

UMA INTRODUÇÃO SOBRE MÉTODOS PARA SÉRIES TEMPORAIS

Guilherme Oliveira Chagas Mikhail José Pires Pedrosa de Oliveira Naiallen Carolyne Rodrigues Lima Rennan de Freitas Bezerra Marujo

Trabalho da Disciplina Tópicos Especiais em Observação da Terra do Curso de Pós-Graduação em Computação Aplicada do Instituto Nacional de Pesquisas Espaciais.

INPE São José dos Campos 2016

SUMÁRIO

Pág.

1 INTRODUÇÃO	2
2 REFERENCIAL TEÓRICO	4
2.1 Sistemas imageadores para séries temporais	4
2.1.1 Programa Landsat	5
2.1.1.1 Landsat-8	6
2.1.2 MODIS	6
2.2 Séries temporais	$\overline{7}$
2.2.1 Variáveis de séries temporais para sensoriamento remoto	9
2.3 Métodos para séries temporais de imagens orbitais	10
2.3.1 STARFM	11
2.3.2 BFAST	14
2.3.3 SVM	17
2.3.4 TWDTW	21
2.3.4.1 DTW	21
2.3.4.2 DTW para subsequências	25
2.3.4.3 O método TWDTW	27
2.3.4.4 Considerações sobre os testes de Maus et al. (2016b)	28
3 TESTES E RESULTADOS	29
3.1 Testes com o método STARFM	29
3.2 Testes com o método BFAST	32
3.3 Testes com o método TWDTW	34
4 CONSIDERAÇÕES FINAIS	37
REFERÊNCIAS BIBLIOGRÁFICAS	38

1 INTRODUÇÃO

Sabendo que a Terra está em constante mudança e que a detecção e compreensão de processos atuantes (desflorestamento, expansão urbana, fenômenos naturais) é vital para a manutenção dos ecossistemas, torna-se importante o desenvolvimento de ferramentas capazes de detectar as variações sofridas (KÜNZER et al., 2015, p. 2). Entender o passado é importante para predizer as mudanças futuras da superfície terrestre, nesse contexto séries temporais de imagens de orbitais provêem modos de monitorar as variações do espaço no tempo. Uma série temporal é um conjunto de observações sequenciais e dependente. A análise de uma série temporal possibilita a verificação de tendências, de periodicidades e predições (EHLERS, 2009).

Sistemas imageadores, como os satélites, são o único meio de obter dados sobre a superfície da Terra de forma constante e consistente (MAUS et al., 2016b). Embora a necessidade de monitoramento contínuo da superfície seja essencial e, desde a década de 1970 até os dias atuais, existam centenas de satélites de observação da Terra o uso de séries temporais ainda é limitado devido às restrições de acesso às imagens no passado.

O Instituto Nacional de Pesquisas Espaciais (INPE) foi pioneiro na disponibilização gratuita de dados de satélite de média resolução (BANSKOTA et al., 2014). Isso porque, em 2004, o INPE liberou imagens do segundo satélite Sino-Brasileiro de Recursos Terrestres (CBERS-2) e posteriormente as suas imagens *Landsat*. A adoção dessa política incentivou o *United States Geological Survey* (USGS) a disponibilizar os dados do arquivo *Landsat* em 2008 (WOODCOCK et al., 2008; BANSKOTA et al., 2014), o que resultou em uma quantidade maior de *downloads* e utilização de imagens orbitais (WULDER et al., 2012).

Na revisão realizada por Coppin et al. (2004) mostrou-se que a maioria dos métodos de detecção de mudanças utiliza séries curtas, que variam entre duas a cinco imagens, não usufruindo de todo o potencial de séries históricas. Diversas abordagens foram propostas para análises de séries temporais, por exemplo, os trabalhos de Roerink, Meneti e Verhoef (2000), Jösson e Eklundh (2002), Lunetta et al. (2006), Verbesselt et al. (2010a), Verbesselt, Zeileis e Herold (2012), Griffiths, Linden e Ku (2013), Forkel et al. (2013) e Maus et al. (2016b).

Neste trabalho são descritos quatro abordagens atuais no contexto de séries temporais: Spatial and Temporal Adaptative Reflectance Fusion Model (STARFM) (GAO et al., 2006), Break for Additive Seasonal and Trend (BFAST) (VERBES- SELT et al., 2010a), alguns métodos baseados em *Support Vector Machine* (SVM) e *Time-Weighted Dynamic Time Warping* (TWDTW) (MAUS et al., 2016a). Os métodos STARFM e BFAST foram selecionados devido as suas relevâncias na literatura. O SVM foi escolhido por ser uma abordagem conhecida e bastante difundida na literatura. O método TWDTW foi selecionado por ser recente e por ser uma variação do *Dynamic Time Warping* (DTW), um método consolidado em mineração de dados.

Este trabalho está organizado como a seguir. No capítulo 2 são descritos alguns conceitos para o entendimento deste texto e são apresentados os métodos STARM, BFAST, SVM e TWDTW. Apresenta-se, no capítulo 3, os resultados de alguns testes realizados com os métodos STARM, BFAST e TWDTW. No capítulo 4, são descritas algumas considerações finais.

2 REFERENCIAL TEÓRICO

Neste capítulo são apresentados alguns conceitos necessários para o entendimento deste texto. Na seção 2.1 são detalhados alguns sistemas imageadores para séries temporais. Apresenta-se, na seção 2.2, os conceitos de série temporal. Descreve-se, na seção 2.3, os métodos para séries temporais abordados neste trabalho.

2.1 Sistemas imageadores para séries temporais

Os satélites para observação da Terra variam de acordo com suas finalidades, tipo de órbita, resolução espacial, resolução temporal, resolução radiométrica, tipo de varredura e etc. Dependendo da faixa de operação no espectro eletromagnético, os sensores podem ser ópticos, termais ou radares (BELWARD; SKØIEN, 2015).

Neste trabalho aborda-se séries temporais na seara de sensores ópticos. Embora existam muitos satélites com esses sensores a bordo, apenas uma pequena parcela destes podem prover conjuntos de dados que cubram algumas décadas e que possam ser utilizados para análise de séries temporais longas (KÜNZER et al., 2015, p. 4). Os sensores/satélites que estão operacionais e que podem prover mais de três décadas de dados são: Advanced Very High Resolution Radiometer (AVHRR), a bordo do National Oceanic and Atmospheric Administration (NOAA); o Enhanced Thematic Mapper Plus (ETM+) e o Operational Land Imager (OLI) a bordo do Landsat7 e Landsat8 (Land Remote Sensing Satellite), respectivamente; e o VEGETATION, a bordo do Satellite Pour l'Observation de la Terre (SPOT) (KÜNZER et al., 2015).

Entre os satélites com sensores ópticos operacionais lançados desde 1999 e que têm potencial de serem usados em séries temporais pode-se citar: o *Moderate Resolution Imaging Spectroradiometer* (MODIS), a bordo do Terra e *Aqua*; o *Advanced Along-Track Scanning Radiometer* (AATSR) e o *Medium Resolution Imaging Spectrometer* (MERIS), a bordo do *European Environmental Satellite* (ENVISAT); o *Advanced Spaceborne Thermal Emission and Reflection Radiometer* (ASTER), também a bordo do Terra. Entre os que têm altíssima Resolução Espacial, pode-se citar: o Quickbird, IKONOS, Worldview, GeoEye e o RapidEye (BELWARD; SKØIEN, 2015).

Na Figura 2.1 é apresentada a relação entre Resolução Espacial e tempo de revisita dos sensores. Nessa figura, considerou-se as bandas na região do visível, por isso o ASTER, que trabalha do Infravermelho Próximo (IVP) ao Termal (ITC, 2016), não aparece. Atualmente, o programa *Landsat* provê o registro mais longo de dados orbitais (COHEN; GOWARD, 2004), fornecendo observações desde 1972. Já o sensor MODIS, embora tenha sido lançado em 1999 no *Terra* e em 2002 no *Aqua* (ITC, 2016), apresenta grande potencial para séries temporais, principalmente na análise de fenômenos que mudam rapidamente. Isso se deve a sua alta Resolução temporal (WU et al., 2012) e melhor resolução espacial, quando comparado com os outros sensores de revisita diária, como o AVHRR, VEGETATION e AATSR. Por isso, neste trabalho, as imagens usadas para teste dos métodos descritos nas próximas seções serão provenientes dessas duas plataformas.



Figura 2.1 - Relação entre resolução espacial e tempo de revisita entre os satélites para sensoriamento remoto. Fonte: Adaptado de ITC (2016)

2.1.1 Programa Landsat

No fim dos anos 60, visando coletar dados sobre recursos naturais renováveis e não renováveis da superfície terrestre, a NASA (*National Aeronautics and Space Administration*) iniciou o programa *Landsat* (USGS, 2015). Atualmente, o programa *Landsat* conta com o lançamento de 8 plataformas, estando em operação o *Landsat-7* (em condições precárias) e o *Landsat-8*.

2.1.1.1 Landsat-8

Em fevereiro de 2013 foi lançado foi lançado o o Landsat-8, que orbita a Terra em órbita quase polar, posicionando-se de maneira heliossíncrona a uma altitude de aproximadamente 705km de modo a conseguir imagear a Terra por meio de seus dois sensores: o sensor OLI (Operacional Land Imager) e o sensor TIRS (Thermal Infrared Sensor) (USGS, 2015). Para as bandas do visível o satélite Landsat-8 apresenta resolução espacial de 30m, 15m para banda pancromática e 100m para as bandas termais (TIRS). As cenas imageadas possuem 185km leste-oeste e apresentam revisita (resolução temporal) em 16 dias. Na Tabela 2.1.1.1 é mostrado, detalhadamente, os comprimentos de onda das bandas presentas a bordo do satélite Landsat-8.

	Bandas	Comprimento de onda (µm)	Resolução (m)		
Banda 1 -	Coastal aerosol	0,43 - 0,45	30		
Banda 2 -	Blue	0,45 - 0,51	30		
Banda 3 -	Green	0,53 - 0,59	30		
Banda 4 -	Red	0,64 - 0,67	30		
Banda 5 -	Near infrared (NIR)	0,85 - 0,88	30		
Banda 6 -	SWIR 1	1,57 - 1,65	30		
Banda 7 -	SWIR 2	2,11 - 2,29	30		
Banda 8 -	Panchromatic	0,50 - 0,68	15		
Banda 9 -	Cirrus	1,36 - 1,38	30		
Banda 10 -	Thermal infrared (TIRS) 1	10,60 - 11,19	100		
Banda 11 -	Thermal infrared (TIRS) 2	11,50 - 12,51	100		

Tabela 2.1 - Bandas multiespectrais do sensor OLI/Landsat-8. Adaptado de (USGS, 2015).

2.1.2 MODIS

Em 1999 a NASA lançou os satélites Terra e Aqua, os quais transportam o sensores MODIS. O *Terra* e o *Aqua* possuem órbita síncrona com o Sol, quase polar, circular e estão a uma altitude de aproximadamente 705km. O MODIS apresenta ampla cobertura espectral (indo do visível até o termal, com 36 banda espectrais), espacial (com faixa de imageamento de 2330 km em *cross track* por 10 km em *along track at nadir*) e temporal (a cada 1-2 dias) (NASA, 2016). Por isso, esse sensor faz a cobertura global quase que diariamente, além disso foi o primeiro a ser utilizado em pesquisas de mudanças globais, sendo utilizado para estudos de atmosfera, oceano e solo. Mostra-se, na Tabela 2.1.2, as resoluções das bandas do MODIS.

O MODIS apresenta ampla cobertura espacial e espectral e, também, foi o

primeiro sensor utilizado em pesquisas de mudanças globais (BARKER et al., 1992). Dessa maneira, esse sensor é utilizado para estudos da atmosfera, oceano e solo.

O MODIS possui uma cobertura global quase diária (a cada 1-2 dias) (JUS-TICE et al., 2002). O MODIS possui 36 bandas espectrais que têm por finalidade detectar as propriedades e dinâmicas das nuvens, da vegetação terrestre e dos oceanos (SALOMONSON; TOLL, 1991). Mostra-se, na Tabela 2.1.2, as resoluções das bandas do MODIS.

Tabela	2.2 -	Resolução Espacial do MODIS
		Fonte: (JUSTICE et al., 2002).

	Bandas	Resolução (m)
Bandas (1 - 2)	Verde e Infravermelho Próximo	250
	(IVP)	
Bandas $(3 - 7)$	Azul, Verde e Infravermelho	500
	Médio,	
Bandas (8 - 36)	Infravermelho Thermal	1000

2.2 Séries temporais

Caracterizar e mapear a cobertura da Terra é essencial para planejar e manejar os recursos naturais, bem como entender a distribuição dos habitats. Devido a crescente disponibilidade de dados e plataformas, o sensoriamento remoto e o processamento de imagens digitais permitem que a observação, identificação, mapeamento e monitoramento da Terra seja feito em nível espacial, temporal, espectral e temático (GÓMEZ et al., 2016). Neste trabalho é abordado o sensoriamento remoto o ponto de vista de séries temporais.

Séries temporais são coleções de observações feitas de maneira cronológica, cujas características incluem: grande quantidade de dados, alta dimensionalidade e atualização continua (FU, 2011). Uma série temporal usualmente consiste em três componentes principais: sazonalidade, que são flutuações nos valores com duração inferior a um ano e que se repetem periodicamente; tendência, que é um comportamento a longo prazo; e irregularidade, que são flutuações inexplicáveis, resultado de eventos inesperados (KÜNZER et al., 2015).

Como exemplo das componentes de uma série temporal em análise de dados de sensoriamento remoto, podemos considerar a observação de uma região de savana. A sazonalidade dessa região seria o vigor da vegetação dependo da estão seca ou chuvosa; a tendência observada durante muitos anos poderia ser crescimento da quantidade de vegetação ou degradação ou ainda a estabilidade da vegetação; as irregularidades podem ser queimadas, mudanças atmosféricas durante a aquisição dos dados, mudança na anisotropia da superfície, diferenças de iluminação, defeito dos sensores (KÜNZER et al., 2015).

O objetivo principal das séries temporais, no âmbito de sensoriamento remoto, é monitorar as mudanças que ocorrem na cobertura da Terra, por isso o intervalo entre uma imagem e outra depende do que se quer monitorar. Muitos programas de observação da Terra que buscam mapear desmatamento, como por exemplo, o brasileiro PRODES, tem intervalo de um ano (PRODES, 2016). Quando se quer monitorar fenômenos que tem ciclo mais rápido, por exemplo, o crescimento de uma cultura, intervalos de tempo mais curtos são exigidos, neste caso pode-se usar as imagens do Landsat (com ciclo de 16 dias) ou mesmo algoritmos que sintetizem imagens com resolução espacial média e resolução temporal diária, por exemplo o STARFM (GAO et al., 2006) e o STRUM (GEVAERT; GARCÍA-HARO, 2015).

As análise de séries temporais tradicionais decaem em quatro situações principais: decomposição, previsão, agrupamento e classificação (HYNDMAN; ATHA-NASOPOULOS, 2014). A decomposição de série temporal consiste em decompor essa série nas sua componentes principais: tendência, sazonalidade e irregularidades (Figura 2.2). Os algoritmos para esse fim são, por exemplo, decomposição aditiva e multiplicativa (HYNDMAN; ATHANASOPOULOS, 2014), o método STL (CLE-VELAND et al., 1990a) utilizada pelo método BFAST (VERBESSELT et al., 2010a), entre outros.

A previsão utilizando séries temporais consiste em analisar dados do passado, que neste estágio já foram processados e separados nas componentes de série temporal, para se adaptar ao futuro (Figura 2.3). Exemplo de métodos são: o método ARIMA, introduzido por Box et al. (2015) na primeira versão do livro em 1970, Redes Neurais, método ARMA Box et al. (2015), entre outros.

A classificação de séries temporais consiste em rotular grupos de dados. Existem diversos métodos para classificar séries temporais, por exemplo, SVM, redes neurais, Transformada de Wavelet, árvores de decisão, Transformada de Fourier, Cadeias de Markov, DTW, etc.



Figura 2.2 - Três componentes de uma série temporal: Sazonalidade, Tendência e Irregularidade. Fonte: Adaptado de Künzer et al. (2015)



Figura 2.3 - Exemplo da Previsão usando séries temporais.

2.2.1 Variáveis de séries temporais para sensoriamento remoto

Para criar uma série temporal é necessário definir o tipo de dado que será utilizado levando em conta o que se quer analisar. Os dados para série temporal podem ser Número Digital (ou nível de cinza - NC), valores de reflectância (em porcentagem), valores de radiância ou variáveis derivadas desses produtos.

As variáveis utilizadas em série temporais de imagens de sensoriamento remoto

podem ser geofísicas, índices, temáticas, topográficas ou de textura (KÜNZER et al., 2015). Na Figura 2.4 são apresentadas as variáveis comumente utilizadas para essa aplicação.



Figura 2.4 - Variáveis comumente utilizadas em sensoriamento remoto para análise de série temporal. Fonte: Adaptado de Künzer et al. (2015)

2.3 Métodos para séries temporais de imagens orbitais

Nesta seção são descritos os métodos para séries temporais abordados neste trabalho. A escolha dos métodos se deu, primeiro, pelo fato de os algoritmos serem atuais e relevantes na literatura, segundo porque essa revisão propõem uma sequência de passos que devem ser seguidos para chegar ao objetivo de classificar séries temporais. Na subseção 2.3.1 descreve-se o método *Special Temporal Adaptative Reflectance Fusion Model* (STARFM) (GAO et al., 2006) por montar a série temporal. Na subseção 2.3.2, o método *Break for Additive Seasonal and Trend* (BFAST) (VERBESSELT et al., 2010a) para determinar as componentes de tendência, sazonalidade, rezidual e pontos de quebra da série. Por fim são mostrados métodos para classificação: métodos baseados em *Support Vector Machine* (SVM) são citados na subseção 2.3.3 e na subseção 2.3.4, o método *Time-Weighted Dynamic Time Warping* (TWDTW) (MAUS et al., 2016a).

2.3.1 STARFM

A fenologia é o estudo dos eventos periódicos e sazonal da vida da planta em função da sua reação às condições do ambiente (FEDERATION, 2016), os três principais fatores não biológicos que afetam a fenologia são: luz do sol, temperatura e precipitação. Portanto, acompanhar as mudanças desses fatores e da fenologia são de suma importância em Observação da Terra.

O método Spatial and Temporal Adaptive Reflectance Fusion Model (STARFM), proposto por Gao et al. (2006), surgiu da necessidade de se obter imagens com resoluções temporal e espacial boas para estudos relacionados à fenologia, principalmente de vegetação que tenham ciclo de vida rápido.

Além disso, atualmente há uma grande disponibilidade de imagens provenientes de sensores multi-espectrais, o que permite desenvolver análises temporais, espectrais e espaciais. No entanto, apesar da gama variada de sensores, ainda não existe um sensor que tenha resolução espacial média ou ótima aliado a uma resolução temporal diária (Figura 2.1). Por isso, a ideia do método STARFM é fusionar uma imagem com resolução espacial boa e temporal ruim com outra de resolução espacial ruim e temporal boa para criar uma resultante com com resoluções espacial e temporal boas.

No artigo abordado nesta seção, intitulado "On the blending of the Landsat and MODIS surface reflectance: Predicting daily Landsat surface reflectance", os autores propõem criar uma imagem sintética, em reflectância, com a resolução espacial das imagens geradas pelo sensor ETM+ do Landsat-7 - que possui 30m de resolução espacial e 16 dias de resolução temporal - com a resolução temporal das imagens geradas pelo MODIS, a bordo dos satélites Terra e Aqua - que possui 250m, 500m ou 1000m de resolução espacial e um dia de resolução temporal.

A escolha desses sensores foi feita levando em consideração as suas correspondências de bandas espectrais e similaridade de órbita dos satélites. As imagens provenientes desses sensores são em reflectância porque em se tratando de Observação da Terra, procura-se significados físicos como radiância, reflectância ou geometria (no caso de imagens de radar).

Neste trabalho, além da abordagem multi-temporal, há a abordagem multisensor. Por isso as imagens precisam ser corrigidas geométrica, radiométrica e atmosfericamente uma em relação a outra. Além disso, as imagens do MODIS precisam ser re-amostradas para que seus pixeis fiquem com o mesmo tamanho dos pixeis do ETM+.

Embora sejam feitas todas as correções entre as imagens, pequenos vieses são esperados. Todavia o STARFM negligencia pequenos erros de geolocalização e diferenças de correções atmosféricas.

Depois de feitas as correções e a re-amostragem, considerando um píxel homogêneo com resolução grosseira do MODIS no tempo t_k , a reflectância superficial do ETM+, também no tempo t_k , pode ser expressa como:

$$L(x_i, y_j, t_k) = M(x_i, y_j, t_k) + \varepsilon_k, \qquad (2.1)$$

em que (x_i, y_j) é um píxel em uma dada posição para o *Landsat* e o MODIS, t_k é o tempo de aquisição para o MODIS e *Landsat*, e ε_k representa a diferença da reflectância superficial entre o MODIS e *Landsat*.

Como o intervalo entre as imagens do *Landsat* é de 16 dias, entre $t_k e t_k + 1$ serão sintetizadas 16 imagens, sendo que a primeira imagem gerada dentro desse intervalo será no dia t_0 e a última no dia t_15 . A imagem *Landsat* sintetizada no dia t_0 pode ser representada pela Equação (2.2).

$$L(x_i, y_j, t_0) = M(x_i, y_j, t_0) + \varepsilon_0$$

$$(2.2)$$

Supondo que a superfície e demais erros entre os pixeis são fixos, podemos considerar que:

$$L(x_i, y_j, t_0) = M(x_i, y_j, t_0) + L(x_i, y_j, t_k) - M(x_i, y_j, t_k)$$
(2.3)

No entanto essa situação ideal não pode ser satisfeita, pois o píxel do MODIS não é homogêneo, a cobertura da Terra pode mudar rapidamente, a função de reflectância bidirecional não pode ser repedida da mesma forma e mudanças atmosféricas não são controladas. Então, para predizer o erro deve-se utilizar a informação dos vizinhos, dando pesos a eles:

$$L(x_{w/2}, y_{w/2}, t_0) = \sum_{i=1}^{w} \sum_{j=1}^{w} \sum_{k=1}^{n} W_{i,j,k} \times M(x_i, y_j, t_0) + L(x_i, y_j, t_k) - M(x_i, y_j, t_k)$$
(2.4)

em que w é a janela de busca, $(x_{w/2}, y_{w/2})$ é píxel central da janela e $W_{i,j,k}$ é o peso.

Para determinar os pesos é necessário primeiro definir os píxeis usados como sementes, eles podem ser determinas por limiares ou pré-classificação, depois é preciso calcular:

• a diferença espectral entre a imagem Landsat e MODIS no tempo k:

$$S_{ijk} = |L(x_i, y_j, t_k) - M(x_i, y_j, t_k)|$$
(2.5)

• a diferença temporal entre t_k e as imagens do intervalo (usamos t_0 como exemplo):

$$T_{ijk} = |M(x_i, y_j, t_k) - M(x_i, y_j, t_0)|$$
(2.6)

• a distância espacial entre o ente o píxel central em $(x_{w/2}, y_{w/2})$ e um píxel candidato (x_i, y_j) :

$$D_{ijk} = 1.0 + d_{ijk}/A (2.7)$$

em que $d_{ijk} = \sqrt{(x_{w/2} - x_i)^2 + (y_{w/2} - y_j)^2}$ e A é uma constante que define uma importância relativa (GAO et al., 2006).

A combinação dessas três medidas é computada como mostrado na Equação (2.8)

$$C_{ijk} = S_{ijk} \cdot T_{ijk} \cdot D_{ijk} \tag{2.8}$$

E o peso é calculado como na Equação (2.9):

$$W_{ijk} = (1/C_{ijk}) \sum_{i=1}^{w} \sum_{j=1}^{w} \sum_{k=1}^{n} 1/(C_{ijk})$$
(2.9)

Na Figura 2.5 é apresentado o fluxo do processo de determinar as imagens sintéticas. Por essa figura podemos dividir o STARFM em três etapas: 1) selecionar píxeis similares espectralmente; 2) determinar os pesos; 3) gerar a imagem sintética. O algoritmo considera que as imagens já estão corrigidas e reamostradas.



Landsat(t₀)



Embora o STARFM tenha apresentado bons resultados na sintetização de imagens do *Landsat*, existem três principais limitações desse método: o tamanho da janela depende da área de estudo e precisa ser ajustada a cada caso; nem sempre similaridades espectrais são encontradas; não tem bom resultado quando aplicadas a áreas heterogêneas.

2.3.2 BFAST

O algoritmo Breaks For Additive Seasonal and Trend (BFAST) (VERBESSELT et al., 2010a) iterativamente detecta o número e o momento de ocorrências de quebras (breaks) em uma série temporal, caracterizando-as quanto a sua magnitude e direção (VERBESSELT et al., 2010a). Devido a sua caracterização em tratar diversos tipos de séries temporais, o algoritmo BFAST vem sendo amplamente aplicado para tratar diferentes tipos de séries temporais: vegetação (VERBESSELT et al., 2010a; VERBESSELT et al., 2010b; VERBESSELT; ZEILEIS; HEROLD, 2012; CHEN; MICHISHITA; XU, 2014; WATTS; LAFFAN, 2014; PERMATASARI et al., 2016), hidrologia (CHEN; MICHISHITA; XU, 2014; AULIA; SETIAWAN; FATIKHUNNADA, 2016), mapeamento cromossômico (PORTER; BERKHAHN; ZHANG, 2015). Basicamente, o algoritmo combina detecção de mudanças e decomposição de sinais, de modo a separar uma série temporal em três componentes: tendência, sazonalidade e componente residual (VERBESSELT et al., 2010a).

O algoritmo BFAST iterativamente assenta modelos lineares e sazonais, gene-

ricamente definidos na Equação 2.10, em uma série temporal (WATTS; LAFFAN, 2013).

$$Y_t = T_t + S_t + e_t, (2.10)$$

em que Y_t é o dado observado no tempo t, T_t é a componente de tendência, S_t é a componente de sazonalidade e e_t é a componente residual (VERBESSELT et al., 2010a; WATTS; LAFFAN, 2013).

As observações de mudanças na componente tendência indicam alterações graduais (oriundas de variações climáticas inter-anuais), ou abruptas (desmatamento, urbanização, fogo e inundações). Mudanças na componente de sazonalidade indicam mudanças fenológicas (alteração na quantidade de folhas ou do vigor vegetativo). Componente residual refere-se a ruídos e demais componentes, que em imagens orbitais podem se referir a elementos originados por geometria de aquisição, efeitos indesejados causados por nuvens e espalhamento atmosférico (JENSEN, 2007).

Inicialmente o algoritmo BFAST estima a componente sazonal, a componente de tendencia e a componente residual iterativamente por meio do método de filtragem *Season-Trend Decomposition Procedure based on Loess* (STL) (CLEVELAND et al., 1990b), ilustrado na Figura 2.6.

Antes de entender o funcionamento do algoritmo BFAST, é importante salientar três conceitos: a janela baseada em soma móvel (MOSUM) parte do principio que manter eventos recentes em um segmento torna-os mais sensíveis à detecção de variações dos parâmetros da série (ZEILEIS, 2005; VERBESSELT et al., 2010a), deste modo o Ordinary Least Square Moving Sum (OLS-MOSUM) é um teste utilizado para verificar a constância de parâmetros em uma série; o método dos mínimos quadrados ordinários (OLS) tem função de determinar parâmetros desconhecidos em um modelo de regressão linear (VERBESSELT et al., 2010a); estimadores M consistem em uma generalização da estimação de máxima verosimilhança, que aplicados a modelos de regressão reduzem a tendência causada por outliers (pontos extremos) no cálculo dos modelos.

Para percorrer as observações, é utilizada uma janela, chamada de segmento, determinada por um parâmetro h. Tal parâmetro determina a quantidade máxima de quebras que podem ser detectadas em um uma janela de tempo (VERBESSELT et al., 2010a; WATTS; LAFFAN, 2013), por exemplo, uma série com 100 observações que utilize h = 1/4, apresenta segmentos de tamanho 100/4 = 25 os quais serão



Figura 2.6 - Decomposição de uma série em tendência, sazonalidade e componente residual. Fonte: adaptado de Cleveland et al. (1990b).

utilizadas para determinar o ponto de quebra. Tal divisão resultará em análises de tamanho máximo de 25 ponto na série, o que resulta em um máximo de 3 pontos de quebra para a série.

Basicamente o algoritmo BFAST repete 4 etapas, até que a quantidade e posições dos pontos de quebra permaneçam inalteradas (VERBESSELT et al., 2010a):

- Etapa 1: se o teste de OLS-MOSUM indicar que os pontos de quebra estão ocorrendo na componente de tendência, o número e posição dos pontos de quebra é estimado por meio do método dos mínimos quadrados a partir dos dados sem sazonalidade Y_t - S_t.
- Etapa 2: estimam-se as componentes inclinação e intercepto de tendência para cada segmento por meio de regressão robusta baseada em estimadores M para verificar possíveis *outliers*, derivar magnitude e a direção dos pontos de quebras.
- Etapa 3: se o teste de OLS-MOSUM indicar que os pontos de quebra

estão ocorrendo na componente sazonal, o número e a posição dos pontos de quebra sazonais são estimados pelo método dos mínimos quadrados a partir do dado sem tendência $Y_t - T_t$.

• Etapa 4: os coeficientes sazonais (amplitude e fase) são estimados para cada segmento por meio de regressão robusta baseada em estimadores M.

Uma implementação bastante utilizada do algoritmo BFAST pode ser encontrada no pacote *bfast* desenvolvido em R (R Development Core Team, 2013) (WATTS; LAFFAN, 2014; PERMATASARI et al., 2016; AULIA; SETIAWAN; FA-TIKHUNNADA, 2016), sendo que o parâmetro h fica a critério do usuário definir de forma empírica.

2.3.3 SVM

O Support Vector Machines (SVM) é um conjunto de métodos de aprendizagem de máquina que analisam dados e reconhece padrões para classificação e analise de regressão. O SVM foi proposto por Vapnik e Chervonenkis (1971). Conforme Vapnik (1999) explica, o SVM é fundamentado nos conceitos de minimização do risco estrutural, ou seja, tenta minimizar o erro sobre os conjuntos de treinamento e de teste.

O objetivo principal do SVM é obter uma proporcionalidade entre esses erros, minimizando o excesso de ajustes com os conjuntos de treinamento e aumentando a eficiência de generalização das classes (VAPNIK, 1999). O problema de excesso de ajustes com os conjuntos (classes) de treinamento (*overfitting*) ocorre quando o classificador realiza a memorização dos padrões de treinamento fixando os seus atributos e ruídos. Em vez disso, o classificador deveria extrair características gerais, o que permitiria a generalização de padrões não utilizados no treinamento do classificador (SMOLA, 2000). Pode-se realizar a generalização de padrões de duas classes, de forma mais simples, quando essas classes são linearmente separáveis (AN-DREOLA, 2009). Considera-se que duas classes são linearmente separáveis quando os dados dessas classes podem ser separados por uma reta em um hiperplano. Uma função que gera uma reta que separa os elementos das duas classes é denominada *função de decisão* (ANDREOLA, 2009), que é ótima quando gera uma reta distante de cada classe. Um exemplo de duas classes linearmente separáveis, separadas por uma função de decisão ótima, é mostrado na Figura 2.7.

A qualidade da solução do método SVM é diretamente ligada ao processo de



Figura 2.7 - Grupo de dados de classes linearmente separáveis e uma possível função de decisão. Fonte: (SOUZA, 2015).

treinamento. Para isso, uma boa maneira de realizar o treinamento do SVM é utilizar classes linearmente separáveis de modo a treinar o classificador com classes bem definidas (SOUZA, 2015).

Formalmente, a função de decisão é definida como na Equação 2.11. Para duas classes $\omega_1 \in \omega_2$, a Equação 2.11 gera um hiperplano (ou uma reta, quando em duas dimensões) que separa os elementos x_i , com i = 1, 2, ..., n, nas classes $\omega_1 \in \omega_2$. Basicamente, para $1 \le k \le n$, se $D(x_k) \ge 1$, então, $x_k \in \omega_1$, se $D(x_k) \le 1$, então, $x_k \in \omega_2$.

$$D(x) = w^T x + b, (2.11)$$

em que w e x são um vetores *n*-dimensionais, sendo w um vetor normal ao hiperplano e *b* é o termo independente ou termo de viés (ABE, 2005). Na Tabela 2.3.3, são apresentadas as funções de decisão (*kernel*) mais utilizadas no SVM (LORENA; CARVALHO, 2007).

Conforme (HUANG; DAVIS; TOWNSHEND, 2002) os dois hiperplanos são escolhidos de tal modo, para não só maximizar a distância entre as duas classes de dados, bem como não acrescentar quaisquer pontos entre eles. Essa escolha dos hiperplanos têm como objetivo principal, descobrir em que classe os novos pontos de dados cairão. Geralmente, o SVM é utilizado para gerar resultados de maior exati-

Tipo de Kernel	Função K (X_i, X_j)	Parâmetros
Polinomial	$(\delta(X_i \cdot X_j) + \mathbf{k})$	$\delta, \; k \; e \; d$
Gaussiano ou Radial-Basis Function (RBF)	$\exp(-\sigma X_i - X_j ^2)$	σ
Sigmoidais	$\tanh\left(\delta\left(X_i \cdot X_j\right) + k\right)$	$\delta \ e \ k$

Tabela 2.3 - Funções de Decisão mais utilizadas. Fonte: (LORENA; CARVALHO, 2007).

dão, mas esses resultados dependem da função de *kernel*, da escolha de parâmetros do *kernel*, da especificação do espaço de atributos e também da metodologia utilizada para o SVM (HUANG; DAVIS; TOWNSHEND, 2002; LORENA; CARVALHO, 2007).

Na entrada do SVM, temos σ (largura da banda da função de *kernel*), *kernel* (função de treinamento e previsão dos dados) e C (valor de ajuste de precisão dos vetores de suporte falsamente classificados), conforme demonstrado genericamente na Figura 2.8.



Figura 2.8 - Processo do SVM.

Pode-se encontrar várias implementações do método SVM, tornando-o um método acessível aos pesquisadores. Por exemplo, encontra-se o SVM na linguagem R (R Core Team, 2013) no pacote *e1071*, disponível na *Comprehensive R Archive Network* (CRAN), na linguagem C++ na biblioteca *LIBSVM* (CHANG; LIN, 2011) e na linguagem Python está disponível biblioteca *scikit-learn* (PEDREGOSA et al., 2011).

O SVM é um método bastante utilizado para classificação de áreas agrícolas, como também para o monitoramento e cobertura da terra. É um método que pode

ser aplicado em vários problemas, inclusive séries temporais. Como pôde se observar nos trabalhos citados nesta seção, o SVM é uma boa alternativa para classificação.

O uso de séries temporais para o cálculo de índices de vegetação vem tendo uma crescente utilização para aplicações de mapeamento, identificação de culturas agrícolas (VICTORIA et al., 2009) e monitoramento de biomas (COSTA et al., 2015). O uso do algoritmo SVM para classificação de culturas agrícolas têm apresentado bons resultados Souza (2015), como também no mapeamento de áreas de pastagem (COSTA et al., 2015). Conforme Gómez et al. (2016), os autores realizaram uma revisão dos algoritmos para classificação da cobertura da terra. Concluiu-se que o SVM têm como ponto forte, o bom desempenho para um conjunto de dados pequenos e como ponto fraco a exigência de grande volume de computação.

Huang, Davis e Townshend (2002) realizaram um comparativo dos algoritmos baseados em SVM, árvores de decisão, redes neurais e o classificador de máxima verossimilhança (MLC), na precisão da classificação por píxel. O SVM mostrou-se superior aos três. No trabalho de Otukei e Blaschke (2010), os autores mapearam o uso da terra. O método SVM apresentou uma acurácia acima de 85%, utilizando imagens Landsat ETM+ de dois anos diferentes. O SVM apresentou bons resultados para o mapeamento de áreas agrícolas (café) Souza (2015). Neste último resultado um dos parâmetros utilizados para SVM foi o resultado de variáveis multitemporais do pacote *Greenbrown*, desenvolvido por Forkel et al. (2013). Esse pacote oferece funções para analisar tendências e suas mudanças, como também inferir sobre as propriedades da série: média, tendência, sazonalidade e entre outras.

No contexto de series temporais uma abordagem utilizada para uso do SVM na classificação das imagens é a extração de uma série temporal de índice de vegetação de cada pixel, onde são extraídos parâmetros como Amplitude, área, área por estação e ângulo (KÖRTING et al., 2013) para o treinamento das classes, similarmente a uma classificação clássica.

Neste contexto, Costa et al. (2015) realizaram um estudo de mapeamento de pastagem cultivada e área nativa do cerrado no Parque Nacional da Serra da Castra, utilizando um serie temporal do sensor MODIS. Os métodos utilizados para a classificação foram SVM e as redes neurais *Multi-Layer Perceptrons* (MLP) e *Autoencoder*. O SVM apresentou os melhores resultados na separação entre classes área nativa e pastagem cultivada, chegando a obter uma precisão 85,96%, através da combinação de todos os atributos relacionados com a série temporal e variáveis derivadas (COSTA et al., 2015). Na Figura 2.9 é mostrado a metodologia para a aplicação do SVM no trabalho de (COSTA et al., 2015).



Figura 2.9 - Classificação de série temporal utilizando SVM, parâmetros temporais extraídos de uma série de EVI para classificação em Campo Nativo, Pastagem Cultivada e Outros. Fonte: Adaptado de (COSTA et al., 2015).

2.3.4 TWDTW

Nesta seção descreve-se o método Time-Weighted Dynamic Time Warping (TWDTW) (MAUS et al., 2016b). Esse método foi proposto para a classificação do uso e cobertura da terra utilizando séries temporais oriundas de imagens orbitais. O TWDTW é uma variação do método Open Boundary Dynamic Time Warping (OBDTW) que, por sua vez, é uma variação do método Dynamic Time Warping (DTW). Por isso, também são descritos, nas subseções seguintes, os métodos DTW e OBDTW. Ainda, para o entendimento do texto desta seção, considere que $V = (v_1, v_2, \ldots, v_m)$ e $U = (u_1, u_2, \ldots, u_n)$ sejam séries temporais, em que $n, m \in \mathbb{N}$.

Esta seção é dividida como a seguir. Na subseção 2.3.4.1 é apresentado o método DTW. Mostra-se, na subseção 2.3.4.2, a variação do método DTW para subsequências. Apresenta-se, na subseção 2.3.4.3, o método TWDTW. Uma breve consideração sobre os testes realizados por Maus et al. (2016b) é realizada na subseção 2.3.4.4.

2.3.4.1 DTW

O Dynamic Time Warping (DTW) é um método para encontrar um alinhamento ótimo entre duas sequências de dados (MÜLLER, 2007, p. 69). Esse método é baseado na distância de Levenshtein (1965) e foi proposto por Sakoe e Chiba (1971), Sakoe e Chiba (1978) para comparar padrões de voz e identifica-los automaticamente. Basicamente, a distância de Levenshtein entre duas *strings* é o menor número de operações necessárias para transformar uma *string* em outra. No DTW, compara-se um padrão temporal conhecido (por exemplo, um sinal de voz identificado) com uma série temporal desconhecida (por exemplo, um sinal de voz de origem não identificada) (BERNDT; CLIFFORD, 1994; MAUS et al., 2016b). Dessa maneira, o DTW encontra um alinhamento e calcula uma medida de similaridade entre duas séries de dados. Como Müller (2007, p. 82) exemplifica, o DTW tem sido utilizado, com sucesso, em áreas como mineração de dados, recuperação da informação, bioinformática, engenharia química, processamento de sinais, robótica e computação gráfica.

O método DTW compara as sequências $V \in U$ e encontra um alinhamento ótimo entre essas sequências. Para isso, é necessário o cálculo da *medida de distância local* (MÜLLER, 2007, p. 69). A medida de distância local entre dois elementos $u_i \in U$ e $v_j \in V$, para $1 \leq i \leq n \in 1 \leq j \leq m$, é definida por $\psi(u_i, v_j)$. Usualmente, se $u_i = v_j$, então $\psi(u_i, v_j) = 0$. Caso $u_i \approx v_j$, então $\psi(u_i, v_j)$ terá um valor baixo e se $u_i \in v_j$ forem muito diferentes, então $\psi(u_i, v_j)$ terá um valor alto (MÜLLER, 2007, p. 69). Por exemplo, Maus et al. (2016b) utilizaram $\psi(u_i, v_j)$ como a diferença absoluta dos valores dos píxeis $u_i \in v_j$. As medidas de distância local compõem a *matriz de* $custo \Psi \in \mathbb{R}^{n \times m}$. Por simplicidade, podemos reescrever $\psi(u_i, v_j)$ como ψ_{ij} , ou seja, $\Psi = [\psi_{ij}]$ para $1 \leq i \leq n \in 1 \leq j \leq m$, em que $\psi(u_i, v_j) = \psi_{ij}$.

O objetivo do método DTW é encontrar uma sequência (caminho), sem repetição, de elementos de Ψ em que o somatório dos valores desses elementos seja mínimo. Essa sequência é denominada de *warping path* e é o alinhamento entre as sequências. Um *warping path* $p = (p_1, p_2, \ldots, p_L)$, em que $p_l = (i_l, j_l) \in n \times m$ deve respeitar as seguintes condições (MÜLLER, 2007, p. 70):

- a) condição de fronteira: $p_1 = (1, 1) e p_L = (n, m);$
- b) condição de monotonicidade: $i_1 \leq i_2 \leq \cdots \leq i_L$ e $j_1 \leq j_2 \leq \cdots \leq j_L$;
- c) condição do tamanho do passo: $p_{l+1} p_l \in \{(1,0), (0,1), (1,1)\}$ para $1 \le l \le L 1$.

O DTW encontra um warping path de custo mínimo (ótimo). O custo de um warping path p entre duas sequências V e U é dado por $c_p(V,U) = \sum_{l=1}^{L} \psi(v_{i_l}, u_{j_l})$

(MÜLLER, 2007, p. 71). Um exemplo de um warping path ótimo em uma matriz de custo Ψ é apresentado na Figura 2.10. Uma forma de se determinar um warping path de custo mínimo entre duas sequências $V \in U$ é gerar todos os warping paths possíveis entre $V \in U$ e selecionar o warping path de menor custo. Claramente, uma implementação dessa abordagem tem complexidade exponencial. Com isso, Sakoe e Chiba (1971), Sakoe e Chiba (1978) propuseram um algoritmo baseado em programação dinâmica com complexidade $O(n \cdot m)$ para o cálculo de um warping path.

	0	2	3	0	3	2	7	0	6	1	8	3	
	じ	Q	0	8	1	(С	0	2	0	2	2	
	8	0.	5	8	5	1	6	3	7	2	2	1	
	5	6	.0	1	1	0	7	6	6	2	8	6	
	7	0	7	·•0	0	0	0	5	5	8	4	3	
$\Psi =$	0	5	2	4	5	4	6	·•0.	7	0	6	3	
	6	5	1	7	0	0	6	3	0	5	2	4	
	6	8	8	6	5	3	6	0	Ö	4	2	1	
	6	5	6	5	6	4	2	3	0.	0	5	3	
	2	8	0	4	8	2	6	4	4	2	0	7	
	1	7	0	7	1	1	5	2	3	3	1	··0	

Figura 2.10 - Exemplo de uma matriz de custo Ψ e um warping path ótimo. Nesta matriz os valores dos custos estão distribuídos no intervalo [0,8] e possuiem tons de cinza proporcional ao valor. Note que os elementos que compõem o warping path (destacados pela linha pontilhada) possuem os menores valores na vizinhança. O warping path desta imagem é válido pois respeita as três condições descritas anteriormente.

Para evitar um algoritmo de força bruta exponencial, Sakoe e Chiba (1971) e Sakoe e Chiba (1978) utilizaram, além da matriz Ψ de custo, a matriz de custo acumulado $D \in \mathbb{R}^{n \times m}$. Por meio da matriz $D = [d_{ij}]$, utilizando conceitos da programação dinâmica, cálculos desnecessários não são realizados. Isso porque, inicialmente, os valores da matriz D eram calculados de forma recursiva. Os elementos d_{ij} , para $1 < i \leq n \in 1 < j \leq m$, da matriz D são calculados conforme mostrado na Equação 2.12 (MAUS et al., 2016b).

$$d_{ij} = \psi_{ij} + \min\{d_{i-1,j}, d_{i,j-1}, d_{i-1,j-1}\},$$
(2.12)

em que os valores de d_{ij} estão sujeitos a

$$d_{ij} = \begin{cases} \psi_{ij}, \text{ para } i = 1 \text{ e } j = 1, \\ \sum_{k=1}^{i} \psi_{kj}, \text{ para } 1 < i \le n \text{ e } j = 1, \\ \sum_{k=1}^{j} \psi_{ik}, \text{ para } 1 < j \le m \text{ e } i = 1. \end{cases}$$
(2.13)

Basicamente, o alinhamento encontrado pelo DTW percorre o "vale" de custos mínimos da matriz D. Essa vale é o warping path (o alinhamento) e se inicia no elemento d_{11} e termina no elemento d_{nm} , respeitando as três condições do warping path apresentadas anteriormente. Com isso, o custo, que é mínimo, do warping path encontrado é dado pelo elemento d_{nm} da matriz D.

Especificamente, para se determinar o warping path é necessário utilizar um passo a passo conforme descrito na Equação 2.14. Na Equação 2.14 define-se o (l-1)-ésimo elemento do warping path, que se inicia no elemento d_{nm} , ou seja, $p_l = (i, j) = p_L = (n, m)$, e termina em $p_1 = (1, 1)$. As três condições do warping path são respeitadas na Equação 2.14.

$$p_{l-1} = \begin{cases} (i, a_k = j), \text{ para } i = 1, \\ (i - 1, j), \text{ para } j = 1, \\ \underset{(i,j)}{\operatorname{argmin}} (d_{i-1,j}, d_{i,j-1}, d_{i-1,j-1}), \text{ caso contrário.} \end{cases}$$
(2.14)

Um pseudo-código do método DTW original é mostrado no algoritmo 1. Esse pseudo-código é baseado no pseudo-código apresentado por Petitjean, Inglada e Gançarski (2012). Pode-se observar que a complexidade desse algoritmo é da ordem de $O(n \cdot m)$. Isso porque há duas estruturas de repetição aninhadas: uma com n-1iterações e a outra com m-1 iterações.

O algoritmo 1 recebe como entrada duas séries temporais $V \in U$, a matriz de custo Ψ e a matriz de custo acumulado D. O retorno desse algoritmo é o n, mésimo elemento da matriz de custo acumulado D, ou seja, o custo do alinhamento (*warping path* mínimo) entre as sequências de entrada. Nas linhas 2 a 8 a matriz de custo acumulado D é inicializada conforme definido pela Equação 2.13. Nas linhas 9 a 13 os demais elementos da matriz D são definidos de acordo com a Equação 2.12. Algoritmo 1: DTW original.

Entrada: uma série temporal $V = [v_1, v_2, \dots, v_m]$; uma série temporal

 $U = [u_1, u_2, \dots, u_n]$ de uma série temporal; matriz de custo Ψ de ordem $n \times m$; matriz de custo acumulado D de ordem $n \times m$;

Saída: valor da similaridade entre as sequências;

1 início

 $D[1,1] \leftarrow \Psi[1,1];$ $\mathbf{2}$ para ($i \leftarrow 2 at e n$) faça 3 $D[i, 1] \leftarrow D[i-1, 1] + \Psi[i, 1];$ $\mathbf{4}$ fim-para; $\mathbf{5}$ para ($j \leftarrow 2 at \acute{e} m$) faça 6 $D[1,j] \leftarrow D[1,j-1] + \Psi[1,j];$ 7 fim-para; 8 para ($i \leftarrow 2 at e n$) faça 9 para ($j \leftarrow 2 at \acute{e} m$) faça 10 $D[i, j] \leftarrow \Psi[i, j] + \min(D[i - 1, j], D[i - 1, j - 1], D[i, j - 1]);$ 11 12fim-para; fim-para; $\mathbf{13}$ // O valor da similaridade é dado pelo coeficiente D[n,m]. retorna D[n,m]; $\mathbf{14}$ 15 fim.

2.3.4.2 DTW para subsequências

O método DTW descrito na subseção 2.3.4.1 só pode ser utilizado quando as duas séries temporais que estão sendo comparadas possuírem comprimento similar. Quando o comprimento de uma das séries for muito maior que a da outra, algumas modificações no método DTW devem ser realizadas. Com isso, em vez de se tentar alinhar essas séries de forma global, procura-se uma subsequência da série de maior comprimento que tenha o melhor alinhamento com a série de menor comprimento (MÜLLER, 2007, p. 79). Essa versão do DTW é conhecida como *Open Boundary DTW* (OBDTW). Na Figura 2.11 é apresentado um exemplo gerado pelas funções e exemplos contidos no pacote dtwSat (MAUS et al., 2016a). Nessa figura é mostrado os melhores alinhamentos para o padrão "soja" na série temporal analisada (MAUS et al., 2016a).

Considere que o comprimento da série temporal V é muito maior que o comprimento da série temporal U, ou seja, m >> n. Conforme Müller (2007, p. 79-80) explica, o método OBDTW encontra uma subsequência $V|_a^b = (v_a, v_{a+1}, \ldots, v_b)$, com $1 \le a \le b \le m$, em que o alinhamento de U com a subsequência $V|_a^b$ é ótimo. Em



Figura 2.11 - Melhores alinhamentos da classe "soja" da série temporal analisada. Esta imagem foi gerada com os métodos e exemplos do pacote dtwSat (MAUS et al., 2016a).

outras palavras, o OBDTW determina um *warping path* de custo mínimo entre a série U e todas as subsequências de V possíveis. Também, o método OBDTW pode encontrar todos os *warping paths* com custos menores que um limiar.

No OBDTW as matrizes de custo Ψ e de custo acumulado D são calculadas da mesma forma que no método DTW. A diferença entre esses métodos está na etapa adicional que o OBDTW possui: determinar as subsequências, seus respectivos intervalos e o custo do alinhamento associado a cada subsequência.

Primeiramente, deve-se encontrar "vales" na matriz D. Os "vales" da matriz Dsão warping paths com custos menores que um limiar τ preestabelecido. Com isso, o número de alinhamentos da série temporal U com a série temporal V será o número de warping paths com custos menores que τ .

Para se encontrar warping paths com custos menores que τ , deve-se analisar a última linha da matriz de custo acumulado D para determinar os índices b de cada subsequência. Dessa maneira, serão selecionados todos os índices j em que $d_{nj} < \tau$ para $1 \leq j \leq m$. Com isso, $b_k = j$, para $k = 1, 2, \ldots, K$ em que K é o número de elementos, da última linha de D, menores que τ . Para encontrar o índice a_k respectivo a cada índice b_k e formar o intervalo da subsequência, é utilizado o mesmo passo a passo, mostrado na Equação 2.14, do método DTW. Com isso, o warping path respectivo ao intervalo (a_k, b_k) também é determinado.

2.3.4.3 O método TWDTW

Maus et al. (2016b) propuseram uma variação do método OBDTW, descrito na subseção 2.3.4.3, para a classificação de séries temporais oriundas de imagens de sensores remotos. Essa variação é denominada de *Time-Weighted Dynamic Time Warping* (TWDTW).

No contexto de processamento digital de imagens, cada série temporal pode ser considerada com os valores de um píxel em um intervalo de tempo. Dessa maneira, para a classificação de duas séries temporais, Maus et al. (2016b) consideraram, além do valor do píxel, a data em que cada valor foi obtido. Então, na etapa do cálculo do alinhamento entre as séries temporais, um peso correspondente à data de obtenção do valor do píxel é adicionado.

A única diferença entre os métodos OBDTW e TWDTW está na construção da matriz de custo Ψ . Para cada elemento ψ_{ij} , com $1 \leq i \leq n$ e $1 \leq i \leq m$, Maus et al. (2016b) utilizaram a diferença absoluta entre os valores i e j dos píxeis. Como descrito anteriormente, a data em que o valor do píxel foi obtido é também considerada. Então, além da diferença absoluta entre os valores dos píxeis, Maus et al. (2016b) adicionaram um peso ω_{ij} referente à diferença de dias entre a obtenção dos valores i e j. Com isso, os valores dos custos locais são definidos pela Equação 2.15.

$$\psi_{ij} = |u_i - v_j| + \omega_{ij}, \qquad (2.15)$$

em que ω_{ij} é dado pela função $g(t_i, t_j)$, que é a diferença entre t_i , a data da obtenção do valor i, e t_j , a data da obtenção do valor j.

Maus et al. (2016b) utilizaram, também, outro modelo para valorar a diferença temporal entre os dados. Em vez de utilizar apenas a diferença em dias da obtenção dos valores das séries, os autores usaram um modelo logístico que obteve melhores classificações que apenas utilizar a diferença em dias. Esse modelo logístico é descrito na Equação 2.16.

$$\omega_{ij} = \frac{1}{1 + \epsilon^{-\alpha(g(t_i, t_j) - \beta)}},\tag{2.16}$$

em que Maus et al. (2016b) obtiveram os melhores resultados utilizando $\alpha = 0, 1$ e $\beta = 100.$

Maus et al. (2016a) disponibilizaram um pacote (dwtSat) contendo uma implementação do método TWDTW na linguagem R (R Core Team, 2013). É possível obter esse pacote na *Comprehensive R Archive Network* (CRAN). Para mais detalhes veja Maus et al. (2016a).

2.3.4.4 Considerações sobre os testes de Maus et al. (2016b)

Maus et al. (2016b) compararam quatro versões do método DTW para a classificação de séries temporais oriundas de imagens orbitais. Foram testados o método DTW original, a modificação do DTW de Petitjean, Inglada e Gançarski (2012), o TWDTW com a função $g(t_i, t_j)$ e o TWDTW com a função logística.

Nos testes realizados os autores utilizaram o Enhanced Vegetation Index (EVI) de dados da região do município de Porto dos Gaúchos, Mato Grosso, Brasil, do sensor MODIS de junho de 2000 a julho de 2013. Maus et al. (2016b) utilizaram padrões de cobertura da terra como: soja, algodão, soja e algodão, soja e milho, floresta e pasto. Os testes foram executados em um computador servidor com 40 processadores com 2,6GHz e com 256Gbytes de memória principal.

Dos quatros métodos testados, o TWDTW logístico obteve as melhores classificações. O DTW obteve as piores classificações.

Embora Maus et al. (2016b) tenham utilizado um computador com 40 processadores, todos os quatro métodos foram executados por 50*min*. Portanto, o custo computacional de métodos baseados no método DTW pode ser considerado um fator impeditivo na classificação de séries temporais.

3 TESTES E RESULTADOS

Nesta capítulo são apresentados alguns testes realizados com os métodos STARFM, BFAST e TWDTW, apresentados no capítulo anterior. Esses testes foram realizados para exemplificar o funcionamento dos métodos. Na subseção 3.1 são apresentados alguns testes com o método STARFM. Mostra-se, na subseção 3.2, os resultados dos testes com o método BFAST. São descritos, na subseção 3.3, alguns testes realizados com o método TWDTW.

3.1 Testes com o método STARFM

Para testar o algoritmo proposto por Gao et al. (2006), foram utilizadas imagens em reflectância do MODIS, produto MOD09GHK, e do *Landsat-7* ETM+, produto gerado pelo *Landsat Ecosystem Disturbance Adaptive Processing System* (LEDAPS), na região do vermelho (Banda 3 do Landsat-7 e Banda 1 do MODIS) e do infravermelho próximo (Banda 4 do Landsat-7 e Banda 2 do MODIS). Nessas bandas, o MODIS tem 250m de Resolução Espacial e 1 dia de Resolução Temporal, enquanto que o *Landsat-7* tem 30m de Resolução Espacial e 16 dias de Resolução Temporal.

As imagens utilizadas são da região sul da área de estudo *Boreal Ecosys*tem-Atmosphere Study (BOREAS), que fica na região de florestas boreais do Canadá destacada pelo retângulo azul na Figura 3.1. Essa região foi sugerida por Gao et al. (2006) por ser uma região em que a estação de crescimento das plantas é curta e a fenologia muda rapidamente.



Figura 3.1 - Localização da área de estudos BOREAS

As imagens MODIS e *Landsat* devem ser pre-processadas, co-registradas e salvas com a mesma resolução espacial, mesmo tamanho de imagem, mesma projeção, mesmo fator de escala de reflectância (usualmente a reflectância varia de 0 a 1 e no MODIS o fator de escala é 10000) e mesma resolução radiométrica.

Para gerar as imagens sintéticas foi utilizado o algoritmo disponibilizado por Gao et al. (2006). Esse algoritmo foi desenvolvido em C++ e as entradas são feitas por linha de comando. A entrada desse algoritmo é um arquivo de texto com informações do número de pares de imagens *Landsat* e MODIS usados para gerar as imagens sintéticas e seus respectivos nomes, o nome da imagem MODIS sobre a qual será gerada a *Landsat* sintética, número de linhas e colunas, fator de escala da reflectância, entre outros. A saída do algoritmo é a imagem *Landsat* sintética em reflectância de superfície e em formato binário. As imagens de entradas também tem que estar em formato binário.

As imagens *Landsat* e MODIS utilizadas para estimar a diferença espectral e a distância espacial são do dia 11 de julho de 2001 e estão apresentadas na Figura 3.2.



Figura 3.2 - Imagens MODIS e Landsat usadas para estimação espectral e espacial

A imagem MODIS utilizada para predizer a *Landsat* sintética é do dia 12 de agosto de 2001. As imagens foram escolhidas com esse intervalo de tempo para que tivéssemos uma imagem *landsat* real para comparação. A Figura 3.3 apresenta as imagens sintéticas geradas e a MODIS e a *Landsat* para efeito de comparação visual.

MODIS-Vermelho(12/08/2001)

Sintética-Vermelho(12/08/2001)

Landsat- Vermelho(12/08/2001)



Figura 3.3 - Localização da área de estudos BOREAS

Na Figura 3.4 é apresentado os gráficos de correlação entre as imagens sintéticas Landsat e as imagens Landsat real. Por esse gráfico pode-se concluir que as imagens sintética e reais estão correlacionadas.



Figura 3.4 - Localização da área de estudos BOREAS

3.2 Testes com o método BFAST

O pacote zoo do R contém uma série temporal NDVI de 12 anos medidos quinzenalmente, ilustrada na Figura 3.5. Inserindo esta série como entrada para o algoritmo BFAST no pacote *bfast* do R, utilizou-se o método de (CLEVELAND et al., 1990b) para extrair as componentes de tendência, sazonalidade e componente residual, conforme demonstradas na Figura 3.6.

Nota-se na Figura 3.6 que há uma transição na componente de tendência, em que a mesma, de uma função crescente, sofre uma grande redução e torna-se decrescente. No ponto da redução da tendência, percebe-se na mesma Figura que a sazonalidade tem sua amplitude reduzida, enquanto que na componente residual, não observa-se nenhum padrão sistemático, de modo que posteriormente esta componente é subtraída da série original para detecção dos pontos de quebra.

Aplicando empiricamente h valendo 0, 11, o teste de OLS-MOSUM indicou que na séria havia um ponto de quebra e como nota-se na Figura 3.7, o mesmo pode ser



Figura 3.5 - Série NDVI contida no pacote zo
o do R,referente a 12 anos medidos quinzenalmente.



Figura 3.6 - Decomposição de componentes de uma série NDVI nas seguintes componentes extraídas pelo método STL (CLEVELAND et al., 1990b): a tendência, a sazonalidade e a componente residual.

determinado no ano de 2005.



Figura 3.7 - Ponto de quebra (tracejado) de tendência (azul) de uma série NDVI (cinza) de 12 anos ajustada pelo modelo de decomposição de tendência (preto) extraído pelo algoritmo BFAST em sua implementação no pacote *bfast* em R, utilizando tamanho de segmento h = 0, 11 (em vermelho).

3.3 Testes com o método TWDTW

Nesta subseção são apresentados os resultados de alguns testes realizados com o método TWDTW. O objetivo desses testes é exemplificar o funcionamento do TWDTW na classificação de uso da terra. Esses testes foram realizados com as mesmas imagens utilizadas por Maus et al. (2016b) e estão disponíveis, como exemplos, no pacote *dtwSat* em R (R Core Team, 2013). Especificamente, os testes realizados nesta seção são os mesmos realizados por Maus et al. (2016b).

Como Maus et al. (2016b) detalham, as imagens disponíveis no pacote dtwSat são oriundas da coleção 5 do produto MOD13Q1 do sensor MODIS (FRIEDL et al., 2010). Ainda, a região dessa imagens é uma área de floresta tropical situada no estado do Mato Grosso, Brasil e possui uma área de $5.300km^2$ com imagens de 2008 a 2013 (MAUS et al., 2016b).

As classificações realizadas nos testes realizados são geradas baseando-se em cincos classes de séries temporais: "algodão-pousio", "floresta", "soja-algodão", "sojamilho" e "soja-painço" (MAUS et al., 2016b). Para cada classe, e para cada banda (*blue, red, nir, mir, evi* e *ndvi*), há um padrão de série temporal. Com isso, o método TWDTW calcula o melhor alinhamento, para cada banda, dessas classes com uma série temporal que se deseja classificar. Os padrões de séries temporais são mostrados na Figura 3.8.

Os padrões mostrados na Figura 3.8 foram obtidos por meio de dados que foram validados. Especificamente, foram utilizados 603 imagens dividas nas cinco classes descritas anteriormente (MAUS et al., 2016b).



Figura 3.8 - Padrões de séries temporais das imagens do pacote dtwSat (MAUS et al., 2016b). São mostrados os padrões nas bandas blue, red, nir, mir, evi e ndvi para as classes "algodão-pousio", "floresta", "soja-algodão", "soja-milho" e "soja-painço". Esta imagem foi obtida utilizando a função plot do pacote dtw-Sat.

Com os padrões mostrados na Figura 3.8 o método TWDTW calcula a distância entre esses padrões e a série de entrada, que possui 160 imagens. Na Figura 3.9 mostra-se o um exemplo do resultado do cálculo de grau de similaridade pelo método TWDTW para cada um dos padrões no ano de 2008. Na Figura 3.9 quanto mais azul o píxel melhor o alinhamento entre a série temporal e o padrão de série temporal. Quanto mais vermelho o píxel pior o alinhamento.

Na imagem 3.10 é apresentado a classificação de utilização do solo realizada pelo método TWDTW. Para cada ano foi slecionado o melhor alinhamento entre os



Figura 3.9 - Exemplo da distância entre todos padrões de séries temporais utilizados e a série temporal do ano de 2008 (MAUS et al., 2016b). Os píxeis azuis possuem um grau de similaridade maior coms os padrões. Os píxeis vermelhos possuem um grau de similaridade menor com os padrões. Esta imagem foi obtida utilizando a função *plot* do pacote *dtwSat*.

padrões e a série temporal. São mostrados os resultados entre os anos 2008 a 2013.



Legend Cotton-fallow Forest Soybean-cotton Soybean-maize Soybean-millet

Figura 3.10 - Classificação de uso do solo, entre os anos 2008 e 2013, realizada pelo método TWDTW (MAUS et al., 2016b). Esta imagem foi obtida utilizando a função plot do pacote dtwSat

4 CONSIDERAÇÕES FINAIS

A adoção de politicas públicas, por algumas agências, para disponibilização gratuita de imagens orbitais, tem possibilitado a pesquisadores o acesso sem precedentes à grandes bases de dados orbitais (MAUS et al., 2016a). Assim, torna-se importante que informações sejam extraídas utilizando o contexto que um conjunto de imagens (séries temporais) pode oferecer. Por isso, é necessário que hajam métodos eficientes e eficazes para a manipulação de séries temporais e que sejam acessíveis para vários pesquisadores. Com isso, é interessante que esses métodos sejam *open-source*.

Dentre os métodos apresentados neste trabalho, percebe-se que o STARFM foi útil para melhorar a qualidade das imagens e compor uma série temporal; a extração das componentes de tendência, sazonalidade, remoção da componente residual, bem como definição das componentes de quebra em uma série foi efetivamente feita pelo algoritmo BFAST; o uso de algoritmos de classificação tradicionais, como o SVM, tem permitido a utilização de parâmetros extraídos de séries temporais, para classificar áreas, considerando mais efetivamente as alterações no espaço-tempo. Hoje o assunto de séries temporais em imagens orbitais continua recente, de modo a existirem novos métodos como DWDTW na tentativa de obter melhores resultados.

Todos os métodos abordados neste texto possuem implementações *open-source*, por isso, são alternativas acessíveis a pesquisadores. Também, são métodos recentes e que apresentaram bons resultados na literatura.

REFERÊNCIAS BIBLIOGRÁFICAS

ABE, S. Support vector machines for pattern classification. Estados Unidos: Springer, 2005. 349 p. 18

ANDREOLA, R. Support vector machines na classificação de imagens hiperespectrais. Dissertação (Mestrado) — UFGRS, 2009. 17

AULIA, M. R.; SETIAWAN, Y.; FATIKHUNNADA, A. Drought Detection of West Java's Paddy Field Using MODIS EVI Satellite Images (Case Study: Rancaekek and Rancaekek Wetan). *Procedia Environmental Sciences*, Elsevier B.V., v. 33, p. 646–653, 2016. ISSN 18780296. Disponível em: http://www.sciencedirect.com/science/article/pii/S1878029616300056>. 14, 17

BANSKOTA, A. et al. Forest monitoring using Landsat time series data: A review. *Canadian Journal of Remote Sensing*, v. 40, n. 5, p. 362–384, 2014. ISSN 0703-8992. 2

BARKER, J. et al. Modis spectral sensivity study: requirements and characterization. *Washington: Nasa, Oct*, 1992. 7

BELWARD, A. S.; SKØIEN, J. O. Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 103, p. 115–128, 2015. 4

BERNDT, D. J.; CLIFFORD, J. Using dynamic time warping to find patterns in time series. In: *AAAI-94 Workshop on Knowledge Discovery in Databases*. Seattle, EUA: AAAI, 1994. p. 359–370. 22

BOX, G. E. et al. *Time series analysis: forecasting and control.* [S.I.]: John Wiley & Sons, 2015. 8

CHANG, C.-C.; LIN, C.-J. Libsvm: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, ACM, v. 2, n. 3, p. 27, 2011. 19

CHEN, L.; MICHISHITA, R.; XU, B. Abrupt spatiotemporal land and water changes and their potential drivers in Poyang Lake, 2000-2012. *ISPRS Journal of Photogrammetry and Remote Sensing*, International Society for Photogrammetry and Remote Sensing, Inc. (ISPRS), v. 98, p. 85–93, 2014. ISSN 09242716. Disponível em: http://dx.doi.org/10.1016/j.isprsjprs.2014.09.014>. 14

CLEVELAND, R. B. et al. Stl: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics*, Statistics Sweden (SCB), v. 6, n. 1, p. 3–73, 1990. 8

CLEVELAND, R. B. et al. STL: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics*, v. 6, n. 1, p. 3–73, 1990. ISSN 0282-423X. 15, 16, 32, 33 COHEN, W. B.; GOWARD, S. N. Landsat's Role in Ecological Applications of Remote Sensing. *BioScience*, v. 54, n. 6, p. 535–546, 2004. Disponível em: 5">http://www.data.forestry.oregonstate.edu/larse/pubs/cohen{_}bioscience.>5

COPPIN, P. et al. Review ArticleDigital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing*, v. 25, n. 9, p. 1565–1596, 2004. ISSN 0143-1161. 2

COSTA, W. et al. Classifying grasslands and cultivated pastures in the brazilian cerrado using support vector machines, multilayer perceptrons and autoencoders. p. 187–198, 2015. 20, 21

EHLERS, R. S. Análise de séries temporais. [s.n.], 2009. http://www.icmc.usp.br/pessoas/ehlers/stemp/ p. Disponível em: <http://www.icmc.usp.br/pessoas/ehlers/stemp/>. 2

FEDERATION, N. W. National Wildlife Federation What is Phenology? 2016. <https://www.nwf.org/Wildlife/Wildlife-Conservation/Phenology.aspx>. Accessed: 2016-09-02. 11

FORKEL et al. Trend change detection in ndvi time series: Effects of inter-annual variability and methodology. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 5, p. 2113–2144, 2013. 2, 20

FRIEDL, M. A. et al. Modis collection 5 global land cover: algorithm refinements and characterization of new datasets. *Remote Sensing of Environment*, v. 114, p. 168–182, 2010. 34

FU, T.-c. A review on time series data mining. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 24, n. 1, p. 164–181, 2011. 7

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*, IEEE, v. 44, n. 8, p. 2207–2218, 2006. 2, 8, 10, 11, 13, 14, 29, 30

GEVAERT, C. M.; GARCÍA-HARO, F. J. A comparison of starfm and an unmixing-based algorithm for landsat and modis data fusion. *Remote sensing of Environment*, Elsevier, v. 156, p. 34–44, 2015. 8

GOMEZ, C. et al. Optical remotely sensed time series data for land cover classification: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 116, p. 55–72, 2016. 7, 20

GRIFFITHS, P.; LINDEN, S. van der; KU. A pixel-based landsat compositing algorithm for large area lande cover mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 6, n. 5, p. 2088–2101, 2013. 2

HUANG, C.; DAVIS, L.; TOWNSHEND, J. An assessment of support vector machines for land cover classification. *International Journal of remote sensing*, Taylor & Francis, v. 23, n. 4, p. 725–749, 2002. 18, 19, 20

HYNDMAN, R. J.; ATHANASOPOULOS, G. Forecasting: principles and practice. [S.l.]: OTexts, 2014. 8

ITC. *ITC's database of Satellites and Sensors List of all sensors*. 2016. <http://www.itc.nl/research/products/sensordb/allsensors.aspx>. Accessed: 2016-09-04. 4, 5

JENSEN, J. R. Remote Sensing of the Environment: An Earth Resource Perspective. 2. ed. Upper Saddle River: Prentice Hall, 2007. 592 p. 15

JÖSSON, P.; EKLUNDH, L. Seasonality extraction by function fitting to time-series of sarellite sensor data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 40, n. 8, p. 1824–1832, 2002. 2

JUSTICE, C. et al. An overview of modis land data processing and product status. *Remote sensing of Environment*, Elsevier, v. 83, n. 1, p. 3–15, 2002. 7

KÖRTING, T. S. et al. Land cover detection using temporal features based on polar representation. Arequipa, Peru, august 2013. Disponível em: http://www.ucsp.edu.pe/sibgrapi2013/eproceedings/wtd/114683.pdf>. 20

KÜNZER, C. et al. Remote Sensing Time Series: Revealing Land Surface Dynamics. [S.l.]: Springer International Publishing, 2015. v. 22. 2, 4, 7, 8, 9, 10

LEVENSHTEIN, V. I. Binary codes capable of correcting deletions, insertions and reversals. *Doklady Akademii Nauk SSSR*, v. 163, p. 845–848, 1965. 22

LORENA, A. C.; CARVALHO, A. C. de. Uma introdução às support vector machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 2007. 18, 19

LUNETTA, R. S. et al. Land-cover change detection using multi-temporal modis ndvi data. *Remote Sensing Environment*, v. 105, n. 2, p. 142–154, 2006. 2

MAUS, V. et al. dtwsat: Time-weighted dynamic time warping for satellite image time series analysis in r. *Journal of Statistical Software*, 2016. No prelo. 3, 10, 25, 26, 28, 37

MAUS, V. et al. A time-weighted dynamic time warping method for land-use and land-cover mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016. No prelo. 1, 2, 21, 22, 23, 27, 28, 34, 35, 36

MÜLLER, M. Information Retrieval for Music and Motion. Nova Iorque, EUA: Springer, 2007. 21, 22, 23, 25

NASA. MODISSpecifications. 2016. <http://modis.gsfc.nasa.gov/about/specifications.php>. Accessed: 2016-09-04. 6 OTUKEI, J. R.; BLASCHKE, T. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 12, p. S27–S31, 2010. 20

PEDREGOSA, F. et al. Scikit-learn: Machine learning in python. Journal of Machine Learning Research, v. 12, n. Oct, p. 2825–2830, 2011. 19

PERMATASARI, P. A. et al. Analysis of Agricultural Land Use Changes in Jombang Regency, East Java, Indonesia Using BFAST Method. *Procedia Environmental Sciences*, Elsevier B.V., v. 33, p. 27–35, 2016. ISSN 18780296. Disponível em:

http://www.sciencedirect.com/science/article/pii/S1878029616002188>. 14, 17

PETITJEAN, F.; INGLADA, J.; GANÇARSKI, P. Satellite image time series analysis under time warping. *IEEE Transactions on Geoscience and Remote Sensing*, v. 50, n. 8, p. 3081–3094, ago. 2012. 24, 28

PORTER, J.; BERKHAHN, J.; ZHANG, L. Chapter 29 - a comparative analysis of read mapping and indel calling pipelines for next-generation sequencing data.
In: TRAN, Q. N.; ARABNIA, H. (Ed.). *Emerging Trends in Computational Biology, Bioinformatics, and Systems Biology*. Boston: Morgan Kaufmann, 2015, (Emerging Trends in Computer Science and Applied Computing). p. 521 – 535. ISBN 978-0-12-802508-6. Disponível em:

http://www.sciencedirect.com/science/article/pii/B9780128025086000296>. 14

PRODES. PROJETO PRODESMonitoramento da Floresta Amazônica Brasileira por satélite. 2016. http://www.obt.inpe.br/prodes/index.php. Accessed: 2016-09-04. 8

R Core Team. R: A Language and Environment for Statistical Computing. Vienna, Austria, 2013. Disponível em: http://www.R-project.org/>. 19, 28, 34

ROERINK, G. J.; MENETI, M.; VERHOEF, W. Reconstructing cloudfree ndvi composites using fourier analysis of time series. *International Journal of Remote Sensing*, v. 21, n. 9, p. 1911–1917, 2000. 2

SAKOE, H.; CHIBA, S. A dynamic programming approach to continuous speech recognition. In: *Proceedings of the 7th International Congress on Acoustics*. Budapeste, Hungria: ICA, 1971. v. 3, p. 65–69. 22, 23

SAKOE, H.; CHIBA, S. Dynamic programming algorithm optimization for spoken word recognition. *IEEE Transactions on Acoustics, Speech and Signal Processing*, ASSP-26, n. 1, p. 43–49, fev. 1978. 22, 23

SALOMONSON, V. V.; TOLL, D. L. Execution phase (c/d) spectral band characteristics of the eos moderate resolution imaging spectrometer-nadir (modis-n) facility instrument. *Advances in Space Research*, Elsevier, v. 11, n. 3, p. 231–236, 1991. 7

SMOLA, A. J. Advances in large margin classifiers. [S.l.]: MIT press, 2000. 17

SOUZA, C. G. Uso de séries temporais para o mapeamento da cafeicultura. 162 p. Tese (Tese de Doutorado (Engenharia Florestal)) — Universidade Federal de Lavras, 2015. 18, 20

USGS. Landsat 8 Surface Reflectance (Provisional) Product Guide : EarthExplorer Version. [S.I.], 2015. 2015 p. 5, 6

VAPNIK, V. N. An overview of statistical learning theory. *IEEE transactions on neural networks*, IEEE, v. 10, n. 5, p. 988–999, 1999. 17

VAPNIK, V. N.; CHERVONENKIS, A. Y. On the uniform convergence of relative frequencies of events to their probabilities. *Theory of Probability and its Applications*, SIAM, v. 16, n. 2, p. 264–280, 1971. Disponível em: http://link.aip.org/link/?TPR/16/264/1>. 17

VERBESSELT, J. et al. Detecting trend and seasonal changes in satellite image time series. *Remote Sensing of Environment*, Elsevier B.V., v. 114, n. 1, p. 106–115, 2010. ISSN 00344257. Disponível em: http://dx.doi.org/10.1016/j.rse.2009.08.014>. 2, 3, 8, 10, 14, 15, 16

VERBESSELT, J. et al. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. *Remote Sensing of Environment*, v. 114, n. 12, p. 2970–2980, 2010. ISSN 00344257. 14

VERBESSELT, J.; ZEILEIS, A.; HEROLD, M. Near real-time disturbance detection using satellite image time series. *Remote Sensing of Environment*, v. 123, n. Turner 2010, p. 98–108, 2012. ISSN 00344257. 2, 14

VICTORIA, D. et al. Análise harmônica de séries temporais de imagens ndvi/modis para discriminação de coberturas vegetais. *Simpósio Brasileiro de Sensoriamento Remoto*, v. 14, p. 1589–1596, 2009. 20

WATTS, L. M.; LAFFAN, S. W. Sensitivity of the BFAST algorithm to MODIS satellite and vegetation index. 20th International Congress on Modelling and Simulation, n. December, p. 1638–1644, 2013. 15

WATTS, L. M.; LAFFAN, S. W. Effectiveness of the BFAST algorithm for detecting vegetation response patterns in a semi-arid region. *Remote Sensing of Environment*, Elsevier Inc., v. 154, n. 1, p. 234–245, 2014. ISSN 00344257. Disponível em: http://dx.doi.org/10.1016/j.rse.2014.08.023>. 14, 17

WOODCOCK, C. E. et al. Free Access to Landsat Imagery. *Science*, v. 320, n. May, p. 1011–1012, 2008. ISSN 00368075. 2

WU, M. et al. Use of modis and landsat time series data to generate high-resolution temporal synthetic landsat data using a spatial and temporal reflectance fusion model. *Journal of Applied Remote Sensing*, International Society for Optics and Photonics, v. 6, n. 1, p. 063507–1, 2012. 5 WULDER, M. A. et al. Opening the archive: How free data has enabled the science and monitoring promise of Landsat. *Remote Sensing of Environment*, Elsevier B.V., v. 122, p. 2–10, 2012. ISSN 00344257. Disponível em: http://dx.doi.org/10.1016/j.rse.2012.01.010>. 2

ZEILEIS, a. A Unified Approach to Structural Change Tests Based on ML Scores, F Statistics, and OLS Residuals. *Econometric Reviews*, v. 24, n. 4, p. 445–466, 2005. ISSN 0747-4938. Disponível em: http://www.tandfonline.com/doi/abs/10.1080/07474930500406053>. 15