



VÍCTOR DANILO MANABE

**METODOLOGIA PARA MAPEAMENTO DA
EXPANSÃO DE CANA-DE-AÇÚCAR NO ESTADO DE MATO
GROSSO POR MEIO DE SÉRIES TEMPORAIS NDVI/MODIS**

CAMPINAS
2014



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Engenharia Agrícola

VÍCTOR DANILO MANABE

METODOLOGIA PARA MAPEAMENTO DA EXPANSÃO DE CANA-DE-AÇÚCAR NO ESTADO DE MATO GROSSO POR MEIO DE SÉRIES TEMPORAIS NDVI/MODIS

Dissertação apresentada à Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Mestre em Engenharia Agrícola, na área de concentração Planejamento e Desenvolvimento Rural Sustentável.

Orientador: Prof. Dr. JANSLE VIEIRA ROCHA

CAMPINAS
2014

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

M311m Manabe, Victor Danilo, 1986-
Metodologia para mapeamento da expansão de cana-de-açúcar no Estado de Mato Grosso por meio de séries temporais de NDVI/MODIS / Vítor Danilo Manabe. – Campinas, SP : [s.n.], 2014.

Orientador: Jansle Vieira Rocha.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola.

1. Agricultura - Sensoriamento remoto. 2. Filtros (Matemática). 3. Classificação. 4. Terra - Uso - Processamento de dados . I. Rocha, Jansle Vieira, 1961-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Methodology for mapping the expansion of sugarcane in Mato Grosso State using NDVI/MODIS time series

Palavras-chave em inglês:

Agriculture - Remote sensing

Smoothing (Mathematical)

Classification

Land - Use - Data processing

Área de concentração: Planejamento e Desenvolvimento Rural Sustentável

Titulação: Mestre em Engenharia Agrícola

Banca examinadora:

Jansle Vieira Rocha [Orientador]

Júlio César Dalla Mora Esquerdo

Luiz Henrique Antunes Rodrigues

Data de defesa: 19-02-2014

Programa de Pós-Graduação: Engenharia Agrícola

Este exemplar corresponde à redação final da **Dissertação de Mestrado** defendida por **Víctor Danilo Manabe**, aprovada pela Comissão Julgadora em 19 de fevereiro de 2014, na Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.



AGRADECIMENTOS

A Universidade Estadual de Campinas (UNICAMP) e a Faculdade de Engenharia Agrícola (FEAGRI) pela oportunidade de pesquisa e aprimoramento.

A Coordenação de Aperfeiçoamento Pessoal de Nível Superior (CAPES) pela bolsa de mestrado concedida.

Ao Prof. Dr. Jansle Vieira Rocha, pela orientação e principalmente por ter acreditado em meu trabalho.

Ao Prof. Dr. Rubens Augusto Camargo Lamparelli, pelas contribuições ao trabalho.

Ao técnico do Laboratório de Geoprocessamento (FEAGRI/UNICAMP) Agmon Moreira Rocha pela disponibilidade de sempre ajudar e pelos momentos de descontração.

Ao pesquisador Dr. Júlio César Dalla Mora Esquerdo e ao Prof. Dr. Marco Tulio Ospina Patino pela participação na banca de qualificação e pelas sugestões que contribuíram para a melhoria do trabalho.

Aos meus amigos e colegas da pós-graduação, Felipe Bocca, Katia Suzigan, Walter Cervi, Marcio Melo, Talita Parizzi, Carlos Wachholz, Gleyce Dantas, Diego Rocha, Daniela Silva, Rafael Bispo, Rafael Moraes, Maria Petrini e João Antunes, pelos momentos de descontração e sempre solidários a qualquer ajuda.

A Manu pelo companheirismo, força e entendimento em toda esta etapa.

Aos meus pais Mario e Sandra, e a minha irmã Caroline, pelo suporte e incentivo.

Muito Obrigado!

RESUMO

O aumento na produção da cana-de-açúcar vem gerando grande discussão sobre a sustentabilidade da produção e a sua influência direta na mudança de uso da terra, principalmente em áreas de pastagem e cultura anual. O estudo da dinâmica da cana-de-açúcar tem influência direta em questões como a composição da produção agrícola, nos impactos sobre a biodiversidade, no desenvolvimento social e humano e na definição de políticas públicas. Índice de vegetação, através de séries temporais de imagens, tem sido utilizado para mapeamento de uso da terra de grandes áreas (estados, países ou regiões), através de produtos do sensor *MODerate resolution Imaging Spectroradiometer* (MODIS). Este trabalho avaliou o desempenho de diferentes técnicas de filtragem em séries temporais e também realizou detecção automatizada de áreas de cana-de-açúcar e principais usos da terra para os anos de 2005, 2008 e 2012, e consequente, mudança de uso da terra, utilizando séries temporais NDVI/MODIS, no estado de Mato Grosso. Foi utilizado o NDVI dos produtos MOD13Q1 e MYD13Q1 do sensor MODIS para identificação das áreas de diferentes usos da terra. Primeiramente foram avaliados os filtros Savitzky-Golay, HANTS e *Flat Bottom* de maneira individual e também com a combinação *Flat Bottom* + HANTS e *Flat Bottom* + Savitzky-Golay, nas séries de dados somente referentes ao NDVI MODIS/Terra e em conjunto com NDVI MODIS/Aqua. Os resultados mostraram que a utilização MODIS/Terra e MODIS/Aqua trouxe melhora significativa no resultado da classificação, quando utilizado em conjunto com algum filtro de série temporal, dentre eles o filtro o Savitzky-Golay apresentou melhor resultado na diferenciação dos alvos. Na identificação e mapeamento automatizado de áreas de cana-de-açúcar e outros principais usos da terra para a região (cultura anual, pastagem, cerrado e mata), realizada para os anos de 2005, 2008 e 2012, os valores de acertos para cana-de-açúcar foram, respectivamente, de 83%, 82% e 85% para os anos 2005, 2008 e 2012, e os acertos globais foram de 89%, 88% e 89%, para os mesmos anos. Ao cruzar os mapeamentos, foi possível realizar a análise da mudança de uso da terra para cana-de-açúcar. A mudança de uso da terra, quando implementada em áreas anteriormente destinadas a agricultura anual, foi de 80% e 82%, na comparação de 2005 para 2008 e 2008 para 2012, respectivamente. No uso anterior de pastagem e cerrado este valor apresentou valores de 69% e 30%, respectivamente, na mudança de 2005 para 2008, e 66% e 34%, respectivamente, na mudança de 2008 para

2012. O resultado na análise de mudança de uso da terra apresentou a predominância de áreas de pastagem como principal uso anterior a cana-de-açúcar, seguida pela agricultura e o cerrado. Assim, o método para identificação da mudança de uso da terra apresentou um erro a ser considerado, porém a tendência de mudança se apresenta de maneira consistente.

Palavras chave: Sensoriamento remoto; Filtragem; Classificação; Uso da terra.

ABSTRACT

The increase of sugarcane production has generated discussion about its sustainability and direct impact on the land use change, especially in pasture and annual crops areas. The study of the dynamics of sugarcane has a direct influence on issues such as the composition of agricultural production, the impacts on biodiversity, social and human development and the definition of public policies. Vegetation index through time series images have been used to map land use of large areas (states, countries or regions) using Moderate Resolution Imaging Spectroradiometer (MODIS) sensor. This study evaluated the performance of different time series smoothing techniques and also held automated detection of sugarcane areas and main land uses for the years 2005, 2008 and 2012, and the consequent land use change, using NDVI/MODIS time series in Mato Grosso state. NDVI products of MOD13Q1 and MYD13Q1 were used to identify areas of different land uses. At first, Savitzky-Golay, Hants and Flat Bottom, individually, and also the combination Flat Bottom + Hants and Flat Bottom + Savitzky-Golay, were applied on NDVI time series data only related to MODIS/Terra and in conjunction with MODIS/Aqua. The result showed that the use MODIS/Terra and MODIS/Aqua brought significant improvement in the overall classification, when used in conjunction with any time series smoothing, and the Savitzky-Golay showed better results in the differentiation of targets. The mapping results for areas of sugarcane and other major land uses (annual crops, grassland, savanna and forest) showed, for the years 2005, 2008 and 2012, respectively, agreement of 83 %, 82 % and 85 % accuracy for sugarcane, and global accuracy of 89 %, 88 % and 89 %. Map overlaying allowed to perform the analysis of the land use change to sugarcane. Analysis of areas of sugarcane previously occupied by annual crops were 80 % and 82 %, respectively, for 2005 compared to 2008 and 2008 compared to 2012. For the previous land use of grassland and savannah, this value, showed values of 69 % and 30 %, respectively, for 2005 compared to 2008, and 66 % and 34 %, respectively, in the change from 2008 to 2012. The result showed predominance of land use change in grazing areas to sugarcane, followed by agriculture and savanna as responsible for the remainder of the previous land use. Although the method to detect land use change has errors to be considered, the trend in land use change appears to occur consistently.

Key-words: Remote sensing; Smoothing; Classification; Land use.

SUMÁRIO

AGRADECIMENTOS	vi
RESUMO	vii
ABSTRACT	ix
1. INTRODUÇÃO	1
1.1. Hipóteses	4
1.2. Objetivos geral e específico	5
1.3. Organização da Dissertação	6
2. REVISÃO BIBLIOGRÁFICA	7
2.1. Expansão da agricultura no Mato Grosso	7
2.2. Cana-de-açúcar	8
2.3. Sensoriamento remoto aplicado a agricultura	9
2.3.1. Resposta Espectral	10
2.3.2. Índice de vegetação	11
2.3.3. Sensor MODIS	12
2.3.4. Séries Mutitemporais	13
2.3.5. Processamento de séries temporais	14
2.4. Mineração de dados	15
3. METODOLOGIA GERAL	17
3.1. Área de estudo	17
3.2. Material	18
4. RESULTADOS	19
4.1. Artigo 1: Avaliação de métodos de filtragem em séries temporais de NDVI/MODIS	19

4.1.1. Introdução	19
4.1.2. Material e Métodos	21
4.1.3. Resultados e Discussão	27
4.1.4. Conclusões	36
4.2. Artigo 2: Mapeamento e monitoramento da expansão da cana-de-açúcar no estado de Mato Grosso, utilizando MODIS/NDVI.....	37
4.2.1. . Introdução	37
4.2.2. Material e Métodos	39
4.2.3. Resultados e Discussão	43
4.2.4. Conclusões	52
5. CONCLUSÕES GERAIS.....	54
6. REFERENCIAS BIBLIOGRÁFICAS	55

1. INTRODUÇÃO

Desde a década de setenta, o governo brasileiro vem incentivando a ocupação para o desenvolvimento da agropecuária no oeste brasileiro. Esforços foram feitos para a expansão da fronteira agrícola em áreas da Amazônia e Cerrado. Ao mesmo tempo pesquisas avançaram para dar condições do estabelecimento de culturas agrícolas como soja e milho em áreas de solo com baixa fertilidade e alta acidez (JEPSON, 2006; MUCHAGATA e BROWN, 2003; WARNKEN, 1999). Desta maneira o estado de Mato Grosso se tornou um dos principais produtores de grãos e gado do mundo, tendo em 2011 uma produção de cerca de 30 milhões de toneladas de grãos e 29 milhões de cabeças de gado (IBGE, 2013).

Nos últimos anos a cana-de-açúcar vem tomando lugar de destaque no agronegócio brasileiro devido à grande demanda para produção de etanol causada pelo aumento da comercialização de carros biocombustíveis. (RUDORFF et al., 2010). No Brasil a produção de cana-de-açúcar obteve um crescimento maior de 100% na última década, sendo que o estado do Mato Grosso, uma região nova para a expansão da cana-de-açúcar, apresentou em crescimento de 70% no mesmo período (IBGE, 2013).

Este aumento na produção da cana-de-açúcar vem gerando grande discussão sobre a sustentabilidade da produção e a sua influência direta na mudança de uso da terra, principalmente em áreas de pastagem e cultura anual (GOLDEMBERG et al., 2008; SMEETS et al., 2008). Mudanças na estrutura produtiva nestas regiões de expansão podem ocorrer, como, por exemplo, aumento da produção agropecuária extensiva (MARTINELLI et al., 2011). O cultivo da cana-de-açúcar ocorre a uma distância média de 60 km das usinas, devido a aspectos logísticos de colheita. Isto permite um planejamento e conhecimento sobre novas áreas que serão implantadas em seu entorno.

Conhecer a dinâmica de uso e de cobertura das terras é fator primordial para elaboração e acompanhamento de políticas públicas. O estudo da dinâmica da cana-de-açúcar tem influência direta, por exemplo, na composição da produção agrícola, nos impactos diretos e indiretos sobre a biodiversidade, no desenvolvimento social e humano e na definição de políticas públicas.

Com isto, desde os anos setenta, o sensoriamento remoto vem sendo utilizado no estudo das mudanças do uso da terra na região Amazônica, especialmente na identificação de áreas de desmatamento (SKOLE E TUCKER, 1993). Os projetos Prodes (MMA, 2014) e Terraclass (INPE, 2014) vêm estudando, por meio de sensoriamento remoto, a evolução e as características do desmatamento nas áreas de floresta do bioma Amazônia. No estado do Mato Grosso a maior parte das áreas desmatadas se encontra como diversos tipos de pastagem, agricultura ou como vegetação secundária (INPE, 2014). Um exemplo da utilização de imagens de satélite no entendimento da mudança de uso da terra é o trabalho realizado por ADAMI et al., (2012a), que estudaram a mudança de uso para cana-de-açúcar na região Centro-Sul, analisando manualmente séries temporais de índice de vegetação, concluindo que 99% das novas áreas a partir do ano 2000 vieram em substituição a pasto e agriculturas de ciclo anual, sendo que a diminuição de áreas de pasto pode ser compensada pela intensificação da pecuária.

O estudo de grandes áreas, como estados e regiões, com sensoriamento remoto traz o desafio de tempo e custo ao projeto, em função da grande quantidade de informações a serem analisadas (FONTANA et al., 2000). Além disto, o trabalho com imagens de séries temporais, que apresentam alta resolução temporal, demanda grande volume de dados. Assim, ao trabalhar dados de séries temporais para um estado como Mato Grosso é importante à automação de etapas, para o aumento da velocidade dos processos, de forma a se obter resultados mais rapidamente (ROGAN et al., 2008).

Séries temporais de índices de vegetação (IV) (BAYARJARGAL et al., 2006; SEILER et al., 2007; VERBESSELT et al., 2010) tem sido utilizadas para mapeamento de uso da terra de grandes áreas (estados, países ou regiões), por meio de produtos com alta resolução temporal do *MODerate resolution Imaging Spectroradiometer* (MODIS). Em uma série temporal os valores de IV podem sofrer interferência pela presença de aerossóis, falhas do detector, geometria de visada, dentre outros. Porém são reconhecidas que as principais causas de ruídos em séries temporais de IV são as condições atmosféricas adversas e a bidirecionalidade da refletância (JÖNSSON e EKLUNDH, 2002; HIRD e MCDERMID, 2009). Para minimizar os efeitos destes ruídos foram desenvolvidos diversos filtros de séries temporais, como Savitzky-Golay (CHEN et al., 2004), HANTS (*Harmonic ANALysis of Time Series*, ROERINK et al., 2000) e *Flat-Bottom* (Wardlow et al., 2006).

Regiões onde, em determinadas épocas do ano, existe alta incidência de interferência atmosférica para a aquisição de imagens de satélite, a utilização em conjunto dos dados do IV *Normalized Difference Vegetation Index* – NDVI, de composição a cada 16 dias dos satélites Terra e Aqua, podem ser de grande ajuda para uma melhora nas informações da série temporal, ao invés de aplicar somente dados do satélite Terra, como se utiliza de maneira geral (ARVOR et al., 2011; ADAMI et al., 2012a), pois as informações oferecidas pelos satélites tem uma diferença de 8 dias no encerramento das composições e diferentes horários de aquisição da informação (JUSTICE et al. 1998). A inserção de dados sem ruídos do satélite Aqua, em uma sequencia com ruídos de aquisições do satélite Terra, traz maiores informações para a realização do procedimento para a retirada das interferências. O filtro *Flat Bottom* foi utilizado com bom resultados por ESQUERDO et al (2013) em séries de NDVI dos satélites Terra e Aqua trabalhadas em conjunto para melhorar valores de informações, sendo essa, também, uma alternativa para a diminuição de ruídos.

Desta maneira, com os avanços tecnológicos disponíveis é fundamental o conhecimento espacial e temporal da expansão e intensificação da atividade agrícola, sendo o primeiro passo para entender as suas consequências na produção agrícola, no meio ambiente, na economia local e no desenvolvimento da região. A cana-de-açúcar por ser um cultivo em aumento de produção e com potencial de crescimento no Mato Grosso deve ser estudada para que se possa entender a sua dinâmica de expansão.

1.1. Hipóteses

As hipóteses a seguir serão consideradas:

- A utilização em conjunto de dados MODIS/Terra e MODIS/Aqua melhora o mapeamento da cana-de-açúcar.
- Diferentes técnicas de filtragem de séries temporais produzem resultados de classificação distintos.
- Identificação da mudança de uso da terra para cana-de-açúcar realizada de maneira automatizada traz resultados confiáveis.

1.2. Objetivos geral e específico

O objetivo geral deste trabalho é avaliar o desempenho de diferentes técnicas de filtragem em séries temporais e também a detecção automatizada de áreas de cana-de-açúcar e principais usos da terra para os anos de 2005, 2008 e 2012, e consequente da mudança de uso da terra, utilizando séries temporais NDVI/MODIS, no estado de Mato Grosso.

O trabalho foi dividido em dois artigos definidos desta maneira:

- Artigo 1 - “Avaliação de métodos para eliminação de ruídos em séries temporais NDVI/MODIS”
- Artigo 2 - “Mapeamento e monitoramento da expansão da cana-de-açúcar no estado de Mato Grosso, utilizando MODIS/NDVI”.

1.3. Organização da Dissertação

O trabalho foi organizado a partir de dois artigos científicos resultantes do projeto de pesquisa desenvolvido como dissertação de mestrado.

A primeira parte trata da introdução, objetivo geral e objetivos específicos. A segunda parte aborda a revisão bibliográfica e a metodologia geral utilizada para o desenvolvimento do trabalho. Os resultados são apresentados na forma de dois capítulos, onde cada um corresponde a um artigo científico, contendo Introdução, Material e Métodos, Resultados e Discussão, Conclusões e Referências.

O artigo 1 avalia diferentes métodos de redução de ruídos em séries temporais de NDVI, através do resultado da classificação dos alvos.

O artigo 2 trata do mapeamento automatizado da cana-de-açúcar e principais usos da terra em Mato Grosso, utilizando dados multitemporais NDVI/MODIS, e análise da mudança de uso da terra para cana-de-açúcar.

Ao final é apresentado um capítulo de Conclusões Gerais sobre toda a dissertação.

2. REVISÃO BIBLIOGRÁFICA

2.1. Expansão da agricultura no Mato Grosso

O crescimento populacional ocasiona a necessidade do aumento da oferta de comida no mundo, historicamente, isto é realizado com o aumento da área destinada à agricultura em detrimento a preocupações com o meio ambiente (BORLAUG, 2000). Desde a década de cinquenta, o rápido aumento populacional tem colocado cada vez mais pressão nas áreas de expansão agrícola (MATSON et al., 1997). A região Sul da Amazônia brasileira, onde se encontra o estado do Mato Grosso, apresenta uma das mais rápidas expansões de fronteira agrícola no mundo.

O governo brasileiro na década de setenta, criou programas para o desenvolvimento agrícola e ocupação da região Amazônica, com incentivos para a implementação de atividades agrícolas e pecuárias (JEPSON, 2006). Esta mudança causou grandes transformações no Mato Grosso, pois os migrantes da região Sul, onde havia um grande desenvolvimento da mecanização agrícola e a prática de cultivo de soja para exportação, tiveram o auxílio do desenvolvimento de novas tecnologias para a criação de condições do estabelecimento de culturas como soja e milho em áreas de solo com baixa fertilidade e alta acidez, levando o Mato Grosso a se tornar o principal produtor de grãos do Brasil e do Mundo (DUBREUIL, 2002; JEPSON, 2006).

Pesquisas identificaram que o processo de expansão da agricultura com a chegada dos agricultores vindos da região Sul entre a década de setenta a noventa foi o principal motivo para o desmatamento do Mato Grosso (CARDILLE e FOLEY, 2003; FEARNSIDE, 2002; MORTON et al., 2006). O tipo de agricultura intensiva adotado causou inúmeros problemas regionais, para o meio ambiente e agricultura, como mudança no armazenamento de carbono e nitrogênio no solo, qualidade da água, biodiversidade e emissão de gases poluentes (MELILLO et al., 2001; MYERS et al., 2000; NEILL et al., 2001).

Novos acordos ambientais envolvendo governos estaduais e federal, ONGs (Organizações Não Governamentais) e os agentes privados estão propondo novas políticas para incentivar os agricultores do Mato Grosso a se preocuparem com questões ambientais (BRANNSTROM, 2009). Exemplos desta nova política de meio ambiente podem ser vistos

em ações do governo estadual do Mato Grosso como mudanças no sistema de licenças e controle ambiental mais rígido (NEPSTAD e STICKLER, 2008), e pela Moratória da Soja estabelecida em 2006 (BRANNSTROM, 2009; RUDORFF et al., 2011).

De acordo com dados do IBGE (2013) soja, milho e algodão são as principais culturas no estado com uma área plantada de 6,4, 1,9, 0,7 milhões de hectares, respectivamente, em 2011. Porém a cana-de-açúcar vem aumentando sua produção nos últimos anos chegando ao acréscimo de 70% na última década em quantidade produzida. Segundo NOVO et al., 2010 indústrias sucroalcooleiras têm aumentado seu interesse em áreas do estado de Mato Grosso, motivados pela presença de grandes áreas destinadas a pecuária com baixa taxa de cabeças de gado por hectare e preço baixo em comparação ao estado de São Paulo. O aumento da produção da cana-de-açúcar no Mato Grosso é menor em comparação aos outros estados do Centro-Oeste, porém a pressão exercida pelo aumento da produção ao redor do estado e os incentivos dados a produção de cana-de-açúcar no Brasil, tendem a elevar a produção de cana-de-açúcar nos próximos anos no estado.

2.2. Cana-de-açúcar

A cana-de-açúcar (*Saccharum officinarum*) é uma gramínea cultivada preferencialmente em latitudes entre 15°N e 30°S e temperatura entre 16°C e 33°C, sendo que valores abaixo de 21°C causam perda de rendimento (MAGALHÃES, 1987). Apesar de não apresentar grande exigência de solos, possui um desenvolvimento melhor em solos férteis, profundos, com boa aeração e capacidade de retenção de água (COPERSUCAR, 1988).

Um dos principais parâmetros agronômicos para o acompanhamento do crescimento da cana-de-açúcar é o Índice de Área Foliar (IAF), que possui forte relação com a produção de matéria orgânica (RODRIGUES, 1995). Disponibilidade de água e nutrientes, temperatura e luz solar são fatores que podem limitar seriamente o desenvolvimento e produção (AFONSI et al., 1987).

A cana-de-açúcar tem seu ciclo de crescimento dividido em quatro fases: brotação, perfilhamento, crescimento e maturação. A brotação consiste no período de plantio ou corte até a brotação das gemas da planta, durando em média 30 a 35 dias. O perfilhamento ocorre até quatro meses após a brotação, sendo caracterizada pela formação de outros brotos após a brotação das gemas. A fase crescimento corresponde ao período de alongamento dos colmos e

acúmulo de matéria seca. Na região Centro-Sul do Brasil a cana cortada ou plantada em Outubro terá um crescimento rápido nos primeiros meses devido as boas condições climáticas, já a cana cortada ou plantada em Abril passará os primeiros meses em crescimento lento, devido às condições de clima desfavoráveis em decorrência do inverno, aumentando após melhora na condição climática (RODRIGUES, 1995). A fase de maturação é a última etapa, onde ocorre o aumento da quantidade de sacarose nos colmos e o crescimento é baixo (BENVENUTTI, 2005). Segundo CASTRO (2000) a concentração de sacarose aumenta em 200% e a de matéria seca 5% nos quatros últimos meses do ciclo.

A cana-de-açúcar plantada pode ter seu primeiro ciclo com 12 meses (cana de ano) ou 18 meses (cana de ano e meio), sendo conhecido como ‘cana planta’. Após o primeiro corte o ciclo passa a ser de 12 meses, passando a ser chamada de ‘cana soca’. A quantidade de ciclos irá variar conforme a região, tipo de solo e tratos culturais, porém a média é a realização de cinco cortes na cultura.

O sistema radicular da cana planta possui um maior desenvolvimento em comparação ao da cana soca, que mesmo com o desenvolvimento de um novo sistema radicular a cada corte se apresenta mais superficial, ocasionando a cada novo ciclo uma perda no desenvolvimento da cultura (HUMBERT, 1974).

As características da cultura descritas anteriormente, assim como outros fatores importantes para o seu cultivo como número de colmos por planta, altura, fechamento de entrelinhas, comprimento e largura das folhas, resistência a doenças e pragas, produtividades e características para o desenvolvimento referente ao ambiente de produção são definidas pelas características varietais da planta. Um dos principais fatores para a escolha de uma variedade é referente ao seu ciclo: precoce, médio ou tardio. Este fator varia conforme o tempo de maturação da variedade, o que possibilita a colheita da cana durante todo o período de safra que usualmente vai de Abril (precoce) a Novembro (tardio) (RODRIGUES, 1995).

2.3. Sensoriamento remoto aplicado a agricultura

O sensoriamento remoto tem se mostrado uma ferramenta valiosa no monitoramento agrícola devido a sua habilidade de “enxergar” em diversos comprimentos de onda (LABUS et al. 2002). As vantagens de sua aplicação vêm com a rapidez na obtenção de informação de

extensas áreas e, e com isto, a possibilidade de monitorar o tipo de extensão, vigor e tipo de cobertura vegetal (REES, 1990).

As culturas agrícolas apresentam um ciclo fenológico bem definido, o monitoramento desta dinâmica necessita de um acompanhamento periódico. Em regiões com grandes dimensões o sensoriamento remoto possui grande utilidade, uma vez que possibilita acompanhar a dinâmica agrícola, o caráter global, multiespectral e repetitivo (SANCHES et al, 2005).

A aplicação do sensoriamento remoto voltado para agricultura vem mostrando seu potencial com trabalhos realizados em mapeamento e monitoramento de culturas (RUDORFF et al., 2010; ROCHA, 2006; ESQUERDO, 2007), mudanças de uso da terra (ARVOR et al., 2012), intensificação da agricultura (ADAMI et al., 2012a; GALFORD et al., 2008), análises de manejo de água para irrigação (PINTER e REGINATO, 1982), controle de nutrientes, pragas e doenças (APAN et al., 2004).

2.3.1. Resposta Espectral

Na superfície terrestre cada alvo apresenta diferente assinatura espectral, seu conhecimento é importante para a identificação do objeto de interesse (PONZONI e DISPERATI, 1995). Os principais fatores físicos que afetam a refletância das folhas são o ângulo de incidência da radiação, arquitetura da planta e ângulo de visada, além dos seguintes mecanismos biológicos, pigmentos, quantidade de água e estrutura celular (MOREIRA, 2001).

A resposta espectral da vegetação nos comprimentos de onda do visível, infravermelho próximo (IVP) e infravermelho médio (IVM), para as fases de crescimento e senescência de um dossel é representada na Figura 2.1. A planta, ao passar da fase de crescimento para senescência, aumenta a refletância na faixa do visível e diminui na faixa do IVP devido a alterações nos mecanismos biológicos, se assemelhando assim a resposta espectral do solo. A energia captada pelo satélite proveniente de uma área agrícola é influenciada pelo solo devido às características da cultura, como espaçamento, porte, vigor e fase de desenvolvimento. No início do crescimento da planta, o solo exposto aparece entre as plantas jovens. Com o desenvolvimento da cultura a cobertura vegetal passa a predominar, diminuindo assim a influência do solo (GUYOT, 1989).




Figura 2.1: Representação da resposta espectral do dossel de uma cultura ao longo do ciclo de desenvolvimento. Fonte: ESQUERDO (2007) adaptado de GUYOT (1989).

2.3.2. Índice de vegetação

Índices de vegetação foram desenvolvidos com objetivo de diferenciar o padrão da variação da vegetação em relação ao solo e demais alvos da superfície (MOREIRA, 2001). São transformações lineares do fator de refletância obtido de duas ou mais bandas espectrais do sensor, envolvendo operações matemáticas como soma, diferença, razão ou qualquer outra (WIEGANG et al., 1991).

O *Normalized Difference Vegetation Index* - NDVI, proposto por ROUSE et al. (1973), é o índice de vegetação mais tradicionalmente adotado para a caracterização da vegetação e é utilizado como uma medida semi-quantitativa da densidade e do vigor vegetativo. O NDVI é calculado a partir da equação:

$$NDVI = \frac{\rho_{IVP} - \rho_{VER}}{\rho_{IVP} + \rho_{VER}}$$

, onde

ρ_{IVP} = fator de refletância na faixa do infravermelho próximo

ρ_{VER} = fator de refletância na faixa do vermelho

Embora numericamente os valores do NDVI possam variar entre -1 e 1, a vegetação está associada aos valores positivos. Já solos descobertos e rochas têm valores próximos à zero. O NDVI pode ter relação com algumas variáveis agrônômicas como altura de planta,

índice de área foliar, matéria seca, grau de cobertura do solo e interceptação de radiação solar global, entre outros (JUSTICE e HIERNAUX, 1986, HOLBEN *et al.*, 1980; PRICE, 1993, BARET e GUYOT, 1991; FONSECA, 2000).

2.3.3. Sensor MODIS

O sensor *MODIS* (*MODerate resolution Imaging Spectroradiometer*) está a bordo dos satélites Terra e Aqua, lançados pela NASA. Com órbita polar, estão a uma altitude de 705 km e faixa imageada de 2.330 x 5.000km. Possui alta sensibilidade radiométrica (12 bits) em 36 bandas espectrais contidas no intervalo de 0,4 a 14,4 μ m do espectro eletromagnético.

São dez produtos relacionados ao balanço de energia: MOD09 e MYD09(refletância de superfície), MOD11 e MYD11(temperatura da superfície da terra e emissividade); MOD43 (BRDF/albedo) e MOD10 e 49 e MYD10 e 49 (cobertura de neve e extensão de gelo na superfície do mar). Para informações de vegetação são disponibilizados os produtos MOD13 e MYD13 (índices de vegetação – NDVI e EVI), MOD15 e MYD15 (índice de área foliar – IAF e fração da radiação fotossinteticamente ativa absorvida pela vegetação – FPAR), MOD17 e MYD17 (fotossíntese líquida e produtividade primária). Uma vez que, a maioria dos produtos são originados da refletância (MOD09 e MYD09), este, vem acompanhado do controle de qualidade (QA) que fornece informações da qualidade do pixel, o que permite ao usuário uma análise da qualidade de cada pixel da imagem (Latorre et al., 2007; Justice et al., 1998).

As imagens de NDVI do produto MOD13Q1 a partir de composições de 16 dias com resolução de 250 m do sensor Terra/MODIS (MODIS, 2010), apresentam larga utilização no mapeamento e monitoramento de culturas agrícolas (CHANG et al., 2007; ADAMI et al., 2012a; VIEIRA et al., 2012).

Sua alta resolução temporal possibilita a identificação de períodos onde se pode realizar mapeamento através de séries temporais (WARDLOW et al., 2007, ARVOR et al., 2011). Trabalhos foram realizados com o objetivo de identificar mudanças no padrão de uso da terra através de série temporal de índices de vegetação. ARVOR et al., (2012) as utilizaram para o mapeamento das culturas de milho, soja, algodão, sorgo e milheto em duas diferentes safras, realizando posteriormente a análise da mudança de uso da terra. ADAMI et al., (2012a) executaram o estudo selecionando áreas de cana-de-açúcar, no Centro-Sul, por amostragem, e

posteriormente identificando as mudanças de uso da terra na série de imagens MODIS de maneira manual.

2.3.4. Séries Multitemporais

A utilização de séries temporais de índices de vegetação para mapeamento e monitoramento de culturas agrícolas apresenta potencial para produzir resultados com maior antecedência, precisão e, ainda, com menor custo operacional do que as técnicas convencionais (FAO, 1998). Além disto, essa alternativa possibilita a execução de análises compatíveis com as escalas regional e nacional, com uma frequência mais elevada, compatível com a dinâmica da agricultura e com as demandas específicas do mercado.

Com uma única imagem de satélite referente a uma data pode não ser possível a obtenção de informações espectrais suficientes para identificar todas as culturas. Porém, utilizando imagens multitemporais é aumentada a possibilidade de um maior número de informações sobre área plantada e o comportamento durante o crescimento e desenvolvimento da cultura, assim como a possibilidade de realização do acompanhamento da safra e o conhecimento do histórico de ocupação da área (SANCHES et al., 2005). O processo de discriminação de culturas e entendimento do uso da terra através de séries multitemporais não é trivial e envolve fatores como, experiência do intérprete, conhecimento das áreas de estudo e das culturas.

Diversos trabalhos foram realizados para a identificação e mapeamento de culturas através de séries temporais. RUDORFF et al. (2010) utilizaram quatro imagens de satélite Landsat de diferentes e conhecidas épocas ao longo do período de safra para a realização do mapeamento de cana-de-açúcar em São Paulo, identificando ainda áreas disponíveis para colheita, área de cana de reforma e área de expansão. WARDLOW et al. (2007) utilizaram 23 imagens MODIS NDVI correspondentes a um ano de informação de safra para o mapeamento das principais culturas de verão e inverno no estado do Kansas nos Estados Unidos.

Outra utilização de séries temporais que começou a ser desenvolvida recentemente é o estudo da mudança do uso da terra. ARVOR et al. (2012) analisaram, no estado de Mato Grosso, a mudança das características do cultivo agrícola através de séries multitemporais de índice de vegetação de imagens MODIS, onde foi constatada a mudança do cultivo de apenas um ciclo de cultura para dois ciclos, tendo assim um maior aproveitamento da terra. ADAMI

et al., (2012a) também utilizaram séries multitemporais de índice de vegetação MODIS para identificar de maneira visual mudanças de usos da terra no Centro-Sul do Brasil.

2.3.5. Processamento de séries temporais

Uma série temporal oriunda das imagens de satélite pode estar sujeita a interferência de diversos fatores relacionados com a presença de nuvens, falhas do detector, geometria de visada, dentre outros (JÖNSSON e EKLUNDH, 2002; HIRD e MCDERMID, 2009). Para minimizar os efeitos destes ruídos foram desenvolvidos diversos filtros. Dentre os algoritmos mais utilizados estão Savitzky-Golay (PRESS et al., 1992), *Flat-Bottom* (WARDLOW et al. 2006) e HANTS - Harmonic Analysis of NDVI Time-Series (ROERINK et al., 2000).

O filtro de Savitzky-Golay (SAVITZKY e GOLAY, 1964) se baseia em regressão polinomial de grau n , seu algoritmo leva os seguintes passos: i) definir a largura da janela temporal; ii) remover o ponto central do intervalo abrangido pela janela; iii) ajustar, pelo método dos mínimos quadrados, um polinômio de grau variável aos dados restantes; iv) utilizar o polinômio para estimar o valor do ponto removido e substituir este valor; v) deslocar a janela para o próximo ponto e repetir o processo anterior (CERQUEIRA *et al.*, 2000).

WARDLOW et al. (2006) desenvolveram o algoritmo para o filtro *Flat-Bottom* que consiste em encontrar valores de mínimos locais e os substituir pelo menor valor adjacente. ESQUERDO et al (2013) utilizaram séries de NDVI dos satélites Terra e Aqua trabalhadas em conjunto para melhorar valores de informações em áreas com grande interferência atmosférica e alcançaram bons resultados.

ROERINK *et al.* (2000) propuseram o algoritmo *Harmonic Analysis of Time Series* (HANTS) que tem por base as séries de Fourier. Em contraste com o padrão *Fast Fourier Transform* (FFT), o algoritmo HANTS trabalha de forma iterativa. O algoritmo inicia com uma série temporal de dados índice de vegetação. Os valores são utilizados como entrada na FFT e harmônicos relevantes. Normalmente os harmônicos que representam a média anual e a média semestral da série temporal são selecionados para recompor a série. Estes harmônicos podem ser selecionados a partir do espectro de Fourier, que é um gráfico que apresenta o número de ocorrência de cada frequência. Aplica-se a FFT inversa (IFFT) para obter os dados filtrados. Em seguida, é feita uma comparação à série original e filtrada, calculando-se a diferença entre a série filtrada e a original. Quaisquer pontos no tempo do índice de vegetação

original da série que estão abaixo do limiar definido pelo usuário são considerados ruídos e são substituídos com o valor do índice de vegetação filtrado. No entanto, ao substituir os valores pode ocorrer a mudança na média de toda a série. Assim, é necessária uma próxima iteração, repetindo o processo até que não haja mais elementos fora do limiar estabelecido ou um número máximo de interações (DILMAGHANI *et al.*, 2007; ZHANG *et al.*, 2008).

2.4. Mineração de dados

O monitoramento de grandes áreas para estudo com dados com alta resolução temporal causa um grande volume de informações a serem trabalhados. Além do mais, cada vez se torna crescente a necessidade da automatização de etapas, assim como, o aumento na velocidade dos processos (ROGAN *et al.*, 2008). Segundo HANSEN *et al.* (2000) técnicas de mineração de dados aplicadas ao sensoriamento remoto podem melhorar e agilizar a análise dos dados.

Segundo FAYYAD *et al.* (1996) a mineração de dados é o processo não trivial de identificação de novos padrões em um conjunto de dados. Existem três tarefas usuais a mineração de dados: associação, classificação e agrupamento. A tarefa de classificação consiste em prever uma variável dependente em função de um conjunto de dados relacionados (HAN e KAMBER, 2006). Dentre os diversos classificadores existentes se destacam Árvore de Decisão, Redes Neurais e Support Vector Machine – SVM.

HAN e KAMBER (2006) define uma árvore de decisão como é um modelo representado graficamente por nós e ramos, parecido com uma árvore, no sentido invertido. O nó raiz é o primeiro nó da árvore, no topo da estrutura. Os nós internos, incluindo o nó raiz, são nós de decisão. Cada um contém um teste sobre um ou mais atributos (variáveis independentes) e os resultados desse teste formam os ramos da árvore. Geralmente, o teste em um nó compara o valor de um atributo com um valor constante. No entanto, algumas árvores podem comparar dois atributos entre si, ou utilizar alguma função envolvendo um ou mais atributos (WITTEN e FRANK, 2005). VIEIRA *et al.* (2012) utilizaram índices de vegetação e bandas espectrais para o mapeamento da cana-de-açúcar na região Centro-Sul com algoritmo de árvore de decisão, obtendo bons resultados com a tarefa.

O classificador de Redes Neurais é uma arquitetura de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias de

unidades computacionais e uma camada de saída. Os sinais de entrada são propagados camada a camada pela rede em direção a saída. A camada de entrada geralmente é composta por unidades que não modificam os sinais externos (neurônios sensoriais), apenas os distribuem para a primeira camada intermediária. As unidades de saída constituem a camada de saída da rede, e as demais unidades constituem as camadas intermediárias (SILVA, 1998). O algoritmo de aprendizado mais utilizado para o treinamento destas redes é o algoritmo retro-propagação (*backpropagation*) (RUMELHART et al., 1986). Seu treinamento é do tipo supervisionado e é baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento (HAYKIN, 1999). PEÑA-BARRAGÁN et al. (2011) utilizou a tarefa de classificação de Redes Neurais para a diferenciação de culturas anuais com séries multitemporais.

O SVM consiste em mapeamento de vetores de entrada em um espaço amostral, por meio de construção do hiper-plano máximo de separação. Para isso, dois hiper-planos auxiliares são construídos, de uma forma que o hiper-plano de separação resultante maximize a distância entre eles (HAN e KAMBER, 2006). FOODY e MATHUR (2006) utilizaram o classificador SVM para o mapeamento de áreas agrícolas, tendo como amostras para geração do modelo, áreas com mistura espectral.

3. METODOLOGIA GERAL

O fluxograma geral se apresenta na Figura 3.1 onde podem ser vistas as principais etapas realizadas na dissertação. Estão presentes três diferentes elementos, sendo os dados de entrada aqueles identificados em verde, as etapas de processamento dos dados e análises das informações em azul e em laranja os resultados finais, em forma de dois artigos. A metodologia específica para cada artigo é encontrada de maneira detalha nos resultados deste trabalho.




Figura 3.1: Fluxograma geral da dissertação.

3.1. Área de estudo

O estudo foi realizado no estado do Mato Grosso. Na Figura 3.2 é mostrada a distribuição da produção municipal da cana-de-açúcar para o ano de 2011 segundo IBGE (2013). É possível a visualização das principais regiões produtoras de cana-de-açúcar no estado. Esta região apresenta uma grande variedade de sistemas naturais, tendo área de

influencia dos biomas Amazônia, Cerrado e Pantanal, e também uma das principais áreas de agricultura do mundo, com grandes áreas de pastagem, cultura anual e cana-de-açúcar. De acordo com mapeamentos realizados anteriormente através dos projetos Probio (MMA, 2014) e TerraClass (INPE, 2014), de maneira generalizada, os principais usos da terra nessas áreas são das coberturas naturais de cerrado e de floresta e das coberturas antrópicas, agricultura (culturas anuais e cana-de-açúcar) e pastagem.




Figura 3.2: Mapa da área colhida de cana-de-açúcar no Mato Grosso em 2011 e a localização das usinas de cana-de-açúcar.

3.2. Material

Para o estudo foram usadas as informações de NDVI e confiabilidade do pixel (Pixel Reliability) de NDVI dos produtos MOD13Q1 e MYD13Q1, respectivamente MODIS/Terra e MODIS/Aqua, com resolução espacial de 250 m e temporal de 16 dias, realizadas através de composição de valor máximo de imagens diárias, disponibilizado no Banco de Produtos MODIS na Base Estadual Brasileira pela Embrapa (ESQUERDO et al., 2011).

4. RESULTADOS

4.1. Artigo 1: Avaliação de métodos de filtragem em séries temporais de NDVI/MODIS

Victor Danilo Manabe, Jansle Vieira Rocha, Rubens Augusto Camargo Lamparelli

4.1.1. Introdução

O sensoriamento remoto vem sendo utilizado como ferramenta para o conhecimento da dinâmica de ecossistemas, pois fornece informações consistentes em uma escala espaço-temporal que proporciona o entendimento de processos bio e geofísicos, além de eventos de mudanças na cobertura terrestre (JIN e SADER, 2005; LINDERMAN et al., 2005; ZHANG et al., 2006). Os índices de vegetação (IV) (BAYARJARGAL et al., 2006; SEILER et al., 2007; VERBESSELT et al., 2009), têm sido utilizados para mapeamento de uso da terra de grandes áreas (estados, países ou regiões), por meio de produtos com alta resolução temporal e baixa resolução espacial do *MODerate resolution Imaging Spectroradiometer* (MODIS). Os produtos MOD13Q1 e MYD13Q1, respectivamente, nas plataformas MODIS/Terra e MODIS/Aqua, possuem resolução espacial de 250m e são adquiridas em diferentes horários, 10:30 e 13:30, respectivamente, e tem a suas composições de 16-dias, dos índices de vegetação NDVI e EVI, fechadas, alternadamente, em um intervalo de 8 dias, permitindo a análise do comportamento vegetativo temporal dos alvos (LATORRE et al., 2007; JUSTICE et al. 1998,). Isto possibilita a elaboração de parâmetros, a partir dos dados temporais, que são utilizados para a classificação e caracterização de diferentes alvos, como áreas de cultura de grãos, cana-de-açúcar, pastagem ou outros tipos de vegetação natural (FERNANDES et al. 2011; ARVOR et al., 2011; PEÑA-BARRAGÁN et al., 2011).

Em uma série temporal os valores de índice de vegetação podem sofrer interferência pela presença de aerossóis na atmosfera, falhas do detector, geometria de visada, dentre outros, sendo algumas dessas interferências corrigidas no processamento realizado antes da aquisição das imagens. Porém são reconhecidas como as principais causas de ruídos em séries temporais de NDVI a presença de nuvens e a bidirecionalidade da refletância (HIRD e MCDERMID, 2009). Para minimizar os efeitos destes ruídos a aplicação de filtro de séries temporais em dados de índice de vegetação é um processo essencial para o acompanhamento do comportamento vegetativo de alvos naturais (MICHISHITA et al, 2014).

A abordagem de filtragens de séries temporais de NDVI tem duas frentes de estudo bem estabelecidas, uma delas é análise da filtragem comparada ao comportamento real, onde trabalhos são realizados com o intuito de corrigir os valores para o mais próximo do verdadeiro (CHEN et al., 2004, MA e VEROUSTRAETE 2006). Dentro deste cenário o método Savitzky-Golay apresenta aplicação efetiva e levando a resultados confiáveis na comparação a outros filtros de série temporal (CHEN et al., 2004). A segunda frente consiste no estudo de métodos de filtragem que destacam a característica temporal dos diferentes usos da terra, bastante utilizada na análise exploratória de dados e no estudo de usos da terra que apresentam ciclos temporais com relação à quantidade de biomassa. Dentre os métodos constantemente trabalhados destacam-se aqueles baseados em análise de séries harmônicas, sendo um dos mais utilizados o algoritmo HANTS (Harmonic ANalysis of Time Series, ROERINK *et al.*, 2000), baseado na análise de Fourier.

Regiões onde, em determinadas épocas do ano, existe alta incidência de nuvens na aquisição de imagens de satélite, a utilização em conjunto dos dados de NDVI de composição a cada 16 dias dos satélites Terra e Aqua, ao invés de aplicar somente dados de satélite Terra pode ser de grande ajuda para uma melhora nas informações da série temporal (ARVOR et al., 2011; ADAMI et al., 2012a; JOHANN et al., 2013), pois as informações oferecidas pelos satélites têm uma diferença de 8 dias no encerramento das composições e diferentes horários de aquisição da informação (JUSTICE et al. 1998). A inserção de dados sem ruídos do satélite Aqua, em uma sequência de aquisições do satélite Terra com ruídos, traz maiores informações para a realização de procedimento para a retirada dos ruídos. O filtro *Flat Bottom* (WARDLOW et al., 2007) foi utilizado com bom resultado por ESQUERDO et al (2013) em séries de NDVI dos satélites Terra e Aqua, trabalhado em conjunto para melhorar valores de informações, sendo, uma alternativa para a diminuição de ruídos.

Além da análise da correção de ruídos normalmente utilizada, há outra visão, que consiste na análise da influência dos diferentes métodos de redução de ruídos (filtros de séries temporais e inserção de mais dados) para a classificação de diferentes alvos, tendo como base séries temporais de NDVI (LHERMITTE et al 2011). Este enfoque se justifica, uma vez que para a classificação são extraídos da série temporal parâmetros que serão utilizados como atributos na tarefa de classificação. Como os diferentes métodos imprimem resultados com características distintas no resultado filtrado da série temporal, a extração destes parâmetros

será influenciada de maneira diferente, levando a resultados de classificação distintos. Isto ocorre porque os parâmetros são estabelecidos conforme o comportamento temporal de NDVI do alvo que se deseja identificar em comparação aos demais alvos em diferentes épocas do ano (ARVOR et al., 2011).

O objetivo deste artigo foi avaliar diferentes métodos de redução de ruídos em séries temporais de NDVI, através do resultado da classificação dos alvos. Foram exploradas as influências dos métodos na elaboração dos parâmetros adotados e por consequência na classificação de diferentes alvos.

4.1.2. Material e Métodos

O fluxograma geral se apresenta na Figura 4.1.1, que mostra as principais realizadas. Estão presentes três diferentes elementos, sendo os dados de entrada aqueles identificados em verde, as etapas de processamento dos dados e análises das informações em azul e em laranja o resultado final.




Figura 2.1.1: Fluxograma geral da metodologia.

4.1.2.1. Área de estudo

As áreas de estudo estão localizadas no estado de Mato Grosso num raio de até 60 km ao redor da localização das usinas. Esta região apresenta uma grande variedade de sistemas naturais, tendo os biomas Amazônia, Cerrado e Pantanal (Figura 4.1.2), e também uma das principais áreas de agropecuária do mundo, com grandes áreas de pastagem, cultura anual e cana-de-açúcar. De acordo com mapeamentos realizados anteriormente através do programa Probio (MMA, 2014) e TerraClass (INPE, 2014), de maneira generalizada, os principais usos da terra nessas áreas são de cerrado, mata, culturas anuais, cana-de-açúcar e pastagem.




Figura 4.1.2: Mapa biomas do Mato Grosso e localização das usinas de cana-de-açúcar.

4.1.2.2. Dados

Para o estudo foram usados os dados de NDVI e confiabilidade do pixel (Pixel Reliability) do NDVI dos produtos MOD13Q1 e MYD13Q1, respectivamente MODIS/Terra e MODIS/Aqua, com resolução espacial de 250 m e resolução temporal de 16 dias, através de composição de valores máximos de imagens diárias, disponibilizados na Base Estadual Brasileira pela Embrapa (ESQUERDO et al., 2011). Foram obtidas imagens entre as datas de

Julho de 2011 até Novembro de 2012, com um total de 63 imagens de NDVI e de Pixel Reliability. Os dados de NDVI que foram considerados como bons são aqueles indicados ‘Dado Bom’ ou ‘Dado Marginal’ da confiabilidade do pixel, conforme a Tabela 4.1.1.

Tabela 4.1.1: Descrição da Imagem Pixel Reliability do produto MOD13Q1 e MYD13Q1.

Valor do Pixel	Resumo QA	Descrição
-1	Sem Dado	Não Processado
0	Dado Bom	Uso com Confiança
1	Dado Marginal	Utilizável, porém consultar outro QA
2	Neve/Gelo	Alvo coberto com neve/gelo
3	Nuvem	Alvo coberto com nuvens

4.1.2.3. Técnicas de eliminação de ruído

Para o trabalho foram selecionadas três diferentes métodos de filtragem de séries temporais (Tabela 4.1.2).

Tabela 4.1.2: Descrição dos filtros de séries temporais.

Método	Descrição	Referência
Savitzky-Golay	Aplica uma média ponderada móvel, em função de uma janela de atuação e o grau de função polinomial, em séries temporais de NDVI	Chen et al. (2004)
HANTS	Considera a série temporal de NDVI como sendo harmônico e de baixa frequência, assim a série é ajustada eliminando as oscilações de alta frequência, baseada no erro mínimo quadrático.	Roerink et al. (2000)
<i>Flat Bottom</i>	Localiza os valores mínimos locais na série temporal de NDVI ($x_{k-1} > x_k < x_{k+1}$) e o substitui pelo menor valor entre x_{k-1} e x_{k+1}	Wardlow et al. (2007) Modificado

O filtro Savitzky-Golay é uma filtragem amplamente utilizada, em trabalhos realizados para classificação de diversos usos da terra em Mato Grosso (ARVOR, et al., 2011). Também foi selecionada a técnica de filtragem HANTS que possui aplicações em agricultura no Brasil, sendo utilizado no mapeamento de cana-de-açúcar e cultura anual, por se basear em análise harmônica (FERNANDES et al., 2011). O terceiro filtro, *Flat Bottom* (Wardlow et al., 2007), tem como característica trabalhar com valores de mínimos locais, os substituindo pelos menores valores adjacentes, trazem uma boa oportunidade de estudo quando trabalhado em conjunto com dados de NDVI MODIS/Terra (T) e MODIS/Aqua (A). Por ser um filtro que não modifica a série temporal de forma tão intensa em comparação aos outros filtros

utilizados, foi testada, também, a sua aplicação em conjunto com os filtros Savitzky-Golay e HANTS.

Com exceção do filtro *Flat Bottom*, os outros necessitam de ajustes de parâmetros para a sua realização, desta maneira foram realizados testes preliminares para se estudar a adequação destes parâmetros para cada método. Desta forma, para o Savitzky-Golay foi selecionada a janela de interação de tamanho três e função de segundo grau e, para o algoritmo HANTS, a janela de frequência de zero a quatro foi selecionada. Assim, foram aplicados os filtros Savitzky-Golay (SG), HANTS(H) e *Flat Bottom* (F) de maneira individual e também com a combinação *Flat Bottom* + HANTS (F+H) e *Flat Bottom* + Savitzky-Golay (F+SG), nas séries de dados somente referentes ao NDVI MODIS/Terra e em conjunto com NDVI MODIS/Aqua. Após esta etapa o período de tempo da série foi reduzido para Agosto de 2011 a Outubro de 2012.

4.1.2.4. Avaliação dos parâmetros e classificação

Cada série de dados trabalhados anteriormente para redução de ruídos foi processada novamente, em rotinas elaboradas no software IDL 7.1, para a extração de parâmetros da série temporal, e foram utilizados na tarefa de classificação neste trabalho (Tabela 4.1.3 e Figura 4.1.3).

Foi escolhido um total de 20.000 pixels das imagens do sensor MODIS, que foram divididos de forma balanceada em cinco classes dos principais usos da terra presentes na região de estudo: ‘cerrado’, ‘mata’, ‘pastagem’, ‘cultura anual’ e ‘cana-de-açúcar’. Estes pontos foram selecionados com auxílio dos mapeamentos realizados anteriormente e disponíveis para consulta como o Probio (MMA, 2014), TerraClass (INPE, 2014) e Canasat (RUDORFF et al., 2011) e também de imagens de média resolução espacial Landsat 5 TM+. Deste total, 13.334 pixels foram separados para serem utilizados como conjunto de treinamento dos modelos de classificação e 6.666 pixels foram deixados para o teste de exatidão dos modelos de classificação. Para cada pixel foram extraídos valores dos parâmetros processados anteriormente.

Tabela 4.1.3: Descrição dos parâmetros utilizados.

Código	Métrica NDVI	Período de análise
V_Max e D_Max	Valor e data da imagem de máximo NDVI de toda série	Agosto/11 - Outubro/12
V_Min e D_Min	Valor e data da imagem de mínimo NDVI de toda série	Agosto/11 - Outubro/12
Dif_1	Diferença entre V_Max e V_Min	-
V_Max2 e D_Max2	Valor e data da imagem de máximo NDVI no período de pico vegetativo	Dezembro/11 - Maio/12
V_Min2 e D_Min2	Valor e data da imagem de mínimo NDVI no período de pico vegetativo	Dezembro/11 - Maio/12
Dif_2	Diferença entre o V_Max2 e V_Min2	-
V_Min3 e D_Min3	Valor e data da imagem de mínimo NDVI no período após colheita da cana-de-açúcar	Julho/12 - Outubro/12
Dif_3	Diferença entre o V_Max2 e V_Min3	-
Media	Valor médio de NDVI de toda série	Agosto/11 - Outubro/12
Media2	Valor médio de NDVI no período de pico vegetativo	Dezembro/11 - Maio/12
Coef_cresc e D_Coef_cresc	Valor e data da maior diferença entre as imagens NDVI nas posições x e x+2 no período de crescimento da cultura	Novembro/11 - Janeiro/12
Coef_senes e D_Coef_senes	Valor e data da menor diferença entre as imagens NDVI nas posições x e x+2 no período de senescência/colheita da cultura	Abril/12- Outubro/12
Var_Coef	Variância da diferença entre as imagens de NDVI das posições x e x+2 em toda série NDVI	Agosto/11 - Outubro/12




Figura 4.1.3: Descrição dos parâmetros utilizados.

Foi analisado o grau de importância de cada parâmetro dentro dos conjuntos de dados extraídos. Para isto, foi utilizada a técnica de seleção de atributos “ganho de informação” (*InfoGain*), que se baseia no cálculo da entropia de cada atributo (MITCHELL, 1997).

Para a classificação foi escolhido o classificador Ibk (AHA e KIBLER, 1991) que se baseia em distância euclidiana, sendo de uma heurística simples. Após testes preliminares, foi definido um total de cinco vizinhos para a classificação.

Conforme é possível notar, o comportamento tanto temporal da série NDVI (Figuras 4.1.6), como da distribuição nos histogramas de frequência de classes por parâmetro trabalhado em todos os conjuntos de dados (Figura 4.1.6, 4.1.7 e 4.1.8), as classes ‘cana-de-açúcar’, ‘pasto’ e ‘cerrado’ possuem comportamento muito semelhante temporalmente e, em consequência, nos parâmetros extraídos, porém são divergentes tanto da classe ‘agricultura’ como da ‘mata’. Assim, visando melhores resultados, o processo de classificação foi dividido em duas etapas: a primeira classificação de três classes ‘agricultura’, ‘mata’ e ‘outros’ (junção das classes ‘cana-de-açúcar’, ‘pastagem’ e ‘cerrado’); a segunda classificação ocorreu somente para as áreas anteriormente classificadas como ‘outros’, onde nessa etapa foram diferenciadas as classes ‘cana-de-açúcar’, ‘pastagem’ e ‘cerrado’.

4.1.3. Resultados e Discussão

A Figura 4.1.3 ilustra o diferente comportamento de um pixel de cada alvo para série de NDVI sem filtragem, ou seja, bruta (B), e com a aplicação das filtrações propostas.

A Figura 4.1.5, mostra em quais datas as imagens apresentaram maior interferência de ruídos, podendo-se perceber maior presença entre os meses de outubro a março, com uma maior intensificação nos meses entre outubro e janeiro. Essa maior presença de ruídos está relacionada à época de chuvas da região, que se apresentam de forma intensa neste período, tendo portanto, uma forte interferência de nuvens. Nesta época é onde se inicia o plantio das culturas anuais e também a fase onde há um maior crescimento de todos os tipos de vegetação devido à maior disponibilidade de água, assim, as nuvens irão prejudicar de uma maneira mais significativa os parâmetros extraídos dentro deste período.




Figura 4.1.4: Comportamento dos diferentes alvos aplicados com as técnicas de eliminação de ruídos.




Figura 4.1.5: Distribuição dos ruídos na série temporal NDVI.

Ao analisar os histogramas de frequência de classes para os parâmetros ‘Var_Coef’, ‘Coef_Senes’ e ‘Dif_3’, Figura 4.1.6, 4.1.7 e 4.1.8, é possível notar claramente dois comportamentos da distribuição dos valores dos atributos para cada classe, o primeiro que as classes ‘mata’ e ‘agricultura’ apresentam um comportamento dos parâmetros consideravelmente distintos, independente do tipo de dado e filtragem, das classes ‘cana-de-açúcar’, ‘cerrado’ e ‘pastagem’, isto já era esperado, uma vez que, ARVOR et al. (2011) encontraram dificuldades para a diferenciação das classes ‘cerrado’ e ‘pastagem’ através de classificação utilizando séries temporais de índices de vegetação. O segundo ponto a ser notado, é que para estes parâmetros, não ocorreu uma mudança no comportamento da distribuição dos valores para as classes conforme a técnica de eliminação de ruídos utilizada, porém, ocorreram mudanças consideráveis com relação aos valores onde se localizam o centro das distribuições.




Figura 4.1.6: Histogramas de frequência de classes do parâmetro 'Var_Coef', do conjunto de treinamento, para todas as filtragens e dados brutos.




Figura 4.1.7: Histogramas de frequência de classes do parâmetro 'Coef_senes', do conjunto de treinamento, para todas as filtragens e dados brutos.




Figura 4.1.8: Histogramas de frequência de classes do parâmetro ‘Dif_3’ do conjunto de treinamento para todas as filtragens e dados brutos.

Tabela 4.1.4: Posição de importância dos atributos.

Posição	1ª Classificação Terra						2ª Classificação Terra					
	B	G	SG	H	F+H	F+SG	B	G	SG	H	F+H	F+SG
1	Dif_3	Dif_1	Dif_3	Dif_3	Dif_1	Dif_3	V_Min3	V_Min	V_Min	V_Min	V_Min	V_Min
2	V_Min3	Dif_3	Dif_1	Dif_1	Dif_3	Dif_1	V_Min	V_Min3	V_Min3	V_Min3	V_Min3	V_Min3
3	Var_Coef	Var_Coef	V_Min3	Var_Coef	Var_Coef	Var_Coef	Coef_senes	Media	Dif_1	Media	Media	Dif_1
4	Dif_1	V_Min	Var_Coef	V_Min3	V_Min	V_Min3	Media	Dif_1	Media	Coef_senes	Dif_1	Media
5	Media	V_Min3	V_Min	V_Min	V_Min3	V_Min	Dif_3	Dif_3	Dif_3	Dif_1	Dif_3	Dif_3
6	Coef_senes	Coef_cresc	Coef_senes	Coef_cresc	Coef_cresc	Coef_cresc	Dif_1	D_coef_senes	Coef_senes	Dif_3	D_coef_senes	Coef_senes
7	V_Min	Coef_senes	Coef_cresc	Media	Coef_senes	Coef_senes	D_coef_senes	Var_Coef	D_coef_senes	D_coef_senes	Var_Coef	D_coef_senes
8	V_Max2	V_Max2	Media	Coef_senes	V_Max2	Media	D_Min	Coef_senes	Var_Coef	Var_Coef	Coef_senes	Var_Coef
9	Dif_2	V_Max	V_Max2	Dif_2	V_Max	V_Max	Var_Coef	Media2	Coef_cresc	V_Min2	V_Min2	Coef_cresc
10	V_Max	Media	V_Max	V_Min2	Media	V_Max2	Media2	V_Min2	D_Min	Media2	Media2	V_Min2
11	Coef_cresc	Dif_2	Dif_2	V_Max2	Dif_2	Dif_2	D_Max	D_Min	Media2	D_Max	D_Min	Media2
12	V_Min2	Media2	V_Min2	V_Max	Media2	V_Min2	V_Max	V_Max	V_Max	D_Min	D_Max	Dif_2
13	Media2	V_Min2	Media2	Media2	V_Min2	Media2	V_Min2	V_Max2	V_Max2	V_Max	Coef_cresc	D_Min
14	D_Min2	D_coef_senes	D_coef_senes	D_Min2	D_coef_senes	D_coef_senes	V_Max2	Coef_cresc	V_Min2	V_Max2	Dif_2	V_Max
15	D_coef_senes	D_Min2	D_Min2	D_coef_senes	D_Min2	D_Min2	V_Max2	Dif_2	Coef_cresc	Coef_cresc	V_Max	V_Max2
16	D_Min	D_Max	D_Max	D_Max	D_Max	D_Max	Coef_cresc	Dif_2	D_Max	Dif_2	V_Max2	D_Max
17	D_Max	D_Min3	D_Min	D_Max2	D_Min3	D_coef_cresc	Dif_2	D_Min3	D_Min3	D_Min3	D_Min3	D_Min3
18	D_Max2	D_coef_cresc	D_Max2	D_coef_cresc	D_Min	D_Min	D_Min2	D_coef_cresc	D_coef_cresc	D_coef_cresc	D_coef_cresc	D_coef_cresc
19	D_coef_cresc	D_Max2	D_coef_cresc	D_Min	D_coef_cresc	D_Min3	D_coef_cresc	D_Min2	D_Min2	D_Max2	D_Min2	D_Max2
20	D_Min3	D_Min	D_Min3	D_Min3	D_Max2	D_Max2	D_Max2	D_Max2	D_Max2	D_Min2	D_Max2	D_Min2

Posição	1ª Classificação Terra+Aqua						2ª Classificação Terra+Aqua					
	B	G	SG	H	F+H	F+SG	B	G	SG	H	F+H	F+SG
1	Dif_3	Dif_1	Dif_3	Dif_3	Dif_1	Dif_3	Media	V_Min	V_Min3	V_Min3	V_Min	V_Min3
2	Media	Dif_3	Dif_1	Dif_1	Dif_3	Dif_1	Coef_senes	V_Min3	V_Min	V_Min	V_Min3	V_Min
3	V_Min3	Var_Coef	V_Min3	V_Min3	Var_Coef	Var_Coef	V_Min3	Media	Coef_senes	Coef_senes	Coef_senes	Coef_senes
4	Dif_1	V_Min	V_Min	V_Min	V_Min	V_Min3	Dif_3	Dif_1	Dif_3	Media	Dif_1	Dif_1
5	V_Max2	V_Min3	Var_Coef	Var_Coef	V_Min3	V_Min	V_Min	Dif_3	Media	Dif_3	Dif_3	Dif_3
6	V_Max	Coef_cresc	Media	Media	Coef_cresc	V_Max	D_Min	D_coef_senes	Dif_1	Dif_1	D_coef_senes	Media
7	V_Min	V_Max	V_Max	Dif_2	V_Max2	V_Max2	Dif_1	V_Min2	D_coef_senes	Var_Coef	Media2	Var_Coef
8	Dif_2	V_Max2	Dif_2	V_Min2	V_Max	Coef_cresc	Media2	Media2	D_Min	Media2	V_Min2	D_coef_senes
9	Var_Coef	Coef_senes	V_Max2	V_Max2	Coef_senes	Dif_2	D_coef_senes	Dif_2	Var_Coef	D_Min	Dif_2	Media2
10	Media2	Dif_2	V_Min2	V_Max	Dif_2	Media	Var_Coef	Var_Coef	Media2	D_coef_senes	Var_Coef	D_Min
11	Coef_senes	Media	Coef_cresc	Coef_senes	Media	V_Min2	V_Max	Coef_senes	V_Max	V_Min2	Coef_senes	V_Min2
12	V_Min2	V_Min2	Coef_senes	Coef_cresc	V_Min2	Coef_senes	V_Max2	D_Min	V_Max2	V_Max	D_Min	Dif_2
13	D_coef_senes	Media2	Media2	Media2	Media2	Media2	D_Max	D_coef_cresc	D_Min3	V_Max2	D_Max	V_Max
14	D_Min2	D_Min2	D_coef_senes	D_Min2	D_Min2	D_Min2	D_Min3	D_Max	D_Max	D_Max	D_coef_cresc	V_Max2
15	Coef_cresc	D_coef_senes	D_Min2	D_coef_senes	D_coef_senes	D_coef_senes	D_Min2	V_Max	V_Min2	Dif_2	V_Max	D_Min3
16	D_Min	D_Max	D_Min	D_Max	D_Min	D_Min	V_Min2	V_Max2	V_Min2	D_Min3	V_Max2	D_Max
17	D_Max	D_Min3	D_Min3	D_Max	D_Min3	D_Max	D_Max2	D_Min2	Dif_2	D_coef_cresc	D_Min2	Coef_cresc
18	D_Max2	D_coef_cresc	D_Max	D_coef_cresc	D_Min	D_coef_cresc	D_coef_cresc	D_Min3	D_Max2	D_Min2	D_Min3	D_Min2
19	D_Min3	D_Min	D_coef_cresc	D_Max2	D_coef_cresc	D_Max2	Dif_2	D_Max2	Coef_cresc	D_Max2	D_Max2	D_coef_cresc
20	D_coef_cresc	D_Max2	D_Max2	D_Min3	D_Max2	D_Min3	Coef_cresc	Coef_cresc	D_coef_cresc	Coef_cresc	Coef_cresc	D_Max2

Tabela 4.1.5: Cinco principais parâmetros para cada método de eliminação de ruídos.

	Terra						Terra + Aqua					
	1 classificação			2 classificação			1 classificação			2 classificação		
	B	H	SG	F	F+H	F+SG	B	H	SG	F	F+H	F+SG
V_Max												
D_Max												
V_Min		x	x	x	x	x	x	x	x	x	x	x
D_Min												
Dif_1	x	x	x	x	x	x	x	x	x	x	x	x
V_Max2							x					
D_Max2												
V_Min2												
D_Min2												
Dif_2												
V_Min3	x	x	x	x	x	x	x	x	x	x	x	x
D_Min3												
Dif_3	x	x	x	x	x	x	x	x	x	x	x	x
Media	x						x					
Media2												
Coef_cresc												
D_coef_cresc												
Coef_senes												
D_coef_senes												
Var_Coef	x	x	x	x	x	x	x	x	x	x	x	x

Ao analisar as tabelas 4.1.4 e 4.1.5 com os atributos com maior poder preditivo analisados, constata-se que os atributos ‘Dif_1’, ‘V_Min’, ‘V_Min3’ e ‘Dif_3’ apresentaram grande força de predição na quase totalidade dos casos apresentados, tanto na primeira como

segunda classificação. Nos cinco atributos com maior poder preditivo para cada caso analisado, o atributo ‘Var_Coef’ apresentou grande importância na 1ª classificação, isso ocorreu devido à baixa variação angular para os alvos ‘mata’ e alta variação angular nos alvos ‘agricultura’. MORAES (2012) utilizou tal parâmetro em seu trabalho de classificação exclusiva de cana-de-açúcar, apresentando bons resultados, isso pode ser notado nas segundas classificações, pois apesar de não estar entre os primeiros na lista apresenta bom poder preditivo. Já para a segunda classificação a ‘Media’ e o ‘Coef_senes’ se mostraram bons parâmetros preditivos, isso ocorreu devido ao corte da cana-de-açúcar, que retira a biomassa de maneira rápida do campo fazendo ter uma queda acentuada e consequentemente um valor mais elevado para o parâmetro ‘Coef_senes’.

Atributos constituídos por datas não apresentaram relevância com exceção da ‘D_Coef_sens’ para a 2ª Classificação, as outras foram pouco representativas. Os valores tanto de ‘Coef_cresc’ como ‘D_coef_cresc’ por estarem associados à época das chuvas, todos os alvos terão um crescimento maior neste período e em datas próximas.




Figura 4.1.9: Resultados das classificações para ‘agricultura’, ‘mata’ e total.




Figura 4.1.10: Resultados das classificações para ‘cana-de-açúcar’, ‘pastagem’ e ‘cerrado’.

As Figuras 4.1.9 e 4.1.10 mostram os resultados da classificação para os alvos estudados e a sua comparação com os diferentes métodos de eliminação de ruídos adotados. Na classificação dos alvos ‘agricultura’ e ‘mata’, todos os métodos apresentaram bom desempenho e resultados muito próximos, porém para os alvos ‘cerrado’, ‘cana-de-açúcar’ e ‘pastagem’ a variação se apresentou de uma maneira mais acentuada e de diferentes formas. Porém para todos os casos, com exceção ao sem nenhuma filtragem, a utilização dos dados MODIS/Terra e MODIS/Aqua em conjunto apresentaram resultados superiores ao somente MODIS/Terra, comprovando desta forma o benefício trazido à inserção de mais dados na composição da série temporal para a realização da filtragem visando a classificação. Porém, somente o acréscimo de dados sem a realização de filtragem, não apresenta ganho de qualidade na classificação, isto porque, os dados MODIS/Terra também apresentam ruídos. A melhora com a filtragem ocorre devido ao acréscimo de dados com qualidade, que trazem maiores quantidades de informações corretas para o ajuste da série temporal.

A filtragem com Savitzky-Golay em conjunto com dados MODIS/Terra e MODIS/Aqua se destacou aos demais na classificação dos alvos estudados. Apresentou o melhor resultado para ‘cana-de-açúcar’ entre as técnicas utilizadas, uma vez que possui um desempenho de classificação desse alvo em torno de 5% melhor em comparação aos demais conjuntos estudados, para os demais alvos apresentou sempre desempenho igual ou superior.

A utilização MODIS/Terra e MODIS/Aqua em conjunto trouxe uma melhora significativa no resultado da classificação em todos os alvos na classificação para a filtragem com HANTS, isto indica que a inserção de mais dados na série temporal de NDVI para esta filtragem ajuda a melhorar a distinção das classes. Porém isto aconteceu de forma menos intensa com a filtragem com *Flat Bottom*, onde para todas as classes classificadas independentemente dos dados utilizados, os resultados foram muito próximos.

O resultado da classificação para os dados com a filtragem *Flat Bottom* anterior ao HANTS e Savitzky-Golay, sempre ficou inferior a pelo menos um dos dois outros filtros aplicados de maneira separadas. Isto indica que a utilização destes filtros de maneira conjunta não traz ganho para classificação.

4.1.4. Conclusões

1. Os parâmetros adotados referentes às datas apresentaram importância menor que aqueles extraídos de valores de NDVI.
2. Os parâmetros ‘Dif_1’, ‘V_Min’, ‘V_Min3’ e ‘Dif_3’ foram os que apresentaram maior importância em todos os casos analisados, seguidos por ‘Coef_senes’ e ‘Media’.
3. A utilização MODIS/Terra e MODIS/Aqua levou à melhora significativa no resultado da classificação, somente, quando utilizada em conjunto com técnicas de filtragem.
4. Para o trabalho que teve como alvo a ‘cana-de-açúcar’, ‘agricultura anual’, ‘pastagem’, ‘cerrado’ e ‘mata’, a filtragem dos dados MODIS/Terra e MODIS/Aqua com o filtro Savitzky-Golay, foi o que apresentou melhor desempenho.

4.2. Artigo 2: Mapeamento e monitoramento da expansão da cana-de-açúcar no estado de Mato Grosso, utilizando MODIS/NDVI.

Victor Danilo Manabe, Jansle Vieira Rocha, Rubens Augusto Camargo Lamparelli.

4.2.1. . Introdução

Desde a década de setenta, o governo brasileiro vem incentivando a ocupação para o desenvolvimento da agropecuária no oeste brasileiro. Esforços foram feitos para a expansão da fronteira agrícola em áreas da Amazônia e Cerrado. Ao mesmo tempo, pesquisas avançaram para dar condições do estabelecimento de culturas agrícolas como soja e milho em áreas de solo com baixa fertilidade e alta acidez (JEPSON, 2006; MUCHAGATA e BROWN, 2003; WARNKEN, 1999). Desta maneira o estado de Mato Grosso se tornou um dos principais produtores de grãos e gado do mundo, tendo em 2011 uma produção de cerca de 30 milhões de toneladas de grãos e 29 milhões de cabeças de gado (IBGE, 2013).

Nos últimos anos a cana-de-açúcar vem tomando lugar de destaque no agronegócio brasileiro devido à grande demanda para produção de etanol causada pelo aumento da comercialização de carros biocombustível. (RUDORFF et al., 2010). No Brasil a produção de cana-de-açúcar cresceu na última década, sendo que o estado do Mato Grosso, uma região nova para a expansão da cana-de-açúcar, apresentou em crescimento de 70% no mesmo período (IBGE, 2013).

Este aumento na produção da cana-de-açúcar vem gerando grande discussão sobre a sustentabilidade da produção e a sua influência direta na mudança de uso da terra, principalmente em áreas de pastagem e cultura anual (GOLDEMBERG et al., 2008; SMEETS et al., 2008). Mudanças na estrutura produtiva nestas regiões de expansão podem ocorrer, como o aumento da produção agropecuária extensiva (MARTINELLI et al., 2011).

Conhecer a dinâmica de uso e de cobertura das terras é fator primordial para elaboração e acompanhamento de políticas públicas. O estudo da dinâmica da cana-de-açúcar tem influência direta, por exemplo, em questões como a composição da produção agrícola, os impactos diretos e indiretos sobre a biodiversidade, o desenvolvimento social e humano e a definição de políticas públicas.

Com isto, desde os anos setenta, o sensoriamento remoto vem sendo utilizado no estudo das mudanças do uso da terra na região Amazônica, especialmente na identificação de áreas de desmatamento (SKOLE E TUCKER, 1993). Os projetos PRODES (MMA, 2014) e TERRACLASS (INPE, 2014) vêm estudando, por meio de sensoriamento remoto, a evolução e as características do desmatamento na área de floresta do bioma Amazônia. No estado do Mato Grosso a maior parte das áreas desmatadas se encontra como diversos tipos de pastagem, agricultura ou como vegetação secundária (MMA, 2013; INPE, 2013).

Um exemplo da utilização de imagens de satélite no estudo da mudança de uso da terra é o trabalho realizado ADAMI et al., (2012a), que analisaram visivelmente séries temporais de índice de vegetação para detectar a mudança de uso para cana-de-açúcar na região Centro-Sul, obtendo como resultado, que 99% das novas áreas a partir do ano 2000 vieram em substituição a pasto e agriculturas de ciclo anual, concluindo que a diminuição de áreas de pasto pode ser compensada pela intensificação da pecuária.

O estudo de grandes áreas, como estados e regiões, com sensoriamento remoto traz o desafio de tempo e custo ao projeto, em função da grande quantidade de informações a serem analisadas (FONTANA et al., 2000). Além disto, o trabalho com imagens de séries temporais demanda grande volume de dados. Assim, ao trabalhar dados de séries temporais para um estado como Mato Grosso é importante à automação de etapas, para o aumento da velocidade dos processos, e assim, obtendo resultados mais rapidamente (ROGAN et al., 2008).

Com os avanços tecnológicos disponíveis é fundamental o conhecimento espacial e temporal da expansão, sendo o primeiro passo para entender as suas consequências na produção agrícola, no meio ambiente, na economia local e no desenvolvimento da região. A cana-de-açúcar, por ser um cultivo em aumento de produção e com potencial de crescimento no Mato Grosso, deve ser estudada para se entender a sua dinâmica de expansão.

O objetivo geral deste trabalho foi a identificação e mapeamento automatizado de áreas de cana-de-açúcar e outros principais usos da terra para o estado de Mato Grosso (cultura anual, pastagem, cerrado e mata), para os anos de 2005, 2008 e 2012, utilizando séries temporais NDVI/MODIS, de forma a acompanhar a dinâmica da mudança do uso da terra em função da cana-de-açúcar.

4.2.2. Material e Métodos

O fluxograma geral, com as principais etapas a serem realizadas no artigo apresentado na Figura 4.2.1. Os dados de entrada são identificados em verde, as etapas de processamento dos dados e análises das informações em azul, e em laranja, o resultado final.




Figura 4.2.3: Fluxograma geral do artigo.

Na Figura 4.2.2 é mostrada a distribuição da produção municipal da cana-de-açúcar para o ano de 2012, segundo IBGE (2013). Foi restringida a área de estudo para aquelas dentro de um raio de 60 km das usinas, por ser considerada a distância média de influência para o plantio da cana-de-açúcar, por aspectos logísticos e de custo de produção, não havendo, desta forma, grandes áreas de cultivo fora deste raio.




Figura 4.2.2: Mapa da área colhida de cana-de-açúcar no Mato Grosso em 2012 e a localização das usinas de cana-de-açúcar.

Para o estudo foram usados dados de NDVI dos produtos MOD13Q1 e MYD13Q1, respectivamente MODIS/Terra e MODIS/Aqua, com resolução espacial de 250 m e temporal de 16 dias, através de composição máxima de imagens diárias (NASA), disponibilizado na Base Estadual Brasileira pela Embrapa (ESQUERDO et al., 2011). A Tabela 4.2.1, mostra o conjunto de imagens utilizadas para análise dos anos de 2005, 2008 e 2012.

Tabela 4.2.1: Intervalos de imagens MODIS/NDVI utilizadas.

Ano	Intervalo de datas	Quantidade de imagens
2005	Julho 2004 a Novembro de 2005	63
2008	Julho 2007 a Novembro de 2008	63
2012	Julho 2011 a Novembro de 2012	63

A utilização conjunta de dados do Terra/MODIS e Aqua/MODIS em regiões que em determinadas épocas do ano, apresentam alta incidência de interferência atmosférica para a aquisição de imagens de satélite, caso do estado do Mato Grosso, pode ser de grande ajuda para uma melhora nas informações da série temporal, ao invés de utilizar somente dados do

satélite Terra (ARVOR et al., 2011; ADAMI et al., 2012a), pois as informações oferecidas pelos satélites têm uma diferença de 8 dias no encerramento das composições e diferentes horários de aquisição da informação (JUSTICE et al. 1998). A inserção de dados sem ruídos do satélite Aqua, em uma sequência de aquisições do satélite Terra com ruídos, traz maiores informações para a realização de procedimento de processamento das imagens temporais e eliminação de interferência na qualidade dos dados. Para a correção das interferências nos valores da série temporal foi utilizado o filtro Savitzky-Golay (CHEN et al., 2004).

Na Tabela 4.2.2 e Figura 4.2.3 constam parâmetros extraídos, em rotinas elaboradas no software IDL 7.1, da série temporal filtrada que foram utilizados para a classificação.

Tabela 4.2.2: Descrição dos parâmetros utilizados.

Código	Métrica NDVI	Período de análise
V_Max e D_Max	Valor e data da imagem de máximo NDVI de toda série	Agosto/11 - Outubro/12
V_Min e D_Min	Valor e data da imagem de mínimo NDVI de toda série	Agosto/11 - Outubro/12
Dif_1	Diferença entre V_Max e V_Min	-
V_Max2 e D_Max2	Valor e data da imagem de máximo NDVI no período de pico vegetativo	Dezembro/11 - Maio/12
V_Min2 e D_Min2	Valor e data da imagem de mínimo NDVI no período de pico vegetativo	Dezembro/11 - Maio/12
Dif_2	Diferença entre o V_Max2 e V_Min2	-
V_Min3 e D_Min3	Valor e data da imagem de mínimo NDVI no período após colheita da cana-de-açúcar	Julho/12 - Outubro/12
Dif_3	Diferença entre o V_Max2 e V_Min3	-
Media	Valor médio de NDVI de toda série	Agosto/11 - Outubro/12
Media2	Valor médio de NDVI no período de pico vegetativo	Dezembro/11 - Maio/12
Coef_cresc e D_Coef_cresc	Valor e data da maior diferença entre as imagens NDVI nas posições x e x+2 no período de crescimento da cultura	Novembro/11 - Janeiro/12
Coef_senes e D_Coef_senes	Valor e data da menor diferença entre as imagens NDVI nas posições x e x+2 no período de senescência/colheita da cultura	Abril/12- Outubro/12
Var_Coef	Variância da diferença entre as imagens de NDVI das posições x e x+2 em toda série NDVI	Agosto/11 - Outubro/12




Figura 4.2.3: Descrição dos parâmetros utilizados.

Para realização da classificação da cana-de-açúcar e dos demais alvos, os seguintes algoritmos de classificação foram testados para a realização do mapeamento de cana-de-açúcar: J48 (Árvore de decisão), MLP – *Multilayer Perceptron* (Redes Neurais) e SMO – *Sequential Minimal Optimization* (SVM). O teste foi realizado para dados base da safra 2012, dos quais foram escolhidos um total de 20.000 pixels do sensor MODIS, divididos em cinco classes dos principais usos da terra presentes na região de estudo ('cerrado', 'mata', 'pastagem', 'cultura anual' e 'cana-de-açúcar'). Estes pontos foram selecionados com auxílio dos mapeamentos realizados anteriormente e disponíveis para consulta Probio (MMA, 2014), TerraClass (INPE, 2014) e Canasat (RUDORFF et al., 2011) e também de imagens de média resolução espacial Landsat 5 TM+. Deste total, 13.334 pixels foram separados para serem utilizados como conjunto de treinamento dos modelos de classificação e 6.666 pontos foram deixados para o teste de exatidão dos modelos de classificação.

Após a escolha do classificador que apresentou o melhor desempenho, outros 20.000 pixels foram selecionados para cada ano, e então, geradas as classificações para os anos 2005, 2008 e 2012 no software ENVI 4.5. Após esta classificação os dados foram cruzados espacialmente, obtendo-se os usos anteriores a cana-de-açúcar para os anos de 2008 e 2012.

Para avaliação dos mapeamentos e do acerto na análise da mudança de uso da terra foram gerados aleatoriamente 300 pontos em cada classe mapeada para o ano de 2012. A partir deles, os mapeamentos 2005, 2008 e 2012 foram avaliadas com auxílio de dados dos projetos Probio (MMA, 2014), TerraClass (INPE, 2014) e Canasat (RUDORFF et al., 2011) e também de imagens de média resolução espacial Landsat 5 TM+, e realizada a matriz de confusão para cada ano. Cruzadas estas avaliações para os mapeamentos 2005 e 2008 e também 2008 e 2012 é possível medir o grau de acerto na mudança do uso da terra para cana-de-açúcar deste trabalho.

4.2.3. Resultados e Discussão

A Figura 4.2.4 mostra que na distribuição no histograma de frequência de classes, 'cana-de-açúcar', 'pasto' e 'cerrado' possuem comportamento muito semelhantes, e divergem tanto da classe 'agricultura' como da 'mata'. Assim, visando melhores resultados, o processo de classificação foi dividido em duas etapas: a primeira classificação de três classes 'agricultura', 'mata' e o 'cpc' (junção das classes 'cana-de-açúcar', 'pastagem' e 'cerrado'); a

segunda classificação ocorreu somente para as áreas anteriormente classificadas como ‘cpc’, onde nessa etapa foram diferenciadas as classes ‘cana-de-açúcar’, ‘pastagem’ e ‘cerrado’.




Figura 4.2.4: Histograma de frequência de classes dos parâmetros utilizados.

Anteriormente à geração das classificações dos alvos para os anos de 2005, 2008 e 2012, foram realizados testes com três classificadores: J48, MLP e SMO. Para a seleção daquele que apresenta o melhor resultado para a classificação foram extraídos um conjunto de treinamento e um conjunto de testes da área de trabalho para realização desta avaliação. As Tabelas 4.2.3 e 4.2.4, indicam a fase calibração dos parâmetros dos classificadores MLP e SMO, respectivamente, onde somente foi trabalhado com o conjunto de treinamento no intuito de preservar o conjunto teste para avaliação geral dos três classificadores.

A Tabela 4.2.3 mostra que para a primeira classificação, o aumento na quantidade de nós presente na camada do classificador MLP causou uma melhora pouca acentuada no acerto,

podendo ser escolhido cinco nós para utilizar na classificação. Já para a segunda classificação ocorreu uma grande diferença no acerto tanto total das três classes, como para identificação da cana-de-açúcar, aumentando o número de nós, desta forma foi selecionado dez nós para a realização da avaliação do MLP na segunda classificação. Na Tabela 4.2.4 é identificado o comportamento da classificação para as diferentes combinações para os parâmetros ‘cost’ e ‘gamma’ no classificador SMO, na tentativa de balancear tanto a taxa de acerto total e para a classe relacionada a cana-de-açúcar, foram selecionados para primeira e segunda classificações os valores de gamma de 10^2 e 10^4 , respectivamente, e o valor de custo de 10^1 .

Tabela 4.2.3: Avaliação da calibração MLP.

			Quantidade de Nós									
			1	2	3	4	5	6	7	8	9	10
T. Acerto	1ªClass	Total	0,894	0,987	0,98	0,98	0,98	0,98	0,98	0,982	0,982	0,981
		CPC	0,942	0,981	0,987	0,986	0,988	987	0,981	0,986	0,986	0,986
	2ªClass	Total	0,67	0,791	0,814	0,832	0,839	0,846	0,841	0,843	0,851	0,854
		Cana	0,743	0,765	0,844	0,811	0,807	0,853	0,843	0,825	0,815	0,863

Tabela 4.2.4: Avaliação da calibração SMO.

1class - Acerto Total cost (10^)						2class - Acerto Total cost (10^)							
-4 -2 0 2 4						-4 -2 0 2 4							
gamma (10^)	4	0,751	0,88	0,955	0,96	0,959	gamma (10^)	4	0,509	0,727	0,872	0,878	0,877
	2	0,974	0,981	0,986	0,987	0,986		2	0,822	0,866	0,891	0,895	0,89
	0	0,98	0,981	0,983	0,985	0,986		0	0,808	0,843	0,867	0,883	0,89
	-2	0,977	0,979	0,981	0,982	0,984		-2	0,77	0,8	0,823	0,853	0,872
	-4	0,973	0,955	0,978	0,98	0,982		-4	0,714	0,757	0,785	0,808	0,83
1class - Acerto CPC cost (10^)						2class - Acerto Cana cost (10^)							
-4 -2 0 2 4						-4 -2 0 2 4							
gamma (10^)	4	0,999	0,998	0,997	0,998	0,997	gamma (10^)	4	0,985	0,942	0,908	0,911	0,91
	2	0,993	0,992	0,992	0,99	0,988		2	0,841	0,853	0,866	0,871	0,876
	0	0,987	0,989	0,99	0,99	0,99		0	0,791	0,823	0,846	0,86	0,866
	-2	0,985	0,986	0,988	0,989	0,99		-2	0,768	0,782	0,808	0,835	0,849
	-4	0,981	0,997	0,985	0,986	0,988		-4	0,779	0,757	0,769	0,792	0,815

Na análise comparativa dos resultados apresentados pelos três diferentes algoritmos nesta primeira etapa da classificação, é notável o seu bom desempenho para as classes ‘agricultura’, ‘mata’ e ‘cpc’ (Tabela 4.2.5). Isto é justificável pela maior diferenciação entre as classes desta etapa. Ao analisar os histogramas de frequência de classes (Figura 4.2.4) é notado claramente, na maioria dos atributos, o comportamento distinto da distribuição das classes ‘agricultura’ e ‘mata’ para as demais.

Tabela 4.2.5: Avaliação do teste primeira classificação.

Uso	Taxa Acerto		
	J48	SMO	MLP
Agricultura	0,972	0,986	0,981
Mata	0,96	0,959	0,965
Cana/Pasto/Cerrado	0,98	0,988	0,987

A segunda etapa de classificação apresentou maior dificuldade de diferenciação entre as classes, devido às características dos parâmetros dos alvos se apresentarem muito semelhantes (Tabela 4.2.6). Isto se refletiu na classificação, apresentando um acerto menor em comparação a primeira etapa. De maneira geral os três classificadores, novamente, apresentaram um comportamento semelhante, porém desta vez houve destaque para SMO nas três classes, por isto ele foi o selecionado para a classificação de toda a área de estudo nos três anos.

Tabela 4.2.6: Avaliação do teste da segunda classificação

Classes	Taxa Acerto		
	J48	SMO	MLP
Cana	0,853	0,866	0,856
Pasto	0,842	0,868	0,864
Cerrado	0,838	0,852	0,846

Nas Figuras 4.2.5, 4.2.6 e 4.2.7 são apresentados os mapas com os cinco grandes grupos de uso da terra para os anos de 2005, 2008 e 2012, e sua distribuição espacial na área de estudo.

Na Tabela 4.2.7, são mostrados os valores de acerto para cada alvo estudado, com uma maior certeza para as classes ‘agricultura’ e ‘mata’ e um pior resultado para os outros alvos. ARVOR et al. (2011) realizaram o mapeamento no estado do Mato Grosso utilizando dados NDVI/MODIS, apresentando resultados inferiores para as áreas de agricultura (95,96%), pastagem (74,31%) e mata (85,96%) e resultado superior para cerrado (87,18%). Apesar de ter trabalhado com todo o estado de Mato Grosso, não há menção a cana-de-açúcar em seu trabalho, impossibilitando o conhecimento do tratamento dado à cultura no seu processo de classificação. Esta seria uma informação importante, dada a dificuldade na separação na classificação da cana-de-açúcar, pastagem e cerrado.




Figura 4.2.5: Mapa da classificação do ano 2005.




Figura 4.2.6: Mapa da classificação do ano 2008.




Figura 4.2.7: Mapa da classificação do ano 2012.

Tabela 4.2.7: Avaliação classificação área de estudo dos anos 2005, 2008 e 2012.

Usos	Taxa Acerto		
	2005	2008	2012
Agricultura	0,98	0,96	0,98
Mata	0,96	0,96	0,97
Cana-de-açúcar	0,83	0,82	0,85
Pasto	0,83	0,84	0,83
Cerrado	0,84	0,80	0,82
Total	0,89	0,88	0,89
Kappa	0,86	0,69	0,73

Comparando-se o resultado obtido pela classificação da cana-de-açúcar com aquele de ADAMI et al. (2012b), nota-se uma diferença metodológica, pois, em seu trabalho, a identificação de cana-de-açúcar, realizada de maneira não automatizada, alcançou resultado de 98% de acerto, muito superior ao resultado encontrado (Tabela 4.2.7), 83%, 82% e 85%, respectivamente, para os anos 2005, 2008 e 2012. Ao comparar os resultados obtidos com aqueles que utilizaram séries temporais de índices de vegetação para mapeamento automatizado de cana-de-açúcar, foi notado que MORAES (2012) e FERNANDES et al. (2011) utilizaram a comparação com dados oficiais para a aferição de sua classificação, tendo uma média de variação em comparação aos dados do IBGE de 7,6% e 25,3%, respectivamente. Desta forma, a Tabela 4.2.8 compara os resultados obtidos com os dados oficiais CONAB (2013) e IBGE (2013), mostrando que, na maioria dos casos, os dados apresentaram uma subestimativa com relação aos valores oficiais, porém com uma diferença não superior a 5,9%.

Tabela 4.2.8: Comparação com dados de cana-de-açúcar com dados oficiais estaduais.

	Area (mil ha)		
	2005	2008	2012
Classificação (mil ha)	195,3	210,8	237,5
CONAB (mil ha)	206,0	218,9	246,3
CONAB Variação (%)	5,5	3,8	3,7
IBGE (mil ha)	205,4	223,2	235,5
IBGE Variação (%)	5,2	5,9	-0,8

MORAES (2012) ainda discute que o erro na estimativa ocorre devido, principalmente, à resolução espacial do sensor MODIS, onde cada pixel tem uma área equivalente a 6,25 hectares e resolução temporal (composição) de 16 dias, pois, caso a área identificada como cana-de-açúcar não seja totalmente colhida no mesmo período, ocorre uma descaracterização da forma do perfil temporal de NDVI, e prejudicando, desta forma, o reconhecimento das áreas de cana-de-açúcar. PETRINI et al., (2011), comparando perfis temporais de NDVI/MODIS a partir de pixels puros e não puros de cana-de-açúcar, constataram que há uma mudança do perfil temporal, descaracterizando sua forma, em áreas que não possuem em sua totalidade cana-de-açúcar, podendo este ser uma fonte de erros.

Foram utilizados neste trabalho parâmetros extraídos da série NDVI similares aos utilizados separadamente por ARVOR et al. (2011), MORAES (2012) e FERNANDES et al.

(2011), assim como outros parâmetros. Na maioria dos casos, na comparação do acerto do mapeamento com os trabalhos citados anteriormente, este apresentou um desempenho melhor, devido ao maior número de parâmetros trabalhados para a classificação, pois com eles foi possível obter maiores informações sobre os diferentes alvos e com isso realização de uma classificação com maior acerto.

Tabela 4.2.9: Ocorrência dos erros para cada classe.

	Usos 2012	Predito (%)				
		Agricultura	Mata	Cana-de-Açúcar	Pasto	Cerrado
Real	Agricultura	-	12	5	4	6
	Mata	5	-	2	3	4
	Cana-de-Açúcar	28	32	-	45	37
	Pasto	32	26	42	-	53
	Cerrado	35	30	51	48	-

	Usos 2008	Predito (%)				
		Agricultura	Mata	Cana-de-Açúcar	Pasto	Cerrado
Real	Agricultura	-	6	3	2	3
	Mata	3	-	6	2	2
	Cana-de-Açúcar	33	44	-	52	39
	Pasto	24	32	55	-	56
	Cerrado	40	18	36	44	-

	Usos 2005	Predito (%)				
		Agricultura	Mata	Cana-de-Açúcar	Pasto	Cerrado
Real	Agricultura	-	9	6	4	3
	Mata	9	-	3	5	7
	Cana-de-Açúcar	34	26	-	48	43
	Pasto	27	42	37	-	47
	Cerrado	30	23	54	43	-

Na Tabela 4.2.9 está indicado a proporção dos erros para cada alvo classificado, mostrando quais alvos apresentou maior confusão entre si. Notou-se que a maior parte do erro ocorre com as classes cana-de-açúcar, pasto e cerrado, e pouca confusão com agricultura e mata. No geral, os erros foram baixos, em função do acerto na classificação acima de 96%, sendo que os maiores erros foram também com as classes cana-de-açúcar, pasto e cerrado.

Na análise de mudança de uso da terra para cana-de-açúcar foi necessária a realização de uma avaliação do acerto da classificação para cada pixel em dois anos de mapeamentos diferentes. Isto serviu para que se tenha uma avaliação da certeza que apresenta os valores de

mudança de uso da terra para cana-de-açúcar. A Tabela 4.2.10 apresenta estes valores, mostrando que, quando ‘cana-de-açúcar’ passa a ocupar áreas anteriormente destinadas a agricultura anual, tem-se 80% e 82 % de certeza desta informação, quando a mudança ocorreu, respectivamente, de 2005 para 2008 e 2008 para 2012. Quando o uso anterior foi pastagem e cerrado estes valores foram de 69% e 30%, respectivamente, de em 2005 para 2008, e 66% e 34%, respectivamente, de 2008 para 2012. Esta diferença nos valores, encontrados principalmente para ‘agricultura anual’ em relação as demais, está relacionada a taxa de acerto dos mapeamentos, nos quais a agricultura teve um acerto maior que pastagem e cerrado.

Tabela 4.2.10: Taxa de acerto da avaliação da mudança do uso da terra para cana-de-açúcar

	Acerto Mudança de uso da terra			
	Agricultura	Pastagem	Cerrado	Mata
0405-0708	82%	69%	30%	-
0708-1112	80%	66%	34%	-

Conhecendo-se os erros presentes na análise de mudança de uso da terra para cana-de-açúcar, os valores encontrados na Tabela 4.2.11 apresentaram uma tendência similar aquela descrita por ADAMI et al. (2012a). Na sua análise, realizada para todo Brasil, 65% da cana-de-açúcar sucederam áreas anteriores de pastagem, 34% áreas de agricultura e 1% outros usos da terra. Neste sentido o trabalho encontrou uma proporção de distribuição similar, apresentando, nas duas etapas de estudo a predominância de áreas de pastagem como principal uso anterior à cana-de-açúcar, seguido pela agricultura, como o uso anterior à cana-de-açúcar. Neste caso, o cerrado foi o responsável pelo o restante do uso da terra anterior a cana-de-açúcar, e a mata não apresentou áreas com uso anterior a cana-de-açúcar.

Tabela 4.2.11: Avaliação da mudança do uso da terra.

	Mudança de uso da terra			
	Agricultura	Pastagem	Cerrado	Mata
0405-0708	24%	73%	3%	-
0708-1112	31%	64%	5%	-

4.2.4. Conclusões

1. A utilização de um maior número de parâmetros extraídos da série temporal de NDVI/MODIS possibilitou um melhor desempenho na classificação automatizada, tanto de áreas de cana-de-açúcar como nas de agricultura, pastagem, cerrado e mata.

2. Na comparação com a classificação das áreas de cana-de-açúcar feitas de maneira não automatizada, esta apresentou um desempenho inferior.
3. Como esperado, a maior confusão na classificação aconteceu entre as classes cana-de-açúcar, pastagem e cerrado. Isto ocorreu devido às características semelhantes no comportamento de NDVI ao longo do tempo.
4. O método para identificação da mudança de uso da terra apresentou um erro a ser considerado, porém a tendência de mudança se apresentou de maneira consistente.

5. CONCLUSÕES GERAIS

Os resultados deste trabalho mostraram que a utilização em conjunto de dados MODIS/Terra e MODIS/Aqua, com posterior filtragem da série, apresentou uma melhora no acerto da classificação, sendo o filtro Savitzky-Golay o que apresentou melhor desempenho considerando as classes, cana-de-açúcar, agricultura anual, pastagem, cerrado e mata.

Dos parâmetros analisados, 'Dif_1', 'V_Min', 'V_Min3' e 'Dif_3' foram os que apresentaram maior importância em todos os casos analisados, seguidos por 'Coef_senes' e 'Media'. Os parâmetros adotados referentes a datas apresentaram importância menor que aqueles extraídos de valores de NDVI.

A utilização de um maior número de parâmetros extraídos da série temporal de NDVI/MODIS possibilitou um melhor desempenho na classificação automatizada, tanto de áreas de cana-de-açúcar, como nas de agricultura, pastagem, cerrado e mata, porém na comparação com classificação não automatizada, esta apresentou resultados inferiores. Assim, a identificação da mudança de uso da terra apresenta um erro a ser considerado, porém a tendência de mudança se apresenta de maneira consistente.

6. REFERENCIAS BIBLIOGRÁFICAS

- AHA, D., KIBLER, D. Instance-based learning algorithms. **Machine Learning**. v.6, p.37-66. 1991.
- ADAMI M., RUDORFF B. F. T., FREITAS R.M., AGUIAR D.A., SUGAWARA L.M., MELLO M.P. Remote Sensing Time Series to Evaluate Direct Land Use Change of Recent Expanded Sugarcane Crop in Brazil. **Sustainability**. 4, 574-585; 2012a.
- ADAMI, M.; MELLO, M.P.; AGUIAR, D.A.; RUDORFF, B.F.T.; SOUZA, A.F. A Web Platform Development to Perform Thematic Accuracy Assessment of Sugarcane Mapping in South-Central Brazil. **Remote Sensing**., 4, 3201-3214. 2012b
- ALFONSI, R. R.; PEDRO, M. J.; BRUNINI, O.; BARBIERI, V. Condições climáticas para a cana-de-açúcar. In: Paranhos, S. **Cana-de-açúcar: cultivo e utilização**. São Paulo: Fundação CARGILL, 1987. Capítulo 1, p. 42-87. 1987.
- AHA, D. E KIBLER, D. Instance-based learning algorithms. **Machine Learning**. 6:37-66. 1991
- APAN, A.; HELD, A.; PHINN, S.; MARKLEY, J. Detecting sugarcane ‘orange rust’ disease using EO-1 Hyperion hyperspectral imagery. **International Journal of Remote Sensing**, v.25, n.2, p.489-498, 2004.
- ALCANTARA, P.C.; RADELOFF, V.C.; PRISHCHEPOV, A.; KUEMMERLE, T. Mapping abandoned agriculture with multi-temporal MODIS satellite data. **Remote Sensing of Environment**, v. 124, p. 334–347, 2012.
- ARRAES, C.L. ; ROCHA, J. V. ; LAMPARELLI, R. A. C. ; ESQUERDO, J.C.D.M. ; SALVADOR, P. ; RODRIGUEZ, J. ; ROQUE, J. C. ; JUSTO, J. S. ; BENNATI, B. G. . Reliability of Summer Crop Masks Derived from Second Order Polynomial Equations. **Journal of Agricultural Science**, v.5, p.63-75, 2013.
- ARVOR, D.; DUBREUIL, V. ; BÈGUÈ, A.; SHUMABUKURO, Y. E. Analyzing the agricultural transition in Mato Grosso, Brazil, using satellite-derived indices. **Applied Geography**, v. 32, p. 702–713, 2012.

ARVOR, D. ; JONATHAN, M. ; MEIRELLES, M.S.P. ; DUBREUIL, V. ; DURIEUX, L. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil. **International Journal of Remote Sensing** , p. 1--25, 2011.

BARET, F., E G. GUYOT. Potentials and limits of vegetation indices for LAI and APAR assessment, **Remote Sensing of Environment**, v. 35,p. 161-173, 1991.

BAYARJARGAL, Y., KARNIELI, A., BAYASGALAN, M., KHUDULMUR, S., GANDUSH, C., TUCKER, C. J. A comparative study of NOAA-AVHRR derived drought indices using change vector analysis. **International Journal of Remote Sensing**, v. 105, 9–22. 2006.

BENVENUTTI, F.A. **Relação de índices espectrais de vegetação com a produtividade da cana-de-açúcar e atributos edáficos**. Dissertação (Mestrado em Engenharia Agrícola) - Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas - SP. 2005.

BORLAUG, N. **The green revolution revisited and the road ahead. Special 30th Anniversary Lecture**. Oslo, Norway: The Norwegian Nobel Institute. 23p. 2000.

CARDILLE, J., E FOLEY, J. Agricultural land-use change in Brazilian Amazônia between 1980 and 1995: evidence from integrated satellite and census data. **Remote Sensing of Environment**, 87(4), 551e562. 2003.

BRANNSTROM, C. **South America's neoliberal agricultural frontiers: places of environmental sacrifice or conservation opportunity?** *Ambio*, 38, 141e149. 2009.

CARDILLE, J., E FOLEY, J. Agricultural land-use change in Brazilian Amazônia between 1980 and 1995: evidence from integrated satellite and census data. **Remote Sensing of Environment**, 87(4), 551e562. 2003.

CASTRO, P.R.C. Aplicações da fisiologia vegetal no sistema de produção da cana-de-açúcar. In: Simpósio Internacional de Fisiologia da Cana-de-Açúcar. **Anais..**, Piracicaba, 2000.

CEPEA. **PIB do agronegócio 2012**
<http://www.cepea.esalq.usp.br/comunicacao/Cepea_PIB_BR_dez_2012.pdf>, acesso em 19 de Fevereiro de 2012.

CERQUEIRA, E. O.; POPPI, R. J.; KUBOTA, L. T.; MELLO, C., Utilização de filtro de transformada de fourier para a minimização de ruídos em sinais analíticas. **Química nova**, p. 23-690, 2000.

CHANG, J.; HANSEN, M.C.; PITTMAN, K.; CARROL, M.; DIMICELI, C. Corn and Soybean Mapping in the United States Using MODIS Time-Series Data Sets. **Agronomy Journal**. 99, p. 1654–1664, 2007.

CHEN, J., JÖNSSON, P., TAMURA, M., GU, Z., MATSUSHITA, B., & EKLUNDH, L. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky–Golay filter. **Remote Sensing of Environment**, v.91, p. 332–334. 2004.

CLARK, M. L.; AIDE, T. M.; GRAU, H. R.; RINER, G. A scalable approach to mapping annual land cover at 250 m using MODIS time series data: A case study in the Dry Chaco ecoregion of South America, **Remote Sensing of Environment**, v. 114, n. 1, p. 2816–2832, 2010.

COOPERATIVA DOS PRODUTORES DE CANA, AÇÚCAR E ÁLCOOL DO ESTADO DE SÃO PAULO (COPERSUCAR). **Recomendação de adubação para a cultura da cana-de-açúcar**. Piracicaba – SP: Copersucar, 1988. 7 p.

DILMAGHANI, S., HENRY, I.C., SOONTHORNNONDA, P., CHRISTENSEN, E. R., HENRY, R.C.. Harmonic analysis of environmental time series with missing data or irregular sample spacing. **Environmental Science & Technology**. v. 41, p. 7030–7038. 2007.

DUBREUIL, V. (Environnement et télédétection au Brésil. Rennes: **Presses Universitaires de Rennes**. 2002

ESQUERDO, J. C. D. M. ; COUTINHO, A. C. ; ANTUNES, J. F. G. . Uso combinado de dados NDVI/MODIS dos satélites Terra e Aqua no monitoramento multi-temporal de áreas agrícolas. In: XVI Simpósio Brasileiro de Sensoriamento Remoto, 2013, Foz do Iguaçu-PR. **Anais...** São José dos Campos-SP: INPE, p. 431-437, 2013.

ESQUERDO, J. C. D. M. ; ANTUNES, J. F. G. ; ANDRADE, J. C. . Desenvolvimento do Banco de Produtos MODIS na Base Estadual Brasileira. In: XV Simpósio Brasileiro de Sensoriamento Remoto, 2011, Curitiba-PR. **Anais...** São José dos Campos: INPE,. p. 7596-7602, 2011.

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 – Universidade Estadual de Campinas. 2007.

FAO - Food and Drug Organization of the United Nations. Multiple frame agricultural surveys: agricultural survey programs based on area frame or dual frame (area and list) sample design.(FAO, **Statistical Development Series**, 10). Rome, v.2, 242p., 1998.

FAYYAD, U. M.; PIATESKY-SHAPIO, G.; SMITH, P. **Advances in Knowledge Discovery and Data Mining.** Massachusetts: MIT Press, 560 p. 1996.

FEARNSIDE, P. M. Soybean cultivation as a threat to the environment in Brazil. **Environmental Conservation**, v. 28, p. 23-38. 2002

FERNANDES, J. L.; ROCHA, J. V.; LAMPARELLI, R. A. C. Sugarcane yield estimates using time series analysis of SPOT vegetation images. **Scientia Agricola**, v. 68, p. 139-146, 2011.

FOODY, G. M., E MATHUR, A. The use of small training sets containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by a SVM. **Remote Sensing of Environment**, v. 103, p. 179–189, 2006.

GALFORD, G.L.; MUSTARD, J.F.; MELILLO, J.; GENDRIN, A.; CERRI, C.C.; CERRI, C.E.P. Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil. **Remote Sensing of Environment**. v. 112, p. 576-587, 2008.

GOLDEMBERG, J.; COELHO, S.T.; GUARDABASSI, P. The sustainability of ethanol production from sugarcane. **Energy Policy**, v.36, p. 2086–2097, 2008.

GUYOT G. **Signatures spectrales des surfaces naturelles.** Collection “Télédétection stellitaire”. Caen: Édition Paradigme, p. 178, 1989.

HAN, J.; KAMBER, M. **Data mining: concepts and techniques.** 2^a ed., p. 770., San Francisco: Morgan Kaufmann, 2006.

HANSEN, MC, DEFRIES, RS, TOWNSHEND, JRG, SOHLBERG, R. Global land cover classification at 1km spatial resolution using a classification tree approach. **International Journal of Remote Sensing**, 21, 1331-1364, 2000.

HIRD, J. N.; MCDERMID, G. J. Noisereductionof NDVI time series: an empirical comparison of selected techniques. **Remote Sensing of Environment**, v. 113, n. 1, p. 248-258, 2009.

HOLBEN, B.N.; TUCKER, C.J.; CHENG-JENG, F. Spectral assessment of soybean leaf area and leaf biomass. **Photogrammetric Engineering and Remote Sensing**, v.46, n.5, p.651-656, 1980.

IBGE. Instituto Brasileiro de Geografia e Estatística: Banco de Dados Agregados. Sistema IBGE De Recuperação Automática – SIDRA. <<http://www.sidra.ibge.gov.br/>>, 18/12/2013.

INPE. INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. TerraClass 2010, 2014. Disponível em http://www.inpe.br/cra/projetos_pesquisas/terraclass2010.php. Acessado em abril de 2014,

JEPSON, W. Private agricultural colonization on a Brazilian frontier, 1970-1980. **Journal of Historical Geography**, v. 32, n. 4, p. 839-863, 2006

JOHANN, J. A. ; ROCHA, J. V. ; OLIVEIRA, MEDEIROS, S. R.; RODRIGUES, ANTUNES, L. H.; LAMPARELLI, R. A. C. Data mining techniques for identification of spectrally homogeneous areas using ndvi temporal profiles of soybean crop. **Engenharia Agrícola**, v. 33, p. 511-524, 2013.

JÖNSSON, P. AND EKLUNDH, L., Seasonality extraction by function fitting to time-series of satellite sensor data, **IEEE Transactions on Geoscience and Remote Sensing**, v. 40, p. 1824-1832, 2002.

JUSTICE, C.O.; VERMOTE,e.; TOWNSHEND, J.R.G.; DEFRIES, R.; ROY, D.P.; HALL, D.H.; SALOMONSON, V.V.; PRIVETTE, J.L.; RIGGS, G.; STRAHLER, A.; LUCHT, W.; MYNENI, R.B.; KNYAZIKHIN, Y; RUNNING, S; NEMANI, R.R.; WAN, Z.; HUETE,A.R.; LEEUWEN, W.V.; WOLFE, R.E.; GIGLIO, L.; MULLER, J-P.; LEWIS, P.; BARNSLEY, M.J. The Moderate Resolution Imaging Spectroradiometer (*MODIS*): land remote sensing for

global change research. **IEEE Transactions on Geoscience and Remote Sensing**. v.36, n.4, p.228-1247, 1998.

JUSTICE, C.O.; HIERNAUX, P.H.Y. Monitoring the grasslands of the Sahel using NOAA AVHRR data: Niger, 1983. **International Journal of Remote Sensing**, v.7, n.11, p.1475-1498, 1986.

LABUS, M.P.; NIELSEN, G.A.; LAWRENCE, R.L.; ENGEL, R. Wheat yield estimates using multi-temporal NDVI satellite imagery. **International Journal of Remote Sensing**, v.23, n.20, p. 4169-4180, 2002.

LATORRE, M.L.; SHIMABUKURO, Y.E.; ANDERSON, L.O. **Produtos para ecossistemas terrestres – MODLAND**. p.23-35. Org: RUDORFF, B.F.T.; SHIMABUKURO, Y.E.; CEBALLOS, J.C. O sensor *MODIS* e suas aplicações ambientais no Brasil. São José dos Campos/SP: Parêntese, 423p, 2007.

LHERMITTE, S., VERBESSELT, J., VERSTRAETEN, W.W., VERAVERBEKE S., COPPIN, P., Assessing intra-annual vegetation regrowth after fire using the pixel based regeneration index , **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, p. 17-27. 2011.

MAGALHÃES, A. C. N. **Ecofisiologia da cana-de-açúcar: aspectos do metabolismo do carbono da planta**. In: Castro, P. R. C.; Ferreira, S. O.; Yamada, T. (Coord.) Ecofisiologia da Produção. Piracicaba: Associação Brasileira para pesquisa do Potássio e do Fósforo. p. 113-118. 1987.

MARTINELLI, L.A.; GARRETT, R.; FERRAZ, S.; NAYLOR, R. Sugar and ethanol production as a rural development strategy in Brazil: Evidence from the state of São Paulo. **Agricultural Systems**, v. 104, p. 419-428, 2011.

MATSON, P., PARTON, W., POWER, A., e SWIFT, M. Agricultural intensification and ecosystem properties. **Science**, v. 277, p. 504-509. 1997.

MELILLO, J. M., STEUDLER, P. A., FIEFEL, B. J., NEILL, C., GARCIA, D., PICCOLO, M. C. Nitrous oxide emissions from forests and pastures of various ages in the Brazilian Amazon. **Journal of Geophysical Research**, v. 34, p. 179–34,188. 2001.

- MICHISHITA, R.; JIN, Z.; CHEN, J.; XU, B.. Empirical comparison of noise reduction techniques for NDVI time-series based on a new measure. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 91, p. 17-28. 2014.
- MMA. Ministério do Meio Ambiente. PROBIO, 2014. Disponível em <http://mapas.mma.gov.br/mapas/aplic/probio>. Acessado em abril de 2014
- MITCHELL, T. M. **Machine Learning**. McGrawhill, USA, 1997.
- MORAES, R. A. **Monitoramento e estimativa da produção da cultura de cana-de-açúcar no estado de São Paulo por meio de dados espectrais e agrometeorológicos**. Campinas, SP. 115p. Tese (Doutorado em Engenharia Agrícola). UNICAMP – Universidade Estadual de Campinas. 2012.
- MOREIRA, M.A. **Fundamentos de Sensoriamento Remoto e Metodologias de Aplicação**. 3ed. Viçosa:UFV, 320p, 2005.
- MORTON, D., DEFRIES, R., SHIMABUKURO, Y., ANDERSON, L., ARAI, E., DEL BON ESPIRITO- SANTO, F.. Cropland expansion changes deforestation dynamics in the southern Brazilian Amazon. **Proceedings of the National Academy of Sciences**, v. 103, p. 14637-14641. 2006.
- MUCHAGATA, M., e BROWN, K. Cows, colonists and trees: rethinking cattle and environmental degradation in Brazilian Amazonia. **Agricultural Systems**, v. 76, n.3, p. 797-816. 2003.
- MYERS, N., MITTERMEIER, R. A., MITTERMEIER, C. G., DE FONSECA, G. A. B, e KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, p. 853–858. 2000.
- NEILL, C., DEEGAN, L., THOMAS, S. M., E CERRI, C. C. Deforestation for pasture alters nitrogen and phosphorus in small Amazonian streams. **Ecological Applications**, v. 11, n.6, p. 1817–1828. 2001.
- NEPSTAD, D., SOARES-FILHO, B. S., MERRY, F., LIMA, A., MOUTINHO, P., CARTER, J.. The end of deforestation in the Brazilian Amazon. **Science**, v.326, p. 1350-1351. 2009.

PEÑA-BARRAGÁN, J. M., NGUGI, M. K., PLANT, R. E.. Johan Six Object-based crop identification using multiple vegetation indices, textural features and crop phenology. **Remote Sensing of Environment**, v. 115, p. 1301–1316, 2011.

REES, W.G. **Physical Principles of Remote Sensing**. Cambridge, UK: Cambridge University Press, 247p, 1990.

PETRINI, M. A.; ARRAES, C. L.; ROCHA, J. V. Comparação entre perfis temporais de NDVI e NDVI ponderado em relação ao uso da terra. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15. (SBSR), 2011, Curitiba-PR. **Anais**. São José dos Campos: INPE, 2011. p. 0452-0458. DVD, On-line. ISBN 978-85-17-00057-7. Disponível em: < <http://www.dsr.inpe.br/sbsr2011/files/p1197.pdf>>. Acesso em: 20.novembro.2013.

PINTER JR, P.J. e REGINATO, R.J. A thermal infrared technique for monitoring cotton water-stress and scheduling irrigations. **Transactions of ASAE**, v.25, n.6, p.1651-1655, 1982.

PONZONI, F. J., DISPERATI, A. A. **Comportamento Espectral da vegetação**. Relatório Técnico – INPE. V.1, n.1, p.1–23, 1995.

Press, W.H., Teukolsky, S.A., Vetterling, W.T. and Flannerty, B.P., **Numerical Recipes in C: The Art of Scientific Computing**, 2ª edição, Cambridge University Press, New York, 1992.

PRICE, J.C. Estimating leaf area index from satellite data. **IEEE Transactions on Geoscience and Remote Sensing**, 31, p.727–734, 1993.

ROERINK, G.J.; MENENTI, M.; VERHOEF, W. Reconstructing cloudfree NDVI composites using Fourier analysis of time series. **International Journal of Remote Sensing**, v. 21, n. 9, p.1911-1917, 2000.

ROGAN, J., FRANKLIN, J., STOW, D., MILLER, J., WOODCOCK, C., e ROBERTS, D. Mapping land-cover modifications over large areas: A comparison of machine learning algorithms. **Remote Sensing of Environment**, v. 112, n. 5, p. 2272–2283. 2008.

ROCHA, J.V. **Crop monitoring in South America (MERCOSUR + Bolivia)**. Bulletin no. 7/2006 (August, 2006). Ispra, Italy: JRC (Joint Research Centre), 2006.

RODRIGUES, J.D. **Fisiologia da cana-de-açúcar**. Unesp Botucatu, Instituto de Biociências, Botucatu, 1995.

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**, v. 2, p. 1057-1076. 2010.

RUDORFF, B. F. T., ADAMI, M., AGUIAR, D. A., MOREIRA, M. A., MELLO, M. P., FABIANI, L., et al The soy moratorium in the Amazon biome monitored by remote sensing images. **Remote Sensing**, 3(1), 185e202. 2011.

SANCHES, I. D. A., EPIPHANIO, J. C. N., FORMAGGIO, A. R. Culturas agrícolas em imagens multitemporais do satélite Landsat. **Revista de Economia Agrícola**, v. 52, n. 1, 14p, São Paulo, 2005.

SEILER, R., KOGAN, F., WEI, G., & VINOCUR, M. Seasonal and interannual responses of the vegetation and production of crops in Cordoba, Argentina assessed by AVHRR derived vegetation indices. **Advances in Space Research**, v.39, n. 88–94. 2007.

SKOLE, D., E TUCKER, C. Tropical deforestation and habitat fragmentation in the Amazon: Satellite data from 1978 to 1988. **Science**, v. 260, p. 1905–1910. 1993.

SMEETS, E.; JUNGINGER, M.; FAAIJ, A.; WALTER, A.; DOLZAN, P.; TURKENBURG, W. The sustainability of Brazilian ethanol: An assessment of the possibilities of certified production. **Biomass Bioenergy**, v. 32, p. 781–813. 2008.

SAVITZKY A. E GOLAY M.J.E., Smoothing and Differentiation of Data by Simplified Least Squares Procedures, **Analytical Chemistry**, v. 36, p. 1627–1639, 1964.

VELLEMAN, P., HOAGLIN, D.C., **Applications, basics and computing of exploratory data analyses**. Duxbury Press. 1981

VERBESSELT, J.; HYNDMAN, R. ; ZEILEIS, A.; CULVENOR, D. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. **Remote Sensing of Environment**, v. 2, n. 4, p. 2970-2980, 2010.

VIEIRA, M. A. ; FORMAGGIO, A. R. ; RENNO, C. D. ; ATZBERGER, C. ; AGUIAR, D. A. ; MELLO, M. P. . Object Based Image Analysis and Data Mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. **Remote Sensing of Environment**, v. 123, p. 553-562, 2012.

WARDLOW, B.D.; EGBERT, S.L.; KASTENS, J.H. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. **Remote Sensing of Environment**, v. 108, p. 290-310, 2007.

WARNKEN, P. F. The development and growth of the soybean industry in Brazil. Ames: **Iowa State University Press**. 1999.

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.

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.

WITTEN, I. H.; FRANK, E. **Data mining**: practical machine learning tools and techniques. 2nd ed. San Francisco: Morgan Kaufmann, 525 p. 2005.

ZHANG, X., FRIEDL, M. A., & SCHAAF, C. B. Global vegetation phenology from Moderate Resolution Imaging Spectroradiometer (MODIS): Evaluation of global patterns and comparison with in situ measurements. **Journal of Geophysical Research**, v.111. 2006.