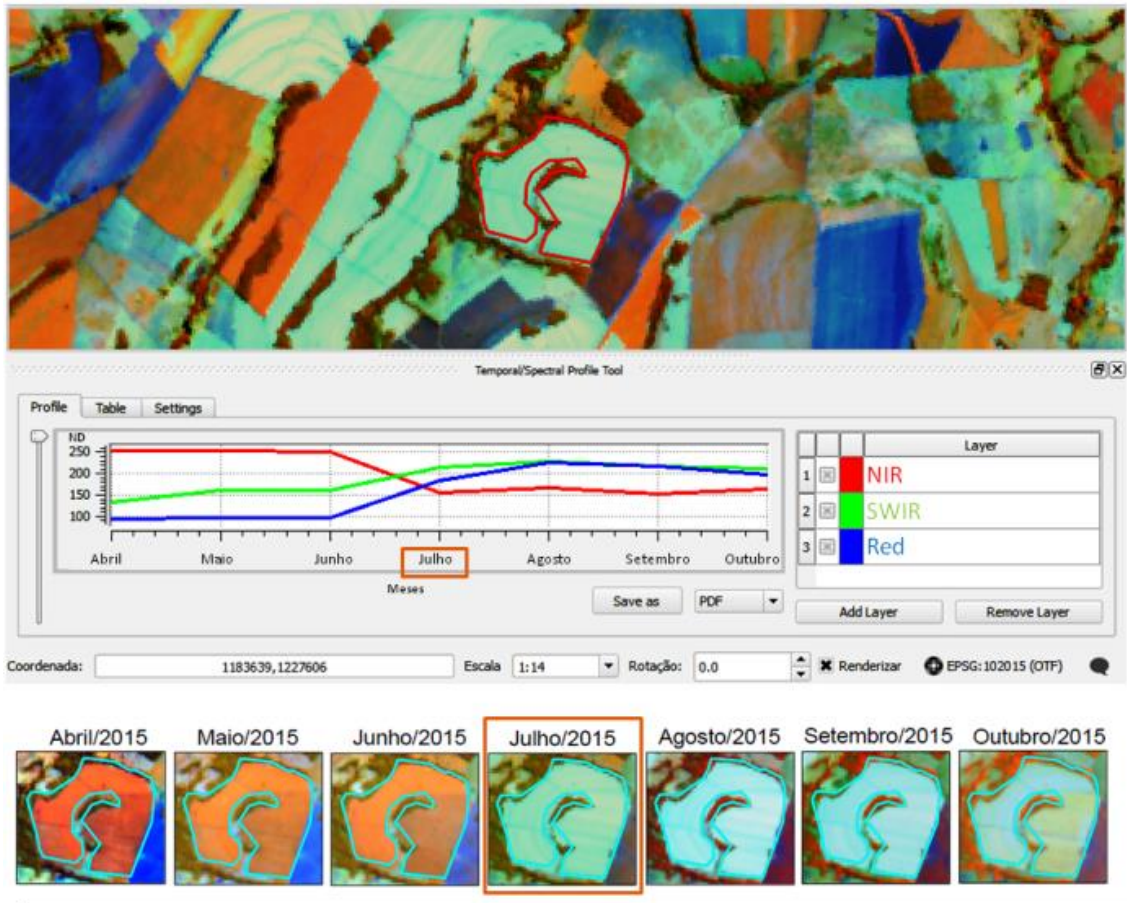
O melhor desempenho do RF é coerente com outras pesquisas (SCHULTZ, et al., 2016), no entanto, não descarta a possibilidade de uso do algoritmo J48 em futuros trabalhos, se uma seleção de atributos for aplicada anteriormente ao processo de classificação.

3.2 Avaliação do perfil espectro-temporal da cana-de-açúcar para identificação do modo de colheita dessa cultura

O perfil temporal dos talhões de cana-de-açúcar foi analisado de abril a outubro de 2015 com base nos espectros das três bandas que compuseram os mosaicos multissensores (Red, NIR e SWIR). A Figura 7 mostra um exemplo de padrão espectral de um pixel dentro de um talhão de cana-de-açúcar colhido com máquina (cana colhida crua); enquanto na Figura 8 é apresentado o padrão de um pixel dentro de um talhão colhido com pré-queima.

Figura 7 – Exemplo de talhão de cana-de-açúcar colhido com máquina: (A) Recortes de imagens Landsat-like na composição colorida RGB NIR-SWIR-Red, e (B) curvas médias dos valores de NDs, por banda, das imagens multitemporais em um pixel de 30 m localizado no interior do talhão. O mês quando ocorreu a colheita do talhão foi destacado com um retângulo laranja.

Cana-de-açúcar colhida crua



Fonte: elaborada pelos autores.

Esses exemplos são apresentados com a intenção de ilustrar, de forma geral, o que acontece em cada uma das bandas que foram utilizadas para formar os mosaicos (Red, NIR e SWIR), quando a cana é colhida com e sem queimada, tendo em vista que o comportamento desse alvo apresenta distinções nas imagens devido à data da colheita e ao modo de colheita (AGUIAR et al, 2009; MELLO et al., 2010). Portanto, o entendimento do que acontece em cada banda é importante para compreender a cor que os alvos assumem na composição escolhida (RGB NIR-SWIR-Red).

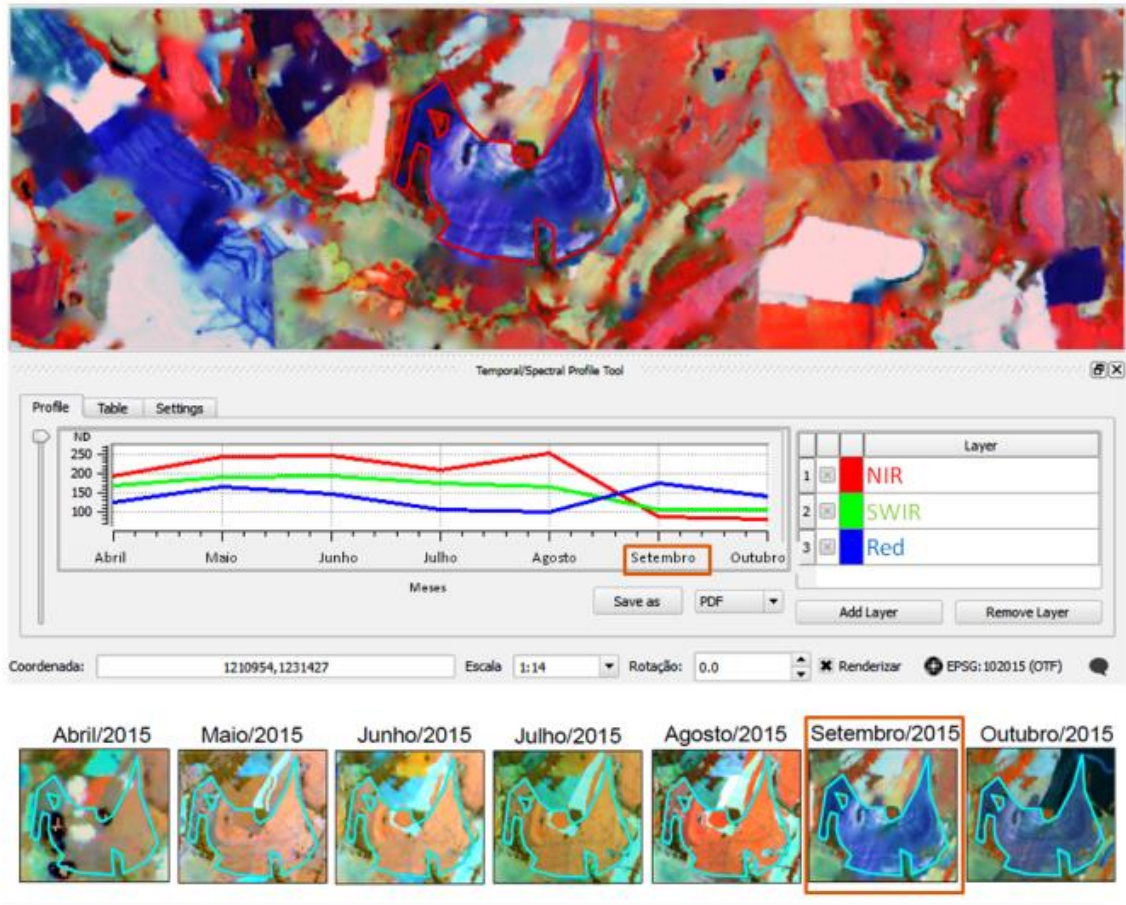
Um talhão de cana-de-açúcar antes da colheita se apresenta em tons de vermelho na composição RGB NIR-SWIR-Red (Figura 7 e 8), pois a vegetação fotossinteticamente ativa reflete bastante no NIR e absorve muito no Red.

Na Figura 7, observa-se que quando foi feita a colheita da cana, o valor de ND do NIR diminui consideravelmente e o do SWIR aumenta. Na faixa do SWIR, que é relacionada com o conteúdo de água nas células foliares (PONZONI e SHIMABUKURO, 2007), o aumento da reflectância está relacionado com a palhada (vegetação seca) deixada na superfície do talhão após a colheita mecanizada. A medida que a palha vai sendo degradada, os valores de ND do Red aumentam (devido a maior exposição do solo) e os do SWIR diminuem gradativamente.

No entanto, como a maior parte da palhada é queimada (Figura 8), o solo do talhão fica exposto após a cultura ser colhida e com presença das cinzas da queima da palhada, o que explica a cor azulada na composição RGB NIR-SWIR-Red, causada pela maior reflectância na banda do Red. Esse comportamento pode ser associado à presença de óxido de ferro presente no Latossolo (SANTANA E FILHO, 1978), que de acordo com Barbieri et al., (2013), há uma maior variabilidade espacial desse componente em áreas de cana queimada.

Figura 8 – Exemplo de talhão de cana-de-açúcar colhido com pré-queima: (A) Recortes de imagens Landsat-like na composição colorida RGB NIR-SWIR-Red, e (B) curvas médias dos valores de NDs, por banda, das imagens multitemporais em um pixel de 30 m localizado no interior do talhão. O mês quando ocorreu a colheita do talhão foi destacado com um retângulo laranja.

Cana-de-açúcar colhida com queima



Fonte: elaborada pelos autores.

A identificação do modo de colheita em campo, mediante os dados de referência (campo + criados via classificação visual), mostrou que apenas cinco pontos foram confundidos pelo modelo de classificação com base no perfil espectral, alcançando Índice Kappa e Exatidão Global de 0,92 e 0,96, respectivamente (Tabela 3). Isso mostra que a informação espectral das bandas do NIR SWIR e Red de mosaicos multitemporais de multissensores

Landsat-like apresenta ótima relação com o modo de colheita da cana-de-açúcar.

Tabela 3- Matriz de confusão para o mapa gerado pela análise do comportamento espectral-temporal da cana, o índice Kappa e Exatidão Global com base em 120 pontos de referência.

Valores em Ha		Referência			Exatidão do Usuário	Erro de inclusão
		Crua	Queimada	Total		
Modo de colheita	Crua	58	3	61	95,08	4,92
	Queimada	2	57	59	96,61	3,39
	Soma	60	60	120		
Exatidão do Produtor		96,67	95,00			
Erro de omissão		3,33	5,00			

Índice Kappa = 0,92 e Exatidão Global = 0,96.

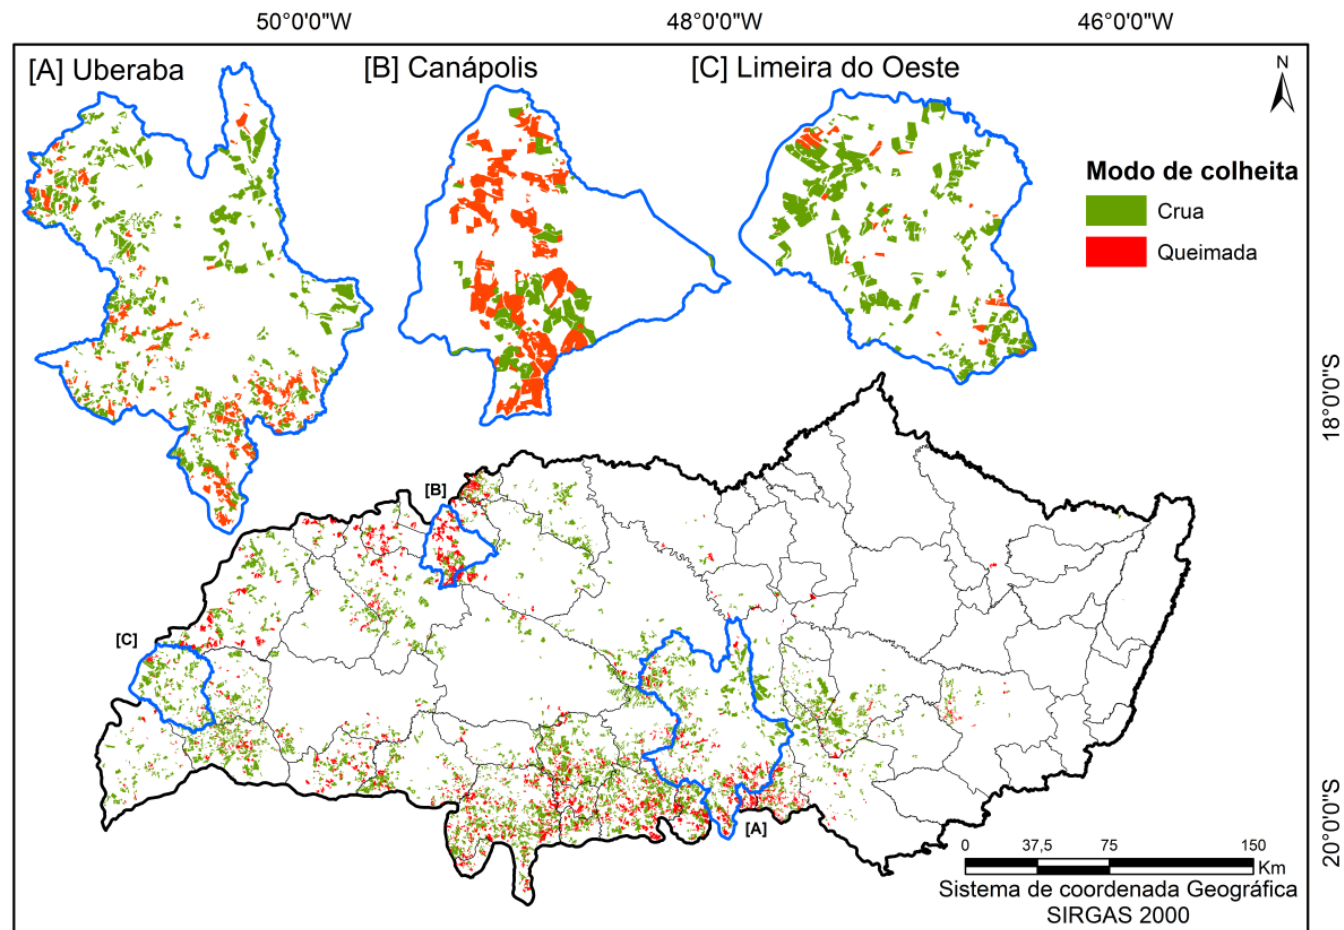
Fonte: elaborada pelo autor

O erro de inclusão foi de 4,92% para cana crua e de 3.39% para a cana queimada. Isso mostra que, em alguns casos, pode ser difícil separar os tipos de colheita com base apenas nas imagens. Isso ocorre porque algumas práticas culturais adotadas no campo podem confundir o intérprete no momento da identificação, como a adição de calcário no solo após a última colheita da cana, que na imagem pode apresentar reflectância semelhante à cana crua; outro exemplo é a queima da palha após a colheita da cana crua, tornando difícil a classificação, pois, quando utilizado, o método pode apresentar-se como crua e passados alguns dias ocorre a queima (AGUIAR et al, 2011).

3.3 Identificação do modo e do mês de colheita da cana-de-açúcar na mesorregião do TM

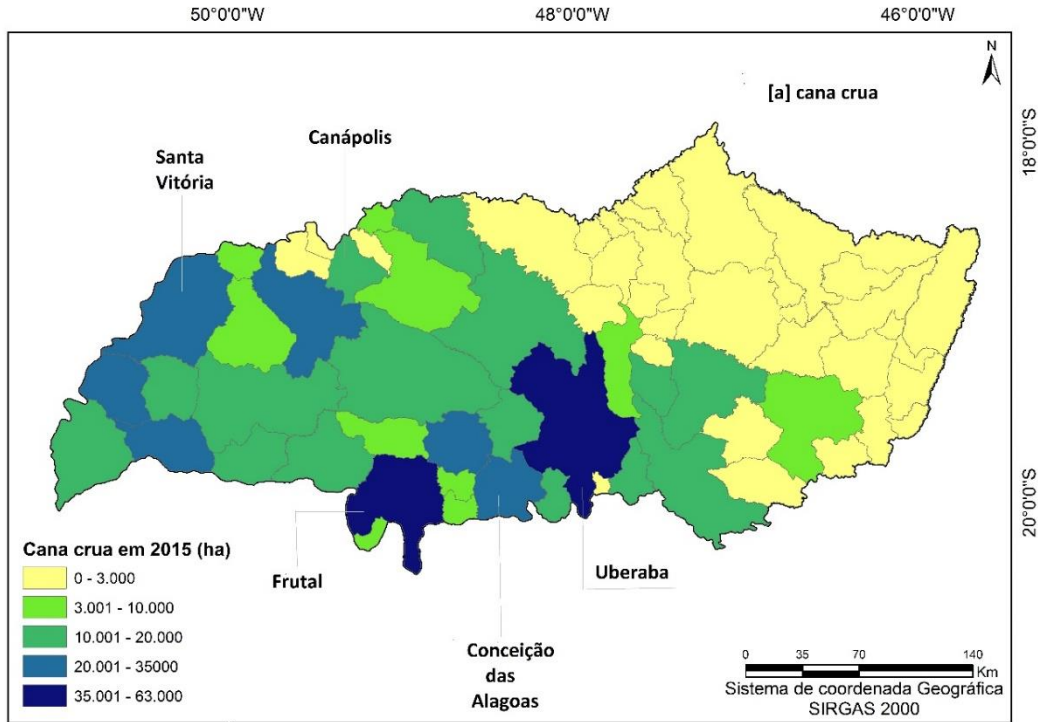
Dos 66 municípios que compõem a mesorregião do TM, 53 deles cultivam a cana com os dois modos de colheita (crua e queimada) (Figura 9). As áreas de cana-de-açúcar com colheita crua são espacializadas na Figura 10a e com queima na Figura 10b em cada município do TM, em 2015.

Figura 9- Mapa temático do modo de colheita (crua e queimada) da cana-de-açúcar na mesorregião do TM. Os municípios de (A) Uberaba, (B) Canápolis e (C) Limeira do Oeste ilustram: proporção similar entre talhões de cana-de-açúcar colhidos mecanicamente e queimada, maior proporção de cana colhida com pré-queima, e maior proporção de cana-de-açúcar colhida crua, respectivamente.



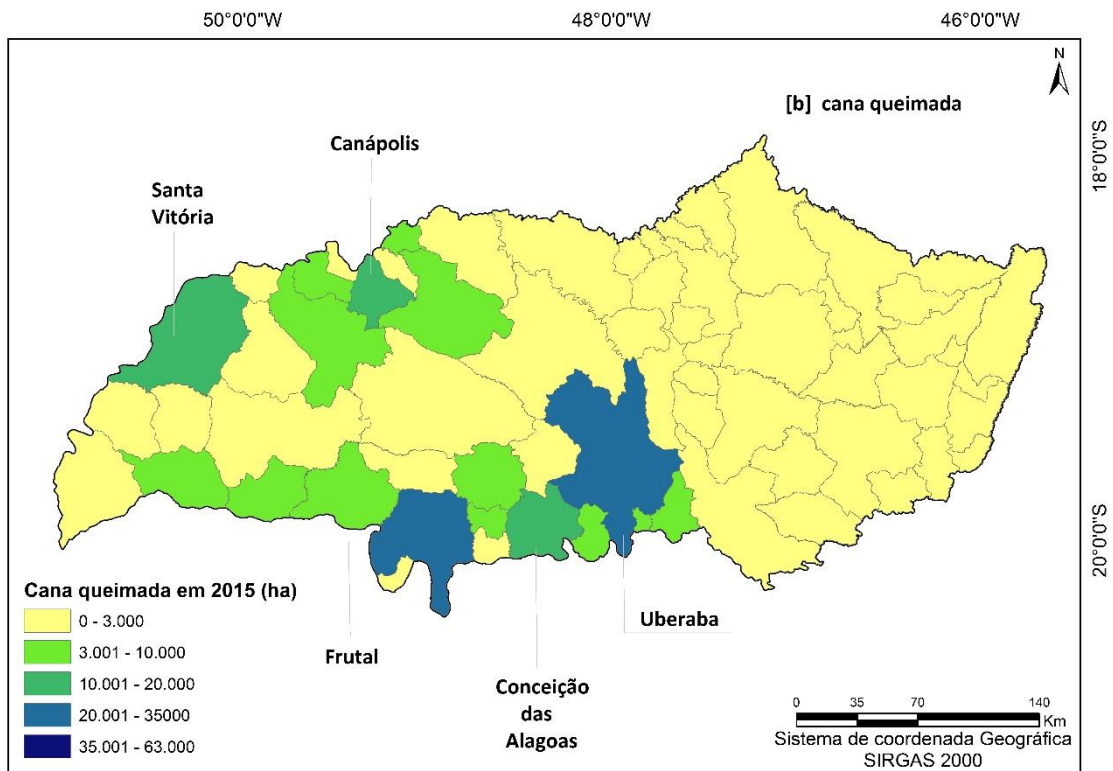
Fonte: elaborada pelo autor

Figura 10a- Mapa do modo de colheita da cana crua em hectares por município.



Fonte: elaborada pelos autores.

Figura 10b- Mapa do modo de colheita da cana queimada em hectares por município.




Fonte: elaborada pelos autores.

Destacam-se os municípios de Uberaba e Frutal, que ocupam as maiores áreas com a produção de cana nessa região, se sobressaem em relação aos demais tanto no modo de colheita mecanizada quanto na queima de pré-colheita. Juntos apresentam uma área de 151 mil ha, com 14,97% de cana-de-açúcar colhida crua e 5,57% com queima. Os demais municípios com as maiores áreas nos dois modos de colheita são: Santa Vitória, Conceição das Alagoas e Canápolis.

Dos 689.129,8 ha identificados como cana-de-açúcar, 75,6% utilizam a mecanização no processo de colheita, enquanto 24,4% ainda utilizam a prática da queima antes do corte. De acordo com a Figura 11, os meses de setembro e outubro foram os meses de maior intensidade de colheita, com 118.590,4 ha e 119.395,0 ha, respectivamente. O mês de setembro representou 17,2% de toda área de cana-de-açúcar colhida, seguido por outubro com 17,1%. Esses foram os meses de maior intensidade de colheita. Julho e agosto obtiveram o menor percentual de cana colhida, com 10,6% e 11,3%, respectivamente.

Figura 11- Área colhida com cana-de-açúcar na mesorregião do TM conforme o mês de colheita.



Fonte: elaborada pelos autores.

Aspectos sociais, econômicos, fisiológicos e tecnológicos são fatores importantes que interferem na colheita da cana-de-açúcar, como exemplo, a cotação internacional, privilégio logístico, clima (disponibilidade de radiação solar e hídrica) (SANTOS e BORÉM, 2013).

Portanto, constata-se para a mesorregião do TM que o mês de colheita não tem relação com o modo de colheita da cana-de-açúcar.

É indispensável a verificação e fiscalização adequada dos órgãos públicos do estado quanto à utilização da queima na pré-colheita. Sendo assim, a criação de protocolos ambientais que extinguem a queima devido às consequências ao meio ambiente e à sociedade são de extrema importância na garantia de minimizar os impactos causados pela agricultura. Uma forma de monitoramento do modo de colheita foi apresentada neste trabalho e mostrou-se eficiente para ser empregado pelos órgãos competentes.

4. Considerações finais

O monitoramento da cana-de-açúcar feito com base em imagens de sensoriamento remoto de média resolução espacial (Landsat-like) na mesorregião do Triângulo Mineiro e Alto Paranaíba no estado de MG permitiu localizar os talhões e identificar o modo de colheita da cana na região de forma satisfatória.

No ano analisado (2015), a área total identificada foi de 689.129,8 ha, sendo verificada a colheita intensiva dos meses de setembro e outubro. Além disso, a cana queimada representou 24,4% (168.445,9 ha) e a cana colhida mecanicamente 75,6% (520.683,9 ha). A identificação do modo de colheita permitiu verificar que na mesorregião do TM ainda há o emprego da queima, prática esta que deve ser extinta devido a impactos ambientais por ela causados e a legislação ambiental que extingue a queimada.

Agradecimentos

Ao CNPq e à FAPEMIG, pelo financiamento do projeto de pesquisa, pela concessão da bolsa de mestrado FAPEMIG-12905 e ao Instituto Nacional de Pesquisas Espaciais (INPE) pelo aprendizado.

Referências

- AGUIAR, D. A.; RUDORFF, B.F.T.; SILVA, W.F.; ADAMI, M; MELLO, M. P. Remote Sensing Images in Support of Environmental Protocol: Monitoring the Sugarcane Harvest in São Paulo State, Brazil, *Remote Sensing*, v.3, n.12, 2011. pp. 2682-2703.
- AGUIAR, D. A.; RUDORFF, B.F.T.; SILVA, W.F.; ADAMI, M; SHIMABUKURO, Y E. Imagens de sensoriamento remoto no monitoramento da colheita da cana-de-açúcar. *Revista Engenharia Agrícola*. V. 29, n. 3, 2009. pp. 440-451.
- AGUIAR, D. A.; RUDORFF, B. F. T.; RIZZI, R.; SHIMABUKURO, Y. E. Monitoramento da colheita da cana-de-açúcar por meio de imagens MODIS. *Revista Brasileira de Cartografia*, v. 60, n. 4, 2008. pp. 375-383.
- BARBIERE, D. M.; MARQUES JÚNIOR, J.; PEREIRA, G. T.; LA SCALA JUNIOR, N.; SIQUEIRA, D, S.; PANOSSO, A. R. Comportamento dos óxidos de ferro da fração argila e do fósforo adsorvido, em diferentes sistemas de colheita de cana-de-açúcar. *Revista Brasileira de Ciência do Solo*, v. 37, 2013. pp. 1557-1568.
- BOUCKAERT, R. R. et al. WEKA Manual for Version 3-7-1. WEKA Documentation, 2010. Site: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Acessado em junho de 2016.
- BRASIL. Agência Minas Gerais. Brasil deve produzir mais álcool em 2016. Site: <<http://www.agenciaminas.mg.gov.br/noticia/estado-deve-produzir-mais-alcool-em-2016>>. Acessado em: junho de 2016.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, v.37, n.1, 1991. pp.35–46.
- IBGE. Instituto Brasileiro de Geografia e Estatística. Informações sobre a mesorregião do Triângulo Mineiro e Alto Paranaíba. Site: <www.ibge.org.br>. Acessado em junho de 2016.
- Gutman, G.; Huang, C.; Chander, G.; Noojipady, P.; Masek, J.G. Assessment of the NASA–USGS global land survey (GLS) datasets. *Remote Sensing of Environment*. v.134, 2013. pp.249–265.
- IMMITZER, M.; VUOLO, F.; ATZBERGER, C. First experience with sentinel-2 data for crop and tree species classifications in Central Europe. *Remote Sensing*. vol. 8, n.166, 2016. Pp. 1-27.

- LUCIANO, A. C. S.; PICOLI, M. C. A.; ROCHA, J. V.; SILVA, A. C. O.; MAIRE, G. Classificação semiautomática de áreas de cana-de-açúcar a partir do algoritmo Random Forest e imagens OLI/Landsat-8. ResearchGate.
- LUIZ, A. J. B.; SHULTZ, B.; TRABAQUINI, K.; EBERHARDT, I. D. R.; FORMAGGIO, A. R. Método para estratificação em levantamentos agrícolas com mais de uma variável. Embrapa Meio Ambiente, Jaguariúna, 2015, 39p.
- MELLO, M. P.; RUDORFF, B. F. T.; VIEIRA, A. O.; AGUIAR, D. A. Classificação Automática da colheita da cana-de-açúcar utilizando Modelo Linear de Mistura Espectral. Revista Brasileira de Cartografia, v. 62, n. 2, 2010. pp. 181-188.
- PARKER, J. A.; KENYON, R. V.; TROXEL, D. E. Comparison of interpolating methods for image resampling. IEEE Transactions on Medicam Imaging, v. MI-2, n. 1, 1983. pp. 31–39.
- PEÑA, J.M.; GUTIÉRREZ, P.A.; HERVÁS-MARTÍNEZ, C.; SIX, J.; PLANT, R.E.; LÓPEZ-GRANADOS, F. Object-based image classification of summer crops with machine learning methods. Remote Sensing. 2014, 6, pp. 5019–5041.
- PONZONI, F. J.; SHIMABUKURO, Y. E. Sensoriamento Remoto no Estudo da Vegetação. São José dos Campos: A. Silva Vieira Ed., 2007. 127 p.
- QGIS. Plugin: Temporal/Spectral Profile Tool. Site: <<https://plugins.qgis.org/plugins/temporalprofiletool/>> Acessado em: março de 2016.
- RUDORFF, B. F. T.; AGUIAR, D. A.; SILVA, W. F.; SUGAWARA, L. M.; ADAMI, M.; MOREIRA, M. A. Studies on the Rapid Expansion of Sugarcane for Ethanol Production in São Paulo State (Brazil) Using Landsat Data. Remote Sensing, vol. 2, n.4, 2010. pp. 1057-1076.
- SANCHES, I. D.; EPIHANIO, J. C. N.; FORMAGGIO, A. R. Culturas agrícolas em imagens multitemporais do satélite Landsat. Agricultura, São Paulo, v. 52, n. 1, 2005. pp. 83-96.
- SANTOS, F.; BORÉM, A. Cana-de-açúcar – Do Plantio à Colheita. 1.ed. Viçosa: UFV. 2013. 257p.
- SCHULTZ, B. LUIZ, A. J. B.; BERTANI, G.; IMMITZER, M.; SANCHES, I. D. A.; FORMAGGIO, A. R.; ATZERGER, C. Equalized Appearance (EqAp) in multi-sensor mosaic composition. Sensors, em revisão.

- SCHULTZ, B.; FORMAGGIO, A. R.; EBERHARDT, I. D. R.; SANCHES, I. D.; OLIVEIRA, J. C.; LUIZ, A. J. B. Classificação orientada a objeto em imagens multitemporais Landsat aplicada na identificação de cana-de-açúcar e soja. *Revista Brasileira de Cartografia*, v.68, 2016. pp.131-143.
- SCHULTZ, B.; IMMITZER, M.; FORMAGGIO, A. R.; SANCHES, I. D. A.; LUIZ, A. J. B.; ATZBERGER, C. Self-Guided Segmentation and Classification of Multi-Temporal Landsat 8 Images for Crop Type Mapping in Southeastern Brazil. *Remote Sensing*, 7, 2015. pp. 14482–14508.
- TORBICK, N.; LEDOUX, L.; SALAS, W.; ZHAO, M. Regional Mapping of Plantation Extent Using Multisensor Imagery. *Remote Sensing*, vol. 8, n.236, 2016. pp. 1-21.
- VENABLES, W.N.; SMITH, D.M.; R Development Core Team. An Introduction to R - Notes on R: a programming environment for data analysis and graphics. Version 3.3.1 (2016-06-21). Site: <<https://www.r-project.org/>>. Acessado em agosto de 2016.