



TÁSSIA BORGES ARANTES

**ANÁLISE DE SÉRIES TEMPORAIS
COMPOSTAS POR IMAGENS SINTETIZADAS
A PARTIR DA FUSÃO DE DADOS MODIS - TM**

**LAVRAS – MG
2014**

TÁSSIA BORGES ARANTES

**ANÁLISE DE SÉRIES TEMPORAIS COMPOSTAS POR IMAGENS
SINTETIZADAS A PARTIR DA FUSÃO DE DADOS MODIS-TM**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Florestal, para obtenção do título de Mestre.

Orientador

Prof. Dr. Luis Marcelo Tavares de Carvalho

**LAVRAS – MG
2014**

**Ficha Catalográfica Elaborada pela Coordenadoria de Produtos e Serviços
da Biblioteca Universitária da UFLA**

Arantes, Tássia Borges.

Análise de séries temporais compostas por imagens sintetizadas a partir da fusão de dados MODIS-TM / Tássia Borges Arantes. – Lavras : UFLA, 2014.

90 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2014.

Orientador: Luis Marcelo Tavares de Carvalho.

Bibliografia.

1. Monitoramento. 2. Dados de sensoriamento remoto. 3. STARFM. 4. Greenbrown. 5. Bfast. I. Universidade Federal de Lavras. II. Título.

CDD – 634.9285

TÁSSIA BORGES ARANTES

**ANÁLISE DE SÉRIES TEMPORAIS COMPOSTAS POR IMAGENS
SINTETIZADAS A PARTIR DA FUSÃO DE DADOS MODIS-TM**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Florestal, para obtenção do título de Mestre.

APROVADA em 17 de Julho de 2014

Dra. Margarete Marin Lordelo Volpato EPAMIG

Dr. Luciano Teixeira de Oliveira UFLA

Prof. Dr. Luis Marcelo Tavares de Carvalho
Orientador

**LAVRAS – MG
2014**

À minha mãe Clara
DEDICO

AGRADECIMENTOS

Primeiramente a Deus, por me proporcionar força e paciência nesta jornada.

À minha família, minha mãe Clara, meus irmãos Eric e Thaís, e minha sobrinha Sofia, que são o motivo por eu estar aqui.

Ao Elcio, pelo companheirismo, pela paciência, pelo amor e pelo apoio imensurável.

Aos colegas e amigos do Laboratório 46, Carol, Polyanne, Lisi e Célio, pelos momentos inesquecíveis e pela ajuda que foi fundamental para o término deste trabalho.

A todos os amigos do mestrado, que deixaram tudo mais divertido.

Ao professor Luis Marcelo (Passarinho) pela orientação, amizade e conhecimento transmitido.

Ao Liliano e Ronaldo pela ajuda fundamental na parte computacional e de programação.

Ao Feng Gao, por ter disponibilizado o algoritmo STARFM, Jan Verbesselt, Matthias Forkel e Feng Tian pela ajuda nos processamentos.

À Universidade Federal de Lavras (UFLA), ao Departamento de Ciências Florestais (DCF), ao Laboratório de Estudos e Projetos em Manejo

Florestal (LEMAF) e ao Programa de Pós Graduação em Engenharia Florestal pela oportunidade concedida para realização do mestrado.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de estudos.

A todos, muito obrigada!

*“Para além da curva da estrada
Talvez haja um poço, e talvez um castelo,
E talvez apenas a continuação da estrada.
Não sei nem pergunto.
Enquanto vou na estrada antes da curva
Só olho para a estrada antes da curva,
Porque não posso ver senão a estrada antes da curva.
De nada me serviria estar olhando para outro lado
E para aquilo que não vejo.
Importemo-nos apenas com o lugar onde estamos.
Há beleza bastante em estar aqui e não noutra parte qualquer.
Se há alguém para além da curva da estrada,
Esses que se preocupem com o que há para além da curva da estrada.
Essa é que é a estrada para eles.
Se nós tivermos que chegar lá, quando lá chegarmos saberemos.
Por ora só sabemos que lá não estamos.
Aqui há só a estrada antes da curva, e antes da curva
Há a estrada sem curva nenhuma.”*

Alberto Caeiro

RESUMO

O monitoramento e a caracterização dos remanescentes de floresta nativa e das áreas antropizadas tornaram-se imprescindíveis para a correta gestão do uso da terra. Uma das ferramentas que podem auxiliar e viabilizar estes estudos, sobre a superfície terrestre, é o sensoriamento remoto. A análise multitemporal de imagens de sensoriamento remoto, integrada aos componentes espectral e espacial, quando devidamente explorados, fornece informações importantes para o monitoramento ambiental, permitindo a análise de padrões complexos e a caracterização da dinâmica de cobertura da superfície terrestre. Em função de algumas limitações nos sensores disponíveis atualmente, no que diz respeito às resoluções, algumas metodologias de fusão entre imagens foram desenvolvidas, entre elas, o STARFM, desenvolvido para estudos que necessitem tanto de uma alta frequência temporal (MODIS) quanto alta resolução espacial (Landsat-TM/ETM+). Assim, objetivou-se neste trabalho avaliar uma série temporal TM, composta por imagens sintéticas, geradas pelo algoritmo de predição STARFM. A área de estudo está localizada ao sul do Estado de Minas Gerais, correspondente à cena Landsat-TM 218/075. Foram adquiridas todas as cenas Landsat-TM e MODIS (cena h13v11) entre 2000 e 2011, cujas bandas NIR e RED foram utilizadas para predição de dados TM. As análises consistiram na comparação de valores de reflectância entre dados TM originais e sintéticos por meio de regressão linear; e na análise das séries temporais MODIS e TM NDVI, para comparação entre as estatísticas das séries, geradas pelo *greenbrown*, e dos componentes temporais de tendência e sazonalidade extraídos dos perfis temporais de algumas classes de uso da terra, gerados pelo *bfast*. Pelos resultados observou-se que, apesar de algumas limitações, o algoritmo STARFM se mostrou bastante promissor na predição das imagens TM; a análise da série temporal NDVI TM sintética fornece maiores detalhes espaciais e temporais do que a série MODIS; a série temporal NDVI composta por imagens TM sintéticas se mostrou bastante semelhante à série MODIS, apresentando a maioria dos *breakpoints* no componente de tendência coincidentes entre as duas séries; os erros na predição das imagens TM podem ocasionar falsas detecções de mudanças. Na análise da série temporal TM forneceram-se maiores detalhes espaciais e temporais do que a série MODIS, sendo uma alternativa para o monitoramento da superfície terrestre em nossa área de estudo.

Palavras-chave: monitoramento, dados de sensoriamento remoto, STARFM, *greenbrown*, *bfast*.

ABSTRACT

Monitoring and characterization of remnants of the native forest and anthropogenic areas are essential for the effective land use management. Remote sensing is one of the most important tools which can assist and aid these studies on the Earth surface. The multi-temporal analysis of remote sensing images, integrated to spectral and spatial components, when properly explored, provides important information for environmental monitoring. It also allows the analysis of complex patterns and characterization of Earth surface covering dynamics. Due to some limitations on the sensors currently available, concerning resolutions, some methodologies of images fusion has been developed, such as the STARFM which is used for studies that require either high time frequency (MODIS) or high spatial resolution (Landsat-TM/ETM+). In this study, we aimed to assess a TM time series comprised by synthetic images, generated using the STARFM prediction algorithm. The study area is located in the southern of Minas Gerais State, Brazil, corresponding to the Landsat-TM 218/075 scene. We acquired all Landsat-TM and MODIS (h13v11 scene) scenes between 2000 and 2011. We used the near infrared (NIR) and red band for prediction of TM data. Analysis consisted in comparing reflectance values among original and synthetic TM data by means of linear regression. We also analysed MODIS and TM NDVI time series to compare statistics of the series generated using greenbrown, and of time components of tendencies and seasonality, obtained from time profiles of some classes of land use, generated using bfast. According to results, although some limitations, the STARFM prediction algorithm was found to be quite promising in predicting TM images. The analysis of TM NDVI time series provided better spatial and time details than the MODIS time series. The NDVI time series, comprised by synthetic TM images was found to be quite similar to MODIS time series, showing the majority of breakpoints in the component of trend coincident between both time series. Errors in predicting TM images can cause false detections of changes. The analysis of TM time series provided better spatial and time details than MODIS time series, so that it can be an alternative for Earth surface monitoring on the area of study.

Key-words: monitoring, remote sensing data, STARFM, greenbrown, bfast.

LISTA DE SIGLAS

AAT	Annual Aggregated Time Series
BFAST	Breaks For Additive Seasonal and Trend
BRDF	Bidirectional Reflectance Distribution Function
CAR	Cadastro Ambiental Rural
CDR	Surface Reflectance Climate Data Record
ESTARFM	Enhanced Spatial and Temporal Adaptive Reflectance Fusion
ETM+	Enhanced Thematic Mapper Plus
Hants	Harmonic ANalysis of Time Series
IAV	Inter-Annual variability
ISTARFM	Integrated STARFM
LandTrendr	Landsat-based detection of Trends in Disturbance and recovery
LEDAPS	The Landsat Ecosystem Disturbance Adaptive Processing System
LOESS	LOcally wEighted regreSion Smoother
MSS	Multispectral Scanner System
MODIS	Moderate Resolution Imaging Spectro-radiometer
NASA	National Aeronautics and Space Administration
NDVI	Normalized Difference Vegetation Index
NIR	Banda do infravermelho próximo
OLI	Operational Land Imager
PCA	Principal Component Analysis
RBV	Return Beam Vidicon Camera
RED	Banda do vermelho
SD	Standard Deviation
STAARCH	Spatial Temporal Adaptive Algorithm for mapping Reflectance Change

STARFM	Spatial and Temporal Adaptative Relfectance Fusion Model
STL	Seasonal-Trend Decomposition
STV	Short Term Variability
TIRS	Thermal Infrared Sensor
TiSeg	Time-series Generator
TM	Thematic Mapper
USGS	United States Geological Survey
UTM	Universal Transversa de Mercator
WRS	Wolrdwide Reference System
6 S	Second Simulation of Satellite Signal in the Solar Spectrum

SUMÁRIO

1	INTRODUÇÃO.....	13
2	REFERENCIAL TEÓRICO.....	18
2.1	Sensores remotos e o monitoramento da vegetação.....	18
2.2	Séries temporais de dados de sensoriamento remoto	25
2.3	Fusão entre imagens	33
3	METODOLOGIA	38
3.1	Área de estudo e dados	38
3.2	Fusão MODIS -TM usando o algoritmo STARFM	40
3.3	Avaliação das imagens TM sintéticas.....	43
3.3.1	Regressão linear	44
3.3.2	Séries temporais NDVI.....	46
3.3.2.1	<i>Greenbrown</i>	47
3.3.2.2	BFAST.....	48
4	RESULTADOS E DISCUSSÃO.....	51
4.1	Análise geral das predições	51
4.2.	Avaliação das imagens TM sintéticas.....	54
4.2.1	Regressão linear	54
4.2.2	Comparação e caracterização das séries temporais TM e MODIS.....	60
4.2.2.1	Parâmetros das séries temporais obtidos pelo <i>greenbrown</i>	60
4.2.2.2	Análise dos perfis temporais	71
5	CONCLUSÕES.....	80
6	TRABALHOS FUTUROS	81
	REFERÊNCIAS.....	83

1 INTRODUÇÃO

Nos últimos anos, tem-se discutido muito sobre as mudanças no Código Florestal Brasileiro e suas implicações práticas tanto para o agronegócio quanto para o meio ambiente e a conservação da biodiversidade. Nessa nova perspectiva instituída pelo Código Florestal Brasileiro, o monitoramento e a caracterização dos remanescentes de floresta nativa e das áreas antropizadas tornaram-se imprescindíveis para a correta gestão do uso da terra. Uma das ferramentas que podem auxiliar e viabilizar estes estudos sobre a superfície terrestre é o sensoriamento remoto.

A partir da década de 70, dados de sensoriamento remoto a bordo de satélites têm possibilitado aos cientistas visualizarem a verdadeira dimensão dos impactos ao meio ambiente causados pelo homem (COHEN; GOWARD, 2004). Outra vantagem, do uso do sensoriamento remoto, é que a maioria dos satélites fornece imagens sistemática e regularmente, permitindo a análise temporal dos dados. Essa análise multitemporal de imagens de sensoriamento remoto, integrada aos componentes espectral e espacial, quando devidamente explorados, fornece informações importantes para o monitoramento ambiental, permitindo a análise de padrões complexos e a caracterização da dinâmica de cobertura da superfície terrestre (BRUZZONE; SMITS; TILTON, 2003).

Por meio da análise de séries temporais, é possível detectar tendências na assinatura temporal, permitindo diferenciar uma mudança natural, geralmente temporária, de uma mudança ocorrida por atividade antrópica, que pode ser permanente (COPPIN et al., 2004). Outro aspecto que pode ser analisado é a fenologia da vegetação, que é bem característica para cada tipo de uso da terra. Ou seja, pela análise de uma série temporal permite-se saber se houve ou não mudança na paisagem e qual o tipo de mudança. Essas mudanças podem ocorrer

de três maneiras: mudança abrupta, que ocorre num curto intervalo de tempo, como desmatamentos e incêndios; gradual, que ocorre num intervalo de tempo maior, tal como incremento de biomassa numa floresta, ou um processo de degradação do solo; e sazonal, que são mudanças ocorridas em virtude de variações climáticas, como temperatura e regime de chuvas (VERBESSELT et al., 2010a, 2010b; VERBESSELT; ZEILEIS; HEROLD, 2012).

As imagens, obtidas pelos sensores dos satélites Landsat, são largamente usadas para o monitoramento da superfície terrestre, principalmente, porque é a série de satélites que fornecem imagens, sistematicamente, em média resolução espacial há mais tempo, desde a década de 1970 (COHEN; GOWARD, 2004), sendo o sensor Thematic Mapper – TM, o mais utilizado. Porém, em regiões tropicais, a frequente cobertura de nuvens pode comprometer ou mesmo inviabilizar a análise multitemporal desses dados e, somado a isso, algumas imagens Landsat não estão disponíveis em certas datas, dificultando o uso contínuo destas imagens. Uma alternativa para contornar estas dificuldades seria o uso de imagens do sensor MODIS, a bordo do satélite Terra, que possuem uma resolução temporal melhor (1 ou 2 dias), o que melhora, significativamente, a composição da série temporal. Porém, dados de satélite de alta frequência temporal, muitas vezes, possuem baixa resolução espacial, o que não é ideal para estudos em regiões onde existe uma alta fragmentação da paisagem, já que os componentes que a formam podem ser pequenos, indetectáveis para tais sensores. O sensor MODIS, por exemplo, possui resolução espacial de 250, 500 ou 1000 metros, a depender da banda. Portanto, algumas limitações tecnológicas, no que concerne às características espaciais, espectrais e temporais dos sensores impedem a caracterização mais detalhada de fenômenos que ocorrem na superfície terrestre (HILKER et al., 2009a).

Em função dessas limitações nos sensores disponíveis atualmente, algumas metodologias de fusão entre imagens foram desenvolvidas (ACERBI-

JUNIOR; CLEVERS; SCHAEPMAN, 2006; Busetto; Meroni; Colombo, 2008; Hansen et al., 2008; Hilker et al., 2009b; Roy et al., 2008; Zhu et al., 2010). O principal objetivo da fusão entre imagens é gerar um produto com melhor qualidade do que os originais, integrando dados espaciais, espectrais (Acerbi-Junior; Clevers; Schaezman, 2006) e temporais (Gao et al., 2006; Hilker et al., 2009a; Zhu et al., 2010) do mesmo sensor ou entre sensores diferentes.

Os primeiros trabalhos sobre fusão de imagens tinham como objetivo a fusão entre bandas multiespectrais com a banda pancromática, de melhor resolução espacial. Acerbi-Junior, Clevers e Schaezman (2006) avaliaram a fusão entre dados MODIS e TM, utilizando transformada wavelet, a fim de mapear áreas de Cerrado, um dos primeiros trabalhos utilizando estes dois sensores para fusão. Porém, essas técnicas não são capazes de melhorar a resolução espacial e temporal, simultaneamente, o que não é ideal para estudos sobre a dinâmica da vegetação, já que o componente temporal é fundamental para estudos sobre a variabilidade inter e intra-anual (Zhu et al., 2010).

Outras metodologias de fusão foram desenvolvidas para agregar dados espaciais com dados temporais. Um destes algoritmos de fusão entre o sensor MODIS e os sensores do satélite Landsat foi desenvolvido por Gao et al. (2006), o STARFM – Spatial and Temporal Adaptive Reflectance Fusion Model, o qual foi desenvolvido para estudos que necessitem tanto de uma alta frequência temporal quanto alta resolução espacial. Posteriormente, outros algoritmos que têm como base o STARFM foram desenvolvidos, como o STAARCH (Zhu et al., 2010) e o ESTARFM (Hilker et al., 2009b), com o objetivo de melhorar alguns aspectos do STARFM.

Muitos trabalhos, utilizando este tipo de algoritmo, foram feitos, principalmente, para estudos sobre a fenologia da vegetação em regiões de florestas boreais e sub-boreais (Hilker et al., 2009a), em florestas

semidecíduais (WALKER; DE BEURS; WYNNE, 2014; WALKER et al., 2012), florestas naturais de eucalipto (BHANDARI; PHINN; GILL, 2012); sobre a viabilidade do uso de imagens preditas para o mapeamento de áreas agrícolas (WATTS et al., 2011), para o monitoramento das mudanças ocorridas na vegetação pelas séries temporais (TIAN et al., 2013); para detecção de eventos de distúrbio (HILKER et al., 2009b); caracterização de paisagens heterogêneas (ZHU et al., 2010), entre outros. Os resultados foram bastante promissores, mas cada algoritmo tem suas vantagens e limitações. A escolha de cada um depende do objetivo e da região onde será realizado o estudo.

Porém, nenhum destes algoritmos que integram dados espaciais e temporais foi testado em regiões do Brasil. Muitos trabalhos foram feitos, utilizando séries temporais, porém, estas geralmente eram curtas ou não contínuas e, quando contínuas, compostas por imagens de baixa resolução espacial. Nenhum trabalho utilizando uma série temporal longa e densa foi desenvolvido com o uso de imagens com melhor resolução espacial, e um dos motivos pode ser, justamente, a frequente cobertura de nuvens. Assim, a utilização de uma série temporal composta por imagens Landsat-TM preditas, pode ser uma alternativa para o monitoramento dos remanescentes de floresta nativa no Brasil.

A utilização de dados de sensoriamento remoto que integram alta resolução espacial e alta frequência temporal pode ser um valioso instrumento aos órgãos competentes para o exercício da fiscalização, principalmente, com aprovação do novo Código Florestal Brasileiro, Lei 12.651 de 2012, que estabelece a criação do Cadastro Ambiental Rural – CAR (BRASIL, 2012).

O CAR tem a finalidade de compor uma base de dados com as informações de cada propriedade rural do Brasil, para o ‘controle, monitoramento, planejamento ambiental e econômico e combate ao desmatamento’ (BRASIL, 2012). Vem como um instrumento para assegurar o

cumprimento da lei, que determina um percentual de área de Reserva Legal e Áreas de Preservação Permanente, em cada propriedade, cada uma com sua função, mas como o principal objetivo a conservação da biodiversidade (BRASIL, 2012).

Por causa da grande extensão territorial do país, a construção dessa base de dados só será possível com a utilização de dados de sensoriamento remoto, os quais serão utilizados para o mapeamento de áreas de remanescente nativo e de uso antrópico. Assim, será possível saber quais proprietários rurais estão em desacordo com a legislação, que terão um prazo para a recomposição das áreas de remanescente. Com a análise de uma série temporal, será possível caracterizar as mudanças que ocorreram ou que estão ocorrendo nessas áreas, como, por exemplo, desmatamentos, degradação do solo ou mesmo a regeneração florestal.

Diante do exposto, objetivou-se neste trabalho avaliar uma série temporal do sensor TM, composta por imagens sintéticas, geradas pelo algoritmo de predição STARFM. Uma série temporal composta por imagens de alta resolução espacial e alta frequência temporal poderá fornecer informações detalhadas sobre as mudanças que ocorrem na superfície terrestre.

Objetivos específicos:

- 1) Avaliar a eficácia do algoritmo STARFM na predição de valores de reflectância de imagens TM.
- 2) Comparar parâmetros estatísticos derivados das séries temporais TM sintéticas, com aqueles derivados das séries temporais MODIS.
- 3) Comparar e analisar padrões de tendência, sazonalidade e mudanças abruptas nos perfis temporais de diferentes classes de uso da terra.

Pergunta científica:

Algoritmos de fusão que agregam dados espaciais e temporais, como o STARFM, são eficazes para o monitoramento das mudanças no uso da terra?

2 REFERENCIAL TEÓRICO

2.1 Sensores remotos e o monitoramento da vegetação

Levantamentos de campo são fundamentais para a compreensão do papel que fatores locais desempenham no reestabelecimento da vegetação. Entretanto, o número de povoamentos analisados é, muitas vezes, menor do que o requerido para validar as relações estatísticas entre os fatores bióticos e abióticos que influenciam, por exemplo, na regeneração da floresta (SCHROEDER; COHEN; YANG, 2007). Além disso, estudos em longo prazo requerem observações de campo, em vários anos, o que demanda uma continuidade de pessoal, equipamentos e recursos financeiros (HALL et al., 1991). Estas limitações podem ser superadas com o uso de imagens obtidas por meio de sensoriamento remoto, o que aumenta, significativamente, o número de povoamentos disponíveis para modelagens estatísticas, proporcionando uma melhor interpretação das características ambientais (SCHROEDER; COHEN; YANG, 2007).

O sensoriamento remoto pode ser definido como:

Processo de captação de informações dos fenômenos e feições terrestres, por meio de sensores, sem contato direto com os mesmos, associado a metodologias e técnicas de armazenamento, tratamento e análise destas informações (FIGUEIREDO 2005).

Os sistemas de sensoriamento remoto, principalmente aqueles a bordo de satélites, fornecem uma visão sistemática e consistente da superfície terrestre, o que permite o monitoramento em curto e longo prazos das mudanças e

impactos causados pela atividade humana (SHOWENGERDT, 2007). Satélites são instrumentos colocados a grandes altitudes, geralmente entre 600 e 1000 quilômetros, com a capacidade de adquirir dados de uma grande porção da superfície terrestre, relacionados às propriedades primárias dos objetos (capacidade de reflexão e emissão de energia eletromagnética) (EIPHANIO et al., 2010), por meio de diversos tipos de sensores.

Os sensores remotos medem alguma grandeza física de interesse, como, por exemplo, a radiação eletromagnética, depois de esta ter interagido com a superfície terrestre e com a atmosfera, sendo assim, cada alvo emite ou reflete essa radiação de forma diferente, para cada comprimento de onda do espectro eletromagnético, o que nos possibilita identificar os diferentes objetos de interesse (CARVALHO; DUTRA, 2008).

Imagens de sensoriamento remoto têm sido amplamente utilizadas para detecção de mudanças no uso e cobertura da terra (GRIFFITHS et al., 2012; KENNEDY; COHEN; SCHROEDER, 2007; LHERMITTE et al., 2011; SCHROEDER et al., 2011). Os estudos em detecção de mudança com o uso do sensoriamento remoto são ricos em estudos de caso, métodos e aplicações, em uma ampla gama de situações práticas (KENNEDY; COHEN; SCHROEDER, 2007). Além disso, os dados de sensoriamento remoto são uma alternativa às pesquisas de campo, que, muitas vezes, são trabalhosas, caras e limitadas em alcances temporal e espacial.

A capacidade técnica dos sensores a bordo de satélites depende de quatro resoluções: (a) *espacial*, que se refere ao tamanho do pixel da imagem gerada, sendo o pixel corresponde à menor parcela imageada; (b) *radiométrica*, que se refere à intensidade da radiância da área de cada pixel que o sensor é capaz de medir, representado por valores numéricos ou nível de cinza, a depender da quantidade de bits de cada sensor (por exemplo, uma imagem de 2 bits possui apenas 4 níveis de cinza, e uma imagem de 8 bits, 256 níveis de

cinza); (c) *espectral*, que se refere ao número de bandas do sensor, sua largura e posição em que estão situadas no espectro eletromagnético; e (d) *temporal*, que corresponde à periodicidade com que o satélite revisita a mesma área (FIGUEIREDO, 2005; MENESES et al., 2012).

Um dos satélites mais usados para estudos da superfície terrestre é o Landsat. O primeiro satélite da série Landsat foi lançado no início dos anos 1970 (COHEN; GOWARD, 2004; EIPHANIO et al., 2010), sendo o primeiro veículo espacial implantado, para o monitoramento terrestre, utilizado até hoje (UNITED STATES GEOLOGICAL SURVEY - USGS, 2014). Atualmente, os principais satélites da série Landsat que são utilizados em pesquisas são o Landsat 5, Landsat 7 e Landsat 8. O sensor Thematic Mapper (TM), a bordo do Landsat 5, tem disponibilizado imagens desde 1984, já o Landsat 7, que possui o sensor Enhanced Thematic Mapper Plus (ETM+), desde 1999 e, atualmente, o Landsat 8, disponibiliza imagens dos sensores OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*), em órbita desde 2013 (USGS, 2014). Na Tabela 1, são mostradas as missões dos satélites da série Landsat.

Tabela 1 Datas das missões Landsat e sensores de cada satélite.

Satélite	Lançamento	Desativação	Sensores
Landsat 1	23 julho, 1972	6 janeiro, 1978	MSS/RBV
Landsat 2	22 janeiro, 1975	27 julho, 1983	MSS/RBV
Landsat 3	5 março, 1978	7 setembro, 1983	MSS/RBV
Landsat 4	16 julho, 1982	15 junho, 2001	MSS/TM
Landsat 5	1 março, 1984	2013	MSS/TM
Landsat 6	5 outubro, 1993	Não alcançou órbita	ETM
Landsat 7	15 abril, 1999	Em operação	ETM+
Landsat 8	11 fevereiro, 2013	Em operação	OLI/TIRS

Fonte: USGS (2014).

O sensor TM, o qual possui a série temporal mais longa, com resolução espacial de 30 m (120 metros na banda termal) e temporal de 16 dias. Cada imagem cobre uma área de 185 x 172 km, quantifica a radiância em 256 níveis de cinza (8 bits) e possui sete bandas no espectro eletromagnético, no intervalo de 0,45 a 2,35 μm (NATIONAL AERONAUTICS AND SPACE ADMINISTRATION - NASA, 2012), conforme Tabela 2.

Tabela 2 Especificações das bandas do sensor TM.

Banda espectral	Comprimento de onda (micrômetros)	Resolução espacial (metros)	Uso
Banda 1 – azul-verde	0,45-0,52	30	Mapeamento batimétrico; distingue solo da vegetação, vegetação conífera de decídua.
Banda 2 – verde	0,52-0,61	30	Realça a vegetação, útil para avaliar o vigor da vegetação.
Banda 3 – vermelho	0,63-0,69	30	Realça os declives da vegetação.
Banda 4 – Infra-vermelho	0,76-0,90	30	Realça o teor de biomassa e encostas.
Banda 5 – Infra-vermelho	1,55-1,75	30	Discrimina conteúdo de umidade do solo e da vegetação; capaz de penetrar nuvens finas.
Banda 6 – termal	10,4-12,5	120	Útil para mapeamento termal e estimativa da umidade do solo.
Banda 7 – Infra-vermelho	2,08-2,35	30	Útil para mapeamento de rochas alteradas hidrotermalmente associadas com depósitos minerais.

Fonte: USGS (2014)

O uso de dados adquiridos pelo Landsat traz inúmeras vantagens, quando se trata de monitoramentos: primeiro, com mais de 30 anos de imagens da Terra, oferece a série temporal mais longa de dados, sistematicamente, coletados de sensoriamento remoto; segundo, a resolução espacial dos dados, que facilita a caracterização da cobertura da terra, bem como as mudanças que ocorrem; terceiro, o TM e mais tarde o ETM+ e o OLI, que adquirem medições espectrais em todas as grandes porções do espectro eletromagnético solar (visível, infravermelho próximo, infravermelho médio), oferecendo vantagens sobre sistemas de sensores menos capazes; e por último, nos últimos anos, os dados Landsat se tornaram mais acessíveis, assim como os computadores necessários para processar esses dados, tornando possível adquirir e analisar grande volume de informações (COHEN; GOWARD, 2004).

Porém, em regiões tropicais, a frequente cobertura de nuvens pode comprometer ou mesmo inviabilizar a análise dos dados e, somado a isso, algumas imagens Landsat não estão disponíveis em certas datas, dificultando o uso contínuo destas imagens.

Outro importante sensor, utilizado para o estudo do sistema terrestre, é o *Moderate Resolution Imaging Spectro-radiometer* – MODIS, a bordo dos satélites Terra e Aqua, lançados em 1999 e 2002, respectivamente. O sensor MODIS foi desenvolvido e projetado para amplos estudos da Terra e suas mudanças temporais e geofísicas (XIONG et al., 2009). Possui as seguintes características: (a) resolução temporal de dois dias; (b) resolução radiométrica de 12 bits (4096 níveis de cinza); e (c) 36 bandas espectrais contidas no intervalo de 0,4 a 14,4 μm do espectro eletromagnético; duas bandas apresentam resolução espacial de 250 m, em outras cinco bandas, de 500 m e as demais de 1 km; (d) a área imageada é de 1200 km² (SOARES; BATISTA; SHIMABUKURO, 2007). Na Tabela 3 são mostradas as especificações para cada banda do sensor MODIS.

Tabela 3 Especificações do espectrorradiômetro MODIS com requisitos de desempenho e aplicações projetadas para as 36 bandas.

Uso Principal	Banda	Largura da banda	Radiância espectral	Requisito de NEΔT
Terra/Nuvens/Aerossóis Limites	1	620 - 670	21.8	128
	2	841 - 876	24.7	201
Terra/Nuvens/Aerossóis Propriedades	3	459 - 479	35.3	243
	4	545 - 565	29.0	228
	5	1230 - 1250	5.4	74
	6	1628 - 1652	7.3	275
	7	2105 - 2155	1.0	110
Cor do Oceano/ Fitoplâncton/ Biogeoquímica	8	405 - 420	44.9	880
	9	438 - 448	41.9	838
	10	483 - 493	32.1	802
	11	526 - 536	27.9	754
	12	546 - 556	21.0	750
	13	662 - 672	9.5	910
	14	673 - 683	8.7	1087
	15	743 - 753	10.2	586
	16	862 - 877	6.2	516
Vapor d'água atmosférico	17	890 - 920	10.0	167
	18	931 - 941	3.6	57
	19	915 - 965	15.0	250
Temperatura Superfície/nuvens	20	3.660 - 3.840	0.45(300K)	0.05
	21	3.929 - 3.989	2.38(335K)	2.00
	22	3.929 - 3.989	0.67(300K)	0.07
	23	4.020 - 4.080	0.79(300K)	0.07
Temperatura atmosférica	24	4.433 - 4.498	0.17(250K)	0.25
	25	4.482 - 4.549	0.59(275K)	0.25
Vapor d'água de Nuvens Cirrus	26	1.360 - 1.390	6.00	150(SNR)
	27	6.535 - 6.895	1.16(240K)	0.25
	28	7.175 - 7.475	2.18(250K)	0.25

Continua...

Tabela 3 Continuação.

Uso Principal	Banda	Largura da banda	Radiância espectral	Requisito de NE Δ T
Propriedade de nuvens	29	8.400 - 8.700	9.58(300K)	0.05
Ozônio	30	9.580 - 9.880	3.69(250K)	0.25
Temperatura da superfície/nuvens	31	10.780 - 11.280	9.55(300K)	0.05
	32	11.770 - 12.270	8.94(300K)	0.05
Altitude de topo de nuvens	33	13.185 - 13.485	4.52(260K)	0.25
	34	13.485 - 13.785	3.76(250K)	0.25
	35	13.785 - 14.085	3.11(240K)	0.25
	36	14.085 - 14.385	2.08(220K)	0.35

Obs: bandas 1 a 19 estão em nm e as bandas 20 a 36 estão em μm , radiância espectral em $(\text{W m}^{-2} \mu\text{m}^{-2} \text{sr}^{-1})$; SNR = taxa sinal-ruído; NE Δ T = Variação da temperatura equivalente de ruído. O objetivo de desempenho é 30-40% melhor que o requisito.

Fonte: Soares, Batista e Shimabukuro (2007)

O sensor MODIS gera produtos de alta qualidade se comparado com outros sensores, graças à melhoria na qualidade dos detectores e no sistema de imageamento, maior número de bandas, além de algoritmos específicos para a geração dos produtos. Algumas bandas do MODIS são exclusivas para a correção atmosférica de outras bandas, o que melhora, significativamente, a qualidade dos dados. Outra vantagem do MODIS é a qualidade geométrica das imagens, aspecto fundamental para o monitoramento das modificações da superfície terrestre (SOARES; BATISTA; SHIMABUKURO, 2007). Por fim, os produtos MODIS são disponibilizados gratuitamente, o que viabiliza seu uso em um grande número de aplicações.

Porém, dados de satélite de alta frequência temporal, muitas vezes, possuem baixa resolução espacial, o que não é ideal para estudos em regiões complexas e heterogêneas, já que os componentes da paisagem, muitas vezes, são pequenos, o que os tornam indetectáveis para tais sensores.

2.2 Séries temporais de dados de sensoriamento remoto

Os ecossistemas estão em um estado de constante mudança, numa variedade de escalas espaciais e temporais. Porém, a maioria das metodologias aplicadas para detecção de mudança, foca apenas na diferença entre duas imagens – uma antes e outra depois da mudança, análise bitemporal (COPPIN et al., 2004), o que impede a detecção de tendências em longo prazo (KENNEDY; COHEN; SCHROEDER, 2007). A análise bitemporal de detecção de mudanças tem dois problemas: a data de aquisição das imagens (em razão das diferenças de sazonalidade) e o intervalo de tempo da mudança (resolução temporal) (COPPIN et al., 2004). Como consequência, a imagem produzida, com base na diferença entre as duas imagens, gera resultados não muito confiáveis, pois está sujeita a erros de registro das imagens, das condições atmosféricas nas datas de imageamento e à própria fenologia da vegetação (CARVALHO; DUTRA, 2008).

Para contornar estes entraves, alguns pesquisadores têm abordado o monitoramento dos ecossistemas, por meio de séries temporais, com o qual é possível avaliar o perfil temporal e os componentes de tendência e sazonalidade.

De acordo com Morettin e Tolo (2004, p. 1), “uma série temporal é qualquer conjunto de observações ordenadas no tempo”. Segundo os mesmos autores, a análise de uma série temporal permite prever valores futuros da série e verificar a existência de tendências e periodicidades nos dados.

Diversos trabalhos têm sido feitos com o uso de séries temporais de dados de sensoriamento remoto para o estudo da superfície terrestre. Os primeiros trabalhos desenvolvidos foram realizados, principalmente, para melhorar o mapeamento da cobertura do uso da terra, utilizando dados multitemporais, representando os estágios fenológicos da vegetação. Engvall, Tubbs e Holmes (1977) desenvolveram um procedimento para classificar campos de trigo, baseado na informação de tendência temporal de imagens do sensor MSS (*MultiSpectral Scanner*), a bordo do satélite Landsat, utilizando imagens em, pelo menos, três estágios de crescimento da lavoura. Badhwar, Austin e Carnes (1982) desenvolveram uma técnica de classificação de áreas agrícolas, baseada em características temporais de, pelo menos, quatro imagens TM. Conese e Maselli (1991) avaliaram a contribuição da informação multiespectral, para a discriminação de diferentes tipos de usos da terra, em uma paisagem heterogênea, onde foram utilizadas imagens TM adquiridas em três diferentes estágios da fenologia da vegetação. Em todos estes trabalhos, os dados temporais melhoraram os resultados dos mapeamentos.

Com o passar dos anos, outras metodologias foram desenvolvidas para agregar dados temporais aos dados espectrais de sensores remotos. Séries temporais de dados de sensoriamento remotos são utilizadas para caracterizar a fenologia da vegetação (AHL et al., 2006; KOLTUNOV et al., 2009; OLIVEIRA et al., 2012; SAKAMOTO et al., 2005; VERBESSELT et al., 2010b; XIAO et al., 2006; ZHANG et al., 2003, 2012), para análise de mudanças e mapeamento no uso da terra (ALCANTARA et al., 2012; FREITAS; SHIMABUKURO, 2008; GRIFFITHS et al., 2012; OHMANN et al., 2012; SCHROEDER et al., 2011; STELLMES et al., 2010; SULLA-MENASHE et al., 2013; VERBESSELT; ZEILEIS; HEROLD, 2012; VIEIRA et al., 2012; VOGELMANN et al., 2012; XIAO et al., 2005; YUAN et al., 2005; ZHONG; GONG; BIGING, 2014).

O componente temporal possibilita observar padrões complexos e analisar a dinâmica de cobertura da superfície. Além disso, a palavra “monitoramento” assume, implicitamente, o domínio temporal das observações, o que claramente enfatiza o papel que imagens multitemporais de sensoriamento remoto podem desempenhar em todos os domínios de aplicações associadas com a dinâmica dos processos ambientais e antropológicos (BRUZZONE; SMITS; TILTON, 2003).

Entende-se por “trajetória” uma série de estados por meio dos quais um sistema procede ao longo do tempo (SCHROEDER; COHEN; YANG, 2007). As detecções de mudanças, baseadas em uma análise da trajetória temporal, são feitas comparando-se a mesma área com múltiplas imagens em intervalos de tempo mais longos (análise multitemporal) (COPPIN et al., 2004). Segundo os mesmos autores, as taxas de mudanças podem ser abruptas, como, por exemplo, causadas por incêndios, ou graduais, tais como acúmulo de biomassa. Muitos fenômenos associados com mudanças nas florestas têm características temporais distintas antes e depois do evento de mudança, que levam a assinaturas temporais no espaço espectral (KENNEDY; COHEN; SCHROEDER, 2007).

O principal desafio, no monitoramento de mudanças no uso da terra, por meio de séries temporais são os ruídos, que podem afetar a detecção de mudanças ou até mesmo criar fenômenos irreais. As causas de tais ruídos podem ser diferenças na absorção e espalhamento atmosféricos em decorrência de variações na concentração de vapor d'água e aerossóis, em momentos diferentes, variações temporais no zênite solar e/ou ângulos de azimute e, ainda, inconsistência na calibração dos sensores em imagens separadas. Sendo assim, o pré-processamento das imagens, antes da detecção de mudanças reais, é essencial, pois permite uma ligação mais direta entre os dados orbitais e os fenômenos biofísicos, a remoção de erros de aquisição de dados e ruídos da

imagem e, ainda, o mascaramento de cenas contaminadas por nuvens, por exemplo (COPPIN et al., 2004).

Além disso, a utilização de séries temporais aumenta ainda mais a complexidade, geralmente, associada com o tratamento de uma única imagem (BRUZZONE; SMITS; TILTON, 2003). Segundo os mesmos autores, a presença do componente temporal deve ser devidamente considerada nos procedimentos de processamento dos dados, além de algoritmos capazes de explorar as relações entre imagens adquiridas, na mesma área geográfica, em momentos diferentes.

Após o pré-processamento, as imagens, geralmente, são transformadas em índices de vegetação. Índices de vegetação são transformações espectrais de duas ou mais bandas, com o intuito de realçar as propriedades espectrais da vegetação, o que permite comparações temporais e espaciais confiáveis da atividade fotossintética terrestre e variações na estrutura do dossel. Como uma simples transformação de bandas espectrais, os índices de vegetação são computados diretamente, sem qualquer tendência ou suposições a respeito da classe de cobertura da terra, tipo de solo, ou condições climáticas. Eles nos permitem monitorar as variações sazonais, interanuais e em longo prazo dos parâmetros estruturais, fenológicos e biofísicos da vegetação (HUETE et al., 2002).

Índices de vegetação espectrais baseados na reflectância do dossel contrastantes nas faixas de ondas do vermelho e do infravermelho próximo são, frequentemente, aplicados em estudos da cobertura vegetal, sendo o NDVI (*Normalized Difference Vegetation Index*) um dos mais usados (GAMON et al., 1995), calculado pela seguinte fórmula:

$$NDVI = (\rho_{NIR} - \rho_{RED}) / (\rho_{NIR} + \rho_{RED}) \quad (1)$$

em que: ρ_{NIR} e ρ_{RED} indicam os valores de reflectância nas regiões do infravermelho próximo e do vermelho, respectivamente (ROUSE et al., 1974). A escolha dessas bandas se baseia no fato de que as plantas utilizam a radiação vermelha para a fotossíntese, resultando em sua baixa reflectância, enquanto a radiação infravermelha é refletida, o que resulta em sua alta reflectância (VICTORIA; OLIVEIRA; GREGO, 2008).

O NDVI fornece um valor, suficientemente, estável para permitir comparações significativas de variações sazonais e interanuais do crescimento e atividade da vegetação (HUETE et al., 2002), podendo ser um ótimo índice, que juntamente com a análise da série temporal, podem fornecer informações necessárias sobre diferentes classes de uso da terra.

Algumas metodologias têm sido desenvolvidas com intuito de extrair trajetórias temporais de mudanças na superfície da terra pelos índices de vegetação, além de eliminar os ruídos que causam alterações na interpretação dos resultados. A seguir, a descrição de algumas dessas metodologias:

- **Landtrendr** (*Landsat-based detection of Trends in Disturbance and recovery*) (KENNEDY; YANG; COHEN, 2010): foi desenvolvido para extrair trajetórias espectrais de uma série temporal anual composta por imagens Landsat, com o objetivo de capturar mudanças abruptas e graduais. É realizada uma segmentação temporal, por meio de regressão linear, onde os vértices e a inclinação das retas caracterizam as mudanças. Uma desvantagem do método é que não existe a caracterização do componente sazonal, apenas do componente de tendência, assim, para estudos sobre a fenologia da vegetação, a metodologia não é apropriada. Outra desvantagem é que as imagens de entrada devem ser livres de nuvens, ou mascaradas, pois estas podem ocasionar falsas detecções de mudanças.
- **TIMESAT** (JÖNSSON; EKLUNDH, 2004): o programa foi desenvolvido para extrair parâmetros sazonais da série temporal, por meio do

ajuste por funções polinomiais, Gaussianas ou sigmoidais, sendo uma metodologia apropriada para caracterizações fenológicas de diferentes tipos de vegetação. Porém, é um método que não caracteriza o componente de tendência.

- **TiSeG** (*Time-series Generator*) (COLDITZ et al., 2008): este algoritmo tem a função de analisar, em nível de pixel, a qualidade de dados MODIS, gerando dois índices: o número de pixels inválidos e o tamanho máximo da lacuna. Assim, o usuário pode comparar diferentes configurações para mascarar ou interpolar as lacunas. Porém, em regiões tropicais, onde a cobertura por nuvem é frequente, as lacunas, geradas por falta de informação ou baixa qualidade dos dados, podem ser muito grandes, diminuindo a eficiência do algoritmo.

- **Hants** (*Harmonic ANalysis of Time Series*) (VERHOEF; OLIVEIRA; GREGO, 1996): também, foi desenvolvido para identificar e remover dados de baixa qualidade, como nuvens, bem como interpolar esses valores, aplicando a transformada Fourier. Tem como desvantagem a mesma citada para o TiSeG.

- **Greenbrown** (FORKEL et al., 2013): o greenbrown é um pacote do software R desenvolvido para extrair parâmetros de uma série temporal. Ele permite avaliar o desempenho de diferentes métodos para estimar a tendência, bem como inferir sobre as propriedades da série: média, tendência, sazonalidade, variabilidade interanual (IAV – *Inter-annual variability*) e variabilidade em curto prazo (STV– *Short-Term Variability*), e seus desvios-padrão (IAV sd e STV sd). O cálculo destes parâmetros é feito pela decomposição da série (Figura 1) seguindo as seguintes etapas (FORKEL et al., 2013, R CORE TEAM, 2013):

1º) A média da série temporal é calculada.

2º) O parâmetro tendência é calculado com base no método AAT – *Annual Aggregated Time Series*, onde os valores mensais da série são agregados a valores anuais e, assim, o coeficiente de inclinação da reta da regressão linear é

estimado, indicando uma tendência positiva ou negativa (sem calcular as mudanças abruptas).

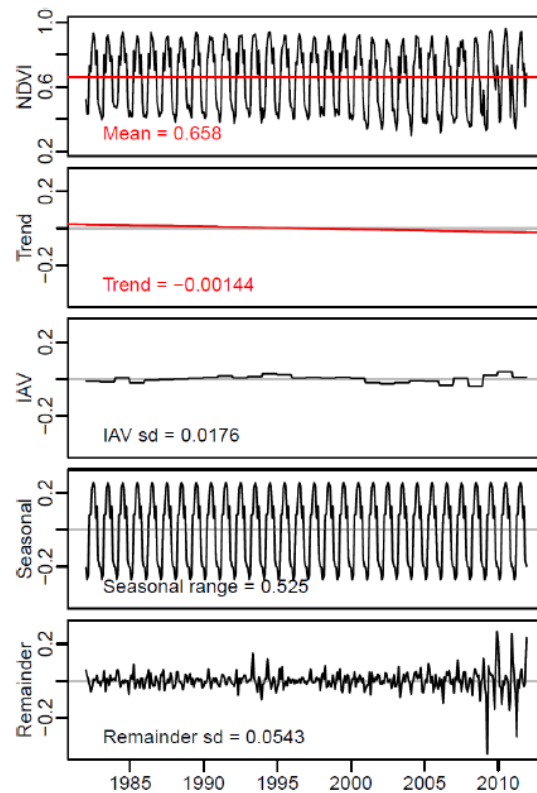


Figura 1 Componentes da série temporal estimados. O painel superior mostra uma série temporal NDVI com o seu valor de médio (linha vermelha). Os próximos painéis mostram a tendência estimada, a variabilidade interanual (IAV) (ou seja, anomalias anuais), sazonalidade (ou seja, a média de ciclo sazonal) e a variabilidade de curto prazo (componente residual), respectivamente. A soma de média, tendência, IAV, componente sazonal e residual compõe a série de temporal original.

Fonte: Forkel et al. (2013).

3º) O IAV, que corresponde ao desvio padrão das anomalias (ruídos) anuais, são gerados pela subtração da média e da tendência dos valores originais da série.

4º) A sazonalidade é calculada pela subtração da média, da tendência e das anomalias da série temporal original.

5º) Por fim, a média, a tendência, as anomalias e o ciclo sazonal são subtraídos da série temporal, resultando as anomalias em curto prazo, ou seja, STV.

- **BFAST** (*Breaks For Additive Seasonal and Trend*) (VERBESSELT et al., 2010a, 2010b): O BFAST é um algoritmo com a capacidade de decompor a série temporal em três componentes separadamente: tendência (Z_t), sazonalidade (S_t) e ruído (ε_t), utilizando métodos para detectar e caracterizar mudanças dentro da série temporal (VERBESSELT et al., 2010a).

Este algoritmo utiliza o procedimento STL – Seasonal-Trend decomposition para decompor a série temporal, o qual fornece uma estimativa precisa e robusta de componentes de tendência e de sazonalidade, graças à sua capacidade de lidar com valores extremos ou a falta de valores dentro da série histórica (VERBESSELT et al., 2010a, 2010b).

O STL é um método não-paramétrico, que, utilizando um modelo aditivo, de forma flexível, decompõe séries temporais. Este tipo de modelo implica que a magnitude das flutuações na série original resultante do padrão sazonal e a componente residual não são afetadas pelo nível da tendência (JACQUIN; SHEEREN; LACOMBE, 2010).

$$X_t = Z_t + S_t + \varepsilon_t \quad (2)$$

STL é um processo iterativo, que utiliza *LOcally wEighted regrESSION Smoother* (LOESS) para decompor os componentes da série temporal

(VERBESSELT et al., 2010b). Com a formação da série temporal decomposta, a componente tendência terá grande relevância na detecção de distúrbio real, pois permite a determinação da direção da mudança analisando o sinal de inclinação da tendência. Na Figura 2 tem-se um exemplo do resultado obtido pelo BFAST.

O BFAST foi escolhido para este estudo por sua fácil implementação (por meio do pacote “bfast” do software livre R) e, por ser um algoritmo mais robusto, podendo ser aplicado a qualquer tipo de sensor, que, além de decompor a série nos componentes de sazonalidade e tendência, detecta mudanças graduais e abruptas na série.




Figura 2 Simulação de uma série temporal MODIS NDVI. Em a) dados originais da série temporal; b) componente sazonal; c) componente de tendência, indicando uma mudança após o ano de 2004; d) componente restante (ruído).

Fonte: Verbesselt et al. (2010a).

2.3 Fusão entre imagens

Em função da falta de detalhamento espacial, temporal ou espectral de alguns sensores, algumas metodologias de fusão entre imagens foram desenvolvidas. O principal objetivo da fusão entre imagens é gerar um produto com melhor qualidade do que os originais, integrando dados espaciais, espectrais (ACERBI-JUNIOR; CLEVERS; SCHAEPMAN, 2006) e temporais (GAO et al., 2006; HILKER et al., 2009a; ZHU et al., 2010) de um mesmo sensor ou entre diferentes sensores.

Os primeiros trabalhos sobre fusão de imagens tinham como objetivo a fusão entre bandas multiespectrais com a banda pancromática, de melhor resolução espacial. Alguns métodos empregados utilizam *Intensity-Hue-Saturation*, análise da componente principal (PCA) e transformada wavelet (LI; KWOK; WANG, 2002). Essas técnicas são eficientes para gerar imagens multiespectrais com alta-resolução espacial (LI; KWOK; WANG, 2002; ZHU et al., 2010). Acerbi-Junior, Clevers e Schaepman (2006) avaliaram a fusão entre dados MODIS e TM utilizando transformada wavelet, a fim de mapear áreas de Cerrado, um dos primeiros trabalhos utilizando estes dois sensores para fusão. Porém, essas técnicas não são capazes de melhorar a resolução espacial e temporal, simultaneamente, o que não é ideal para estudos sobre a dinâmica da vegetação, já que o componente temporal é fundamental para estudos sobre a variabilidade inter e intra-anual (ZHU et al., 2010).

O STARFM - *Spatial and Temporal Adaptive Reflectance Fusion Model* (GAO et al., 2006) é um algoritmo de fusão de imagens desenvolvido para estudos sobre a dinâmica da vegetação.

Este algoritmo de fusão de imagens prediz valores de reflectância da superfície a uma resolução espacial e espectral de imagens dos sensores TM ou ETM+ do satélite Landsat utilizando a frequência temporal de imagens MODIS (HILKER et al., 2009a). A vantagem de se utilizar imagens TM/ETM+ e MODIS para a fusão é a similaridade entre os parâmetros orbitais de seus

satélites (GAO et al., 2006). Além disso, estes sensores (TM/ETM e MODIS) possuem bandas em locais similares no espectro eletromagnético (GAO et al., 2006). O algoritmo deve ser aplicado de preferência em imagens TM/ETM+ processadas pelo LEDAPS (*The Landsat Ecosystem Disturbance Adaptive Processing System*), o qual utiliza metodologia de correção atmosférica 6S baseada nas imagens MODIS (MASEK et al., 2006).

Para a fusão, o STARFM prediz valores de reflectância da superfície de imagens TM/ETM+ com base em pares de imagens TM/ETM+ (*fine-resolution*) e MODIS (*coarse-resolution*) de preferência de mesma data. Desse modo, temos uma imagem MODIS e uma imagem TM/ETM+ no tempo (T_1), e uma imagem MODIS correspondente à data da imagem TM/ETM+ a ser predita (tempo T_2). O resultado final é uma imagem com resolução temporal diária (a depender do produto MODIS a ser utilizado) e resolução espacial de 30 metros (GAO et al., 2006).

Uma janela móvel é utilizada a fim de evitar problemas causados tanto pelas diferenças entre as imagens TM/ETM+'s e MODIS (resoluções espaciais), tanto por mudanças temporais (mudanças no uso da terra, fenologia da vegetação ou BRDF – *Bidirectional Reflectance Distribution Function*). Sendo assim, é gerada uma função com diferentes pesos para cada pixel vizinho ao pixel central dentro da janela, sendo usados somente aqueles espectralmente similares e livres de nuvens (Figura 3). O algoritmo é dado por (GAO et al., 2006):

$$L\left(\frac{x_w}{2}, \frac{y_w}{2}, T_2\right) = \sum_{i=1}^w \sum_{j=1}^w W_{ij} (M(x_i, y_j, T_2) + L(x_i, y_j, T_1) - M(x_i, y_j, T_1)) \quad (3)$$

em que $L\left(\frac{x_w}{2}, \frac{y_w}{2}, T_2\right)$ é o valor do pixel TM/ETM+ predito para o tempo 2 (T_2), w é o tamanho da janela móvel e $\left(\frac{x_w}{2}, \frac{y_w}{2}\right)$ é o pixel central dessa janela móvel.

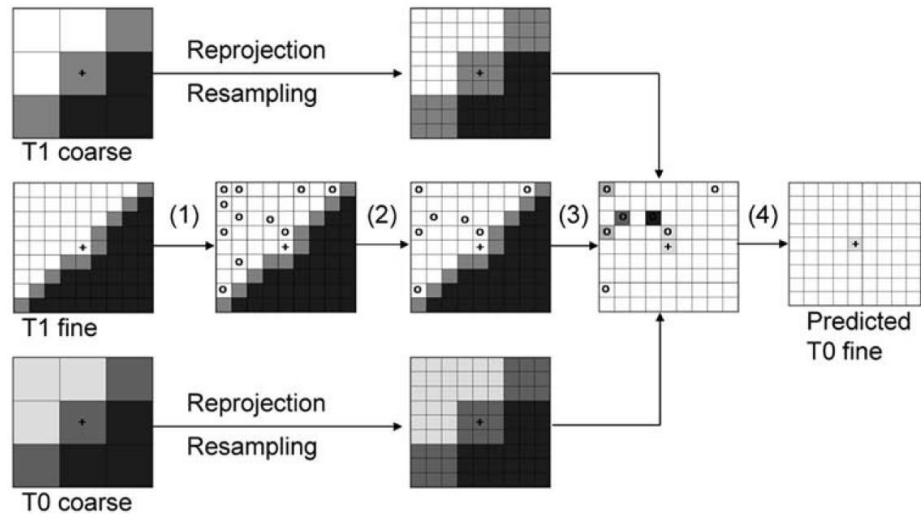


Figura 3 Esquema da metodologia empregada pelo STARFM. (passo 1) Dados de melhor resolução (fine-resolution) são primeiramente usados para procurar pixels (o) que são espectralmente similares ao pixel central (+) dentro da janela móvel. Estas amostras precisam ser filtradas para assegurar uma boa seleção (passo 2). Ambos dados, de melhor e pior resolução são, então, usados para determinar o peso das amostras (passo 3) de acordo com a função de peso descrita anteriormente (o pixel de cor preta possui o peso maior). Por último, o valor predito é computado com base no peso dos cinco pixels selecionados (passo4).

Fonte: Gao et al. (2006).

O peso W_{ij} é calculado baseado em três medidas: diferença espectral entre MODIS e TM/ETM+, diferença temporal entre MODIS T_1 e MODIS T_2 e a distância entre o pixel central predito e o pixel vizinho candidato espectralmente similar e, assim, determina o quanto cada pixel vizinho (x_i, y_j) irá contribuir

para estimar o valor de reflectância do pixel central (GAO et al., 2006). $M(x_i, y_j, T_2)$ é a reflectância da imagem MODIS em x_i, y_j observada no T_2 . Por fim, $L(x_i, y_j, T_1)$ e $M(x_i, y_j, T_1)$ são as reflectâncias das imagens TM/ETM+ e MODIS no tempo T_1 , respectivamente (HILKER et al., 2009a). O peso W_{ij} é calculado pela seguinte formula:

$$W_{ij} = (1/C_{ij} / \sum_{i=1}^w \sum_{j=1}^w (1/C_{ij})) \quad (4)$$

O algoritmo foi testado e validado por Gao et al. (2006), utilizando produto MODIS MOD09GHK, 500 metros de resolução e imagens Landsat-7 ETM+ e obtiveram as seguintes conclusões acerca do algoritmo: 1) os dados estimados apresentaram uma boa acurácia, preservando à alta resolução espacial das imagens TM/ETM+ e à alta resolução temporal das imagens MODIS; 2) para regiões que apresentam paisagem mais complexa, alguns parâmetros, como o tamanho da janela móvel devem ser ajustados para melhorar a performance do algoritmo; 3) a predição pode ser feita com apenas um par de imagem MODIS e TM/ETM+ como entrada, mas o resultado pode ser melhor se mais de um par for utilizado; 4) Mudanças ocorridas em uma escala menor que o pixel MODIS não são preditas pelo algoritmo.

Hilker et al. (2009a) testaram o uso do STARFM para avaliar mudanças sazonais em regiões de florestas boreais e sub-boreais, encontrando bons resultados. As imagens preditas mantiveram os detalhes espaciais, porém, o algoritmo foi menos eficaz em prever eventos de distúrbio.

Bhandari, Phinn e Gill (2012) e Tian et al. (2013) e avaliaram o uso do STARFM para gerar imagens TM/ETM+ sintéticas, para compor uma série temporal densa, a qual foi compatível com a série temporal MODIS correspondente ao mesmo período.

Posteriormente, alguns algoritmos de fusão foram desenvolvidos para sanar as falhas do STARFM. O ESTARFM - *Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model* (ZHU et al., 2010) e o STAARCH - *Spatial Temporal Adaptive Algorithm for mapping Reflectance Change* (HILKER et al., 2009b) foram desenvolvidos para predição de imagens para regiões heterogêneas e para predição de eventos de distúrbio, respectivamente. Ambos têm como base o STARFM e tiveram melhores acurácias de predição em situações como as citadas acima, porém, exigem, pelo menos, dois pares de imagens TM/ETM+ e MODIS como entrada, o que pode ser um problema para regiões onde a cobertura por nuvens é frequente.

3 METODOLOGIA

3.1 Área de estudo e dados

A área de estudo está centralizada em 20° 51' 7" de latitude sul e 45° 36' 44" de longitude oeste, ao Sul do Estado de Minas Gerais, região sudeste do Brasil. Ela cobre o território corresponde à cena 218/75 do *Worldwide Reference System* (WRS-2) usado para catalogar dados derivados da série de satélites TM (Figura 4). A vegetação é caracterizada por fitofisionomias pertencentes a dois importantes biomas brasileiros, Mata Atlântica e Cerrado (CARVALHO; DUTRA, 2008), que são considerados hotspots de biodiversidade (MYERS et al., 2000) e encontram-se ameaçados pelo desenvolvimento regional que aconteceu nas últimas décadas (METZGER, 2003). O clima predominante na região é o Cwa (clima temperado úmido com inverno seco e verão quente), segundo a classificação de Köppen (KOTTEK et al., 2006). Esta área é de especial interesse ecológico por cobrir parte da região de transição entre os biomas citados e por apresentarem uma grande heterogeneidade de paisagens naturais e antropogênicas.

Para este estudo, foram utilizadas imagens de dois sensores: *Thematic Mapper* (TM), do satélite *Landsat-5* e *Moderate Resolution Imaging Spectroradiometer* (MODIS), do satélite *TERRA*.

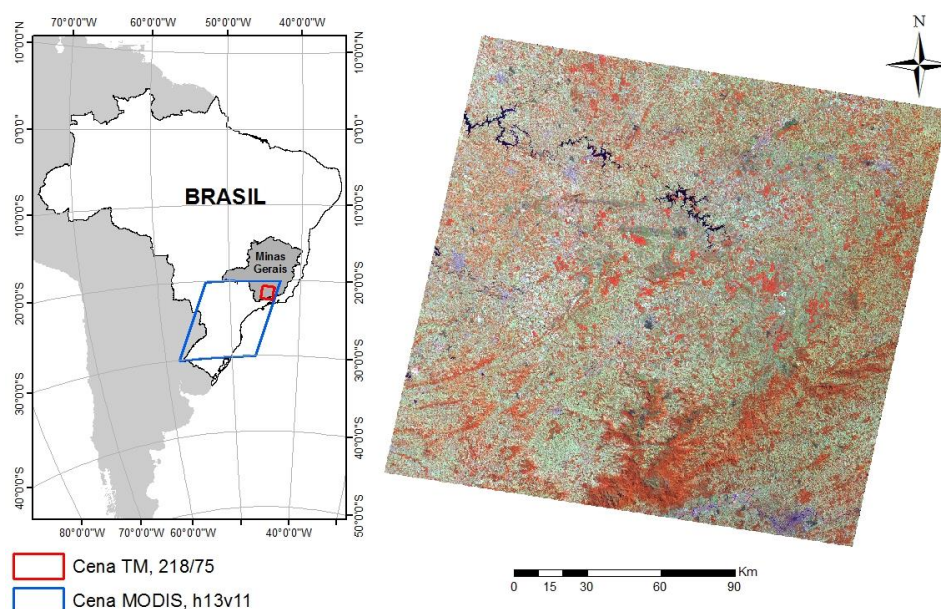


Figura 4 Localização da área de estudo, região sul do estado de Minas Gerais, Brasil, com a localização das cenas TM 218/75 e MODIS h13v11. Em detalhe a cena TM na composição R(4)G(5)B(3).

Todas as imagens TM disponíveis entre 2000 e 2011, relativas à cena WRS-2 218/75, foram adquiridas junto ao portal *U. S. Geological Survey* (<http://earthexplorer.usgs.gov/>), totalizando 195 imagens, com resolução espacial de 30 metros. O produto adquirido foi o *Landsat CDR – Surface Reflectance Climate Data Record*, onde as imagens passam por um processo de correção radiométrica e atmosférica por meio do *LEDAPS – Landsat Ecosystem*

Disturbance Adaptive Processing System. Este produto foi desenvolvido com o objetivo de auxiliar os estudos da superfície terrestre, como mapeamentos e detecção de mudanças, além de permitir a comparação dos dados de reflectância de imagens TM com os de imagens MODIS (MASEK et al., 2006).

Além das imagens TM, foram adquiridas 273 imagens MODIS, cena h13v11 (Figura 4), produto MOD13Q1, no portal *MODIS Reproject Tools Web* (<https://mrtweb.cr.usgs.gov/>) correspondentes ao mesmo intervalo de tempo das imagens TM. Os dados do produto MOD13Q1 consistem em um mosaico de pixels de melhor qualidade, observados nas imagens diárias, durante um período de 16 dias (ANDERSON; SHIMABUKURO, 2007), e possuem resolução espacial nominal de 250 metros, para as bandas do infravermelho próximo (NIR) e do vermelho (RED), as quais foram usadas neste estudo.

3.2 Fusão MODIS -TM usando o algoritmo STARFM

Para a fusão das imagens TM e MODIS, utilizamos o algoritmo STARFM – *Spatial and Temporal Adaptive Reflectance Fusion Model*, desenvolvido por Gao et al. (2006). A fusão foi realizada, utilizando as bandas NIR e RED de ambos os sensores. O algoritmo STARFM prediz valores de reflectância da superfície Terrestre com a mesma resolução espacial de imagens TM. A predição é feita, baseada em uma imagem TM e de um par de imagens MODIS. Desse modo, temos uma imagem MODIS e uma imagem TM de determinada data (tempo T_1), e uma imagem MODIS correspondente à data da imagem TM a ser predita (tempo T_2). O produto resultante é uma base de dados que apresenta as vantagens de ambos os sistemas de sensoriamento remoto, ou seja, resolução temporal equivalente à da base de dados MODIS e resolução espacial equivalente à da base de dados TM (GAO et al., 2006).

No algoritmo STARFM, uma janela móvel é utilizada a fim de evitar problemas causados tanto pelas diferenças entre as imagens TM e MODIS (resoluções espaciais), quanto por mudanças temporais (mudanças no uso da terra, fenologia da vegetação ou BRDF - *Bidirectional Reflectance Distribution Function*). Sendo assim, é gerada uma função com diferentes pesos para cada pixel vizinho ao pixel central dentro da janela, sendo usados somente aqueles espectralmente similares e livres de nuvens. O algoritmo é dado por (GAO et al., 2006):

$$L\left(x_{\frac{w}{2}}, y_{\frac{w}{2}}, T_2\right) = \sum_{i=1}^w \sum_{j=1}^w W_{ij} (M(x_i, y_j, T_2) + L(x_i, y_j, T_1) - M(x_i, y_j, T_1)) \quad (3)$$

em que $L\left(x_{\frac{w}{2}}, y_{\frac{w}{2}}, T_2\right)$ é o valor do pixel TM predito para o tempo 2 (T_2), w é o tamanho da janela móvel e $\left(x_{\frac{w}{2}}, y_{\frac{w}{2}}\right)$ é o pixel central dessa janela móvel.

O peso W_{ij} é calculado, com base em três medidas: diferença espectral entre MODIS e TM, diferença temporal entre MODIS T_1 e MODIS T_2 e a distância entre o pixel central predito e o pixel vizinho candidato espectralmente similar e, assim, determina o quanto cada pixel vizinho (x_i, y_j) irá contribuir para estimar o valor de reflectância do pixel central (GAO et al., 2006). $M(x_i, y_j, T_2)$ é a reflectância da imagem MODIS em x_i, y_j observada no T_2 . Por fim, $L(x_i, y_j, T_1)$ e $M(x_i, y_j, T_1)$ são as reflectâncias das imagens TM e MODIS no tempo T_1 , respectivamente (HILKER et al., 2009a).

O produto CDR contém uma máscara binária das áreas afetadas por cobertura de nuvens. Todos os pixels rotulados como nuvem de todas as imagens TM da série temporal foram preditas usando o STARFM. Portanto, onde não havia nuvem na imagem, os valores originais dos pixels foram

mantidos. Imagens originais com mais de 80% de cobertura de nuvem foram completamente substituídas pelas imagens previstas.

As bandas NIR e RED das imagens MODIS foram reprojctadas para o sistema de coordenadas UTM, datum WGS-84 zona 23S e o pixel reamostrado para 30 metros (método do vizinho mais próximo), seguindo os mesmos parâmetros das imagens TM, a fim de seguir os pré-requisitos de entrada de dados para o algoritmo STARFM.

Para a predição, optamos por usar a imagem TM totalmente sem nuvem ou com menos de 20% de cobertura de nuvem, e adquiridas na data mais próxima da imagem a ser predita, pois, quanto maior a distância entre o T_1 e T_2 , menor a qualidade da predição (OLEXA; LAWRENCE, 2014). A imagem MODIS T_1 foi aquela cuja data estava mais próxima à data da imagem TM T_1 . Já a imagem MODIS T_2 , foi aquela correspondente à imagem TM a ser predita (Tabela 4).

Tabela 4 Exemplo de imagens MODIS e TM em T_1 e T_2 usadas para a predição de imagens TM em T_2 , para o ano de 2010.

MODIS T_1	TM T_1	MODIS T_2
28/07/2010	01/08/2010	01/01/2010
02/02/2010	06/02/2010	17/01/2010
09/05/2010	13/05/2010	02/02/2010
02/02/2010	06/02/2010	18/02/2010
28/07/2010	01/08/2010	06/03/2010
28/07/2010	01/08/2010	22/03/2010
28/07/2010	01/08/2010	07/04/2010
09/05/2010	13/05/2010	23/04/2010
28/07/2010	01/08/2010	25/05/2010
28/07/2010	01/08/2010	10/06/2010
28/07/2010	01/08/2010	26/06/2010

Continua...

Tabela 4 Continuação.

MODIS T_1	TM T_1	MODIS T_2
28/07/2010	01/08/2010	12/07/2010
14/09/2010	18/09/2010	13/08/2010
16/10/2010	20/10/2010	14/09/2010
16/10/2010	20/10/2010	30/09/2010
16/10/2010	20/10/2010	16/10/2010
16/10/2010	20/10/2010	01/11/2010

Na Figura 5 encontra-se o fluxograma dos processamentos realizados para cada base de dados para a fusão.

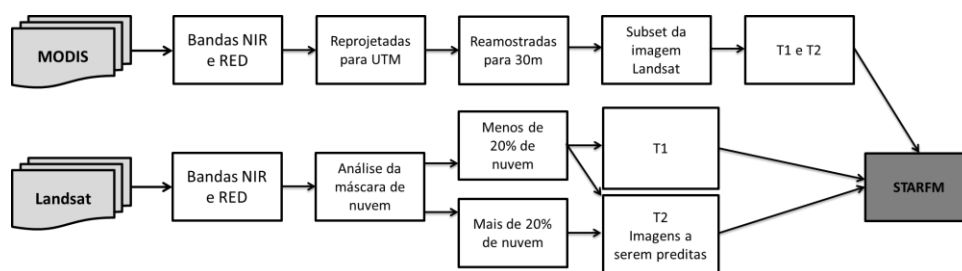


Figura 5 Fluxograma mostrando as etapas dos processos realizados para cada base de dados, MODIS e Landsat, antes da fusão das imagens com o algoritmo STARFM.

3.3 Avaliação das imagens TM sintéticas

A avaliação das imagens TM sintéticas foi feita em duas etapas: primeiro, por meio de regressão linear entre os valores de reflectância das imagens TM originais e previstas; segundo, por meio da análise das séries

temporais NDVI derivadas das bases TM e MODIS.

3.3.1 Regressão linear

Para avaliar a eficácia do STARFM na predição usando regressão linear foram utilizadas duas abordagens: uma baseada em objetos e outra baseada em pixels. As análises, tanto por pixel quanto por objeto foram feitas em 5 subsets (regiões) dentro da cena WRS-2 218/75 (Figura 6).

As regressões foram feitas para os valores de reflectância das bandas 3 e 4 e índice NDVI, entre a imagem original e a respectiva imagem predita, para os 5 subsets (Figura 6).

A predição das imagens foi feita referente aos anos 2000, 2001, 2007 e 2010 (Tabela 5), com o objetivo de comparar os valores originais (dos objetos e dos pixels) com os valores preditos, onde foram selecionadas datas de imagens livres de nuvens. Para o ano de 2010, foram feitas duas predições, variando o T_L . As regressões lineares simples foram realizadas para avaliarmos o coeficiente de determinação (R^2), das bandas 3 e 4 e do índice NDVI.

Na abordagem por objeto, a imagem TM original foi segmentada, sendo utilizados os mesmos objetos para as imagens sintéticas.




Figura 6 Localização dos 5 subsets onde foram feitas as análises estatísticas.

Tabela 5 Datas das imagens TM e MODIS as quais foram usadas para a predição e posterior cálculo das regressões lineares entre valores originais e preditos das imagens TM.

Data	MODIS T_1	TM T_1	MODIS T_2	TM T_2^*
1	25/06/2000	18/06/2000	28/08/2000	21/08/2000
2	23/04/2001	18/04/2001	14/09/2001	09/09/2001
3	12/07/2007	08/07/2007	29/08/2007	25/08/2007
4	09/05/2010	13/05/2010	29/08/2010	02/09/2010
5	28/07/2010	01/08/2010	29/08/2010	02/09/2010

*Data da imagem TM original no tempo T_2 .

Na Figura 7 mostra-se o fluxograma dos processos realizados para a análise da regressão linear.




Figura 7 Fluxograma mostrando as etapas dos processos realizados para as bandas NIR e RED do sensor TM após a fusão das imagens com o algoritmo STARFM para a análise da regressão linear.

3.3.2 Séries temporais NDVI

A série temporal TM foi constituída por imagens originais e sintéticas. Para compor a série, foi calculado o índice de vegetação NDVI (*Normalized Difference Vegetation Index*), de acordo com a fórmula:

$$NDVI = (\rho_{NIR} - \rho_{RED}) / (\rho_{NIR} + \rho_{RED}) \quad (1)$$

em que, ρ_{NIR} e ρ_{RED} indicam os valores de reflectância nas regiões das bandas NIR e RED, respectivamente (ROUSE et al., 1974).

O NDVI é o índice de vegetação mais usado em estudos sobre vegetação (SONNENSCHNEIN et al., 2011; VERBESSELT et al., 2010a), e varia de -1 a 1. É uma combinação da reflectância nas bandas do vermelho (RED) e do infravermelho próximo (NIR) do espectro eletromagnético, onde a primeira tem uma relação indireta e não-linear com a biomassa verde e a segunda uma relação direta não-linear (TUCKER, 1979). Assim, o NDVI realça a vegetação na imagem, onde valores mais próximos a 1 indicam áreas mais vegetadas.

Uma série temporal MODIS NDVI foi construída, para comparação com a série TM NDVI, a fim de avaliarmos a eficácia de uma série temporal TM que inclui imagens sintéticas, comparando alguns parâmetros entre as duas séries. A

análise das séries temporais foi realizada de duas maneiras: pelas estatísticas das séries, geradas pelo *greenbrown* e pela análise dos componentes temporais de diferentes classes de uso da terra, gerados pelo *bfast*.

Na Figura 8 observa-se o fluxograma dos processos realizados para a análise das séries temporais.

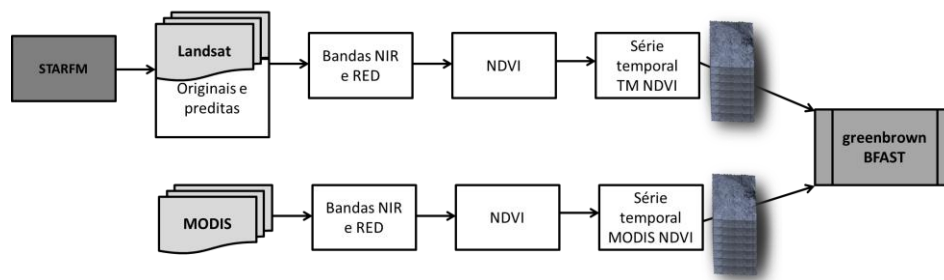


Figura 8 Fluxograma mostrando as etapas dos processos realizados para as bandas NIR e RED dos sensores TM e MODIS para a construção das séries temporais para posterior análise por meio do *greenbrown* e *bfast*.

3.3.2.1 *Greenbrown*

Foram computadas as estatísticas das duas séries, entre 2000 e 2011: média, tendência, sazonalidade, variabilidade interanual (IAV – *Inter-annual variability*) e variabilidade em curto prazo (STV – *Short-Term Variability*), bem como seus desvios-padrão (IAV sd e STV sd), por meio do pacote “*greenbrown*” (FORKEL et al., 2013), disponível no software R (R CORE TEAM, 2013). O

cálculo destes parâmetros é feito baseado na decomposição da série seguindo as seguintes etapas (FORKEL et al., 2013; R CORE TEAM, 2013):

1º) A média da série temporal é calculada.

2º) O parâmetro tendência é calculado com base no método AAT – *Annual Aggregated Time Series*, onde os valores mensais da série são agregados a valores anuais e, assim, o coeficiente de inclinação da reta da regressão linear é estimado, indicando uma tendência positiva ou negativa (sem calcular as mudanças abruptas).

3º) O IAV, que corresponde ao desvio padrão das anomalias (ruídos) anuais, são gerados pela subtração da média e da tendência dos valores originais da série.

4º) A sazonalidade é calculada pela subtração da média, da tendência e das anomalias da série temporal original.

5º) Por fim, a média, a tendência, as anomalias e o ciclo sazonal são subtraídos da série temporal, resultando as anomalias em curto prazo, ou seja, STV.

3.3.2.2 BFAST

Além de comparar as estatísticas das duas séries temporais, também, foram comparados os perfis temporais de algumas classes de uso da terra. Para isso, uma imagem mais recente da série TM sem nuvem (2011) foi segmentada. O processo de segmentação da imagem TM foi feita em duas etapas: (1) aplicação do algoritmo *Multi-resolution Image Segmentation*, baseada nos parâmetros escala, *shape* e *compactness*; (2) aplicação do algoritmo *Spectral Difference Merging*, a qual consiste num processo de resegmentação da etapa (1), em que objetos vizinhos são unidos de acordo com a diferença espectral mínima entre dois objetos adjacentes, com um limiar máximo estabelecido pelo

usuário (ECOGNITION DEVELOPER, 2011). Posteriormente, foram coletados objetos dessa segmentação, atentando-se para que o tamanho do objeto fosse, no mínimo, três vezes maior que o tamanho do pixel MODIS (MOLENAAR, 1998).

Os perfis temporais destes objetos foram analisados por meio do BFAST (*Breaks for Additive Season and Trend*), para posterior comparação entre os componentes da série – Tendência, Sazonalidade e Ruído, bem como as mudanças abruptas ocorridas no componente de tendência. Diferentemente das estatísticas globais resultantes do pacote *greenbrown*, o algoritmo BFAST é capaz de decompor a série temporal em outras três séries que caracterizam cada componente separadamente: tendência (T_t), sazonalidade (S_t) e ruído (et). O algoritmo utiliza métodos para detectar e caracterizar mudanças ao longo da série temporal (VERBESSELT et al., 2010a). O modelo pode ser expresso por:

$$Y_t = T_t + S_t + et, t = 1, \dots, n \quad (5)$$

em que, Y_t são os dados observados no tempo t , T_t é o componente de tendência, S_t é o componente sazonal, e et é o componente restante ou ruído. Estas mudanças são detectadas pela identificação de pontos de quebra (posteriormente chamados de *breakpoints*) resultantes do processo de decomposição BFAST.

Este algoritmo utiliza o procedimento STL – *Seasonal-Trend decomposition*, para decompor a série temporal, o qual fornece uma estimativa precisa e robusta de componentes de tendência e de sazonalidade, graças à sua capacidade de lidar com valores extremos ou a falta de valores dentro da série histórica (JACQUIN; SHEEREN; LACOMBE, 2010). STL é um processo iterativo, que utiliza *LOcally wEighted regreSion Smoother* (LOESS) para decompor os componentes da série temporal (VERBESSELT et al., 2010a). Para

a aplicação deste método, foi utilizado o pacote “bfast” disponível no software R 3.0.2 (R CORE TEAM, 2013).

Foram escolhidos 10 objetos correspondentes a cada uma das seguintes classes: Agricultura, Eucalipto, remanescente de floresta nativa (posteriormente chamada Nativa) e pastagem natural (posteriormente chamada Pastagem) (Figura 9). As séries temporais TM e MODIS foram processadas para cada objeto por meio do BFAST, para análise dos componentes de tendência, sazonalidade, bem como o período em que ocorreram mudanças abruptas nos perfis temporais.




Figura 9 Exemplo de objetos coletados das classes Pastagem, Agricultura, Eucalipto e Nativa, mostrando a segmentação da imagem Landsat.

4 RESULTADOS E DISCUSSÃO

4.1 Análise geral das predições

De um total de 195 imagens TM disponíveis para *download*, apenas 16 imagens, ou seja, 8,2% do total, estavam totalmente sem nuvem, e 46 imagens, ou 23,5% do total, estavam totalmente ou quase totalmente cobertas de nuvem (mais de 70% de cobertura de nuvem). Além disso, 77 imagens TM não estavam disponíveis. Sendo assim, no total, 256 imagens foram preditas, algumas totalmente e outras parcialmente.

Na Tabela 6 verifica-se a relação entre a porcentagem de cobertura de nuvem e a quantidade de imagens TM.

Tabela 6 Relação entre a quantidade de imagens TM e a porcentagem de cobertura de nuvem.

Cobertura de nuvem	Quantidade de imagens	%
Menos que 10%	57	29,2
10 a 20%	17	8,7
20 a 30%	19	9,7
30 a 40%	18	9,2
40 a 50%	18	9,2
50 a 60%	10	5,1
60 a 70%	10	5,1
70 a 80%	15	7,7
80 a 90%	12	6,2
90 a 100%	19	9,7
Total	195	100

Apenas 30% das imagens TM disponíveis continham menos que 10% de cobertura de nuvens. Estas imagens, geralmente, datavam entre junho e setembro, durante a estação seca do ano, o que mostra a necessidade da predição de imagens TM em regiões tropicais.

Além do STARFM, existem outros algoritmos para fusão de imagens. Hilker et al. (2009b) e Zhu et al. (2010) desenvolveram outros dois algoritmos de predição de imagem que têm como base o STARFM: STAARCH e ESTARFM, respectivamente, os quais foram desenvolvidos com o objetivo de sanar algumas falhas do STARFM, como a não detecção de eventos de distúrbios em nível de subpixel MODIS (HILKER et al., 2009b) e a baixa qualidade da predição em paisagens heterogêneas (ZHU et al., 2010). Porém, ambos os algoritmos necessitam de, pelo menos, dois pares de imagens TM e MODIS, ao contrário do STARFM, que necessita apenas de um par dessas imagens. Este foi um dos fatores determinantes para a escolha do STARFM para a região de estudo, onde as imagens TM livre de nuvens são muito poucas. E até mesmo dentre as imagens MODIS, muitas apresentavam baixa qualidade dos dados. Assim, para minimizar as falhas do algoritmo, optamos por prever apenas locais com nuvens, ou as imagens TM que continham mais de 80% de cobertura de nuvem, bem como escolher o par de imagens T_1 com a data mais próxima possível da imagem a ser predita em T_2 .

Para a predição de uma imagem TM, é necessária outra imagem TM com o mínimo de cobertura de nuvens, e um par de imagens MODIS, correspondentes às datas T_1 e T_2 . Porém, nem sempre as imagens MODIS *composite* estão livres de nuvens, o que compromete o resultado final da predição.

Na Figura 10a, temos um exemplo de como a informação espectral da imagem MODIS é importante e pode influenciar na predição da imagem TM.




Figura 10 Imagens NDVI derivadas das bandas 3 e 4 TM e MODIS nos tempos T_1 e T_2 , mostrando a influência da imagem MODIS T_2 na predição da imagem TM T_2 . Em A, mostra o resultado da predição não muito bom, e em B, resultado da predição com melhor qualidade.

São mostradas as imagens NDVI, derivadas das bandas 3 e 4, usadas para a predição, área correspondente ao subset 4 (Figura 5). Como pode ser observado, a imagem MODIS T_2 apresentava baixa qualidade dos dados, o que resultou em uma imagem TM sintética NDVI, também, com baixa qualidade dos dados. Já, na Figura 10b, é mostrado o resultado da predição, utilizando a mesma MODIS T_1 , porém com uma MODIS T_2 diferente, onde os dados apresentam uma melhor qualidade. Assim, o resultado da predição foi mais consistente. Os valores de reflectância preditos em T_2 são estimados com base na relação entre a imagem TM e MODIS em T_1 . (GAO et al., 2006). Por isso, a escolha das imagens de entrada deve ser cuidadosa.

4.2. Avaliação das imagens TM sintéticas

4.2.1 Regressão linear

As regressões foram feitas para os valores de reflectância das bandas 3 e 4 e índice NDVI, entre a imagem original e a respectiva imagem predita, para os 5 subsets (Figura 6). Em algumas imagens TM sintéticas, os valores de alguns pixels foram preditos erroneamente, com valores de background, tanto para a banda 3 quanto para a banda 4. Dessa forma, ao gerar a imagem NDVI, alguns pixels apresentaram valores maiores que 1 e/ou valores menores que -1. Uma possível explicação para este fato é que esses pixels geralmente se encontravam em locais de sombra na imagem TM, ou seja, apresentavam um valor de reflectância muito baixo na imagem TM em T_1 , mas um valor não muito baixo na imagem MODIS em T_1 , pois o pixel MODIS é maior, cujo valor de reflectância é a soma das reflectâncias de diferentes alvos da superfície, conseqüentemente, não há um detalhamento destes locais sombreados. Esta situação se agrava quando uma das imagens MODIS (T_1 ou T_2) apresenta baixa

qualidade dos dados.

Outro fato que deve ser levado em conta é o uso de imagens MODIS *composite*, que têm a vantagem de serem imagens compostas por pixels de melhor qualidade entre os 16 dias, mas que em contrapartida, também, possuem dados com múltiplos ângulos de visada e sujeitos a variações espectrais, o que não acontece em imagens TM, que, possivelmente, pode ser mais uma fonte de erros na predição de imagens (HILKER et al., 2009a).

Em trabalho realizado por Hilker et al. (2009a), a qualidade dos dados preditos, também, foram afetados em razão da presença de nuvem nas imagens MODIS em T_2 , principalmente, nos comprimentos de onda mais curtos.

Na abordagem por pixel, aqueles preditos com valor de background foram excluídos das análises e, na abordagem por objeto, foram excluídos aqueles objetos que apresentaram valor médio de reflectância negativo, o que significa a presença de pixels com valores de background.

Nas Tabelas 7 e 8 mostram-se os valores dos coeficientes de determinação (R^2), bem como o número de observações que foram excluídas das análises em decorrência do erro na predição, para as análises por pixel (Tabela 7) e objeto (Tabela 8) em todos os subsets.

Na abordagem por pixel, para a Data 1, o coeficiente de determinação (R^2) apresentou a maior variação entre os subsets ($\sigma=0,26$; 0,14 e 0,23, respectivamente, para as bandas 3, 4 e NDVI). As menores correlações foram encontradas para os subsets 2 e 4, justamente os locais onde existe baixa qualidade dos dados na imagem MODIS no T_2 . O mesmo resultado foi encontrado na abordagem por objeto, onde o desvio padrão foi de 0,29 para a banda 3; 0,16 para a banda 4 e 0,26 para o NDVI.

A menor variação de R^2 entre os subsets na abordagem por pixel foi encontrada para a banda 3 na Data 5 ($\sigma=0,016$). Já, na abordagem por objeto, a menor variação ocorreu para o NDVI, também, na Data 5 ($\sigma= 0,014$). O par de

imagens, TM e MODIS, que foram utilizadas para esta predição, apresentavam boa qualidade dos dados, o que refletiu na qualidade dos dados de saída.

As Datas 4 e 5 foram feitas para a mesma imagem TM T_2 , variando as imagens MODIS e TM em T_1 (Tabela 5). Para a Data 4, utilizamos uma imagem MODIS, contendo pouca nuvem em alguns locais da imagem, principalmente, naqueles correspondentes aos subsets 1, 3 e 4. Para o subset 1 da banda 4 sintética, foram encontrados 2797 pixels com valores de background. Estes pixels estão localizados, principalmente, em áreas sombreadas por causa do relevo bastante acidentado da região, além do fato de que a MODIS T_1 apresentava baixa qualidade dos dados justamente nessa região.

Já, para a Data 5, tanto as imagens MODIS T_1 e T_2 quanto a imagem TM T_1 estavam boas. Este fato refletiu nos resultados da análise estatística, que foram melhores do que a Data 4, nas duas abordagens. Isso demonstra que a quantidade de pixels com valores errados de reflectância na Data 4 pode ser em virtude da qualidade da imagem MODIS. Além disso, as duas imagens TM T_2 foram imageadas com valores de azimuth e elevação solar bem próximos, portanto o sombreamento era similar nas duas datas. Nas Figuras 11 e 12 verifica-se o resultado das comparações por pixel e por objeto, nas datas 4 e 5, para as bandas RED, NIR e NDVI.

As duas abordagens, por pixel e por objeto, apresentaram resultados semelhantes, porém, na abordagem por objeto, os valores de R^2 , em geral, foram maiores. O valor de reflectância de um objeto é a média dos valores dos pixels que compõem esse objeto, sendo assim, os erros de predição ocorridos em nível de pixel são minimizados na abordagem por objeto. Portanto, para análises baseadas em objeto, o uso de imagens sintéticas, preditas pelo algoritmo STARFM, pode ser uma boa alternativa, já que a maioria dos trabalhos, atualmente, utiliza esta abordagem para classificação.

Tabela 7 Resultado das análises estatísticas na abordagem por pixel, nos 5 subsets, para as 5 datas, onde r^2 é o coeficiente de determinação e σ é o desvio padrão de r^2 entre os 5 subsets. Todos os resultados de R^2 foram significativos ($p=0,05$).

Data		Subset 1		Subset 2		Subset 3		Subset 4		Subset 5		σ
		r^2	Pixels excluídos	r^2	Pixels excluídos	r^2	Pixels excluídos	r^2	Pixels excluídos	r^2	Pixels excluídos	
1	Banda 3	0.76	293	0.29	207	0.75	3	0.12	0	0.66	3	0.261
	Banda 4	0.76	318	0.57	233	0.64	5	0.35	9	0.65	13	0.136
	NDVI	0.56	573	0.14	354	0.7	8	0.19	9	0.59	16	0.227
2	Banda 3	0.74	11	0.75	1	0.78	0	0.72	7	0.65	0	0.043
	Banda 4	0.51	395	0.31	161	0.3	91	0.31	48	0.35	102	0.079
	NDVI	0.46	402	0.53	162	0.67	91	0.61	52	0.55	102	0.071
3	Banda 3	0.91	173	0.89	2	0.89	2	0.89	8	0.84	85	0.023
	Banda 4	0.83	55	0.84	6	0.82	15	0.79	23	0.9	14	0.036
	NDVI	0.82	228	0.87	8	0.89	17	0.89	31	0.91	99	0.031
4	Banda 3	0.77	169	0.73	1	0.75	13	0.59	272	0.67	0	0.065
	Banda 4	0.68	2797	0.66	39	0.64	92	0.48	542	0.74	129	0.087
	NDVI	0.34	2922	0.65	40	0.74	105	0.48	796	0.73	129	0.155
5	Banda 3	0.91	9	0.89	0	0.91	1	0.88	1	0.87	1	0.016
	Banda 4	0.87	4	0.84	6	0.83	2	0.82	0	0.88	16	0.023
	NDVI	0.84	10	0.88	6	0.92	3	0.89	1	0.89	17	0.026

Tabela 8 Resultado das análises estatísticas na abordagem por objeto, nos 5 subsets, para as 5 datas, onde r^2 é o coeficiente de determinação σ é o desvio padrão de r^2 entre os 5 subsets. Todos os resultados de R^2 foram significativos ($p=0,05$).

Data		Subset 1		Subset 2		Subset 3		Subset 4		Subset 5		σ
		r^2	Objetos excluídos	r^2	Objetos excluídos	r^2	Objetos excluídos	r^2	Objetos excluídos	r^2	Objetos excluídos	
1	Banda 3	0.80	52	0.28	12	0.85	0	0.15	0	0.75	0	0.291
	Banda 4	0.86	11	0.57	13	0.71	0	0.37	0	0.70	0	0.164
	NDVI	0.67	0	0.14	0	0.77	0	0.18	0	0.63	0	0.264
2	Banda 3	0.84	2	0.85	0	0.85	0	0.82	0	0.75	7	0.038
	Banda 4	0.58	10	0.35	8	0.28	5	0.32	1	0.37	7	0.104
	NDVI	0.56	0	0.62	1	0.73	0	0.68	0	0.63	0	0.057
3	Banda 3	0.95	32	0.85	0	0.94	0	0.90	2	0.93	0	0.036
	Banda 4	0.86	2	0.88	0	0.85	2	0.81	0	0.89	0	0.028
	NDVI	0.90	0	0.93	0	0.93	0	0.93	0	0.95	0	0.016
4	Banda 3	0.80	24	0.74	0	0.75	2	0.55	20	0.69	0	0.085
	Banda 4	0.69	85	0.72	4	0.64	3	0.4	24	0.64	4	0.113
	NDVI	0.45	0	0.72	0	0.78	0	0.49	0	0.73	0	0.136
5	Banda 3	0.92	2	0.89	0	0.90	0	0.86	0	0.86	0	0.023
	Banda 4	0.90	0	0.86	1	0.83	0	0.81	0	0.81	1	0.034
	NDVI	0.91	0	0.93	0	0.95	0	0.94	0	0.92	0	0.014

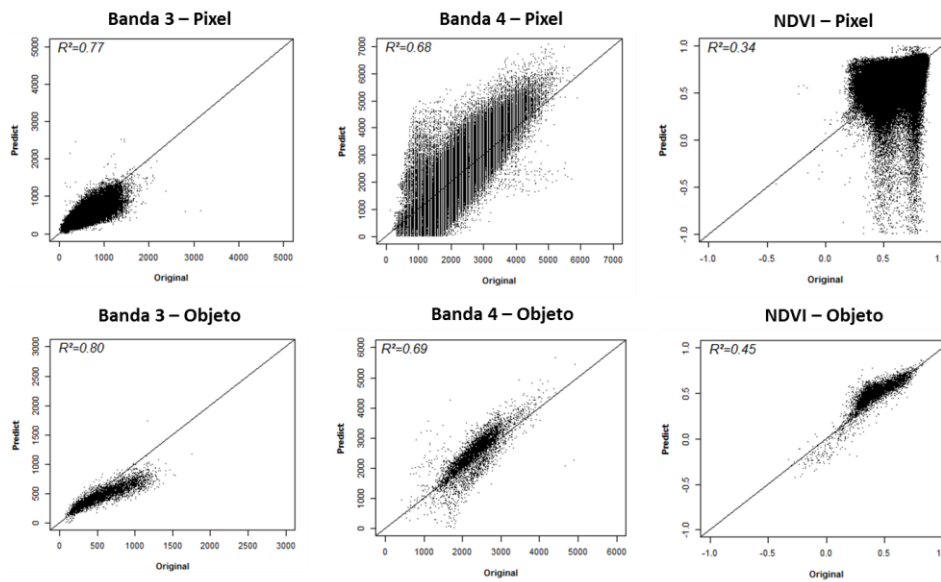


Figura 11 Gráficos de dispersão para as bandas 3, 4 e NDVI, data 4, subset 1, nas abordagens por pixel e objeto.

Nas duas abordagens, o coeficiente de determinação para a banda 4 apresentou, na maioria das vezes, valores menores do que a banda 3, resultado semelhante ao encontrado por Walker, De Beurs e Wynne (2014) e Walker et al. (2012) em florestas semidecíduais. Isto ocorreu, porque os efeitos do ângulo de visada não foram corrigidos para as imagens TM, enquanto o ângulo de visada das TM sintéticas é baseado nas correções das imagens MODIS na data de predição. Além disso, em regiões onde a vegetação se apresenta em diversas camadas, existe um alto espalhamento da radiação na região do infravermelho próximo (WALKER; DE BEURS; WYNNE, 2014). Porém, as maiores acurácias foram encontradas para a banda 4, em trabalhos realizados por Bhandari, Phinn e Gill (2012), em florestas de eucalipto, na Austrália e por Hilker et al. (2009a) em florestas de coníferas. Neste último caso, os efeitos

atmosféricos na região de estudo são maiores para comprimentos de onda mais curtos.

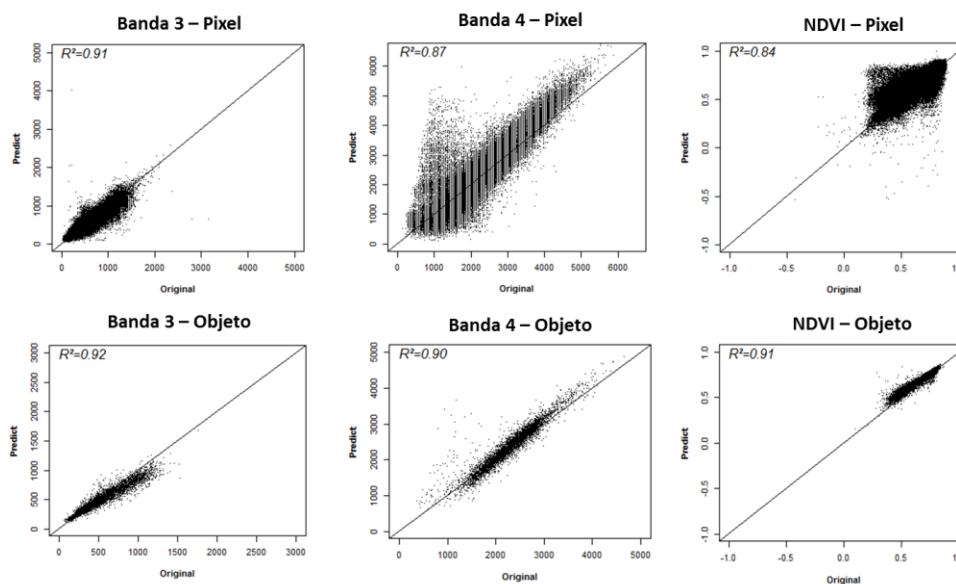


Figura 12 Gráficos de dispersão para as bandas 3, 4 e NDVI, data 5, subset 1, nas abordagens por pixel e objeto.

4.2.2 Comparação e caracterização das séries temporais TM e MODIS

4.2.2.1 Parâmetros das séries temporais obtidos pelo *greenbrown*

Um dos aspectos avaliados, para se conhecer a eficácia de uma série temporal TM, composta por imagens sintéticas, foi compará-la a uma série temporal MODIS. A comparação foi feita na região correspondente ao subset 1 da área de estudo (Figura 6). O ideal seria comparar a série TM sintética com uma série TM original, porém, em consequência da grande falta de informação e

da grande quantidade de nuvens nas imagens TM, esta comparação torna-se inviável para a região de estudo.

Na Figura 13 salientam-se os resultados obtidos para cada série, onde A corresponde à série temporal TM e B à série temporal MODIS, variando o gradiente de cor do menor ao maior valor (do laranja ao azul, respectivamente) e a Tabela 10 mostra a variação, (os valores mínimos e máximos) para cada parâmetro.

13.1. Média





Figura 13 Resultados dos parâmetros estatísticos obtidos pelo *greenbrow* calculados para as séries temporais TM (A) e MODIS (B). Em 13.1, é mostrada a média; 13.2, tendência; 13.3, IAV; 13.4, desvio padrão (sd) de IAV; 13.5, sazonalidade; 13.6, STV e 13.7, desvio padrão (sd) de STV. (Continua...)

13.2. Tendência



13.3. IAV





Figura 13 Continuação.

13.4. IAV sd



13.5. Sazonalidade




Figura 13 Continuação.



13.6. STV**13.7. STV sd**

Figura 13 Continuação.

Tabela 10 Valores mínimos e máximos e a média dos parâmetros estatísticos calculados para as séries temporais TM e MODIS no subset 1 da área de estudo.

		Média	Tendência	IAV	IAV sd	Sazonalidade	STV	STV sd
TM	Mínimo	-0,082214	-0,059654	0,013868	0,004866	0,053558	0,206257	0,033698
	Máximo	0,857488	0,055487	2,358644	0,635680	1,999852	21,22272	1,259025
	Média	0,626775	0,000957	0,139586	0,040214	0,23518	0,636333	0,072142
MODIS	Mínimo	0,2900342	-0,014851	0,024749	0,007579	0,077585	0,248262	0,028708
	Máximo	0,838552	0,025381	0,297201	0,082191	0,442517	1,040000	0,144537
	Média	0,668544	0,000687	0,086212	0,025031	0,241150	0,645792	0,075907

Observa-se que a amplitude dos valores mínimos e máximos dos parâmetros da série TM sempre foram maiores do que na série MODIS. Os menores valores de média correspondem a áreas urbanas (3 cidades), representados pela cor laranja (Figura 14), e os maiores valores correspondem, principalmente, às áreas de remanescente nativo e agricultura perene (geralmente café) (Figura 15).




Figura 14 Mapa de média da série TM (A) e detalhe em uma cena RapidEye de uma das áreas urbanas (B), representada na cor laranja em (A).




Figura 15 Mapa de média da série TM (A) e detalhe em uma cena RapidEye de áreas de remanescente de vegetação nativa e áreas de café (B).

Analisando o mapa de tendência (Figura 13.2), observamos que a maior parte dos pixels, tanto de A quanto de B, não possui tendência, ou seja, inclinação igual a zero (amarelo em A, laranja em B), o que significa que não houve mudança no componente de tendência nessas áreas. As regiões em azul (tendência positiva) correspondem, principalmente, às áreas de agricultura perene (café) (Figura 16), já, as regiões mais alaranjadas (tendência negativa), correspondem às áreas que foram desmatadas, agricultura anual ou pastagem (Figura 17).




Figura 16 Mapa de tendência da série TM (A), detalhe em uma cena RapidEye de uma área de café (B) e detalhe correspondente no mapa de tendência (C).

A variação inter-anual (IAV) significa a variação das anomalias anuais, sendo calculada pela subtração da média e da tendência da série original (FORKEL et al., 2013). As áreas em azul/verde correspondem, principalmente, à agricultura, tanto perene quanto anual, enquanto as áreas alaranjadas se referem à floresta nativa (Figura 18).




Figura 17 Mapa de tendência da série TM (A) e detalhe em escala maior de uma área onde houve desmatamento (em laranja) (B). Em 2000 – remanescente de floresta nativa (C); em 2011 – pastagem (D).




Figura 18 Mapa de IAV da série TM (A) e cena RapidEye respectiva (B). As áreas circuladas correspondem, principalmente, à agricultura, e as áreas indicadas por setas, áreas de floresta nativa.

A sazonalidade foi estimada como o ciclo sazonal médio, ou seja, a média anual da amplitude sazonal. Analisando a Figura 13.5, observamos que as menores amplitudes sazonais (regiões em amarelo-laranja) ocorrem em áreas de remanescente nativo, agricultura perene e áreas urbanas.

O STV é calculado baseado na subtração de todos os outros componentes da série original, ou seja, corresponde ao ruído da série temporal. Na série temporal TM, o STV apresentou valores muito altos, com um valor máximo de 21,22, em contrapartida o valor máximo para a série temporal MODIS foi de 1,04 (Figura 13.6). Isto pode ter ocorrido em virtude do erro de predição em algumas imagens, onde alguns pixels apresentaram valor de background nas bandas 3 e 4, sub ou superestimando os valores de NDVI. Já, as imagens MODIS não apresentam este tipo de erro. Isto pode implicar em análises erradas da série temporal se o erro persistir em determinada área. Como a variação dos valores de STV foi alta para a série temporal TM, conseqüentemente, o desvio padrão de STV, também, foi alto para esta série, o mesmo não ocorrendo para a série temporal MODIS. Na Figura 19 observa-se o resultado do STV, cujos valores discrepantes foram retirados, mostrando que sem eles, as séries temporais TM e MODIS ficam mais parecidas analisando este parâmetro.

Os detalhes observados nos mapas das estatísticas, puderam ser melhor visualizados nos mapas da série TM, que, apesar de apresentar alguns valores discrepantes, torna-se muito mais viável para análises mais detalhadas do que os mapas da série MODIS. Para esta área de estudo, assim como em outras áreas heterogêneas, as imagens com melhor resolução espacial, como as imagens TM, tornam-se essenciais para a sua caracterização. Assim, a combinação de dados de alta frequência temporal e espacial podem melhorar o mapeamento e monitoramento dessas áreas.

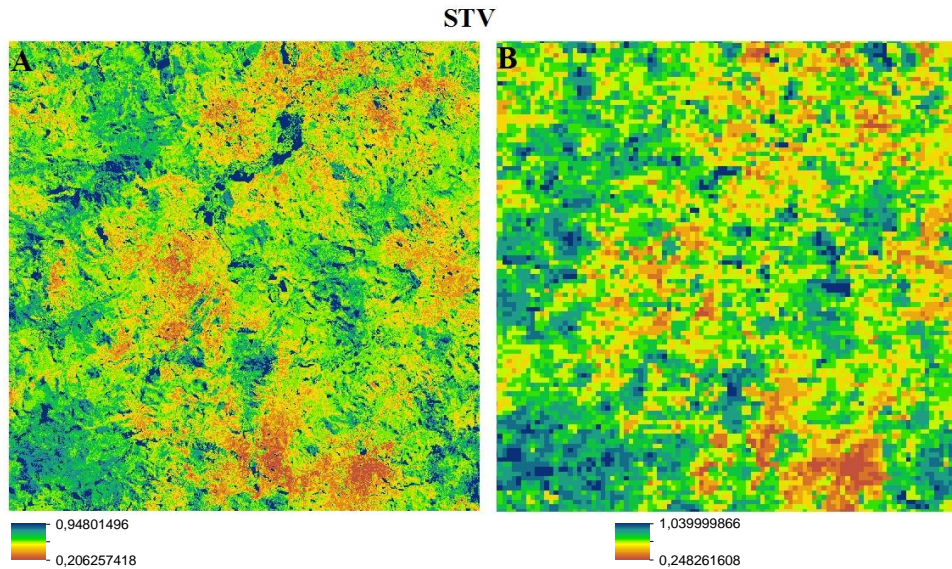


Figura 19 Resultado do parâmetro estatístico STV calculados para as séries temporais TM (A) e MODIS (B), onde foram retirados os outliers da série TM para mostrar a similaridade entre as duas séries.

4.2.2.2 Análise dos perfis temporais

Além das comparações feitas acima, foram selecionados objetos com base na segmentação da imagem TM, sem nuvem mais recente da pilha, a fim de compararmos o perfil temporal de imagens TM e MODIS destes objetos. Na Tabela 11 mostra-se o número total de *breakpoints* (pontos de quebra que podem significar mudança), encontrado no componente de tendência em todos os 10 objetos das 4 classes, bem como o número de objetos que apresentaram *breakpoints*, tanto para a série TM quanto para a MODIS. Mostra-se, também, o número de *breakpoints* coincidentes, ou seja, aqueles com a data mais próxima

entre si, além da média, maior e menor diferença, em meses, entre os *breakpoints* coincidentes das séries TM e MODIS.

Tabela 11 Número total de *breakpoints* e número de objetos com *breakpoints* para o componente de tendência, para as séries TM e MODIS. Média maior e menor diferença se referem aos *breakpoints* coincidentes entre as duas séries.

		Agricultura	Eucalipto	Nativa	Pastagem
Nº total de <i>breakpoints</i>	TM	31	42	12	35
	MODIS	16	36	4	12
Nº objetos com <i>breakpoints</i>	TM	10	10	4	10
	MODIS	7	10	2	6
Nº <i>breakpoints</i> coincidentes		16	31	4	10
Média (meses)		4,1	5,9	5,8	4,5
Maior diferença (meses)		30,4	26,1	18,6	18,1
Menor diferença (meses)		0	0,5	0,5	0

Com exceção da classe Eucalipto, onde todos os objetos apresentaram *breakpoints* no componente de tendência, observa-se que, em todas as classes de uso da terra, o número total de *breakpoints*, no componente de tendência, dos objetos da série TM é maior do que os objetos da série MODIS, assim como o número de objetos com *breakpoints*. Isso pode ter acontecido tanto por erros na predição, que pode ocasionar falsas detecções de mudanças, ou porque a série temporal TM é composta por imagens de melhor resolução espacial, o que pode levar à melhor caracterização temporal.

O número de *breakpoints* coincidentes foi maior para a classe Eucalipto, que, também, foi a classe que apresentou o maior número de *breakpoints*, tanto para objetos TM quanto MODIS. Uma explicação para isso pode ser os objetos desta classe, que, por serem maiores, puderam ser bem caracterizados na série temporal MODIS. Além disso, as florestas de eucalipto são bem manejadas, e o corte, geralmente, acontece para todo o talhão numa mesma época. A classe que apresentou o menor número de *breakpoints* foi a Nativa (12 e 4, para TM e MODIS, respectivamente), talvez, por ser uma classe com pouca ou nenhuma intervenção antrópica. O número maior de *breakpoints* no componente de tendência para a série TM pode ter sido causado por erros na predição das imagens, conforme será explicado mais adiante (Figura 14).

Analisando a média da diferença, em meses, dos *breakpoints* coincidentes, encontramos o menor valor para a classe Agricultura (4,1 meses) e o maior valor para a classe Eucalipto (5,9 meses), mas todas as médias encontradas podem ser consideradas com um valor, relativamente, baixo. Em trabalho realizado por Forkel et al. (2013), foram avaliados diferentes métodos para estimar *breakpoints* na série temporal. Se a diferença entre o *breakpoint* da série simulada e o da série real foi maior que 5 anos, então, o *breakpoint* foi considerado como não detectado. No presente estudo, a maior diferença entre o tempo de detecção foi de 30,4 meses, ou, aproximadamente, dois anos e meio, ou seja, metade do limite estipulado pelo autor. Isso significa que grande parte dos *breakpoints*, detectados no componente de tendência, na série temporal MODIS, também, pôde ser detectada na série temporal TM sintética.

Os objetos de Agricultura, Eucalipto e Pastagem foram os que apresentaram maior número de *breakpoints* no componente de tendência, praticamente, em todos os objetos da série temporal TM e MODIS. Agricultura e Eucalipto correspondem a áreas antrópicas, altamente manejadas. Muitos desses *breakpoints* podem significar cortes ou plantio. Já, a classe Pastagem, apesar de

natural, também, sofre intervenção antrópica na região, por pastejo do gado, por exemplo.

Analisando os objetos de Agricultura, algumas mudanças que puderam ser observadas na série TM não foram detectadas na série MODIS, provavelmente, porque o pixel MODIS é muito maior e mais homogêneo, mostrando menos detalhes do que a mesma área correspondente na imagem TM (Figura 20). Gao et al. (2006) afirmam que mudanças ocorridas na superfície que não são detectadas por meio de imagens MODIS, também, tornam-se indetectáveis com o uso do STARFM. O algoritmo não foi eficaz para capturar mudanças de distúrbios ocorridas em nível de pixel, ou seja, menores que o tamanho do pixel MODIS (GAO et al., 2006; HILKER et al., 2009a). Porém, como neste trabalho a predição das imagens TM foi feita apenas em locais com nuvens, mantendo os valores de reflectância originais nos outros locais da imagem, essas mudanças imperceptíveis na série temporal MODIS puderam aparecer na série TM.

Alguns *breakpoints* no componente de tendência detectados pelo *bfast* na série temporal TM, mas não foram detectados na série MODIS, podem ter sido em virtude de erros na predição, ou onde a predição ficou ruim. Portanto, ao se utilizar uma série temporal, composta por imagens sintéticas, deve-se atentar para não confundir detecções de mudança, causadas por erro na predição das imagens, com detecções reais.




Figura 20 Detalhe de mudança ocorrida em 2006, detectada pelo *bfast* na série temporal TM, mas não detectada na série MODIS, no objeto à esquerda. Datas em dia juliano.

O componente sazonal, no geral, foi bastante semelhante entre as duas séries, apresentando uma diferença de amplitude bem pequena em alguns objetos. Para a classe Agricultura, apenas 3 objetos apresentaram *breakpoints* no componente sazonal para a série TM e nenhum para a série MODIS. A classe Eucalipto foi a que apresentou o maior número de objetos com *breakpoints* no componente sazonal, 5 para a série TM e 7 para a série MODIS. A classe Pastagem apresentou apenas 1 objeto com *breakpoints*, na série MODIS, e a classe Nativa não apresentou nenhum objeto com *breakpoint* no componente

sazonal. O componente sazonal é bem característico para cada classe de uso da terra, podendo servir como um parâmetro de separabilidade entre as classes, ficando evidente a importância deste componente ser bem caracterizado na série temporal TM.

Nas Figuras 21 a 24 encontram-se dois exemplos, para cada classe de uso da terra, mostrando a série temporal com dados TM e MODIS e o resultado do processamento do *bfast* (componentes de tendência e sazonalidade). Fazendo uma análise visual, podemos verificar que as séries temporais TM e MODIS são bastante parecidas, apesar do componente de tendência da série TM apresentar mais *breakpoints*.

Podemos observar que os valores de NDVI dos perfis temporais MODIS, geralmente, são maiores que os perfis temporais TM. Como as séries temporais são derivadas de dados de sensores diferentes, com diferentes resoluções espaciais, é de se esperar um certo nível de diferença entre elas (BHANDARI; PHINN; GILL, 2012).

Em trabalho realizado por Bhandari, Phinn e Gill (2012), também, foi avaliada uma série temporal NDVI composta por imagens TM preditas pelo algoritmo STARFM. Os resultados mostraram semelhanças entre os componentes de tendência e sazonalidade das séries TM e MODIS, o que confirmou a capacidade da série temporal TM, composta por imagens sintéticas, em capturar a fenologia da vegetação e a tendência na região de estudo.

Trabalho semelhante foi realizado por Tian et al. (2013), que utilizaram imagens sintéticas para compor a série temporal. Pelos resultados confirmou-se a eficácia de uma série temporal NDVI, composta por imagens TM sintéticas, em capturar informações sobre a vegetação, as quais são indetectáveis na série temporal MODIS.

De forma geral, para nossa área de estudo, as séries temporais TM NDVI e MODIS NDVI, mostraram-se bastante semelhantes. Além disso, pela

série TM, os detalhes temporais e espaciais se tornaram muito mais evidentes do que na série MODIS, confirmando a viabilidade do uso de imagens TM sintéticas para análises em uma série temporal.

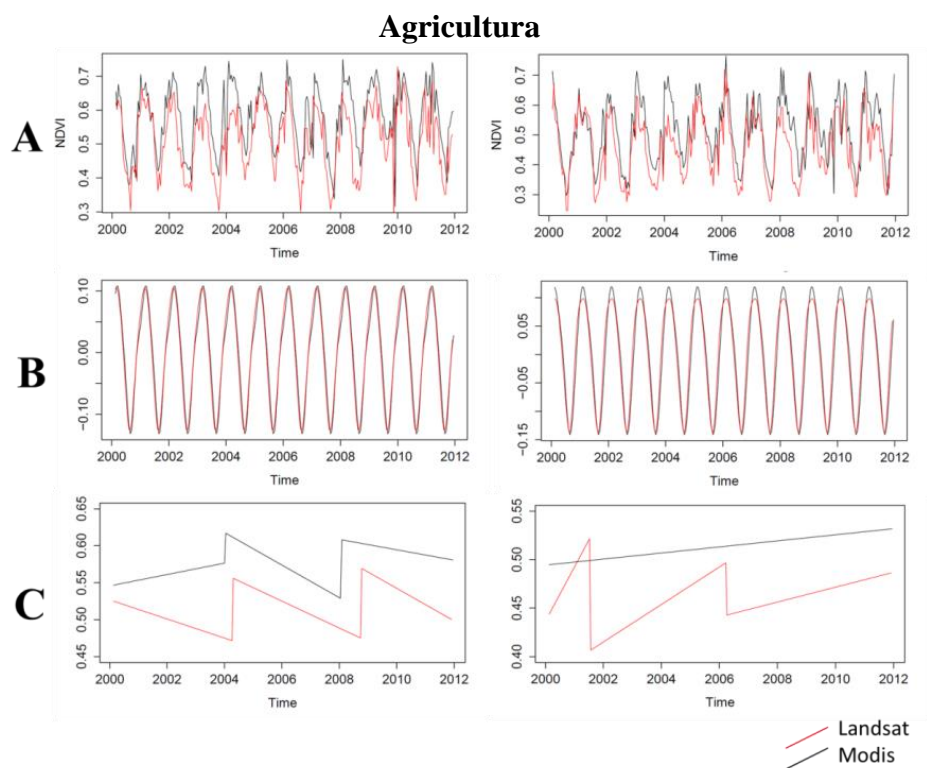


Figura 21 Resultado da análise das séries temporais TM e MODIS por meio do *bfast*. São mostrados dois exemplos para a classe de uso Agricultura, onde A é a série com os dados originais; B é componente de sazonalidade e C, o componente de tendência. A linha preta é a série temporal MODIS e a linha vermelha a série temporal TM.

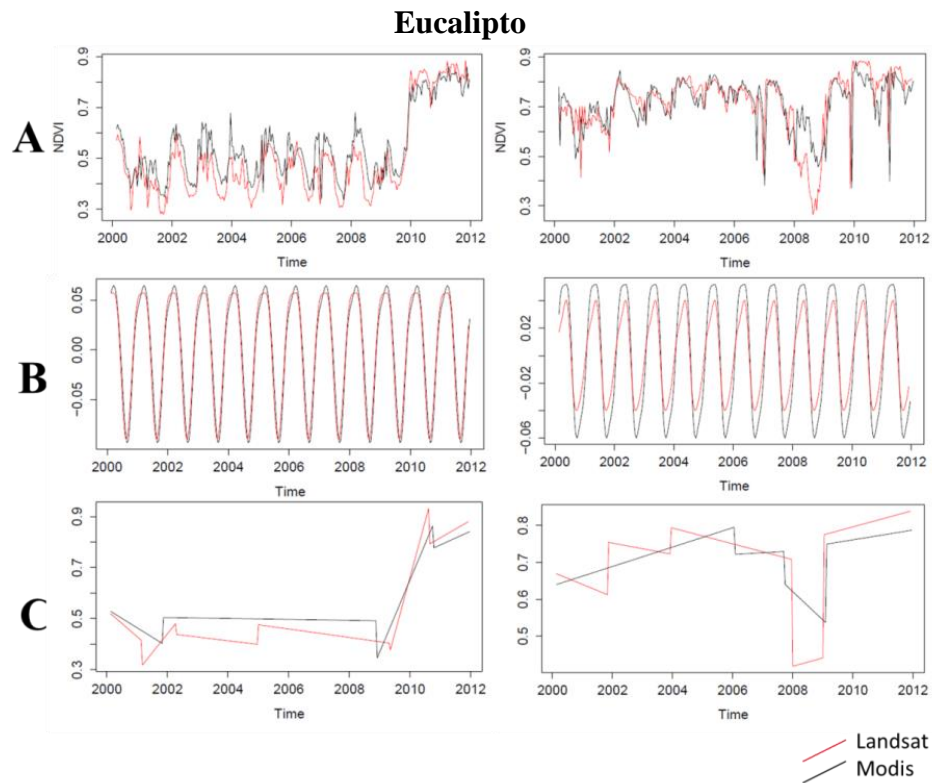


Figura 22 Resultado da análise das séries temporais TM e MODIS por meio do *bfast*. São mostrados dois exemplos para a classe de uso Eucalipto, onde A é a série com os dados originais; B é componente de sazonalidade e C, o componente de tendência. A linha preta é a série temporal MODIS e a linha vermelha a série temporal TM.

Pastagem

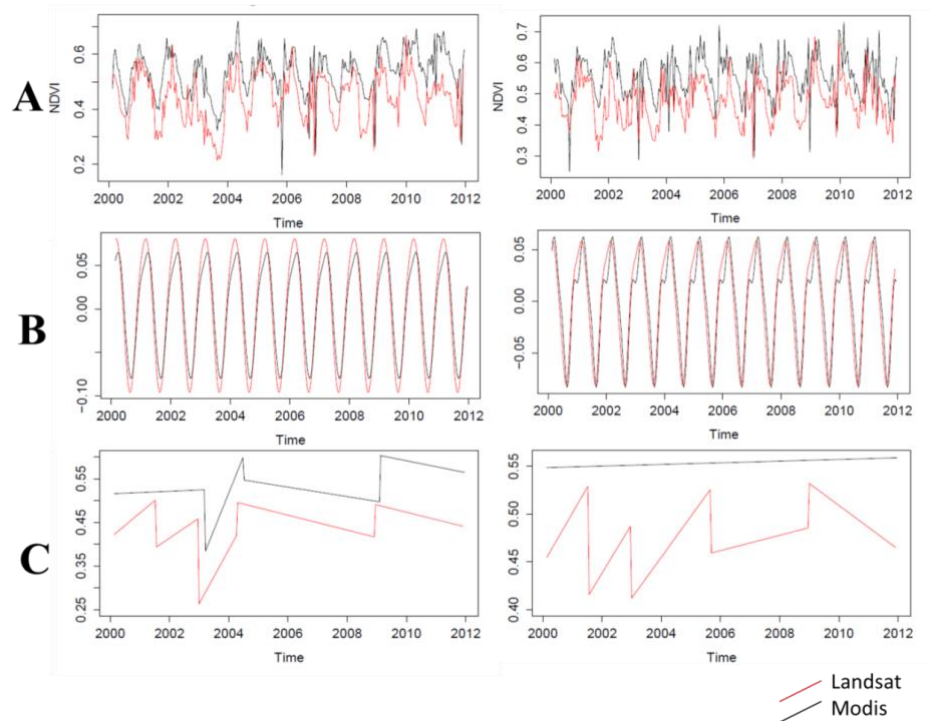


Figura 23 Resultado da análise das séries temporais TM e MODIS por meio do *bfast*. São mostrados dois exemplos para a classe de uso Pastagem, onde A é a série com os dados originais; B é componente de sazonalidade e C, o componente de tendência. A linha preta é a série temporal MODIS e a linha vermelha a série temporal TM.

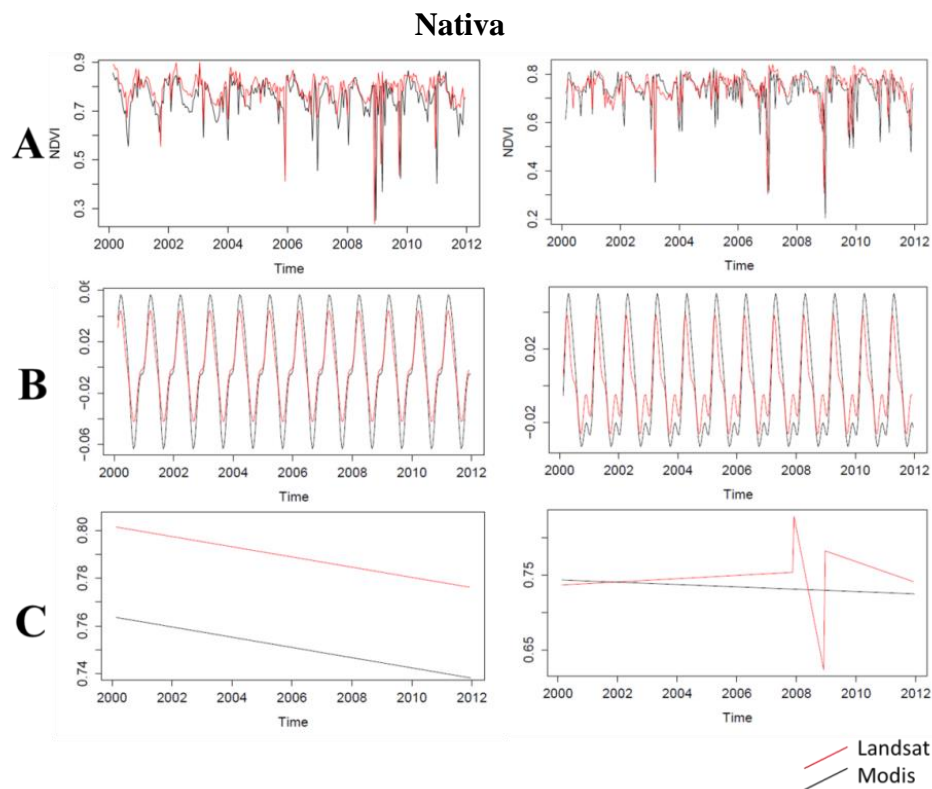


Figura 24 Resultado da análise das séries temporais TM e MODIS por meio do *bfast*. São mostrados dois exemplos para a classe de uso Nativa, onde A é a série com os dados originais; B é componente de sazonalidade e C, o componente de tendência. A linha preta é a série temporal MODIS e a linha vermelha a série temporal TM.

5 CONCLUSÕES

Este trabalho foi realizado com o intuito de avaliar a eficácia de uma série temporal NDVI, composta por imagens TM sintéticas, previstas pelo algoritmo STARFM. Em regiões tropicais, como a nossa área de estudo, a grande frequência de cobertura de nuvens inviabiliza o uso de uma densa série

temporal, composta por imagens TM, que, por sua resolução espacial de 30 metros, é a ideal para o estudo da dinâmica da superfície terrestre nesta região. Portanto, a solução viável encontrada foi a utilização de metodologias de fusão de imagens. Com base nos resultados obtidos, concluímos que:

- Apesar de algumas limitações, o algoritmo STARFM se mostrou bastante promissor na predição das imagens TM.
- A análise da série temporal NDVI TM sintética fornece maiores detalhes espaciais e temporais do que a série MODIS.
- A série temporal NDVI, composta por imagens TM sintéticas, mostrou-se bastante semelhante à série MODIS, apresentando a maioria dos *breakpoints* no componente de tendência coincidentes entre as duas séries.
- Os erros na predição das imagens TM podem ocasionar falsas detecções de mudanças.

6 TRABALHOS FUTUROS

Recentemente, uma nova abordagem de predição de imagens foi desenvolvida, para construção de séries temporais densas e longas, mesmo em regiões onde a cobertura por nuvens é frequente: o Integrated STARFM (ISTARFM), onde vários procedimentos foram feitos para melhorar a consistência entre dados MODIS e TM utilizando o STARFM. Apesar de exigir processos mais complexos e computacionalmente intensivos, os resultados obtidos com a nova abordagem se mostraram bastante promissores (WANG; GAO; MASEK, 2014). Trabalhos futuros poderão ser conduzidos, em nossa área de estudo, a fim de comparar as duas abordagens e, assim, avaliar qual série temporal se mostra mais consistente.

Outro aspecto que poderá ser considerado em trabalhos futuros são as correções topográficas nas imagens TM e MODIS. Tian et al. (2013) afirmam

que o produto MOD13Q1 pode introduzir erros na predição, pois este produto apresenta uma diferença nos valores de NDVI, quando comparado ao produto MCD434A, o BRDF (*Bidirectional Reflectance Distribution Function*) ajustado (BHANDARI; PHINN; GILL, 2011). Assim, realizar correções topográficas, nos pares de imagens TM e MODIS, antes da predição, pode melhorar os resultados de saída, principalmente, em regiões montanhosas (TIAN et al., 2013).

REFERÊNCIAS

- ACERBI-JUNIOR, F. W.; CLEVERS, J. G. P. W.; SCHAEPMAN, M. E. The assessment of multi-sensor image fusion using wavelet transforms for mapping the Brazilian Savanna. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 8, n. 4, p. 278-288, Dec. 2006.
- AHL, D. E. et al. Monitoring spring canopy phenology of a deciduous broadleaf forest using MODIS. **Remote Sensing of Environment**, New York, v. 104, n. 1, p. 88-95, Sept. 2006.
- ALCANTARA, C. et al. Mapping abandoned agriculture with multi-temporal MODIS satellite data. **Remote Sensing of Environment**, New York, v. 124, p. 334-347, Sept. 2012.
- ANDERSON, L. O.; SHIMABUKURO, Y. E. Classificação espectro-temporal de formações vegetais. In: RUDORFF, B. F. T.; SHIMABUKURO, Y. E.; CEBALLOS, J. C. (Ed.). **O sensor MODIS e suas aplicações ambientais no Brasil**. São José dos Campos: Parêntese, 2007. p. 159-171.
- BADHWAR, G. D.; AUSTIN, W. W.; CARNES, J. G. A semi-automatic technique for multitemporal classification of a given crop within a landsat scene. **Pattern Recognition**, Amsterdam, v. 15, n. 3, p. 217-230, 1982.
- BHANDARI, S.; PHINN, S.; GILL, T. Preparing Landsat Image Time Series (LITS) for monitoring changes in vegetation phenology in Queensland, Australia. **Remote Sensing**, New York, v. 4, n. 12, p. 1856-1886, June 2012.
- BRASIL. **Lei nº 12.651**, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa; altera as Leis nos 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis nos 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a Medida Provisória no 2.166-67, de 24 de agosto de 2001; e dá outras providências. Brasília, 2012. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112651.htm>. Acesso em: 8 maio 2014.
- BRUZZONE, L.; SMITS, P. C.; TILTON, J. C. Special issue on analysis of multitemporal remote sensing images. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 41, n. 11, p. 2419-2422, 2003.
- BUSETTO, L.; MERONI, M.; COLOMBO, R. Combining medium and coarse spatial resolution satellite data to improve the estimation of sub-pixel NDVI

time series. **Remote Sensing of Environment**, New York, v. 112, n. 1, p. 118-131, Jan. 2008.

CARVALHO, L. M. T.; DUTRA, G. C. Fundamentos de sensoriamento remoto. In: CARVALHO, L. M. T. (Ed.). **Sistemas de informações geográficas e sensoriamento remoto dos recursos florestais**. Lavras: UFLA, 2008.

COHEN, W. B.; GOWARD, S. N. Landsat's role in ecological applications of remote sensing. **BioScience**, Washington, v. 54, n. 6, p. 535-545, 2004.

COLDITZ, R. R. et al. TiSeG : a flexible software tool for time-series generation of MODIS data utilizing the quality assessment science data set. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 46, n. 10, p. 3296-3308, 2008.

CONESE, C.; MASELLI, F. Use of multitemporal information to improve classification performance of TM scenes in complex terrain. **ISPRS Journal of Photogrammetry and Remote Sensing**, New York, v. 46, n. 4, p. 187-197, Aug. 1991.

COPPIN, P. et al. Review article digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, Basingstoke, v. 25, n. 9, p. 1565-1596, May 2004.

ECOGNITION DEVELOPER. Using eCognition® developer in quickmap mode. In: _____. **User guide**. München: Trimble Germany GmbH, 2011. p. 27-39.

ENGVALL, J. L.; TUBBS, J. D.; HOLMES, Q. A. Pattern recognition of landsat data based upon temporal trend analysis. **Remote Sensing of Environment**, New York, v. 6, n. 4, p. 303-314, Jan. 1977.

EPIPHANIO, J. C. N. **Satélites de sensoriamento remoto**. São José dos Campos: INPE, [2010]. 37 p. Disponível em: <http://www.dsr.inpe.br/vcsr/files/capitulo_2.pdf>. Acesso em: 24 out. 2012.

FIGUEIREDO, D. **Conceitos básicos de sensoriamento remoto**. Brasília: CONAB, 2005. Disponível em: <http://www.conab.gov.br/conabweb/download/SIGABRASIL/manuais/conceitos_sm.pdf>. Acesso em: 10 set. 2011.

FORKEL, M. et al. Trend change detection in NDVI time series: effects of inter-annual variability and methodology. **Remote Sensing**, New York, v. 5, n. 5, p. 2113-2144, May 2013.

FREITAS, R. M.; SHIMABUKURO, Y. E. Combining wavelets and linear spectral mixture model for MODIS satellite sensor time-series analysis. **Journal of Computational Interdisciplinary Sciences**, Brasília, v. 1, n. 1, p. 51-56, 2008.

GAMON, J. A. et al. Relationships between NDVI, canopy structure, and photosynthesis in three californian vegetation types. **Ecological Applications**, Tempe, v. 5, n. 1, p. 28-41, 1995.

GAO, F. et al. On the blending of the Landsat and MODIS surface reflectance: predicting daily landsat surface reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 44, n. 8, p. 3287-3319, Oct. 2006.

GRIFFITHS, P. et al. Using annual time-series of Landsat images to assess the effects of forest restitution in post-socialist Romania. **Remote Sensing of Environment**, New York, v. 118, p. 199-214, Mar. 2012.

HALL, F. G. et al. Large-scale patterns of forest succession as determined by remote sensing. **Ecology**, Durham, v. 72, n. 2, p. 628-646, 1991.

HANSEN, M. C. et al. A method for integrating MODIS and Landsat data for systematic monitoring of forest cover and change in the Congo Basin. **Remote Sensing of Environment**, New York, v. 112, n. 5, p. 2495-2513, May 2008.

HILKER, T. et al. Generation of dense time series synthetic Landsat data through data blending with MODIS using a spatial and temporal adaptive reflectance fusion model. **Remote Sensing of Environment**, New York, v. 113, n. 9, p. 1988-1999, Sept. 2009a.

HILKER, T. et al. A new data fusion model for high spatial- and temporal-resolution mapping of forest disturbance based on Landsat and MODIS. **Remote Sensing of Environment**, New York, v. 113, n. 8, p. 1613-1627, Aug. 2009b.

HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, New York, v. 83, n. 1/2, p. 195-213, Nov. 2002.

JACQUIN, A.; SHEEREN, D.; LACOMBE, J. P. Vegetation cover degradation assessment in Madagascar savanna based on trend analysis of MODIS NDVI time series. **International Journal of Applied Earth Observation and Geoinformation**, New York, v. 12, p. S3-S10, 2010. Supplement.

JÖNSSON, P.; EKLUNDH, L. TIMESAT: a program for analyzing time-series of satellite sensor data. **Computers & Geosciences**, New York, v. 30, n. 8, p. 833-845, Oct. 2004.

KENNEDY, R. E.; COHEN, W. B.; SCHROEDER, T. A. Trajectory-based change detection for automated characterization of forest disturbance dynamics. **Remote Sensing of Environment**, New York, v. 110, n. 3, p. 370-386, Oct. 2007.

KENNEDY, R. E.; YANG, Z.; COHEN, W. B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1., LandTrendr, temporal segmentation algorithms. **Remote Sensing of Environment**, New York, v. 114, n. 12, p. 2897-2910, Dec. 2010.

KOLTUNOV, A. et al. Selective logging changes forest phenology in the Brazilian Amazon: evidence from MODIS image time series analysis. **Remote Sensing of Environment**, New York, v. 113, n. 11, p. 2431-2440, Nov. 2009.

KOTTEK, M. et al. World map of the Köppen-Geiger climate classification updated. **Meteorologische Zeitschrift**, Berlin, v. 15, n. 3, p. 259-263, June 2006. Disponível em: <<http://koeppen-geiger.vu-wien.ac.at/present.htm>>. Acesso em: 11 jun. 2014.

LHERMITTE, S. et al. A comparison of time series similarity measures for classification and change detection of ecosystem dynamics. **Remote Sensing of Environment**, New York, v. 115, n. 12, p. 3129-3152, Dec. 2011.

LI, S.; KWOK, J. T.; WANG, Y. Using the discrete wavelet frame transform to merge Landsat TM and SPOT panchromatic images. **Information Fusion**, New York, v. 3, n. 1, p. 17-23, Mar. 2002.

MASEK, J. G. et al. A Landsat surface reflectance dataset. **IEEE Geoscience and Remote Sensing Letters**, New York, v. 3, n. 1, p. 68-72, 2006.

MENESES, P. R. et al. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UnB, 2012. 276 p.

METZGER, J. P. Como restaurar a conectividade de paisagens fragmentadas? In: KAGEYAMA, P. et al. (Org.). **Restauração ecológica de ecossistemas naturais**. Botucatu: FEPAF, 2003. p. 49-76.

MOLENAAR, M. **An introduction to theory of Spatial object modelling for GIS**. Enschede: Taylor & Francis, 1998. 246 p.

MORETTIN, P. A.; TOLOI, C. M. C. Preliminares. In: _____. **Análise de séries temporais**. São Paulo: E. Blücher, 2004. p. 1-20.

MYERS, N. et al. Biodiversity hotspots for conservation priorities. **Nature**, London, v. 403, n. 6772, p. 853-858, Feb. 2000.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. **About Landsat**. Disponível em: <<http://landsat.gsfc.nasa.gov/about/tm.html>>. Acesso em: 24 out. 2012.

OHMANN, J. L. et al. Mapping change of older forest with nearest-neighbor imputation and Landsat time-series. **Forest Ecology and Management**, Amsterdam, v. 272, p. 13-25, May 2012.

OLEXA, E. M.; LAWRENCE, R. L. Performance and effects of land cover type on synthetic surface reflectance data and NDVI estimates for assessment and monitoring of semi-arid rangeland. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 30, p. 30-41, Aug. 2014.

OLIVEIRA, T. et al. NDVI time series for mapping phenological variability of forests across the cerrado biome. In: ZHANG, X. (Ed.). **Phenology and climate change**. New York: In Tech, 2012. p. 253-272.

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2013. Disponível em: <<http://www.R-project.org/>>. Acesso em: 10 dez. 2013.

ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3., 1973, Washington. **Proceedings...** Washington: NASA, 1974. v. 1, p. 309-317.

ROY, D. P. et al. Multi-temporal MODIS-Landsat data fusion for relative radiometric normalization, gap filling, and prediction of Landsat data. **Remote Sensing of Environment**, New York, v. 112, n. 6, p. 3112-3130, June 2008.

SAKAMOTO, T. et al. A crop phenology detection method using time-series MODIS data. **Remote Sensing of Environment**, New York, v. 96, n. 3/4, p. 366-374, June 2005.

SCHROEDER, T. A.; COHEN, W. B.; YANG, Z. Patterns of forest regrowth following clearcutting in western Oregon as determined from a Landsat time-series. **Forest Ecology and Management**, Amsterdam, v. 243, n. 2/3, p. 259-273, May 2007.

SCHROEDER, T. A. et al. Mapping wildfire and clearcut harvest disturbances in boreal forests with Landsat time series data. **Remote Sensing of Environment**, New York, v. 115, n. 6, p. 1421-1433, June 2011.

SHOWENGERDT, R. A. The nature of remote sensing. In: _____. **Remote sensing: models and methods for image processing**. 3rd ed. Tucson: Elsevier, 2007. p. 1-44.

SOARES, J. V.; BATISTA, G. T.; SHIMABUKURO, Y. E. Histórico e descrição. In: RUDORFF, B. F. T.; SHIMABUKURO, Y. E.; CEBALLOS, J. C. (Ed.). **O sensor MODIS e suas aplicações ambientais no Brasil**. São José dos Campos: Parêntese, 2007. p. 3-21.

SONNENSCHNEIDER, R. et al. Differences in Landsat-based trend analyses in drylands due to the choice of vegetation estimate. **Remote Sensing of Environment**, New York, v. 115, n. 6, p. 1408-1420, June 2011.

STELLMES, M. et al. Dryland observation at local and regional scale: comparison of Landsat TM / ETM + and NOAA AVHRR time series. **Remote Sensing of Environment**, New York, v. 114, n. 10, p. 2111-2125, 2010.

SULLA-MENASHE, D. et al. Detecting forest disturbance in the Pacific Northwest from MODIS time series using temporal segmentation. **Remote Sensing of Environment**, New York, v. 151, p. 114-123, Nov. 2013.

TIAN, F. et al. Mapping and evaluation of NDVI trends from synthetic time series obtained by blending Landsat and MODIS data around a coalfield on the loess plateau. **Remote Sensing**, New York, v. 5, n. 9, p. 4255-4279, Sept. 2013.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, New York, v. 8, p. 127-150, 1979.

UNITED STATES GEOLOGICAL SURVEY. **Landsat**: a global land-imaging mission. Disponível em: <<http://pubs.usgs.gov/fs/2012/3072/fs2012-3072.pdf>>. Acesso em: 4 jun. 2014.

VERBESSELT, J. et al. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, New York, v. 114, n. 1, p. 106-115, Jan. 2010a.

VERBESSELT, J. et al. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. **Remote Sensing of Environment**, New York, v. 114, n. 12, p. 2970-2980, Dec. 2010b.

VERBESSELT, J.; ZEILEIS, A.; HEROLD, M. Near real-time disturbance detection using satellite image time series. **Remote Sensing of Environment**, New York, v. 123, p. 98-108, Aug. 2012.

VERHOEF, W.; MENENTI, M.; AZZALI, S. A colour composite of NOAA: AVHRR-NDVI based on time series analysis: 1981-1992. **International Journal of Remote Sensing**, Basingstoke, v. 17, n. 2, p. 231-235, 1996.

VICTORIA, D. D. C.; OLIVEIRA, A. F. de; GREGO, C. R. **Análise harmônica de séries temporais de imagens de satélite para identificação de atividades agrícolas**: um estudo de caso de imagens NDVI/MODIS na região de Ribeirão Preto, SP. Brasília: EMBRAPA, 2008. 18 p. (Documentos Online EMBRAPA, 72).

VIEIRA, M. A. et al. 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**, New York, v. 123, p. 553-562, Aug. 2012.

VOGELMANN, J. E. et al. Monitoring gradual ecosystem change using Landsat time series analyses: case studies in selected forest and rangeland ecosystems. **Remote Sensing of Environment**, New York, v. 122, p. 92-105, July 2012.

WALKER, J. J.; DE BEURS, K. M.; WYNNE, R. H. Dryland vegetation phenology across an elevation gradient in Arizona, USA, investigated with fused MODIS and Landsat data. **Remote Sensing of Environment**, New York, v. 144, p. 85-97, Mar. 2014.

WALKER, J. J. et al. Evaluation of Landsat and MODIS data fusion products for analysis of dryland forest phenology. **Remote Sensing of Environment**, New York, v. 117, p. 381-393, Feb. 2012.

WANG, P.; GAO, F.; MASEK, J. G. Operational data fusion framework for building frequent landsat-like imagery. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 52, n. 11, p. 7353-7365, 2014.

WATTS, J. D. et al. Improved classification of conservation tillage adoption using high temporal and synthetic satellite imagery. **Remote Sensing of Environment**, New York, v. 115, n. 1, p. 66-75, Jan. 2011.

XIAO, X. et al. Detecting leaf phenology of seasonally moist tropical forests in South America with multi-temporal MODIS images. **Remote Sensing of Environment**, New York, v. 103, n. 4, p. 465-473, Aug. 2006.

XIAO, X. et al. Mapping paddy rice agriculture in southern China using multi-temporal MODIS images. **Remote Sensing of Environment**, New York, v. 95, n. 4, p. 480-492, Apr. 2005.

XIONG, X. et al. NASA EOS Terra and Aqua MODIS on-orbit performance. **Advances in Space Research**, Oxford, v. 43, n. 3, p. 413-422, Feb. 2009.

YUAN, F. et al. Land cover classification and change analysis of the Twin Cities (Minnesota) metropolitan area by multitemporal Landsat remote sensing. **Remote Sensing of Environment**, New York, v. 98, n. 2/3, p. 317-328, Oct. 2005.

ZHANG, X. et al. Long-term detection of global vegetation phenology from satellite instruments. In: ZHANG, X. (Ed.). **Phenology and climate change**. New York: In Tech, 2012. p. 297-330.

ZHANG, X. et al. Monitoring vegetation phenology using MODIS. **Remote Sensing of Environment**, New York, v. 84, n. 3, p. 471-475, Mar. 2003.

ZHONG, L.; GONG, P.; BIGING, G. S. Efficient corn and soybean mapping with temporal extendability: a multi-year experiment using Landsat imagery. **Remote Sensing of Environment**, New York, v. 140, p. 1-13, Jan. 2014.

ZHU, X. et al. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. **Remote Sensing of Environment**, New York, v. 114, n. 11, p. 2610-2623, Nov. 2010.