

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - UFRGS
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E
METOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO**

ANIBAL GUSSO

**AVALIAÇÃO DO IMPACTO DE TEMPERATURAS NAS SAFRAS DE VERÃO POR
INTEGRAÇÃO DE DADOS DOS SATÉLITES AQUA E TERRA/MODIS**

**PORTO ALEGRE
2014**

ANIBAL GUSSO

**AVALIAÇÃO DO IMPACTO DE TEMPERATURAS NAS SAFRAS DE VERÃO POR
INTEGRAÇÃO DE DADOS DOS SATÉLITES AQUA E TERRA/MODIS**

Tese apresentada como requisito final para obtenção do título de Doutor em Sensoriamento Remoto ao Programa de Pós-Graduação em Sensoriamento Remoto da Universidade Federal do Rio Grande do Sul - UFRGS

Orientação: Prof. Dr. Jorge Ricardo Ducati;
Coorientação: Prof. Dr. Ricardo Wanke de Melo

PORTO ALEGRE

2014

AGRADECIMENTOS

Ao professor Jorge Ricardo Ducati por sua valiosa orientação e contribuição nesta Tese de doutorado, sendo ainda um ótimo exemplo de como deve ser um pesquisador;

À Universidade Federal do Rio Grande do Sul e ao Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia;

Aos amigos e colegas Mauricio Roberto Veronez, Fabiane Bordin, Eliete Doncato Brasil, Cleonice Silveira da Rocha e Ricardo Wanke de Melo pelo incentivo e colaboração na realização deste trabalho;

Aos pesquisadores Damien Arvor, Silvia Rolim e Josicléda Domiciano Galvincio por sua importante contribuição na realização deste trabalho.

E à Deus, por sua fonte infinita de inspiração e recomeço.

Dedico este trabalho ao Dr. Alcides Gusso e Arcolina T. Mozer, meus pais.

RESUMO

Devido às características geopolíticas do Brasil, a obtenção de estimativas agrícolas confiáveis é de fundamental importância para o país proporcionando a manutenção do equilíbrio entre oferta e demanda na cadeia produtiva de alimentos. Os Estados do Mato Grosso e Rio Grande do Sul são dois grandes produtores de soja no Brasil, ocupando a primeira e a terceira posição respectivamente, e apresentam características climáticas e ecoregionais bem diferenciadas. Tipicamente, dados de imagens dos satélites Terra do programa EOS-MODIS (Earth Observing System-Moderate Resolution Imaging Spectroradiometer), e dos satélites NOAA (National Oceanic and Atmospheric Administration) têm sido utilizadas em aplicações do monitoramento do ciclo de desenvolvimento das culturas e estimativa da produção agrícola. Em busca da estruturação de modelos de caráter prognóstico, inteiramente baseados em dados de sensoriamento remoto, este estudo visa explorar a combinação entre o EVI (Enhanced Vegetation Index - ou Índice de vegetação realçado), produto MOD13Q1-V005 e a LST (Land Surface Temperature – ou Temperatura da Superfície Terrestre), produto MYD11A2-V005 na estimativa da produtividade da soja. Nesse sentido, o objetivo nesta Tese foi aprofundar o conhecimento sobre os efeitos conjugados do estresse hídrico e da ocorrência de temperaturas elevadas no dossel da vegetação como contribuição ao avanço dos modelos espectrais de estimativa da produção. A abordagem inicial foi desenvolver um modelo espectral acoplado CM (Coupled Model) a partir do MCDA (MODIS Crop Detection Algorithm – ou Algoritmo de Detecção de Área Agrícola por MODIS) e do MPDM (MODIS Productivity Detection Model – ou Modelo de Detecção de Produtividade da Soja por MODIS), que utilizam apenas dados EVI como variáveis de entrada. Os resultados do modelo acoplado de estimativa da produção foram comparados com dados provenientes do IBGE (Instituto Brasileiro de Geografia e Estatística) e de precipitação ocorrida proveniente do INMET (Instituto Nacional de Meteorologia), entre 2001 e 2011 para os Estados do Mato Grosso e Rio Grande do Sul. Os dois Estados apresentaram tendências semelhantes com aderência aos dados oficiais em nível estadual e municipal. Para o Mato Grosso o modelo acoplado CM, obteve estimativas de $R^2=0,96$ e RMSD=47.878 toneladas em nível municipal. Testes de validação adicionais foram realizados na safra 2006, utilizando dados de campo, em que se obteve $R^2=0,88$ e RMSD=104 toneladas. Para o Rio Grande do Sul foi obtido $R^2=0,91$ e RMSD=10.841 toneladas em nível municipal. Na análise da relação entre LST sobre o dossel da vegetação agrícola e produtividade, Mato Grosso e Rio Grande do Sul apresentaram respostas divergentes. O Mato Grosso apresentou uma relação matemática direta entre LST-dossel e produtividade, com $R^2=0,60$ e RMSD=6,2%. No Rio Grande do Sul foi observado uma relação matemática inversa, com $R^2=0,73$ e RMSD=17,8%. Os resultados mostram que a quantidade da precipitação acumulada, no período da safra de verão, desempenha papel fundamental na manutenção do equilíbrio da demanda evaporativa quando ocorrem temperaturas elevadas sobre o dossel da vegetação.

Palavras-chave: Sensoriamento remoto. Temperatura da superfície. Produtividade. Modelo espectral. Soja. Climatologia.

ABSTRACT

Reliable agricultural estimates are important for most countries, and crucial for Brazil, due to its geopolitical characteristics derived from a vast territory. Good estimates ensure a balance between offer and needs inside the food chain production. The States of Mato Grosso and Rio Grande do Sul are large soybean producers, ranking first and third respectively in Brazil, and present quite different climatic and ecological characteristics. As an alternative to conventional estimation methods, soybean crops have been monitored and grain production estimated using Remote Sensing data with sources as EOS-MODIS (Earth Observing System-Moderate Resolution Imaging Spectroradiometer) from Terra satellite and also from the NOAA (National Oceanic and Atmospheric Administration) satellites. This work aimed to the development of forecasting models completely based in Remote Sensing data, by integrating information on EVI (Enhanced Vegetation Index), product MOD13Q1-V005, and LST (Land Surface Temperature), produto MYD11A2-V005, to estimates of soybean yield. More precisely, the objective of this work was to advance the knowledge on the superposed effects of water stress and high temperatures on the vegetation canopy, as a contribution to the development of spectral models for production estimates. The starting approach was to develop a coupled spectral model (CM - Coupled Model), from the MCDA (MODIS Crop Detection Algorithm) and from the MPDM (MODIS Productivity Detection Model), which use only EVI data as input variables. The production estimates, as results of this Coupled Model, were compared with similar data from IBGE (Instituto Brasileiro de Geografia e Estatística) and matched with records on precipitation from INMET (Instituto Nacional de Meteorologia) between 2001 and 2011 for Mato Grosso and Rio Grande do Sul States. For both States the application of the coupled model produced results close to the official data at state and county levels. For Mato Grosso, correlations of CM with official data were $R^2=0.96$ and RMSD=47,878 metric tons at county level. Additional validation tests were performed for the 2006 crop, using field data, producing $R^2=0.88$ and RMSD=104 metric tons. For Rio Grande do Sul results were $R^2=0.91$ and RMSD=10,841 metric tons at municipality level. In the analysis on the relationship between canopy LST and yield, Mato Grosso and Rio Grande do Sul presented opposite results. Mato Grosso showed a direct mathematical correlation between canopy LST and yield, with $R^2=0.60$ and RMSD=6.2%. For Rio Grande do Sul an inverse mathematical expression was derived, with $R^2=0.73$ and RMSD=17.8%. These results show that the accumulated precipitation during the summer crops is crucial to maintain a balance of the evaporative demand when the vegetation canopy is exposed to high temperatures.

Key-word: Remote sensing. Surface temperature. Yield. Spectral model. Soybean. Climatology.

LISTA DE FIGURAS

Figura 1 - Representação esquemática da atividade fotossintética de plantas do tipo C3 e C4 em função da temperatura e luminosidade sobre o dossel	15
Figura 2 - Área de estudo: Estado do Rio Grande do Sul e a área de validação, Estado do Mato Grosso.....	19
Figura 3 - Fluxograma de classificação de áreas de soja baseada em imagens MODIS/EVI (<i>Adaptado do Apêndice C</i>).....	20
Figura 4 - Comparação da produção estimada pelo modelo acoplado (CM) e dados IBGE e CONAB, nas safras 2001 a 2011 no Estado do Rio Grande do Sul	22
Figura 5 - Comparação entre todas as estimativas municipais da produção obtidas do IBGE e do MPDM, em cada ano-safra, de 2001 a 2011, Rio Grande do Sul.....	22
Figura 6 - Comparação da produção estimada pelo modelo acoplado (CM) e dados IBGE e CONAB, nas safras 2001 a 2011 no Estado do Mato Grosso	23
Figura 7 - Comparação entre todas as estimativas municipais da produção obtidas do IBGE e do MPDM, em cada ano-safra, de 2001 a 2011, Mato Grosso.....	23
Figura 8 - Comparação.....	24
entre a produção estimada pelo modelo acoplado e observada em 211 áreas de soja referente aos talhões visitados, em 2006, no Mato Grosso.....	24
Figura 9 - Área de estudo no Rio Grande do Sul mostrando a região de intensa produção da soja na análise inicial e a distribuição das 16 estações meteorológicas	25
Figura 10 - Área de estudo, Estado do Rio Grande do Sul e regionais EMATER	27
Figura 11 - Mapa de área de soja obtido com aplicação do MCDA compondo as safras 2003 a 2012.....	30
Figura 12 - Comparação entre diagramas de dispersão dos valores de LST e EVI, no mês de fevereiro dentro da área de intensa produção da soja (a, c, e, g, i, k, m, o, q, s) com a distribuição da precipitação acumulada entre outubro de fevereiro (b, e, f, h, j, l, n, p, r, t) nas safras de 2003 a 2012.	33

LISTA DE TABELAS

Tabela 1 - Médias estaduais e desvio padrão da LST-dossel, produtividade da soja e precipitação, obtidas pela interpolação espacial dos dados, no período entre 2003 e 2012 na área de intensa produção da soja	38
--	----

SUMÁRIO

1 INTRODUÇÃO	8
1.1 Objetivos	11
1.1.1 Objetivo Geral	11
1.1.2 Objetivos Específicos	11
2 REFERENCIAL TEÓRICO.....	12
2.1 Combinação da LST com EVI.....	12
3 MATERIAIS E MÉTODO.....	17
3.1 Área de Estudo e Área de Validação do Modelo Acoplado	17
3.2 Segunda Parte: estudo da distribuição da LST e EVI em região de alta densidade agrícola.....	24
3.3 Terceira Parte: análise regional de distribuição da LST e da produtividade	26
4 RESULTADOS.....	31
5 CONCLUSÕES	40
REFERÊNCIAS.....	41
APÊNDICE A - Artigo publicado (Gusso e Ducati, 2012). Compõe a metodologia de estimativa de área da cultura da soja no Rio Grande do Sul. Título: Algorithm for Soybean Classification Using Medium Resolution Satellite Images	48
APÊNDICE B - Artigo publicado (Gusso, 2013). Compõe uma abordagem inicial para a fundamentação física entre LST-dossel e produtividade da soja. Título: Integração de Imagens NOAA/AVHRR: rede de Cooperação para Monitoramento Nacional Da Safra de Soja	49
APÊNDICE C - Artigo publicado (Gusso et al., 2012). Compõe a metodologia de estimativas de área no Rio Grande do Sul. Título: Soybean Crop Area Estimation by MODIS/EVI Data	50
APÊNDICE D - Artigo publicado (Gusso et al., 2013). Compõe a metodologia CM para produtividade da soja no Rio Grande do Sul. Título: Spectral Model for Soybean Yield Estimate Using MODIS/EVI Data	51
APÊNDICE E - Artigo publicado (Gusso et al., 2014a). Compõe o estudo da sazonalidade da LST-dossel no Rio Grande do Sul. Título: Monitoring Heat Waves and Their Impacts on Summer Crop Development in Southern Brazil	52
APENDICE F - Artigo publicado (Gusso et al., 2014b). Compõe a metodologia de análise da LST-dossel e impactos na produtividade da soja no Rio Grande do Sul.	

Título: Avaliação do Impacto de Ondas de Calor em Safras de Verão por Integração de Dados dos Satélites Aqua e Terra/MODIS.....	53
APÊNDICE G - Artigo publicado (Gusso et al., 2014c). Compõe a metodologia de estimativa da área da soja no Mato Grosso. Título: Assessing the MODIS Crop Detection Algorithm for Soybean Crop Area Mapping and Expansion in the Mato Grosso State, Brazil.	54
APENDICE H - Artigo submetido (Gusso et al., 2014d). Analisa a relação da LST-dossel e impactos na produtividade da soja no Estado do Mato Grosso e demonstra a necessidade de ajuste da <i>Hipótese 1</i> . Título: Impacts of Heat Waves Over Summer Crops in Mato Grosso State, Brazil.	55

1 INTRODUÇÃO

O monitoramento e o gerenciamento agrícola têm um papel importante frente ao aumento da demanda por produtos agrícolas e as incertezas quanto às flutuações das condições ambientais. Na primeira década do terceiro milênio, intensas flutuações das condições agrometeorológicas causaram efeitos severos na produção de alimentos e na economia, em especial no sul do país. Geralmente as culturas mais afetadas foram as de soja e milho, sendo que na safra da soja em 2005, no Rio Grande do Sul, a produção apresentou uma redução de 75% na produção de grãos, quando comparada à safra de 2003 (IBGE, 2012). Liu e Kogan (2002), em uma análise da produção brasileira utilizando imagens de satélite, salientam que mesmo com clima geralmente favorável na maior parte das áreas de cultivo ocorrem grandes variações na produção agrícola de um ano para outro. No Estado do Rio Grande do Sul (RS) a frequência e a intensidade das chuvas, no período que vai da semeadura até a colheita, têm sido variáveis e frequentemente são insuficientes para o pleno desenvolvimento da cultura (MATZENAUER et al., 2002). A grande variabilidade interanual da precipitação, verificada principalmente em função dos fenômenos El Niño e La Niña, é o principal fator responsável pelas oscilações de produtividade na região sul (FERREIRA, 2010), sendo que as culturas mais afetadas geralmente são as da soja e do milho (FONTANA et al., 2002) na safra de verão. Entretanto, a ocorrência de altas temperaturas e ondas de calor, associadas ou não à ocorrência de estiagem, vem ganhando interesse em publicações científicas (BATISTTI; NAYLOR, 2009) devido à necessidade de caracterização da vulnerabilidade e sustentabilidade dos processos agrícolas (GUSSO, 2013). Lobell e Asner (2003), analisando um período de 17 anos entre 1982 a 1998, observaram que a perda de produtividade das culturas agrícolas de verão nos Estados Unidos da América (EUA) esteve associada ao aumento das temperaturas durante o período de desenvolvimento da safra, indicando a ocorrência de stress térmico sobre as culturas. Em um panorama de risco na produção de alimentos em decorrência de flutuações do clima, parâmetros físicos da superfície terrestre como disponibilidade hídrica e evapotranspiração devem sofrer alterações nas próximas décadas (SIQUEIRA et al., 2000; PETERSON; STOTT; HERRING, 2012) restringindo as condições de evolução dos cultivos e a produção (LOBELL et al., 2008; NELLEMANN et al., 2009). Como resultado, distorções e incertezas nas

políticas agrícolas devem acentuar perdas e estabelecer barreiras para o financiamento agrícola (FAO, 2011), pela imprevisibilidade de políticas agrícolas governamentais que tem maior influência na volatilidade dos preços nos países do que as flutuações do mercado internacional (NELLEMANN et al., 2009). Desta maneira, o desenvolvimento de metodologias simplificadas para o monitoramento das condições de evolução dos cultivos proporciona uma caracterização mais detalhada sobre a vulnerabilidade e sustentabilidade da agricultura no Brasil (GUSSO et al., 2013). Tais desenvolvimentos são necessários frente à probabilidade e intensidade da ocorrência de altas temperaturas (WHEELER et al., 2000), para a elaboração de prognósticos mais precisos (LOBELL; ASNER, 2003), e no aumento da capacidade de gerenciamento na produção das commodities agrícolas (SCHLENKER; ROBERTS, 2009; GUSSO et al., 2013). Tipicamente, dados de imagens dos satélites Terra e Aqua do programa Earth Observing System - Moderate Resolution Imaging Spectroradiometer (EOS-MODIS) têm sido aplicados no monitoramento e modelagem de processos bioclimáticos, de ciclos de desenvolvimento das culturas, e em estimativa da produção agrícola (HUETE et al., 2002; SHIMABUKURU; MAEDA; FORMAGGIO, 2009; GUSSO et al., 2012). O potencial científico destes dados proporciona uma análise continuada de parâmetros representativos das condições físicas da superfície terrestre, e tem um vasto campo de aplicações no monitoramento de parâmetros agrometeorológicos (GUSSO; FONTANA; GONÇALVES, 2007; LIU; KOGAN, 2002; KOGAN, 2001). Também oferecem maior agilidade frente aos dados meteorológicos pontuais, obtidos por instrumentos em abrigos meteorológicos ou por estações automáticas que, freqüentemente estão incompletos ou não disponíveis para uma avaliação em tempo hábil (NICÁCIO, 2008; KOGAN, 2002). Trabalhos recentes têm evidenciado o efeito da ocorrência de temperaturas elevadas sobre a queda de produtividade das principais commodities agrícolas, como soja, milho e algodão. Estudos com séries temporais de dados de satélites têm evidenciado que os danos causados às plantas, com diminuição do desenvolvimento da cultura, podem estar associados à vulnerabilidade frente à ocorrência de ondas de calor (NEMANI; RUNNING, 1997; LIU; KOGAN, 2002; SCHLENKER; ROBERTS, 2009; GUSSO, 2013). Prejuízos na produtividade da soja ocorrem mesmo quando as temperaturas médias atingem apenas um ou dois graus acima do ideal para a cultura (LOBELL; ASNER, 2003; SEDIYAMA, 2009), seja pela redução na atividade fotossintética no dossel da

vegetação em situação de estresse térmico (BOARD; KAHLON, 2007; CARMO-SILVA et al., 2012), seja pelo aumento da demanda evaporativa (HOPE et al, 1986; NEMANI; RUNNING, 1997), ou pela alteração na duração do período de florescimento (RODRIGUES et al., 2001). Mesmo tendo sido observado que o período de florescimento é mais sensível à temperatura do que ao estresse hídrico (LIU; KOGAN, 2002; BOARD; KAHLON, 2007; CRAUFURD; WHEELER, 2009; BATISTTI; NAYLOR, 2009; CARMO-SILVA et al., 2012), os impactos de ondas de calor na produtividade ainda não são bem conhecidos (SALVUCCI, 2008; MEERBURG et al., 2009; SCHLENKER; ROBERTS, 2009). Com base nos conceitos analisados anteriormente, a hipótese que norteia esta Tese está fundamentado na possibilidade de relacionar duas variáveis de monitoramento das condições de desenvolvimento da vegetação LST e EVI, com a produtividade, conforme as seguintes premissas:

Premissa da área - É possível identificar e quantificar segmentos de área com presença de cultivo da soja com base em características do perfil de desenvolvimento descrito pelo EVI e de maneira independente das condições de desenvolvimento da cultura (Apêndice A; Apêndice C e Apêndice F);

Premissa agrometeorológica – A produtividade da cultura de um determinado segmento de área está associada às flutuações do total de precipitação acumulada ocorridos no desenvolvimento da safra. A *Premissa agrometeorológica* desempenha papel fundamental pois afirma a relação entre o vigor da vegetação exibido pelo índice de vegetação e a produtividade (Apêndice B).

Premissa do ciclo de desenvolvimento - Existe correlação entre o vigor vegetativo exibido pelo índice de vegetação EVI e a produtividade da cultura da soja de maneira que o EVI pode ser considerado um agente integrador das condições do ciclo de desenvolvimento por meio de uma relação matemática direta. Considera-se ainda o perfil de desenvolvimento da safra como função do EVI. Dessa maneira, a área calculada abaixo da curva, e acima de zero, é proporcional à produtividade máxima da cultura, de modo que em cada safra diferentes condições de desenvolvimento da cultura são descritas por diferentes perfis do EVI, varrendo diferentes áreas em janelas de tempo iguais (Apêndice D).

A partir da estruturação das premissas básicas, as hipóteses propostas que devem ser testadas são as seguintes:

Hipótese 1 – É possível estabelecer uma relação matemática entre as flutuações da LST-dossel em torno da média, representativa do dossel da vegetação, associada com flutuações da produtividade;

Hipótese 2 - Existe uma correlação inversa universal entre a LST-dossel e as condições de desenvolvimento da cultura da soja exibida pelo EVI.

1.1 Objetivos

1.1.1 Objetivo Geral

A partir da formulação das hipóteses iniciais da presente Tese, o objetivo geral é investigar a relação entre a temperatura no dossel da vegetação e a produtividade na cultura da soja no Rio Grande do Sul, utilizando dados dos sensores MODIS a bordo dos satélites Terra e Aqua.

1.1.2 Objetivos Específicos

- 1º Investigar a relação entre o desenvolvimento da vegetação da soja com base nos dados do EVI, e a produtividade da soja no Rio Grande do Sul;
- 2º Desenvolver método espectral de estimativa da produção da soja (espectral acoplado), com base nos dados de índice de vegetação EVI;
- 3º Investigar as escalas (espaciais e temporais) de ocorrência de temperaturas sobre o dossel da vegetação no Estado e sua distribuição espacial;
- 4º Investigar a relação entre a ocorrência de temperaturas elevadas e o desenvolvimento da vegetação da soja no Rio grande do Sul;
- 5º Analisar o impacto da ocorrência de temperaturas elevadas no dossel da vegetação em áreas agrícolas sobre a produtividade.

2 REFERENCIAL TEÓRICO

Para o entendimento desta proposta de Tese, é necessária uma revisão da caracterização das variáveis LST e EVI, quando representativas das condições de desenvolvimento da cultura e que estão associadas às flutuações da produtividade.

2.1 Combinação da LST com EVI

No Brasil, a maioria das cultivares adaptadas para as condições locais apresentam um ciclo entre 90 e 150 dias (SEDIYAMA, 2009). No Mato Grosso, calendário predominante de plantio da soja vai do início de setembro a meados de outubro, segundo o zoneamento agrícola de menor risco climático para diferentes solos, regiões e cultivares (MAPA). No Rio Grande do Sul, o calendário predominante de plantio da soja vai do final de outubro a meados de dezembro, segundo o zoneamento agrícola de menor risco climático para diferentes solos, regiões e cultivares (CUNHA et al., 2001; BRASIL, 2010), normalmente atingindo o período da floração em meados de fevereiro (PINTO; FONTANA, 2011). A LST-dossel entre 25 °C e 35 °C, quando a indução floral é ótima, são as temperaturas mais frequentemente mencionadas como as condições ideais para a soja, tendo uma média ideal para seu desenvolvimento próximo a 30 °C (BOARD; KAHLEN, 2007; SEDYIAMA, 2009; SCHLENKER; ROBERTS, 2009; KHAN et al., 2011).

Em geral, as plantas têm a capacidade de manter o conteúdo de água nos tecidos independentemente da temperatura, quando a umidade é suficiente, no entanto, altas temperaturas prejudicam severamente essa tendência quando o suprimento de água é limitado (MACHADO; PAULSEN, 2001). Basicamente, as condições biofísicas da superfície terrestre determinam as temperaturas do solo e da vegetação assim como da temperatura do ar próxima à superfície do solo (GOWARD; XUE; CZAJKOWSKI, 2002; OUAIDRARI et al., 2002).

Em sistemas agrícolas tão homogêneos como em campos de cultivo, mesmo quando as condições de disponibilidade hídrica não são limitantes para o crescimento e desenvolvimento das plantas, a radiação incidente também afeta a capacidade dos estômatos para transpiração, alterando a relação entre calor

sensível e calor latente (NEMANI; RUNNING, 1997; SANDHOLT; RASMUNSEN; ANDERSEN, 2002; KHAN et al., 2011).

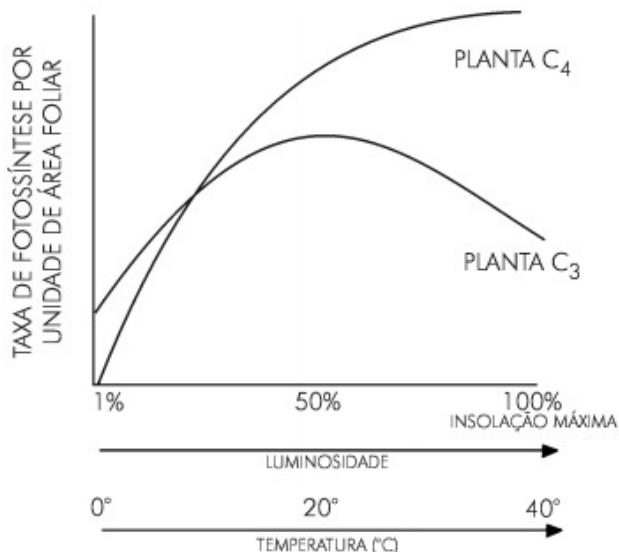
A ocorrência de estresse por temperaturas elevadas durante o período de floração e formação das vagens (R1-R5) afeta o número de sementes (GIBSON; MULLEN, 1996), e está fortemente associada às variações na produtividade (BOARD; KAHLEN, 2007), tendo efeito cumulativo no desenvolvimento da vegetação (GUSSO et al., 2013). Dessa maneira, o uso combinado da LST e índice de vegetação supõe uma relação matemática inversa entre vigor vegetativo e a resposta termal característica do dossel (HOPE et al, 1986; SANDHOLT; RASMUNSEN; ANDERSEN, 2002; GUSSO, 2013), iniciando processo de estresse térmico com perda de produtividade quando ocorrem temperaturas elevadas que este limite (SCHLECKER; ROBERTS, 2009). Entretanto, índices de vegetação, tipicamente fundamentados na relação entre bandas posicionadas das regiões do vermelho e infravermelho próximo, não são bons indicadores do estresse hídrico, pois a vegetação pode permanecer verde, após o estresse hídrico inicial (SANDHOLT; RASMUNSEN; ANDERSEN, 2002, SIMS et al., 2008) com pouca ou nenhuma alteração detectável pelo EVI. Goetz (1997) salienta esta característica observando que existe um período mínimo de resposta entre a diminuição da disponibilidade hídrica e alteração dos valores do índice de vegetação, mas uma resposta mais imediata é dada pelo aumento da temperatura do dossel, como efeito de redução na disponibilidade hídrica. Neste sentido, mesmo quando o índice de vegetação ainda sinaliza uma característica típica da vegetação verde, uma sensível redução na disponibilidade hídrica promove o fechamento dos estômatos, o que ocasiona uma redução na capacidade das plantas em reter a energia solar incidente por meio de absorção (KHAN, M.; ASGHER; KHAN, N., 2013), afetando também a capacidade da realização da fotossíntese e ocasionando perda do potencial de produtividade (SALVUCCI; CRAFTS-BRENDNER, 2004). Em resposta à baixa circulação de água na estrutura interna (mesofílica) da vegetação, a temperatura do dossel aumenta rapidamente (GOETZ, 1997). Já na situação oposta, em que predominam superfícies bem úmidas e com boa disponibilidade hídrica, a relação entre índice de vegetação e LST-dossel está mais diretamente relacionada à umidade da superfície, pelo aumento da inércia térmica do solo (FRIEDL; DAVIS, 1994).

Alguns trabalhos já exploraram uma relação entre índices de vegetação e o comportamento térmico da superfície obtido por dados de sensoriamento remoto (e.g., NEMANI et al., 1993; GOETZ, 1997; LAMBIN; EHRLICH, 1995, SANDHOLT; RASMUNSEN; ANDERSEN, 2002; KOGAN et al., 2004). Alguns destes estudos têm sido desenvolvidos sobre firmes bases teóricas (e.g. MORAN et al., 1994), enquanto outros ainda estão fortemente fundamentados em parametrizações empíricas com imagens de satélite obtidas por sensores colocados em órbita (e.g. SANDHOLT; RASMUNSEN; ANDERSEN, 2002; KOGAN, 2002; KOGAN et al., 2004). Entretanto, abordagens científicamente robustas devem estar mais fundamentadas na representatividade das condições físicas de desenvolvimento da vegetação, que permita um entendimento mais amplo do processo, do que meramente em ajustes estatísticos (SINCLAIR; SELIGMAN, 2000).

A LST-dossel tem efeito direto sobre a capacidade de realização da fotossíntese e, entre os principais impactos que são promovidos por altas temperaturas, o efeito sobre a fotossíntese é o mais importante porque inibe o crescimento da planta afetando sua produtividade (SALVUCCI; CRAFTS-BRANDNER, 2004; BOARD; KAHLON, 2007; GUSSO et al., 2014a). Vários autores (SALVUCCI; CARFTS-BRENDNER, 2004; SALVUCCI, 2008; KHAN, M.; ASGHER; KHAN, N., 2013) têm investigado o processo de inibição da fotossíntese de plantas do tipo C3 (soja e trigo), como uma consequência da dependência da molécula RuBisCO (ribulose 1,5-bisfosfato carboxilase/oxigenasse) às condições de temperatura do ambiente.

Em geral, para plantas do tipo C3, a capacidade de tolerância ao estresse térmico envolve a manutenção da capacidade de aumentar a demanda evaporativa para evitar o sobreaquecimento do dossel (MACHADO; PAULSEN, 2001). A Figura 1 mostra uma representação gráfica da resposta das plantas C3 ao estresse térmico.

Figura 1 - Representação esquemática da atividade fotossintética de plantas do tipo C3 e C4 em função da temperatura e luminosidade sobre o dossel



Fonte: Adaptado de Board e Kahlon, (2007).

O fechamento dos estômatos é a resposta mais imediata da planta ao estresse hídrico minimizando a perda de água pela evapotranspiração, mas principalmente, reduzindo o fluxo de CO₂. Desta diminuição decorre uma severa limitação da taxa de realização da fotossíntese em função da baixa afinidade natural da enzima Rubisco pela assimilação do CO₂ (SALVUCCI; CRAFTS-BRANDNER, 2004; KHAN, M.; ASGHER; KHAN, N., 2013). A transpiração reduzida em condições de aquecimento e incidência de radiação direta ocasiona a diminuição da capacidade de resfriamento da folha elevando a temperatura, o que consequentemente leva ao estresse térmico. Adicionalmente, a fotossíntese é extremamente sensível mesmo à ocorrência de estresse térmico moderado por estar associado entre outros fatores a uma instabilidade da molécula Rubisco, em associação a outros processos que, em última análise, evitam a denaturação da molécula Rubisco, mas que como efeito, reduzem a atividade fotossintética da planta (SALVUCCI; CRAFTS-BRANDNER, 2004; SALVUCCI, 2008; KHAN, M.; ASGHER; KHAN, N., 2013). A partir da influência do estresse térmico e dos efeitos biogeoquímicos sobre a vegetação, decorre que, a formação das vagens está associada aos eventos de estresse predominantes que ocorrem antes do período da

floração, mas o enchimento de grãos e a maturação são sensíveis ao estresse causado por temperaturas elevadas durante o desenvolvimento (KHAN et al., 2011).

3 MATERIAIS E MÉTODO

Na presente Tese, a proposta é ampliar o entendimento sobre os efeitos da ocorrência de temperaturas elevadas sobre o dossel da vegetação da cultura da soja (LST-dossel) em termos quantitativos. Isto permitirá que posteriormente a variável LST-dossel possa ser incluída no modelo espectral acoplado *Coupled Model* (CM) que considera o *MODIS Crop Detection Algorithm* (MCDA) desenvolvido para o Rio Grande do Sul, por Gusso et al. (2012), conforme Apêndice C também adaptado para o Estado do Mato Grosso em Gusso et al. (2014a), conforme Apêndice F e o *MODIS Productivity Detection Model* (MPDM). MCDA e MPDM resultam no CM desenvolvido por Gusso et al. (2013) conforme Apêndice D, para estimativa da produtividade. Tal abordagem, teve como objetivo principal estabelecer uma relação matemática simplificada entre índice de vegetação e estimativa da produtividade e produção da soja. Dessa maneira, o desenvolvimento desta Tese foi elaborado em três partes, como segue:

Na primeira parte, item 3.1, conforme os Apêndices A, C, D e F, são apresentados os resultados obtidos com o desenvolvimento e adaptação do modelo acoplado CM de estimativa da produção para os Estados do Mato Grosso e Rio Grande do Sul. Embora tais desenvolvimentos também sejam parte dos resultados, estes foram mantidos na seção Materiais e Método, pois compõem a fundamentação desta Tese.

Na segunda parte, item 3.2, como continuidade dos resultados apresentados Apêndice II, foi realizada uma investigação mais aprofundada da relação entre LST e EVI sobre área de intensa produção da soja, no período de desenvolvimento da cultura das safras 2003 a 2012.

Na terceira parte, item 3.3, conforme desenvolvimentos nos Apêndices Apêndice B, E, F, G e H, são apresentados os resultados da análise na avaliação regional, na relação entre LST-dossel na vegetação da cultura da soja, EVI, precipitação acumulada e produtividade.

3.1 Área de Estudo e Área de Validação do Modelo Acoplado

Os Estados do Mato Grosso e Rio Grande do Sul são dois grandes produtores de soja no Brasil e ocupam a primeira e a terceira posição,

respectivamente, mas exibem características climáticas e ecoregionais bem diferenciadas.

O Estado do Mato Grosso responde por mais de 30% da produção da soja no Brasil e é o maior produtor do país (IBGE, 2012). No Estado do Mato Grosso, localizado na fronteira sul da Amazônia, as áreas de cultivo da soja passaram de aproximadamente 100.000 ha, no final da década de 1970 para mais de 6.000.000 ha em 2011 (CONAB, 2012). Este processo de expansão levou o Estado a ser o maior produtor de soja do Brasil. Nos anos 2000, práticas agrícolas intensivas como a implementação de uma segunda safra após a safra principal, tem sido amplamente utilizadas de maneira a obter o melhor aproveitamento das condições mais favoráveis ao cultivo, isto é, o período chuvoso. Atualmente, o Mato Grosso tem uma área agrícola de soja maior que 6 milhões de hectares em 141 municípios. O calendário de semeadura para soja vai do início de setembro ao final de novembro, sendo o período ótimo para plantar em outubro, com base no zoneamento agrícola para os solos, as regiões, e as cultivares (MAPA). O clima predominante é tropical superúmido (*Af*) com períodos secos (KÖPPEN, 1948). A precipitação acumulada anual é em média de 1610 mm (INMET, 2009), com período seco. Tipicamente, a precipitação acumulada neste período, que compreende a safra de verão, é 2491 mm com desvio padrão 414 mm (INMET, 2009). A temperatura média anual é 24,5 °C, mas ocorrem máximas absolutas elevadas em janeiro com 37,6 °C, com 37,1 °C em fevereiro, e 36,1 °C em março (INMET, 2009). A principal característica agrícola é a disponibilidade de chuvas favorável à safra de verão no período crítico ao desenvolvimento da vegetação.

O Estado do Rio Grande do Sul responde por quase 15% da produção brasileira de soja e é o terceiro produtor do país (IBGE, 2012). O Estado tem uma área de cultivo da soja maior que 4 milhões de hectares em 497 municípios. O calendário preferencial de semeadura para soja vai do início de outubro a meados de dezembro (MAPA), normalmente atingindo o período da floração em meados de fevereiro (PINTO; FONTANA, 2011). O clima predominante é subtropical úmido (*Cfa* e *Cfb*) com quatro estações bem definidas (KÖPPEN, 1948). A precipitação acumulada anual é relativamente bem distribuída ao longo do ano com média de 1594 mm (INMET, 2009) e sem período seco, especialmente na metade norte do Estado, onde o cultivo da soja é dominante. Tipicamente, a precipitação acumulada neste período, que compreende a safra de verão é 647 mm com desvio padrão 106 mm (INMET, 2009). A temperatura média anual é 18,1 °C, mas ocorrem máximas

absolutas elevadas em janeiro com 42,2 °C, 39,6 °C em fevereiro, e 38,7 °C em março (INMET, 2009). A principal característica agrícola é a ocorrência de períodos de estiagem durante as safras de verão, mas a ocorrência de temperaturas elevadas vem ganhando interesse. A Figura 2 mostra a área estudada, os Estados do Mato Grosso e Rio Grande do Sul. A Figura 2 mostra a área de estudo.,

Figura 2 - Área de estudo: Estado do Rio Grande do Sul e a área de validação, Estado do Mato Grosso

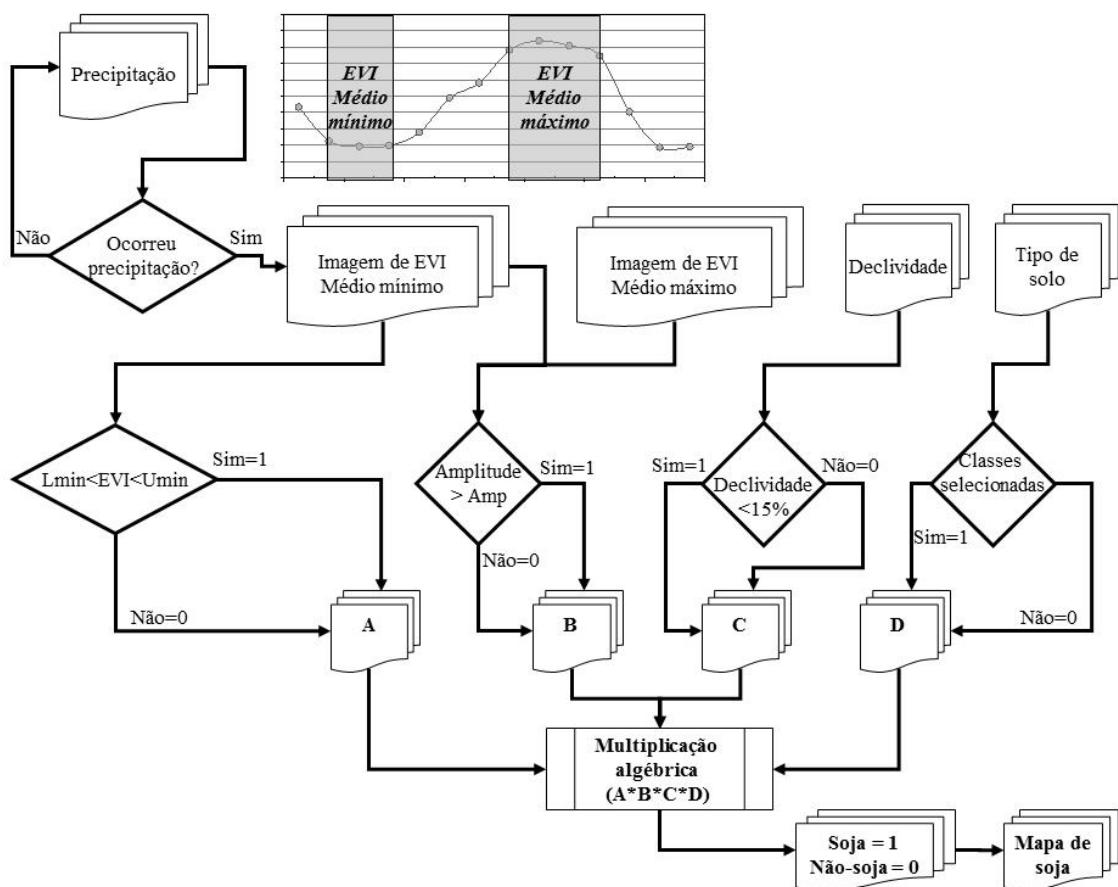


Fonte: Elaborada pelo autor.

Este segmento avaliou o desempenho do modelo acoplado CM para as estimativas de produção de culturas, antecipadamente ao período da colheita, na avaliação da relação entre o índice de vegetação e a produtividade, usando dados EVI do sensor MODIS. No cálculo da produção, a estimativa precisa da área ocupada pela cultura da soja desempenha papel importante. O método de estimativa de área utilizado foi o MCDA desenvolvido por Gusso et al. (2012) conforme Apêndice C. A Figura 3 mostra o fluxograma de classificação de áreas de soja. As estimativas de produção resultantes, nos Estados do Mato Grosso (dados não publicados) e Rio Grande do Sul (GUSSO et al., 2013) foram comparados às estatísticas agrícolas oficiais do Instituto Brasileiro de Geografia e Estatística (IBGE)

e da Companhia Nacional de Abastecimento (CONAB) nas escalas estaduais, municipais e de lavoura.

Figura 3 - Fluxograma de classificação de áreas de soja baseada em imagens MODIS/EVI (Adaptado do Apêndice C)



Fonte: Elaborada pelo autor.

Para a realização desta primeira etapa, os dados utilizados foram os seguintes:

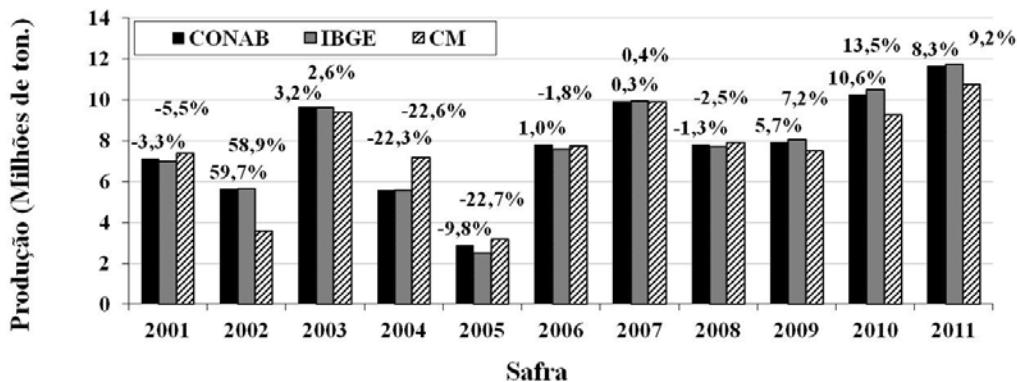
- a) dados EVI de 2000 a 2011 derivados de sensor MODIS a bordo do satélite Terra, produto MOD13Q1 coleção-5, para o Mato Grosso (Tiles H11V09, H11V10, H12V09, H12V10, H13V09 e H13V10) e para Rio Grande do Sul (Tiles H13V11 e H13V12);
- b) dados de altimetria proveniente do Shuttle Radar Topography Mission (SRTM) foram utilizados para gerar um mapa de declividade, com 90

metros de resolução espacial, de modo a excluir as áreas impróprias para mecanização agrícola (declividade > 15%);

- c) dados climatológicos da precipitação (1961-1990), provenientes do Instituto Nacional de Meteorologia (INMET), durante o período de setembro a fevereiro, foram utilizados para identificar as características de disponibilidade hídrica nos dois Estados;
- d) estatísticas agrícolas anuais de produção da soja, em nível estadual e municipal para o Mato Grosso e Rio Grande do Sul, foram utilizados para comparar e avaliar os resultados (IBGE, 2012);
- e) estatísticas agrícolas anuais de produção da soja, em nível estadual, para o Mato Grosso e Rio Grande do Sul, foram utilizados para comparar e avaliar os resultados (CONAB, 2012);
- f) dados de campo (área de cultivo, produção e cultura) foram obtidos da safra 2006, quando várias fazendas foram visitados, durante trabalho de campo realizado em 2007 ao longo BR163 (ARVOR et al., 2011).

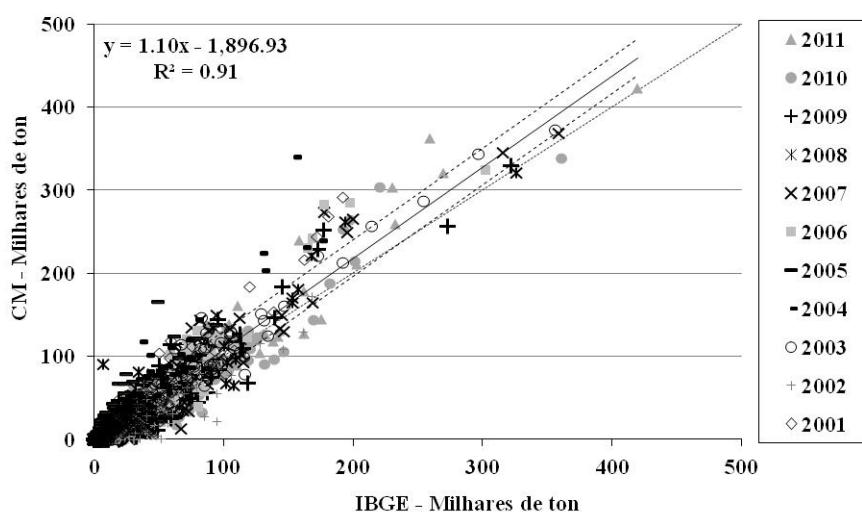
Os resultados obtidos nesta etapa, com base nas estimativas do modelo acoplado de produção, mostram o potencial desta metodologia, tanto ao nível estadual, municipal e lavoura, para fornecer informação espacial antecipada ao período da colheita da soja. Os resultados mostram a correlação R^2 e o desvio médio quadrado *Root Mean Square Deviation* (RMSD) na comparação geral ao nível municipal nas 11 safras estudadas. No Estado do Rio Grande do Sul, a comparação geral nas estimativas municipais obteve correlação, com $R^2=0,91$ e RMSD=10.841 toneladas. A produção de soja em comparação com as estimativas do IBGE e CONAB, no nível estadual para o Mato Grosso e Rio Grande do Sul, de 2001 a 2011, é apresentada nas Figuras 4 e 6. Estimativas em nível municipal são apresentadas nas Figuras 5 e 7.

Figura 4 - Comparação da produção estimada pelo modelo acoplado (CM) e dados IBGE e CONAB, nas safras 2001 a 2011 no Estado do Rio Grande do Sul



Fonte: Elaborada pelo autor.

Figura 5 - Comparação entre todas as estimativas municipais da produção obtidas do IBGE e do MPDM, em cada ano-safra, de 2001 a 2011, Rio Grande do Sul

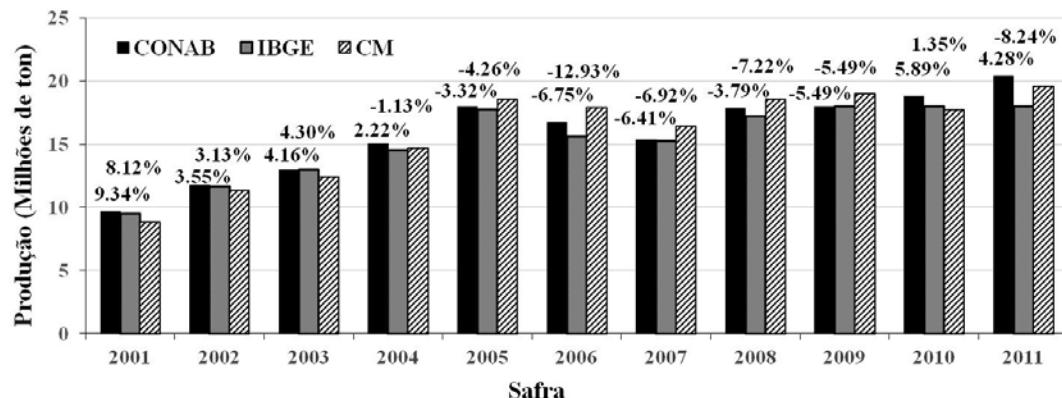


Fonte: Elaborada pelo autor.

A validação do modelo acoplado CM, para o Estado do Mato Grosso obteve estimativas de $R^2=0,96$ e $RMSD=47.878$ toneladas. Testes de validação adicionais foram realizados utilizando dados de campo por meio de 211 áreas de lavoura de soja visitadas no Mato Grosso (variando entre 45 e 225 hectares), na safra 2006 em


que se obteve $R^2=0,88$ e $\text{RMSD}=104$ toneladas. A Figura 8 apresenta a validação com dados de campo no Mato Grosso.

Figura 6 - Comparação da produção estimada pelo modelo acoplado (CM) e dados IBGE e CONAB, nas safras 2001 a 2011 no Estado do Mato Grosso



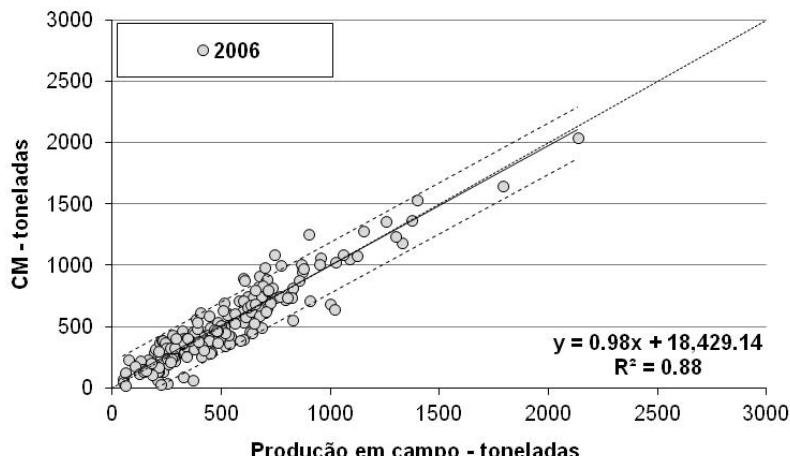
Fonte: Elaborada pelo autor.

Figura 7 - Comparação entre todas as estimativas municipais da produção obtidas do IBGE e do MPDM, em cada ano-safra, de 2001 a 2011, Mato Grosso



Fonte: Elaborada pelo autor.

Figura 8 - Comparação entre a produção estimada pelo modelo acoplado e observada em 211 áreas de soja referente aos talhões visitados, em 2006, no Mato Grosso



Fonte: Elaborada pelo autor.

3.2 Segunda Parte: estudo da distribuição da LST e EVI em região de alta densidade agrícola

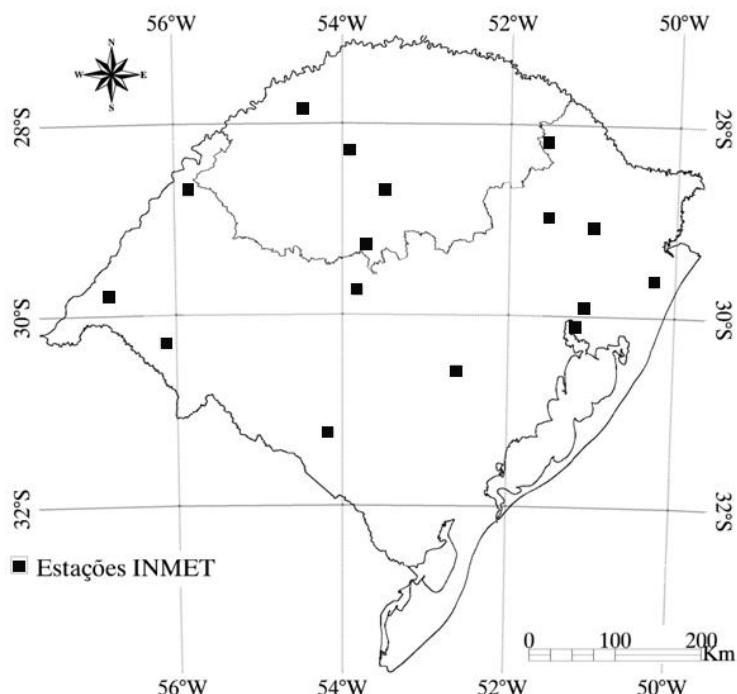
Nesta etapa, como continuidade do trabalho apresentado no Apêndice B, em que foi estudada uma área de intensa produção da soja, no norte do Estado Rio Grande do Sul, buscou-se testar simultaneamente a relação da LST e EVI com a produtividade da soja, conforme proposto nas *Hipóteses 1 e 2*. Pois a associação direta entre EVI e produtividade foi observada no Item 3.1. Dessa maneira, os dados de temperatura da superfície terrestre LST, representativos do dossel da vegetação (LST-dossel) e índice de vegetação EVI do mês de fevereiro, foram combinados e analisados em nível de pixel, com resolução espacial de 1000 metros, em gráficos de dispersão cobrindo somente a área de intensa produção da soja. Nesta etapa da pesquisa foram utilizados os seguintes dados:

- a) dados do índice de vegetação, produtos MOD13Q1-V005, coleção 5, obtidos a partir dos dados do sensor MODIS satélite Terra, em composições de 16 dias e com passagem em horário anterior ao meio-dia local (Tiles H13V11 e H13V12);
- b) dados de LST, produtos MYD11A2-V005, coleção 5, obtidos a partir dos dados do sensor MODIS a bordo do satélite Aqua, por fazer a passagem

próximo ao horário de máxima temperatura, no início da tarde em composições de 8 dias (Tiles H13V11 e H13V12);

- c) base de dados vetorial municipal do IBGE;
- d) precipitação acumulada dos meses de outubro a fevereiro, das safras de 2003 a 2012 obtidos da Fundação de Amparo a Pesquisa Agropecuária do Rio Grande do Sul (FEPAGRO/INMET). A Figura 9 mostra a área de intensa produção de soja no Rio Grande do Sul.

Figura 9 - Área de estudo no Rio Grande do Sul mostrando a região de intensa produção da soja na análise inicial e a distribuição das 16 estações meteorológicas



Fonte: Elaborada pelo autor.

É importante notar que os dados LST foram agrupados em composição de 32 dias cobrindo o período do mês de fevereiro, a partir do dia juliano DOY 033 (entre 2 de fevereiro e 5 de março), tipicamente associado ao período da floração no Rio Grande do Sul. Estes foram obtidos do produto MYD11A2, que corresponde à composição de médias de oito dias, conforme distribuído pela NASA. Os dados de índice de vegetação EVI, também agrupados em composições de 32 dias, foram obtidos pela combinação de duas composições de 16 dias.

Foram usados mapas interpolados de precipitação acumulada de outubro a fevereiro de cada safra, para comparação com a distribuição da nuvem de pontos, entre 2003 e 2012, obtidos do INMET.

A geração de dados espaciais interpolados foi obtida por meio da aplicação do método de *kriging* (esférica/ordinária) que é baseada na tendência de variabilidade do valor das amostras e da distância entre elas (JIAN-GUO; MASON, 2009). A metodologia *kriging* destaca-se em especial por ser um método efetivo quando os dados a serem interpolados são esparsos, aplicando-se perfeitamente à situação encontrada no presente trabalho, no qual um número reduzido de estações meteorológicas estava disponíveis. Foram gerados mapas interpolados de produtividade e precipitação para análise em relação às imagens de LST e EVI.

Para cada município, foi obtido o centróide ao qual foi atribuído o valor de produtividade do município e, em seguida, geradas as médias regionais. Os dados de precipitação foram obtidos por meio da distribuição suavizada da precipitação obtida do período de outubro a fevereiro de cada safra, entre 2003 e 2012, obtidos do INMET. Os mapas de cada safra foram comparados ao mapa interpolado com 33 estações pluviométricas obtido das Normais Climatológicas. Os dados de produtividade de cada safra foram comparados às médias obtidas do IBGE, de 2003 a 2012.

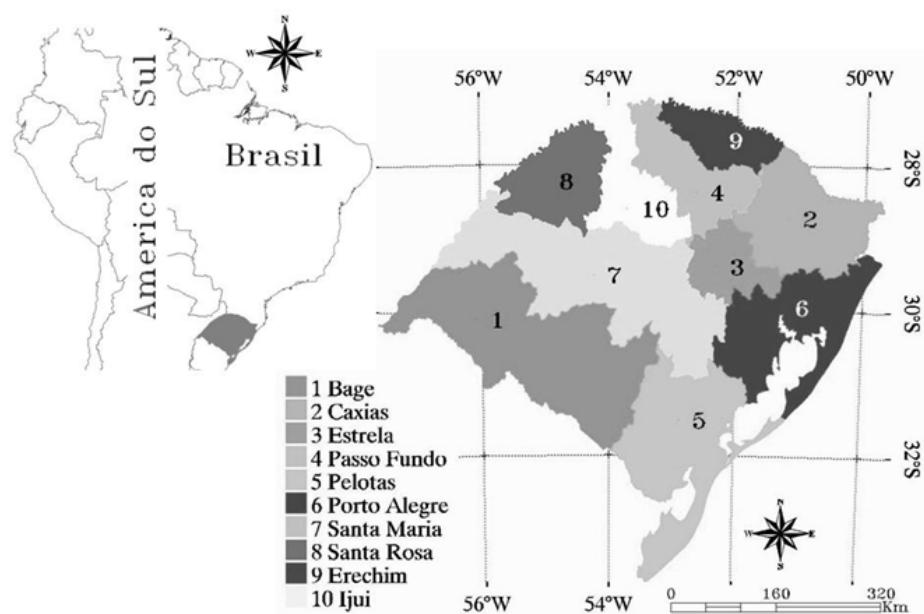
3.3 Terceira Parte: análise regional de distribuição da LST e da produtividade

Nesta etapa, buscou-se testar a *Hipótese 2*, pois uma relação matemática inversa entre LST-dossel e EVI, foi observada para o Estado do Rio Grande do Sul no item 3.2, o que corrobora a *Hipótese 1*. A área estudada inicialmente foi o território do Rio Grande do Sul (RS) com 496 municípios, agrupados em dez regiões definidas pela Empresa de Assistência Técnica e Extensão Rural (EMATER) de maneira a evitar a influência do efeito escala presente na análise pixel-a-pixel. O período analisado foi os meses de outubro a fevereiro das safras de 2003 até 2012.

Dados dos 496 municípios foram agrupados pelas áreas administrativas regionais da EMATER. É importante observar que a análise dos desvios, decorrente dos mapas suavizados, foi realizada somente sobre as áreas mapeadas como cultivo de soja, entre 2003 e 2012. Também é importante notar que os dados LST foram agrupados em composições de 32 dias. Estes foram obtidos do produto

MYD11A2, que corresponde à composição de médias de oito dias, conforme distribuído pela NASA. Os dados de índice de vegetação EVI também foram agrupados em composições de 32 dias, pela combinação de duas composições de 16 dias. A Figura 10 mostra a área de estudo. A avaliação da produtividade em relação à precipitação e a LST-dossel ficou restrita a áreas de cultivo da soja, reduzindo ao máximo o efeito de suavização do EVI por outros tipos de cobertura que não da vegetação da soja.

Figura 10 - Área de estudo, Estado do Rio Grande do Sul e regionais EMATER



Fonte: Elaborada pelo autor.

No período entre as safras de 2003 e 2012 houve três ocorrências de estiagens nas safras de verão de 2004, 2005 e 2012, que afetaram a produtividade em diferentes níveis de intensidade. Nesse sentido, vários níveis de informação aliados aos dados de satélite foram aplicados de maneira a configurar adequadamente a distribuição espacial das grandezas evolvidas, conforme segue:

- a) dados do índice de vegetação EVI obtidos do sensor MODIS a bordo do satélite Terra, o produto MOD13Q1-coleção 5, foram utilizados na seleção das áreas agrícolas e posterior análise da temperatura sobre o dossel da vegetação (LST-dossel). Neste estudo, os dados EVI em 250 metros também são utilizados como dados de entrada para o algoritmo de

estimativa de área de soja MODIS Crop Detection Algorithm (MCDA) na seleção dos pixels representativos sobre áreas de cultivo agrícola com soja. Na coleção 5, o EVI é obtido por uma composição de máximo valor Maximum Value Composite (MVC) associada aos menores ângulos de visada do imageamento (DIDAN; HUETE, 2006). O EVI é representativo do vigor da vegetação, por estar fundamentado na reflectância característica do dossel da vegetação, e foi desenvolvido de maneira a minimizar os efeitos de contaminação da reflectância residual do solo e da influência atmosférica em observações feitas por satélites (HUETE et al., 2002; JUSTICE et al., 2002). Este produto está inserido no produto MOD13Q1-V005 que é estruturado como uma combinação das melhores medidas radiométricas e geométricas dos pixels que formam a imagem na composição de 16 dias. A equação que calcula o valor de EVI é dado por: $2.5 * (\text{Nir} - \text{Red}) / (\text{Nir} + 6 \text{ Red} - 7.5 \text{ Blue} + 1)$, onde Nir, Red, e Blue são as reflectâncias superficiais corrigidas atmosfericamente das bandas de detecção posicionadas sobre as faixas do infravermelho próximo, do vermelho e do azul respectivamente (HUETE et al., 2002);

- b) dados de temperatura da superfície terrestre Land Surface Temperature (LST) produto MYD11A2, coleção-5 do sensor Moderate-Resolution Imaging Spectroradiometer (MODIS) a bordo do satélite Aqua do mês de fevereiro, tipicamente associado ao período da floração no Rio Grande do Sul (PINTO; FONTANA, 2011), foram utilizados para a obtenção das médias e derivação dos desvios da temperatura sobre o dossel nas safras de 2003 a 2012. Os dados de LST do satélite Aqua foram escolhidos por serem coletados durante a passagem da tarde, momento do dia em que são registradas as maiores temperaturas;
- c) Normal Climatológica, utilizada na parametrização do modelo para localizar espacialmente as áreas com maior disponibilidade hídrica no período das safras de verão e seus desvios;
- d) dados de precipitação ocorrida no RS, obtidos do Instituto Nacional de Meteorologia (INMET) para a análise dos desvios em relação à Normal Climatológica;

- e) dados estatísticos oficiais e históricos de área ocupada, obtidos do IBGE, foram utilizados para comparação com a variabilidade na produtividade da soja;
- f) dados estatísticos oficiais e históricos da produção de soja e área municipal, do IBGE, para geração dos dados de produtividade municipal.

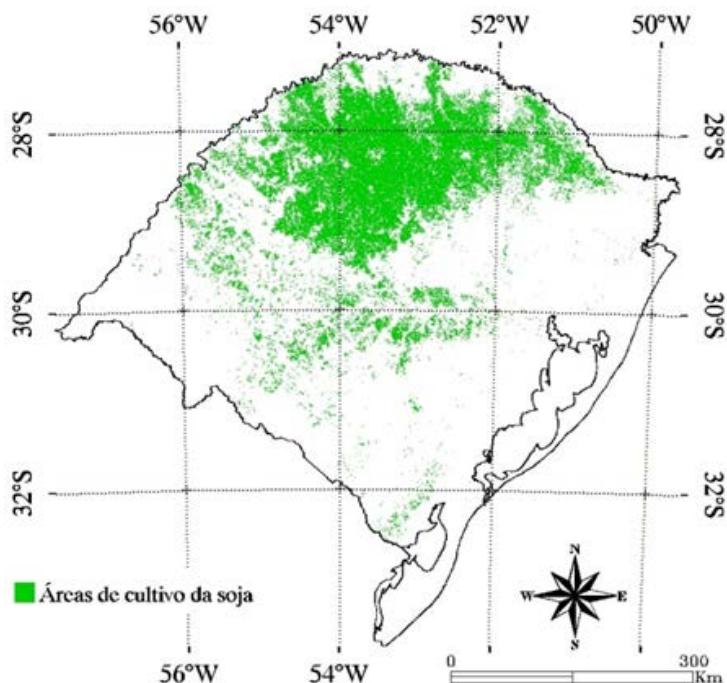
Os produtos MODIS são extraídos pelo aplicativo MODIS Reprojection Tool (MRT) que permite aos usuários ler e converter arquivos de dados no formato distribuído pela NASA (HDF-EOS) e especificar um recorte geográfico e o conjuntos de dados/produtos específicos. Este aplicativo também permite executar a transformação para um diferente sistema de coordenadas e projeção cartográfica (NASA, 2011). Os produtos EVI e LST são distribuídos em formato de 16 bits e é necessário convertê-los para os valores de índice de vegetação e temperatura. Para a obtenção da área de cobertura do Estado do Rio grande do Sul o MRT realiza um processo de mosaicagem de dois recortes de imagens (Tiles H13V11 e H13V12) com base em um geóide de Datum WGS84. Após o processamento dos dados de imagens pelo MRT o EVI deve ser escalonado para valores entre -1 e 1. Os dados LST são inicialmente escalonados para uma distribuição em valores de temperatura em Kelvin. Após estes procedimentos iniciais, todas as imagens foram reprojetadas segundo a Projeção Cônica de Albers para Cálculo de Áreas Iguais, pois existe a necessidade de uma maior precisão espacial ao serem aplicadas metodologias auxiliares de estimativa de área da soja em ambos os produtos.

Assim, os dados da LST são representativos das médias máximas das temperaturas ocorridas no período de 32 dias a partir do dia juliano 033 do produto MYD11A2 (de 2 de fevereiro até 6 de março) tipicamente associado ao período da floração, em acordo com o calendário agrícola médio da cultura da soja no Rio Grande do Sul (PINTO; FONTANA, 2011).

A delimitação adequada da área agrícola é necessária, pois buscamos analisar principalmente o comportamento da LST representativa da temperatura sobre o dossel da vegetação agrícola de soja. Desta maneira, o levantamento da área da cultura da soja foi obtido pela aplicação do MODIS Crop Detection Algorithm (MCDA), desenvolvido por Gusso et al. (2012), e calculado para cada ano-safra. A geração do mapa de cultivo da soja para as dez diferentes safras foi realizado considerando uma composição que é um resultado da combinação de cada um dos

mapas de área estimada das safras entre 2003 e 2012. O mapa obtido com esta composição média inclui todos os pixels selecionados como soja em que sua identificação como área de soja ocorre pelo menos duas vezes, nas dez safras conforme mostra a Figura 11. Assim, os dados derivados das Normais Climatológicas de precipitação normal, precipitação ocorrida, LST e produtividade da soja também são representativos de áreas onde houve cultivo da soja pelo menos duas vezes no período estudado. Tal procedimento resultou em um mapa com 5,37 milhões de hectares, o que corresponde a uma área 37,7% maior que a área média de soja ocupada pela cultura no período entre 2003 a 2012, com aproximadamente 3,9 milhões de hectares (CONAB, 2012).

Figura 11 - Mapa de área de soja obtido com aplicação do MCDA compondo as safras 2003 a 2012



Fonte: Elaborada pelo autor.

4 RESULTADOS

Os resultados obtidos na presente Tese são apresentados em forma de artigos anexados nos apêndices A, B, C, D, E, F, G e H por ordem de aplicação.

Conforme pode ser verificado, os resultados de Gusso et al. (2014a), conforme Apêndice E, e Gusso et al. (2014b), conforme Apêndice G, obtidos no Rio Grande do Sul, sugerem que a disponibilidade hídrica é condição necessária e desempenha papel fundamental, mas não suficiente para maiores produtividades. Adicionalmente, foi observado a ocorrência de LST-dossel abaixo da média conjugada com precipitação acumulada acima da média, o que favorece maior produtividade, também observado por Ferreira, (2010). Nesse sentido, nota-se que perdas na produtividade podem ser amplificadas quando ocorre a conjugação de altas temperaturas no dossel da vegetação com estiagem, após o inicio do período de florescimento no Estado do Rio Grande do Sul.

No Rio Grande do Sul, essa relação inversa está associada ao sobreaquecimento da vegetação, o que promove um aumento da demanda evaporativa, levando ao estresse hídrico. Os resultados sugerem que a influência de temperaturas elevadas no dossel da vegetação é reduzida quando a disponibilidade hídrica é maior que a média regional. Tal influência é reforçada na análise dos resultados obtidos sobre o Estado do Mato Grosso, onde se observa uma relação direta das variações da LST-dossel associadas com elevação da produtividade (GUSSO et al., 2014d), conforme Apêndice H. No Estado do Mato Grosso, o regime hídrico, em geral, compreende uma disponibilidade hídrica maior que no Rio Grande do Sul.

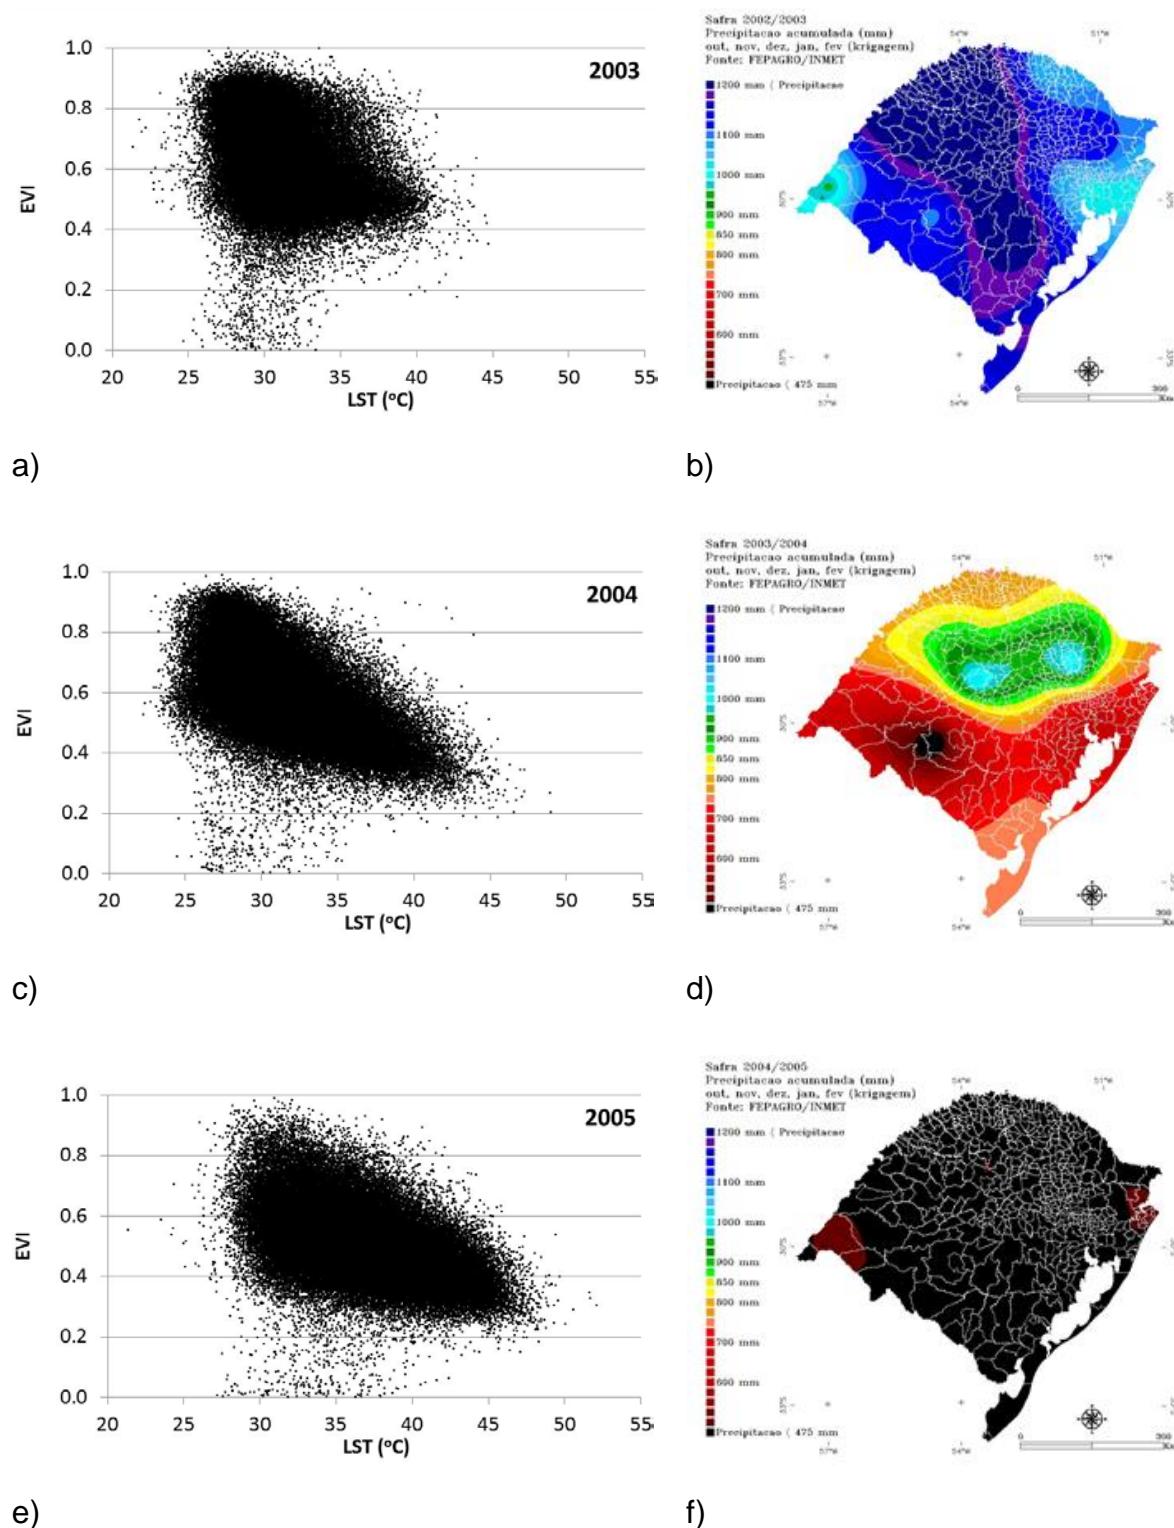
A precipitação acumulada nos principais meses de cultivo, entre outubro e fevereiro no Rio Grande do Sul é 647 mm com desvio padrão 106 mm (INMET, 2009). No Mato Grosso, a precipitação acumulada nos principais meses de cultivo, entre setembro e janeiro é 2491 mm com desvio padrão 414 mm. Nesse sentido, o aumento da demanda evaporativa promovida por sensíveis elevações da temperatura média, não resultam em estresse hídrico, o que favorece a cultura em última análise.

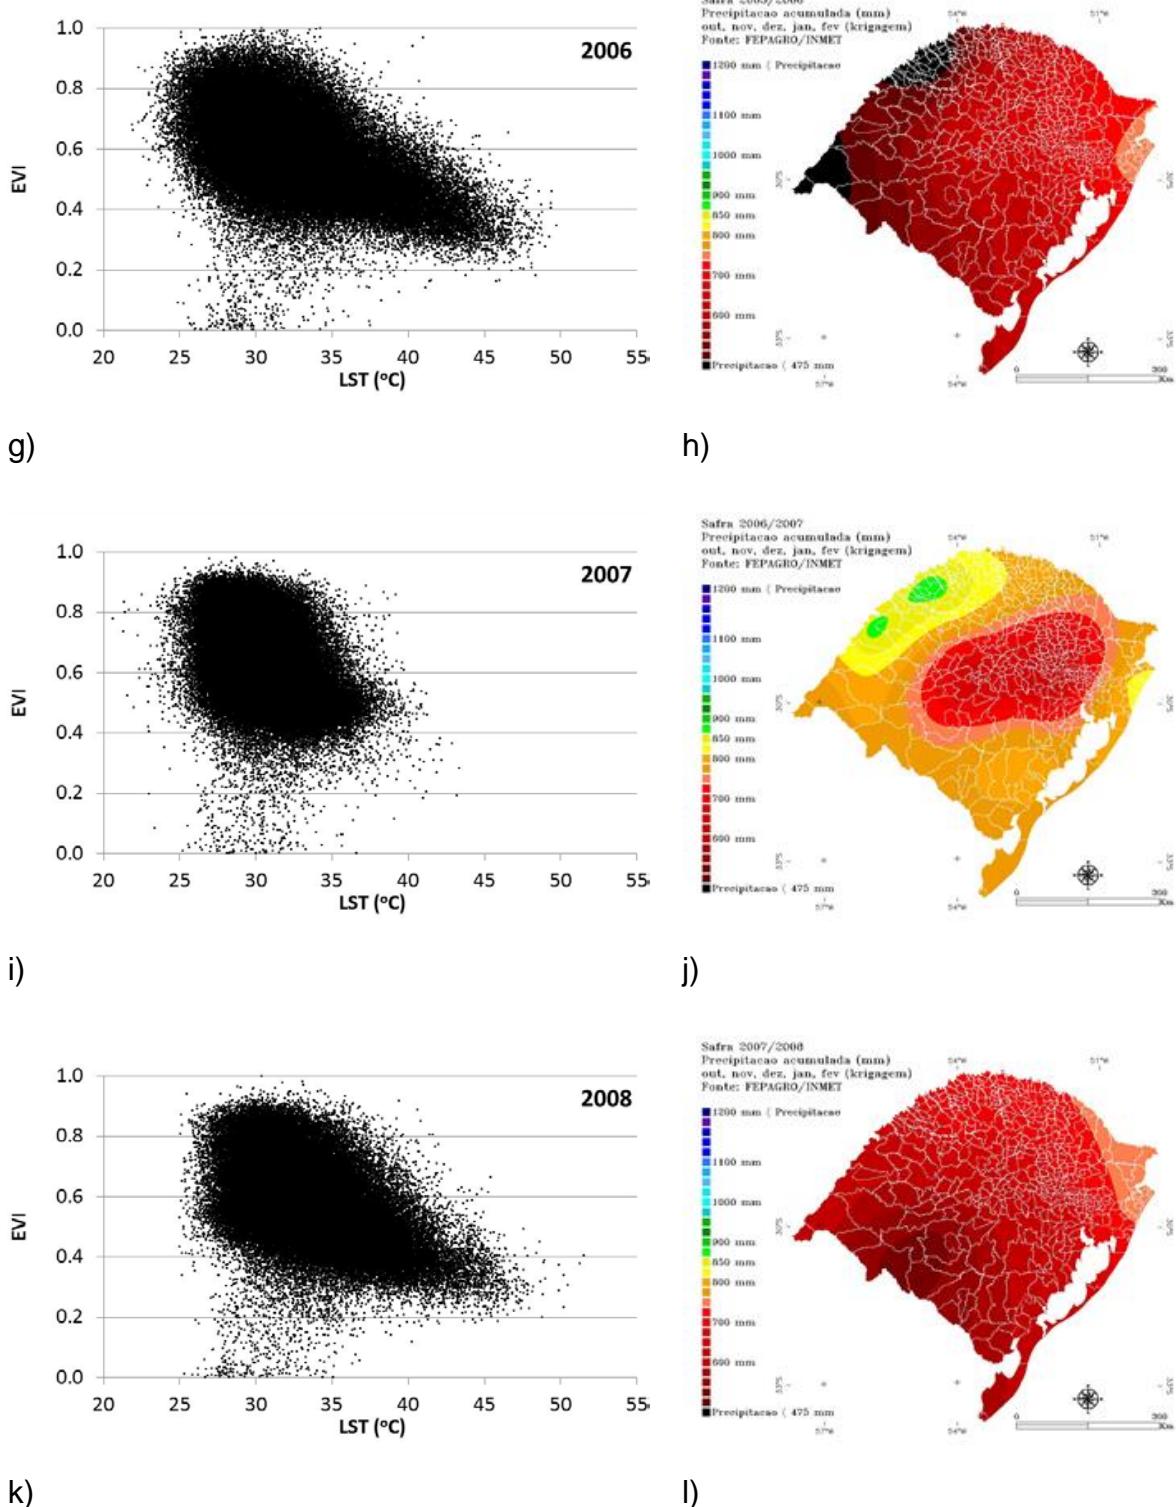
Uma inspeção visual na distribuição do EVI em função da LST demonstra o deslocamento do conjunto de pontos em decorrência das condições agrometeorológicas predominantes. Tal característica foi utilizada na presente


Tese a fim de verificar a influência da LST sobre o dossel nas condições de desenvolvimento da vegetação caracterizada pelo EVI. Conforme Liu e Kogan (2002) salientam, é uma condição física que relaciona o índice de vegetação e a temperatura da superfície terrestre, e que esta relação impõe que as mais altas LST, obtidas no período de máximo desenvolvimento, estão associadas às condições mais desfavoráveis de crescimento da vegetação. De maneira simétrica, os maiores valores do índice de vegetação, representativo do maior vigor vegetativo, devem estar associados com as LST mais baixas, indicando as melhores condições de crescimento da vegetação. Complementarmente, em períodos secos, um suprimento insuficiente de água no interior da planta leva ao sobre-aquecimento da vegetação, o que teoricamente intensifica impacto da deficiência hídrica (LIU; KOGAN, 2002), pela elevação da temperatura ou hot extreme (ALLEN et al., 2010).

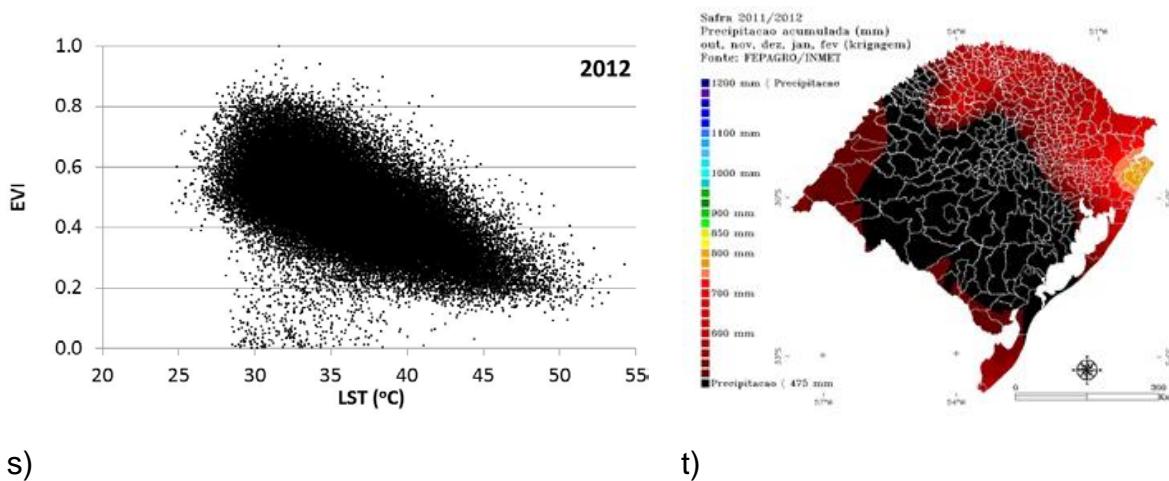
Os mapas de precipitação acumulada no período de desenvolvimento da safra de verão da Figura 12 evidenciam as diferentes condições hídricas entre as safras analisadas em caráter experimental. A precipitação acumulada no período de outubro de 2002 a fevereiro de 2003 se caracterizou por um total acima da média na região, enquanto que as temperaturas ficaram em torno da média (Figuras 12a e 12b). Da mesma forma, o período de outubro de 2009 a fevereiro de 2010 (Figuras 12o e 12p). Em contraste, dois períodos específicos ficam bem evidentes quanto à disponibilidade hídrica. A precipitação acumulada na safra 2005 ficou abaixo da média (Figuras 12e e 12f) como também em 2012 (Figuras 12s e 12t).

Figura 12 - Comparação entre diagramas de dispersão dos valores de LST e EVI, no mês de fevereiro dentro da área de intensa produção da soja (a, c, e, g, i, k, m, o, q, s) com a distribuição da precipitação acumulada entre outubro de fevereiro (b, e, f, h, j, l, n, p, r, t) nas safras de 2003 a 2012.









Fonte: Elaborada pelo autor.

Nos conjunto de gráficos da Figura 12 os valores mais baixos de EVI, tipicamente entre zero e 0,2, representam corpos d'água, solo úmido ou sem cobertura vegetal, grandes áreas urbanas ou mesmo contaminação residual de nuvens. Portanto, foram considerados sem relevância neste experimento.

Ainda com relação ao conjunto de gráficos da Figura 12, analisando os gráficos de dispersão 12c e 12e, em relação ao gráfico da Figura 12a, é possível observar que há uma migração intensa de pontos para a direita, entre 22 $^{\circ}$ C e 42 $^{\circ}$ C, ocasionando um maior Desvio Padrão da LST, configurando um *spread*, caracterizando assim uma forma triangular na distribuição, também observada nos trabalhos de Gilles et al. (1997) e Goward, Xue e Czajkowski (2002). Na Figura 12e, e também na Figura 12s, o efeito *spread* se intensifica, e ocorre um deslocamento generalizado dos pontos com reagrupamento em direção as maiores LST, na borda da distribuição de pontos referente à configuração de um ressecamento lento da vegetação (*dry-edge*), analisado por Sandholt, Rasmussen e Andersen (2002), que é devido às condições do estresse hídrico associado às LST prolongadas, como prevê a relação física estabelecida pela teoria. Entretanto, na safra 2005 (Figura 12e e 12f), na região de baixas temperaturas da Figura 12e, se observa a configuração de um grupo de pontos assumindo a configuração de queda no índice de vegetação, mas sem promover deslocamento dos pontos para maiores temperaturas (*wet-edge*). Este efeito é caracterizado por um sobre-aquecimento da superfície vegetada, antes da forçante imposta pela deficiência hídrica, o que sugere que para algumas parcelas da área estudada, houve uma redução do índice de vegetação.

Tal efeito, quando em condições satisfatórias de disponibilidade hídrica, pode estar relacionado à radiação incidente sobre o dossel da vegetação, pois esta afeta a resistência dos estômatos à evapotranspiração, o que também influencia as parcelas do calor sensível e latente (SANDHOLT; RASMUNSEN; ANDERSEN, 2002). Este resultado sugere a necessidade de um estudo mais aprofundado na associação das áreas agrícolas com o comportamento térmico da superfície, pois a confirmação desse processo exige um acompanhamento das variáveis LST e EVI no decorrer da safra. Assim, o acompanhamento do fluxo de migração dos pontos pelos modos *dry-edge* ou *wet-edge* podem dar pistas importantes sobre o processo envolvido na caracterização das condições de desenvolvimento dos cultivos. Consideram-se relevantes pequenas variações nos valores médios da LST e do EVI, visto que são representativos de um número superior a 76.000 pixels, em cada uma das safras estudadas. O Teste-t heterocedástico não indicou probabilidade de semelhança entre os conjuntos de dados do EVI ou LST, na comparação das safras de desenvolvimento mais favorável (2003 e 2010) com as consideradas de desenvolvimento mais desfavorável (2005 e 2012).

É importante notar que na comparação do conjunto de dados apresentados nos gráficos de dispersão da Figura 11, com dados tabelados das médias estaduais, a quantidade de precipitação acumulada é condição necessária, mas não suficiente para explicar as maiores produtividades médias estaduais. Na Tabela 1, os períodos de ocorrência de maior precipitação média acumulada (2003, 2004, 2009 e 2010), não correspondem necessariamente às safras de maior produtividade. Entretanto, as safras com as maiores produtividades (2003, 2007, 2010 e 2011) são favorecidas por baixas LST-dossel ocorridas no período, indicando que a precipitação total acumulada é condição necessária, mas não suficiente para maiores produtividades no Rio Grande do Sul. A Tabela 1 apresenta as médias regionais de LST-dossel e produtividade da soja por safra.

Tabela 1 - Médias estaduais e desvio padrão da LST-dossel, produtividade da soja e precipitação, obtidas pela interpolação espacial dos dados, no período entre 2003 e 2012 na área de intensa produção da soja

Médias estaduais								
Ano/Safra	Produtividade (Kg ha ⁻¹)	Desvio Padrão	LST-dossel, DOY033 (°C)	Desvio padrão	EVI	Desvio Padrão	Precipitação acumulada (mm)	Desvio Padrão
2003	2687	392	30,7	2,5	0,62	0,13	1228	86
2004	1549	295	31,3	3,4	0,59	0,14	840	99
2005	695	125	35,9	3,9	0,51	0,12	463	10
2006	2138	486	32,4	4,1	0,58	0,14	592	68
2007	2543	325	30,3	2,5	0,62	0,14	761	55
2008	2191	245	33,3	3,3	0,57	0,14	650	52
2009	2217	290	30,4	2,9	0,58	0,14	798	84
2010	2620	348	30,8	2,3	0,63	0,13	1194	126
2011	2895	388	28,4	2,8	0,65	0,14	725	110
2012	1601	466	35,4	3,8	0,47	0,12	500	43

Fonte: Elaborada pelo autor.

No Brasil, a evapotranspiração máxima, que é a demanda hídrica da cultura da soja nas melhores condições, está entre 550 e 800 mm (BERLATO; MATZENAUER; BERGAMASCHI, 1986, FARIAS et al., 2001). Conforme os resultados obtidos no Apêndice H, no Estado do Mato Grosso, não foi observada a associação de estresse hídrico, pelo aumento da demanda evaporativa, com anomalias positivas da temperatura. Dessa maneira, os resultados sugerem que a influência de temperaturas elevadas no dossel da vegetação é reduzida quando a disponibilidade hídrica é maior que a média regional. No Rio Grande do Sul, a relação inversa está associada ao sobreaquecimento da vegetação, o que promove um aumento da demanda evaporativa, levando ao estresse hídrico. Tal influência é reforçada na análise dos resultados obtidos sobre o Estado do Mato Grosso, onde se observa uma relação direta das variações da LST-dossel associadas com elevação da produtividade. No Estado do Mato Grosso, o regime hídrico, em geral, compreende uma disponibilidade hídrica maior que no Rio Grande do Sul. Nesse sentido, o aumento da demanda evaporativa promovida por sensíveis elevações da temperatura média, não resultam em estresse hídrico, o que favorece a cultura em última análise.

5 CONCLUSÕES

Os resultados indicam que *Hipótese 1* deve ser aceita pois é possível estabelecer uma relação matemática entre LST-dossel e produtividade. Entretanto, os resultados obtidos no Mato Grosso não corroboram a *Hipótese 2*, pois a relação matemática que descreve as flutuações da LST-dossel em torno da média com a produtividade, é direta no Mato Grosso mas no Rio Grande do Sul é uma relação matemática inversa.

A disponibilidade hídrica é condição necessária e desempenha papel fundamental, mas não suficiente para maiores produtividades. Pois, a ocorrência de LST-dossel abaixo da média, conjugada com precipitação acumulada acima da média, favorece maior produtividade. Adicionalmente, perdas na produtividade são amplificadas quando ocorre a conjugação de altas temperaturas no dossel da vegetação com estiagem, após o inicio do período de florescimento no Estado do Rio Grande do Sul.

Os resultados mostram que a influência de temperaturas elevadas no dossel da vegetação é reduzida quando a disponibilidade hídrica é maior que a média regional. No Rio Grande do Sul, a relação inversa está associada ao sobreaquecimento da vegetação, o que promove um aumento da demanda evaporativa, levando ao estresse hídrico. Tal influência é reforçada na análise dos resultados obtidos sobre o Estado do Mato Grosso, onde se observa uma relação direta das variações da LST-dossel associadas com elevação da produtividade. No Estado do Mato Grosso, o regime hídrico, no período da safra de verão, compreende uma disponibilidade hídrica maior que no Rio Grande do Sul. Nesse sentido, conclui-se que o aumento da demanda evaporativa promovida por elevação da temperatura desempenha papel importante nas condições gerais de desenvolvimento da safra. acima da média, não resultam em estresse hídrico.

REFERÊNCIAS

- ALLEN, C. D. et al. A global overview of drought and heat-induced tree mortality reveals emerging climate change risks for forests. *Forest Ecology and Management*, Amsterdam, NL, v. 259, n. 4, p. 660–684, Feb. 2010.
- ARVOR, D. et al. Classification of MODIS EVI time series for crop mapping in the State of Mato Grosso, Brazil. *International Journal of Remote Sensing*, Basingstoke, GB, v. 29, p. 1-25, 2011.
- ARVOR, D. et al. Spatial patterns of rainfall regimes related to levels of double cropping agriculture systems in Mato Grosso (Brazil). *International Journal of Climatology*, Chichester, GB, v. 34, p. 2622–2633, 2013.
- BATISTTI, D. S.; NAYLOR, R. L. Historical warnings of future food insecurity with unprecedented seasonal heat. *Science*, Washington, DC, v. 323, n. 5911, p. 240-244, Jan. 2009. Disponível em: <10.1126/science.1164363>. Acesso em: 21 mar. 2012.
- BERLATO, M. A.; MATZENAUER, R.; BERGAMASCHI, H. Evapotranspiração máxima da soja, relações com a evapotranspiração calculada pela equação de Penman, evaporação de tanque “classe A” e radiação solar global. *Agronomia Sulriograndense*, Porto Alegre, v. 22, p. 243-259, 1986.
- BOARD, J. E.; KAHLON, C. S. Soybean yield formation: what controls it and how it can be improved. In: EL-SHEMY, H. A. (Ed.). *Soybean physiology and biochemistry*, Rijeka, Croatia: InTech, 2007. p. 1-36.
- BRASIL. Ministério da Agricultura, Pecuária e do Abastecimento (MAPA). Portaria n. 126, de 20 de julho de 2009. Aprova o zoneamento agrícola para a cultura de soja no Estado do Rio Grande do Sul, ano safra 2009/2010. *Diário Oficial [da] República Federativa do Brasil*, Brasília, DF, Seção 1, p. 15, 2010.
- CARMO-SILVA, A. E. et al. Decreased CO₂ availability and inactivation of Rubisco limit photosynthesis in cotton plants under heat and drought stress in the field. *Environmental and Experimental Botany*, Elmsford, NY, v. 83, p. 1-11, 2012.
- COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). *Acompanhamento da safra brasileira de grãos*. Brasília: CONAB/DIPAI/SUINF/GEASA, 2012.
- CRAUFURD, P. Q.; WHEELER, T. R. Climate change and the flowering time of annual crops. *Journal of Experimental Botany*, Oxford, UK, v. 60, n. 9, p. 2529–2539, 2009.

CUNHA, G. R. et al. Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. *Revista Brasileira de Agrometeorologia*, Santa Maria, RS, v. 9, 446-459, 2001.

DIDAN, K.; HUETE, A. *MODIS vegetation index product series: collection 5 change summary*. Tucson, AZ: TBRs Laboratories: The University of Arizona, 2006.

FARIAS, J. R. B. et al. Caracterização de risco de déficit hídrico nas regiões produtoras de soja no Brasil. *Revista Brasileira de Agrometeorologia*, Santa Maria, RS, v. 9, n. 3, p. 415-421, 2001.

FERREIRA, D. B. *Análise da variabilidade climática e suas consequências para a produtividade da soja na região sul do Brasil*. 2010. Tese (Doutorado em Meteorologia) -- Curso de Pós-Graduação em Meteorologia, Instituto Nacional de Pesquisas Espaciais INPE, São José dos Campos, 2010.

FONTANA, D. C. et al. Monitoramento da cultura da soja no centro-sul do Brasil durante La Niña de 1998/2000. *Revista Brasileira de Agrometeorologia*, Santa Maria, RS, v. 10, n. 2, p. 343-351, 2002.

FOOD AND AGRICULTURE ORGANIZATION (FAO). *The state of food insecurity in the world*. Rome, IT: Economic and Social Development Department, 2011. Disponível em: <<http://www.fao.org/docrep/013/i2050e/i2050e07.pdf>>. Acesso em: 29 nov. 2012.

FRIEDL, M. A.; DAVIS, F. W. Sources of variation in radiometric surface temperature over a tallgrass prairie. *Remote Sensing of Environment*, New York, US, v. 48, n. p.1-17, Apr. 1994.

GIBSON, L. R.; MULLEN, R. E. Soybean seed quality reductions by high day and night temperature. *Crop Science*, Madison, WI, v. 36, n. 6, p. 1615-1619, 1996.

GOETZ, S. J. Multi-sensor analysis of NDVI, surface temperature and biophysical variables at a mixed grassland site. *International Journal of Remote Sensing*, Basingstoke, GB, v. 18, n. 1, p. 71-94, 1997.

GOWARD, S. N.; XUE, Y.; CZAJKOWSKI, K. P. Evaluating land surface moisture conditions from the remotely sensed temperature/vegetation index measurements: An exploration with the simplified simple biosphere model. *International Journal of Remote Sensing*, Basingstoke, GB, v. 79, n. 2-3, p. 225-242, Feb. 2002.

GUSSO, A. et al. Assessing the MODIS Crop Detection Algorithm for soybean crop Area mapping and expansion in the Mato Grosso State, Brazil. *The Scientific World Journal*, Philadelphia, USA, p. 1-9, 2014c.

GUSSO, A. et al. Avaliação do impacto de ondas de calor em safras de verão por integração de dados dos satélites Aqua e Terra/MODIS. *Revista Brasileira de Geografia Física*, Recife, PE, v. 6, n. 1, p. 1673-1688, 2014b.

GUSSO, A. et al. Impacts of heat waves over summer crops in Mato Grosso State, Brazil. *International Journal of Climatology*, Chichester, GB, 2014d. Artigo submetido.

GUSSO, A. et al. Monitoring heat waves and their impacts on summer crop development in southern Brazil. *Agricultural Sciences*, Irvine, CA, v. 5, n. 4, p. 353-364, Mar. 2014a.

GUSSO, A. et al. Soybean area estimation and mapping by means MODIS/EVI data. *Pesquisa Agropecuária Brasileira*, Brasília, DF, v. 47, n. 3, p. 425-435, mar. 2012.

GUSSO, A. et al. Spectral model for soybean yield estimate using MODIS/EVI data. *International Journal of Geosciences*, Irvine CA, v. 4, n. 9, p. 1233-1241, Nov. 2013.

GUSSO, A. Integração de imagens NOAA/AVHRR: rede de cooperação para monitoramento nacional da safra da soja. *Revista Ceres*, Vícose, MG, v. 60, n. 2, p. 43-52, mar./abr. 2013.

GUSSO, A.; FONTANA, D. C.; GONÇALVES, G. A. Mapeamento da temperatura da superfície terrestre com uso do sensor AVHRR/NOAA. *Pesquisa Agropecuária Brasileira*, Brasília, DF, v. 42, n. 2, p. 231-237, fev. 2007. Disponível em: <<http://www.scielo.br/pdf/pab/v42n2/12.pdf>>. Acesso em: 31 mar. 2007.

HOPE, A. S. et al. Simulated relationships between spectral reflectance thermal emissions and evapotranspiration of a soybean canopy. *Water Resources Bulletin*, Baton Rouge, LA, v. 22, n. 6, p. 1011–1019, Dec. 1986.

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

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). *SIDRA*: sistema IBGE de recuperação automática. Rio de Janeiro, RJ, 2012. Disponível em: <<http://www.sidra.ibge.gov.br/>>. Acesso em: 12 out. 2012.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). *Normais climatológicas do Brasil de 1961 a 1990*. Brasília, DF, 2009. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>. Acesso em: 30 mar. 2012.

JIAN-GUO, L.; MASON, P. J. *Essential image processing and GIS for remote sensing*. Hoboken, NJ: Wiley-Blackwell, 2009. 460 p.

JUSTICE, C. O. et al. An overview of MODIS Land data processing and product status. *Remote Sensing of Environment*, New York, US, v. 83, n. 1-2, p. 3-15, Nov. 2002.

KHAN, A. Z. et al. Seed quality and vigor of soybean cultivars as influenced by canopy temperature. *Pak. J. Bot., Karachi* v. 43, v. 1, p. 643-648, 2011.

KHAN, M. I. R.; ASGHER, M.; KHAN, N. A. Rising temperature in the changing environment: A serious threat to plants. *Climate Change and Environmental Sustainability*, New Delhi, v. 1, n. 1, p. 25-36, 2013.

KOGAN, F. N. et al. AVHRR-based spectral vegetation index for quantitative assessment of vegetation state and productivity: calibration and validation. *Photogrammetric Engineering & Remote Sensing*, Falls Church, VA, v. 69, p. 899-906, 2003.

KOGAN, F. N. et al. Derivation of pasture biomass in Mongolia from AVHRR-based vegetation health indices. *International Journal of Remote Sensing*, Basingstoke, GB, v. 25, n. 14, p. 2889-2896, 2004.

KOGAN, F. N. Operational space technology for global vegetation assessment. *Bulletin of American Meteorological Society*, Boston, MA, v. 82, N. 9, p. 1949-1964, Sept. 2001.

KOGAN, F. N. World droughts in the millennium from AVHRR-based vegetation health indices. *Eos, Transactions, American Geophysical Union*, Washington, DC, v. 83, n. 48, p. 557-564, Nov. 2002.

KÖPPEN, W. *Climatología: con un estudio de los climas de la tierra*. México: Fondo de Cultura Económica, 1948. 466 p.

LAMBIN, E. F.; EHRLICH, D. Combining vegetation indices and surface temperature for land-cover mapping at broad spatial scales. *International Journal of Remote Sensing*, Basingstoke, GB, v. 16, n. 3, p. 573– 579, 1995.

LIU, W. T; KOGAN, F. Monitoring Brazilian soybean production using NOAA/A VHRR based vegetation indices. *International Journal of Remote Sensing*, Basingstoke, GB, v. 23, n. 6, p. 1161-1180, 2002.

LOBELL, D. B. et al. Prioritizing climate change adaptation needs for food security in 2030. *Science*, Washington, DC, v. 319, n. 5863, p. 607-610, Feb. 2008. Disponível em: <<http://dx.doi.org/10.1126/science.1152339>>. Acesso em: 17 nov. 2012.

LOBELL, D. B.; ASNER, G. P. Climate and management contributions to recent trends in U.S. agricultural yields. *Science*, Washington, DC, v. 229, n. 5609, p. 1032, Feb. 2003.

MACHADO, S.; PAULSEN, G. M. Combined effects of drought and high temperature on water relations of wheat and sorghum. *Plant and Soil*, The Hague, NL, v. 233, n. 2, p. 179–187, June 2001.

MATZENAUER, R. et al. *Consumo de água e disponibilidade hídrica para milho e soja no Rio Grande do Sul* (Water consumption and water availability for corn and soybean in Rio Grande do Sul), Porto Alegre: FEPAGRO, 2002. 105 p.

MEERBURG, B. G. et al. Do nonlinear temperature effects indicate severe damages to US crop yields under climate change? *Proceedings of the National Academy of Sciences*, Washington, DC, v. 106, n. 120, 2009. Disponível em: <<http://dx.doi.org/10.1073/pnas.0910618106>>. Acesso em: 04 jul. 2012.

MORAN, M. S. et al. Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. *Remote Sensing of Environment*, New York, US, v. 49, n. 3, p. 246– 263, Sept. 1994.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA). *Land Processes Distributed Active Archive Center (LPDAAC)*. Sioux Falls, SD, 2011. Disponível em: <https://lpdaac.usgs.gov/data_access/data_pool>. Acesso em: 5 jan. 2014.

NELLEMANN, C. et al. (Ed.). *The environmental food crisis*. The environment's role in averting future food crises. Arendal: United Nations Environment Programme. Environmental Food Crisis (UNEP), Feb. 2009. Disponível em: <http://www.unep.org/pdf/foodcrisis_lores.pdf>. Acesso em: 1 mar. 2010.

NEMANI, R. et al. Developing satellite-derived estimates of surface moisture status. *Journal of Applied Meteorology*, Washington, DC, v. 32, n. 3, p. 548–557, 1993. Disponível em: <[http://dx.doi.org/10.1175/1520-0450\(1993\)032<0548:DSDEOS2.0.CO;2](http://dx.doi.org/10.1175/1520-0450(1993)032<0548:DSDEOS2.0.CO;2)>. Acesso em: 22 nov. 2011.

NEMANI, R.; RUNNING, S. Land cover characterization using multitemporal red, near-ir, and thermal-ir data from NOAA/AVHRR. *Ecological Applications*, Tempe, US, v. 7, n. 1, p. 79–90, Feb. 1997.

NICÁCIO, R. M. *Evapotranspiração real e umidade do solo usando dados de sensores orbitais e a metodologia SEBAL na Bacia do Rio São Francisco*. 2008. 320 f. Tese (Doutorado em Ciências em Engenharia Civil) -- Universidade Federal do Rio de Janeiro-UFRJ, 2008.

OUAIDRARI, H. et al. Land surface temperature estimation from AVHRR thermal infrared measurements: an assessment for the AVHRR Land Pathfinder II data set. *Remote Sensing of Environment*, New York, US, v. 81, n. 1, p. 114-128, July 2002.

PETERSON, T. C.; STOTT, P. A.; HERRING, S. Explaining extreme events of 2011 from a climate perspective. *American Meteorological Society*, Boston, US, v. 93, n. 7, p. 1041-1067, July, 2012. Disponível em: <<http://dx.DOI:10.1175/BAMS-D-11-00021.1>>. Acesso em: 5 jan. 2013.

PINTO, D. G.; FONTANA, D. C. Inferências sobre o calendário agrícola da soja a partir de perfis temporais de NDVI em imagens MODIS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, 15., Curitiba, PR, 2011. *Anais ... São José dos Campos: INPE*, 2011. Disponível em: <<http://www.dsr.inpe.br/sbsr2011/files/p0455.pdf>>. Acesso em: 27 abr. 2013.

RODRIGUES, O. et al. Resposta quantitativa do florescimento da soja à temperatura e ao fotoperíodo. *Pesquisa Agropecuária Brasileira*, Brasília, DF, v. 36, n. 3, p. 431-437, mar. 2001.

SALVUCCI, M. Association of rubisco activase with chaperonin-60b: a possible mechanism for protecting photosynthesis during heat stress. *Journal of Experimental Botany*, Oxford, GB, v.59, n. 7, p. 1923-1933, 2008.

SALVUCCI, M.; CRAFTS-BRANDNER, S. J. Relationship between the heat tolerance of photosynthesis and the thermal stability of rubisco activase in plants from contrasting thermal environments. *Plant Physiology*, Glasgow UK, v. 134, n. 4, p. 1460–1470, Apr. 2004.

SANDHOLT, I.; RASMUNSEN, K.; ANDERSEN, J. A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment*, New York, US, v. 79, n. 2-3, p. 213-224, Feb. 2002.

SCHLENKER, W.; ROBERTS, M. Nonlinear temperature effects indicate severe damages to U.S. crop yields under climate change. *Proceedings of the National Academy of Sciences*, Washington, DC, v. 106, p. 15594-15598, 2009.

SEDIYAMA, T. (Org.). *Tecnologias de produção e usos da soja*. 1. ed. Londrina, PR: Mecenas, 2009. v. 1, 314 p.

SHIMABUKURU, Y. E.; MAEDA, E. E.; FORMAGGIO, A. R. Sensoriamento remoto e sistemas de informações geográficas aplicados ao estudo dos recursos agronômicos e florestais. *Revista Ceres*, Vícose, MG, v. 56, n. 4, p. 399-409, jul./ago. 2009.

SIMS, D. A. et al. A new model of gross primary productivity for North American ecosystems based solely on the enhanced vegetation index and land surface temperature from MODIS. *Remote Sensing of Environment*, New York, US, v. 112, n. 15, p. 1633-1646, Apr. 2008. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2007.08.004>>. Acesso em: 10 maio 2011.

SINCLAIR, T. R.; SELIGMAN, N. Criteria for publishing papers on crop modeling. *Field Crops Research*, Amsterdam, NL, v. 68, n. 3, p. 165-172, Nov. 2000.

SIQUEIRA, O. J. W. et al. Mudanças climáticas projetadas através dos modelos GISS e reflexos na produção agrícola brasileira. *Revista Brasileira de Agrometeorologia*, Santa Maria, RS, v. 8, n. 2, p. 311-320, 2000.

WHEELER, T. R. et al. Temperature variability and the yield of annual crops. *Agriculture, Ecosystems and Environment*, Amsterdam, v. 82, n. 1-3, p. 159–167, Dec. 2000.

APÊNDICE A - Artigo publicado (Gusso e Ducati, 2012). Compõe a metodologia de estimativa de área da cultura da soja no Rio Grande do Sul. Título: **Algorithm for Soybean Classification Using Medium Resolution Satellite Images.**

APÊNDICE B - Artigo publicado (Gusso, 2013). Compõe uma abordagem inicial para a fundamentação física entre LST-dossel e produtividade da soja. Título: **Integração de Imagens NOAA/AVHRR: rede de Cooperação para Monitoramento Nacional Da Safra de Soja.**

APÊNDICE C - Artigo publicado (Gusso et al., 2012). Compõe a metodologia de estimativas de área no Rio Grande do Sul. Título: **Soybean Crop Area Estimation by MODIS/EVI Data.**

APÊNDICE D - Artigo publicado (Gusso et al., 2013). Compõe a metodologia CM para produtividade da soja no Rio Grande do Sul. Título: **Spectral Model for Soybean Yield Estimate Using MODIS/EVI Data.**

APÊNDICE E - Artigo publicado (Gusso et al., 2014a). Compõe o estudo da sazonalidade da LST-dossel no Rio Grande do Sul. Título: **Monitoring Heat Waves and Their Impacts on Summer Crop Development in Southern Brazil.**

APENDICE F - Artigo publicado (Gusso et al., 2014b). Compõe a metodologia de análise da LST-dossel e impactos na produtividade da soja no Rio Grande do Sul.

Título: **Avaliação do Impacto de Ondas de Calor em Safras de Verão por Integração de Dados dos Satélites Aqua e Terra/MODIS.**

APÊNDICE G - Artigo publicado (Gusso et al., 2014c). Compõe a metodologia de estimativa da área da soja no Mato Grosso. Título: **Assessing the MODIS Crop Detection Algorithm for Soybean Crop Area Mapping and Expansion in the Mato Grosso State, Brazil.**

APENDICE H - Artigo submetido (Gusso et al., 2014d). Analisa a relação da LST-dossel e impactos na produtividade da soja no Estado do Mato Grosso e demonstra a necessidade de ajuste da *Hipótese 1*. Título: **Impacts of Heat Waves Over Summer Crops in Mato Grosso State, Brazil.**

Algorithm for Soybean Classification Using Medium Resolution Satellite Images

Anibal Gusso ^{1,2,*} and Jorge Ricardo Ducati ^{1,3}

¹ Center for Remote Sensing and Meteorological Research, Federal University of Rio Grande do Sul, Porto Alegre-RS, CP15044, Brazil

² Environmental Engineering, University of Vale do Rio dos Sinos (UNISINOS), São Leopoldo-RS, CP275, Brazil

³ Astronomy Department, Federal University of Rio Grande do Sul, Porto Alegre-RS, CP15044, Brazil; E-Mail: ducati@if.ufrgs.br

* Author to whom correspondence should be addressed; E-Mail: anibal.gusso@ufrgs.br; Tel.: +55-51-3308-6432; Fax: +55-51-3308-6657.

Received: 18 August 2012; in revised form: 27 September 2012 / Accepted: 29 September 2012 /

Published: 18 October 2012

Abstract: An accurate estimation of soybean crop areas while the plants are still in the field is highly necessary for reliable calculation of real crop parameters as to yield, production and other data important to decision-making policies related to government planning. An algorithm for soybean classification over the Rio Grande do Sul State, Brazil, was developed as an objective, automated tool. It is based on reflectance from medium spatial resolution images. The classification method was called the RCDA (Reflectance-based Crop Detection Algorithm), which operates through a mathematical combination of multi-temporal optical reflectance data obtained from Landsat-5 TM images. A set of 39 municipalities was analyzed for eight crop years between 1996/1997 and 2009/2010. RCDA estimates were compared to the official estimates of the Brazilian Institute of Geography and Statistics (IBGE) for soybean area at a municipal level. Coefficients R^2 were between 0.81 and 0.98, indicating good agreement of the estimates. The RCDA was also compared to a soybean crop map derived from Landsat images for the 2000/2001 crop year, the overall map accuracy was 91.91% and the Kappa Index of Agreement was 0.76. Due to the calculation chain and pre-defined parameters, RCDA is a timesaving procedure and is less subjected to analyst skills for image interpretation. Thus, the RCDA was considered advantageous to provide thematic soybean maps at local and regional scales.

Keywords: remote sensing; classification; crop area; reflectance

Abbreviations

CONAB	Companhia Nacional de Abastecimento
IBGE	Instituto Brasileiro de Geografia e Estatística
TM	Thematic Mapper
MCDA	MODIS Crop Detection Algorithm
INPE	Instituto Nacional de Pesquisas Espaciais
SRTM	Shuttle Radar Topography Mission
GLS	Global Land Survey
DN	Digital Number
NIR	Near Infrared
RCDA	Reflectance-based Crop Detection Algorithm
NDVI	Normalized Difference Vegetation Index
LAI	Leaf Area Index
IR	Infrared
PDC	Physically Driven Components
UFRGS	Universidade Federal do Rio Grande do Sul

1. Introduction

Statistical data in agriculture plays a key role in the food supply chain and improvements in methods of precise and timely estimates for crop areas and yield are extremely important for management, trade and pricing policies. The Brazilian agencies CONAB (Companhia Nacional de Abastecimento—National Company of Food Supply) and IBGE (Instituto Brasileiro de Geografia e Estatística—Brazilian Institute of Geography and Statistics) are both responsible for the official agricultural statistics in Brazil. Presently, these estimates are based heavily on polls made on a farmer level, being considered subjective and without associated error measurement [1].

Remote sensing satellite data have been successfully used on mappings of crops in Brazil such as soybean [2,3] and sugarcane [4]. Most of the research related to crop area estimation is associated with classification of Landsat Thematic Mapper (TM) images of medium spatial resolution [3]. In Brazil, important know-how of large scale agricultural monitoring was gained from the projects GeoSafras (soybean, maize and rice fields mapping) and Canasat (sugarcane mapping) [5,6]. The main difficulties were clearly associated with the handling of a large volume of data and a timely generation of the desired products. Another two difficulties were the pressure for results and systematic cloud cover occurrences. The former leads to the need of a large staff team and the latter can limit the Landsat-like images operability in providing agricultural statistics [7,8]. Focused on the crop area problem in Brazil, several studies [1,9,10] have been conducted using different conceptual approaches with high temporal-resolution data with coarser spatial-resolution. However, these methodologies did not prove to be useful to routine monitoring, and were generally applied for relatively few crop years and


specific regions. Other developments as made with the MODIS Crop Detection Algorithm (MCDA) [11], produced R^2 greater than 0.95 and overall accuracy of 82% for several crop years in Rio Grande do Sul State, but they also found limitations on mapping accuracy dependence with mean field size, according to [12], since they used 250 m spatial-resolution.

Literature reviewing has shown that automated moderate spatial resolution models are able to generate timely classification results, and that medium spatial resolution can generate good mapping accuracy. This work is going a step further, combining both methods to obtain timely classification results with good mapping accuracy. The objective in this work is to evaluate a reflectance-based algorithm using medium resolution sensor images, to the accurate classification of soybean areas prior to the time of crop harvest.

2. Material and Methods

In recent years, the average contribution of Rio Grande do Sul State accounted for about 17% of the national grain production. It is the third soybean producer in Brazil [13] and both yield and crop area is still rising. The State has a total area of 282,062 km² with 496 municipalities. Its soybean production is concentrated in the center-north region. The average annual rainfall is 1,500 mm, being relatively well distributed throughout the year, but subjected to dry periods. The State climate is subtropical with four well-defined seasons. The 39 municipalities analyzed are totally covered by a Landsat scene path/row 222-080. All municipalities are aggregated inside an intensive soybean production area, which is shown at Figure 1.

Figure 1. Rio Grande do Sul State, Brazil, and the 39 municipalities evaluated.



2.1. Study Area

The covered crop area represents nearly 18% of total area of soybean crops in Rio Grande do Sul. The sowing calendar for soybean goes from early October to late December, based on agricultural

zoning for different soils, regions, and cultivars [14]; depending on sowing date, maximum plant growth is thus observed from late January to early March [11].

2.2. Satellite Data

The data sources used for the algorithm development were the following: (i) Landsat-5 TM images, obtained from Instituto Nacional de Pesquisas Espaciais (INPE: www.dgi.inpe.br); (ii) Shuttle Radar Topography Mission (SRTM) data, used to generate a slope map with 90 m spatial resolution, according to [15], in order to exclude improper areas for mechanization (slope > 12%); (iii) annual soybean agricultural statistics, at State and municipality level, from IBGE, used to compare and evaluate the obtained results from the present soybean area estimation procedure for the 39 municipalities; (iv) a soybean reference thematic map, available for crop year 2000/2001 [3] obtained from multi-temporal Landsat TM images analysis, at 30 m spatial resolution, used to evaluate the soybean thematic map obtained from 2000/2001 in this study; and (v) geolocation reference images from Global Land Survey (GLS), which is composed by cloud free images and geo-referencing metrics with good quality. This product was used to provide an accurate geo-registration of the selected images at Table 1.

Table 1. Selected Landsat-5 TM images for soybean crop area detection.

Crop year	Path/Row 222/080	Data Situation
1997	13 January/29 January/14 February	Ok
1998	-	No overpassing
1999	-	No overpassing
2000	-	No overpassing
2001	24 January/25 February/13 March	Ok
2002	-	No overpassing
2003	-	No overpassing
2004	17 January/2nd February/18 February	Ok
2005	19 January/4 February/8 March	Clouds
2006	23 February/11 March	Ok
2007	25 January/26 February/14 March	Ok
2008	28 January/13 February/16 March	Ok
2009	30 January/15 February/3 March	Ok
2010	2nd February/18 February	Ok

2.3. LANDSAT Image Calibration

The Landsat-5 TM images were fully calibrated and corrected to generate reflectance values, according to Landsat Calibration Documents [16,17]. Usually, correction includes atmospheric and sensor related parameters and thus leads to the derivation of physical units such as reflectance [18]. In the strict sense, full absolute image correction involves both applications of absolute calibration coefficients for sensor and related parameters of atmospheric correction, to derive estimates of surface reflectance in order to produce a consistent temporal reflectance trajectory [18]. In this work, the first

step was to convert the digital numbers (DN) into radiance and afterwards to reflectance, according to calibration parameters of [17]. After the transformation of DN to reflectance, images were atmospherically corrected according to the methodology of [19].

2.4. Selected Bands

During soybean vegetation development, a rapid increase of near-infrared (NIR) reflectance values is observed, reaching its maximum values after a relatively short period. After that, the maximum vegetation period is observed in the time window between 20 January and before 20 March [11,20] for Rio Grande do Sul. During the maximum vegetation development stage, soybean crop cultivation presents a particular spectral behavior when compared with other classes of regional land use cover [3]. At that stage, vegetation is expected to present low reflectance values at the red band (0.65 to 0.69 μm), high reflectance values at the NIR band (0.76 to 0.90 μm) and a very steady reflectance variation at the Short-Wave Infrared (SWIR) band (1.55 to 1.75 μm), as described in [21] for irrigated and rainfed soybean crops. So, using a mathematical-computational rule, it is possible to establish operators that are able to identify soybean crop area characteristics that remain through time even under different vegetation development conditions. This means that an algorithm that meets the appropriate mathematical combination of bands 3, 4 and 5 can accurately select soybean crop areas.

Soybean sowing occurs from around early October to early December. Usually, maize is sown earlier than soybean [20], favoring a calendar-based discrimination. In this sense, even when maize is sown during the same period as soybean, it would not be erroneously tagged as soybean, because it is possible to identify a particularly spectral behavior by using simultaneously the bands 3–5 that is associated to each culture.

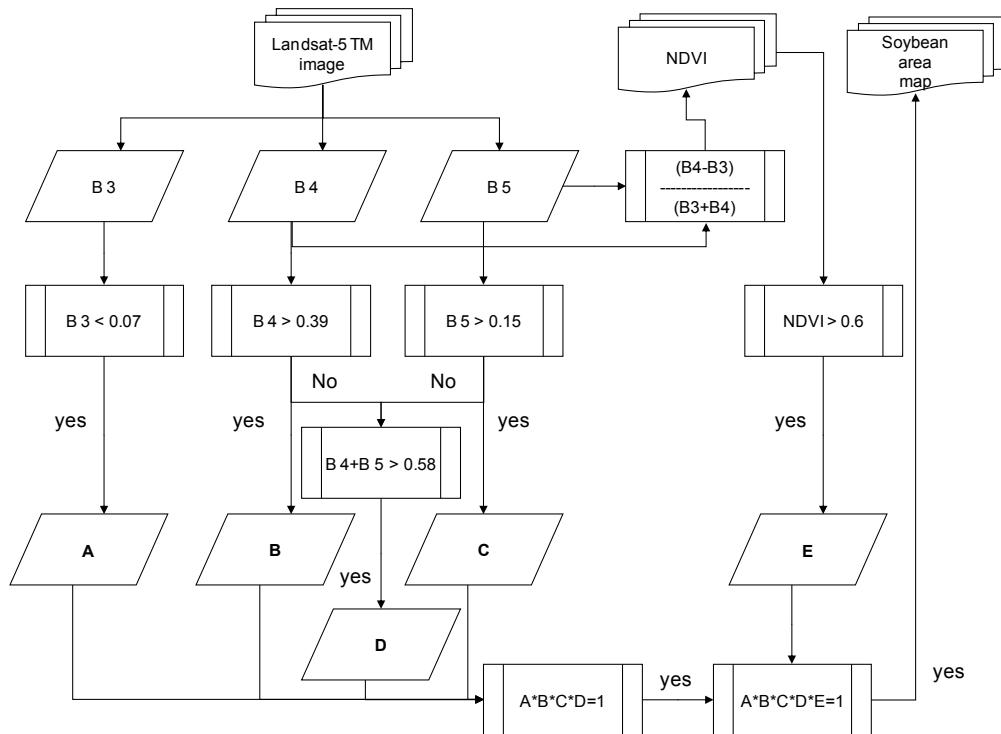
2.5. Algorithm Development: Theoretical Approach

The soybean classification procedure developed in this study was named Reflectance-based Crop Detection Algorithm (RCDA), whose diagrammatic flowchart is presented in Figure 2. RCDA was developed in the ERDAS 9.1 Modeler Environment. Initially, surface reflectance values for soybean during maximum plant development were tested. Based on published spectral characteristics [22,23] of bands 3–5 of Landsat-5 TM, soybean crop vegetation typically presents a calibrated reflectance of about 5%, 50% and 21% respectively. It is because those reflectance values, usually available on literature, are averaged from standardized conditions and represent soybean crop fields at full-pixel coverage over soybean areas.

It is well known that in drought-free years, well developed vegetation reflects just a little part of incident solar radiation in the visible band of spectrum, due to chlorophyll absorption properties and others plant pigments that absorbs sunlight. In the NIR, plants reflect much more, due to a scattering effect caused by the internal structure of leaves and water content [24]. Depending on the intensity of water deficit due to drought, seasonal heat waves or both effects coupled together [25] it is possible that vegetation remains green for a time lag after the onset of water stress [26]. In this way, it is expected that bands 3 (red) and 4 (NIR) do not retrieve detectable changes during this time lag. Additionally, reflectance at band 5 of Landsat is closely associated to vegetation moisture [27,28] and therefore, its behavior through time needs to be more deeply investigated. However, it is also known to

have the property of penetrating thin clouds due to wavelength size [28,29], which tends to be very useful in a mapping study and land use change.

Figure 2. Flowchart of the Reflectance-based Crop Detection Algorithm (RCDA).



It became clear that the challenge is to find out those accurate reflectance values located at the lower limits of the spectral range (lower reflectance values) for each band, in a way that includes not only pure soybean pixels at the normal conditions, but also under water deficit development or mixed pixels located at the border of soybean fields. Those lower limits values were defined in this work as R3min, R4min and R5min.

2.6. RCDA Development: Test Sites

One way to perform the better fitting of the representative reflectance values, due to their importance as input parameters for RCDA, was to obtain a set of soybean reflectance samples in each of the bands 3–5 from selected test sites inside the 39 municipalities.

Direct visual inspection and mapping over the images was used to set the location of test sites with total of 9,925 pixels through all crop years 1996/1997, 2000/2001, 2003/2004, 2005/2006, 2006/2007, 2007/2008, 2008/2009 and 2009/2010. It is important to note that at least, two of the selected crop years (2003/2004 and 2006/2007) were under quite different development conditions [30]. So, different Physically Driven Components (PDC) related to agricultural practices, weather or climatological forcings were acting at the agricultural system. We refer PDC to the main physical dynamic processes involved, from one harvest to another, which leads to adjustments in the mathematical modeling of vegetation development. PDC investigation became necessary in order to identify more accurately a multi-temporal threshold for band 3–5 that remained representative of soybean vegetation through time.

The soybean areas were mapped and selected by using false-color composition of bands (RGB-453) described at [3]. Those minimum reflectance values for each band are also associated to the limits of border regions between full-pixel coverage of soybean and mixed pixels.

Pixels below R3min are typically associated to cloud shadows or water bodies. Actually, it was observed at the test sites that soybean vegetation reflectance, even under different development conditions, stands lower than 0.07 in the red, band 3; stands greater than 0.42 in the NIR band 4; and stands greater than 0.18 in the Short-wave Infrared (SWIR) band, band 5. In terms of reflectance, these are crucial as input parameters to soybean characterization.

2.7. RCDA Development: How Does That Work?

For a given crop year, all available Landsat-5 TM images from the maximum development period were combined into the algorithm. In doing so, five computational steps were established in order to get the best use of PDC that rule soybean spectral behavior in bands 3–5.

Pixels with reflectance values that fall under the defined R3min were tagged as soybean according to condition A; pixels with reflectance values that fall above R4min were tagged as soybean according to condition B; pixels with reflectance values that fall above R5min were tagged as soybean according to condition C; pixels which the reflectance are above the sum of bands 4 and 5 were tagged as soybean according to condition D; and pixels with NDVI values which are above NDVImim were tagged as soybean according to condition E, in Figure 2. In the final step, all conditions are multiplied and a pixel that is representative of a soybean area must have the value one. In this procedure, a pixel will be automatically classified as soybean if it adheres simultaneously to conditions A, B, C, D and E. By using mathematical Boolean rule, a pixel will be selected as soybean if all conditions are simultaneously satisfied.

Pixels with a calibrated reflectance that does not follow at least one of defined rules A, B, C, D or E, are not selected, because they will overlap areas that are not from soybean crops. Additionally, all four conditions are modulated by NDVI values greater than 0.6 units in order to avoid background and/or cloud contamination that usually have high values of reflectance. Also, saturation effects of Normalized Difference Vegetation Index (NDVI) when Leaf Area Index (LAI) is greater than 3 can mask water stress [31].

2.8. Tuning Procedure of the RCDA

After a first run of the RCDA, follows a tuning phase based on a stepwise procedure using some specific Landsat satellite image from Table 1. This step is necessary to interactively fine tune the most appropriate values of R3min, R4min and R5min in order to minimize the omission and commission errors, when comparing to the reference map from [3].

A comparison of Landsat images and RCDA mapping was then performed. By overlaying the Landsat images and the classification maps, we observed that the soybean area was overestimated for the first run of the RCDA. Therefore, a second run was performed adjusting the values of R3min, R4min and R5min. For each combination, a new soybean classification was generated, which was visually compared with the corresponding available Landsat-5 TM images.

After several interactions, over several crop years and comparing the results of each one of new RCDA classification with Landsat-5 TM images, the combination with best performance of the final calibrated values of RCDA were defined as $R3min = 0.07$; $R4min = 0.39$; $R5min = 0.15$ and $R4min + R5min = 0.58$, according to Figure 2.

We should emphasize that the RCDA tuning procedure is only completed when $R3min$, $R4min$ and $R5min$, which were chosen to be representative of predominantly PDC of soybean, can be used as the same input for all analyzed crop years. Therefore, once the parameters $R3min$, $R4min$ and $R5min$ were identified, no post-adjustment was allowed, partially to constrain dynamical adjustment process of the algorithm. During this phase, when some further adjustment was needed, in order to plot a better fitting of crop area map for one crop year or more, then this new parameter is run for all tested crops years.

Since the RCDA map is a binary image where 1 indicates soybean and zero indicates non-soybean, the next step is to combine a soybean area map from one Landsat-5 TM image to another one. It is expected that a combination of three consecutive Landsat-5 TM images would be available for the maximum vegetation development period. According to [3], it is mandatory that at least two images inside the critical period with good quality and low cloud contamination exist. If cloud occurrence is severe over the interest area, a delay of 16 d is expected in order to acquire the next Landsat-5 TM image. Therefore, the soybean estimation can be released no later than early March if two or more Landsat-5 TM images are available. Even if a third image is necessary, a soybean map can still be released during March. However, if no useful images were found due to at least one of the following situations, no other computational rules are applicable and no crop area estimation is generated for the crop year: cloud contamination, named as situation Cloud; image quality/noise presence, named as situation Quality, or unavailable overpassing, named as situation No overpassing,. In the case of a crop area forecast, a RCDA map can be provided right after a second Landsat-5 TM image is available inside the time-window, which normally occurs in mid/late February. Table 1 presents all Landsat-5 TM images available. All crop years that the available Landsat-5 TM images have flagged as OK, in Table 1, were used in the validation process. It is important to emphasize that the parameters defined in RCDA for detection crop areas are constant, as a fixed criteria during the period we studied (eight crop years between 1996/1997 and 2009/2010).

3. Validation

3.1. Validation of the RCDA: Step 1

RCDA was developed in order to provide an automated tool for soybean classification. The performance of the RCDA was validated in two steps. The first one was using a thematic soybean map elaborated from multi-temporal Landsat images for crop year 2000/2001 of [3]. The confusion matrix and the overall map accuracy were provided.

When comparing the obtained results of RCDA estimates with those obtained by [3] for crop year 2000/2001, we noticed that the two estimates are in good agreement. Table 2 shows the confusion matrix resulting from the comparison between the mapping provided by [3] and the RCDA. The overall map accuracy was approximately 91.91% and the Kappa Index of Agreement was 0.76. For

classification maps assessment, usually Kappa Index of Agreement values greater than 0.5 are considered good results [32].

Analysis of the user's (commission) and producer's (omission) accuracy for the soybean class is similar, indicating that errors tend to be compensated among the overall calculation. Figure 3 presents a comparison between a Landsat-5 TM and RCDA classification over 2000/2001 soybean crop areas. Figure 4 presents a scatterplot diagram and regression analysis for the 39 municipality estimates from the RCDA procedure and from the reference map [3] for the crop years 2000/2001. Coefficient of determination (R^2) was 0.99.

Visual inspection of the RCDA map compared to reference map suggests a slight displacement towards Northeast direction of RCDA map, of a length at around one pixel. It might be considered that an inaccurate process of registration for the assembling of the three images can increase errors in this analysis. RCDA applied to other Brazilian regions where soybean crop areas used to be extensive must generate better results.

Table 2. Confusion matrix from the comparison of RCDA mapping and [3] mapping.

RCDA	Reference (Pixels)				User's Accuracy
	Soybean	Non Soybean	Total Classified		
Soybean	4,764,107	1,409,792	6,173,899		77.17%
Non soybean	773,466	20,033,427	20,806,893		96.29%
Reference total	5,537,573	21,443,219	26,980,792		
Producer's accuracy	86.03%	93.42%			
Overall accuracy	91.91%				
Kappa Index	0.76				

Figure 3. Sector enlargement in Rio Grande do Sul State, for comparison between: (A) Landsat-5TM, (RGB/453) in 25 February 2001; and (B) resulting soybean map classification from RCDA in 2000/2001 crop year.

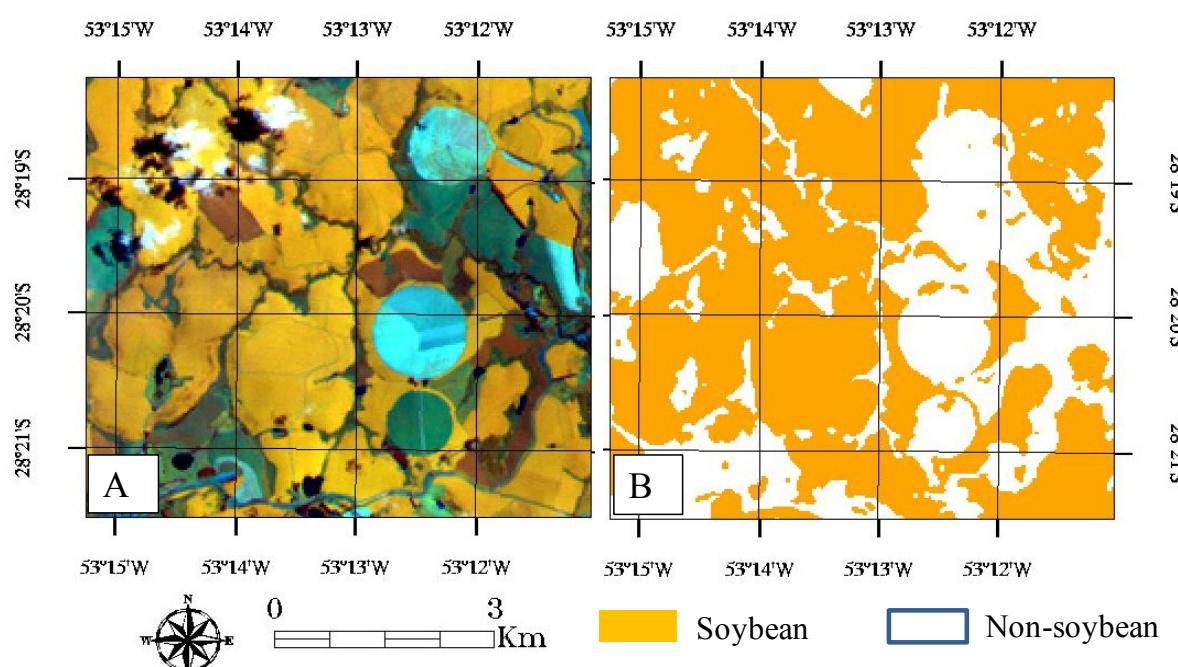
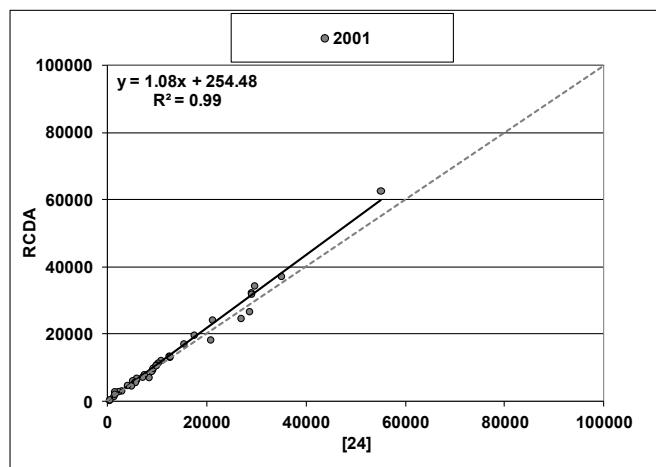


Figure 4. Scatterplot diagram and regression analysis, of soybean area estimates, between RCDA and the reference map [3].



3.2. Validation of RCDA: Step 2

In the second validation step, in order to have some perception of its performance, we compared its results to results generated by a classification through Maximum Likelihood procedure, which is widely known as a robust method for classification.

For the same Landsat-5 TM images used for RCDA, in 2001 crop year, which are presented in Table 1, we selected seven classes, in order to accurately identify soybean pixels separately from non-soybean classes. The selected classes are: soybean new, soybean old, other vegetation, forest, urban area, crop harvest and water bodies. The Maximum Likelihood procedure operates under an analyst-made classification procedure with the visual selection of pixels of all chosen classes. This is a laborious and time-consuming task because it is done manually and consists of several steps, including the visual selection of the representative sample pixels of each class. Obviously, results depend on skills and subjective judgment of the analyst. After this, we generated the soybean map from Maximum Likelihood classification procedure (ML map). The generated ML map was also compared to the reference map from [3].

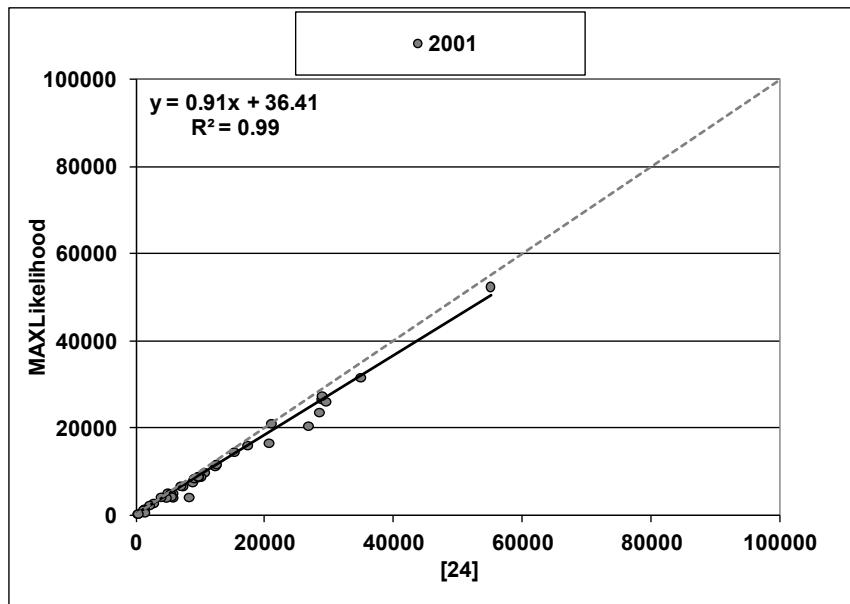
Table 3 shows the confusion matrix resulting from the comparison between the mapping provided by [3] and the ML map. The overall map accuracy was approximately 92.45% and the Kappa Index of Agreement was 0.76.

Table 3. Confusion matrix from the comparison between ML map and the [3] mapping.

ML Map	Reference (pixels)				User's Accuracy
	Soybean	Non Soybean	Total Classified		
Soybean	4,282,230	781,079	5,063,309		84.57%
Non soybean	1,255,343	20,662,140	21,917,483		94.27%
Reference total	5,537,573	21,443,219	26,980,792		
Producer's accuracy	77.33%	96.36%			
Overall accuracy	92.45%				
Kappa Index	0.76				

Figure 5 present a scatterplot diagram and regression analysis for the 39 municipality estimates from the ML map procedure and from the reference map [3] for the crop years 2000/2001. Coefficient of determination (R^2) was 0.99.

Figure 5. Scatterplot diagram and regression analysis, of soybean area estimates, between ML map and the reference map [3].



According to Tables 2 and 3, and comparing results from Figures 4 and 5, in both validation tests it becomes clear that RCDA and the Maximum Likelihood procedures are essentially similar in accuracy. The main difference is that RCDA is an objective automated tool for soybean classification and which does not depend upon the analyst skills and subjective sources of decision, as described previously, being rather based in physical criteria. This is perceived from confusion matrix comparison, where the Kappa Index of Agreement had the same result (0.76) but RCDA Producer's accuracy, for soybean, is 8.7% greater than Maximum Likelihood procedure. Besides, RCDA leads to rapid results.

4. Results and Discussion

Even in a low temporal resolution of Landsat-5 TM images and reflectance of soybean crop field heterogeneity, throughout the summer season, the computational approach of RCDA has shown to be consistent and stable. Soybean area provided by RCDA was estimated by municipality and compared to official estimates provided by IBGE (<http://www.sidra.ibge.gov.br>) using regression analysis. IBGE data are only published around 18 months after the end of the soybean season. So, presently, the most recent data from IBGE is 2009/2010.

For crop years 1996/1997 and 2003/2004 IBGE data do not indicate a crop area presence greater than zero for several municipalities. However, further analysis, by means of detailed visual inspection and mapping with Landsat images (RGB-453) revealed the presence of soybean crops.

Figure 6 present scatterplot diagrams and regression analysis for the 39 municipality estimates from the RCDA procedure and from IBGE for the crop years 1996/1997 to 2009/2010. Coefficients of

determination (R^2) were between 0.81 and 0.98, an agreement indicator between the estimates. The averaged slope value around 1.005 for all tested crops also indicates good agreement. In Figure 7, the comparing totals from RCDA and IBGE in municipality estimates level are shown.

Figure 6. Scatterplot diagram and regression analysis, of soybean area estimates, between RCDA and IBGE municipalities for each of the selected crop years through 1996/1997 to 2009/2010.


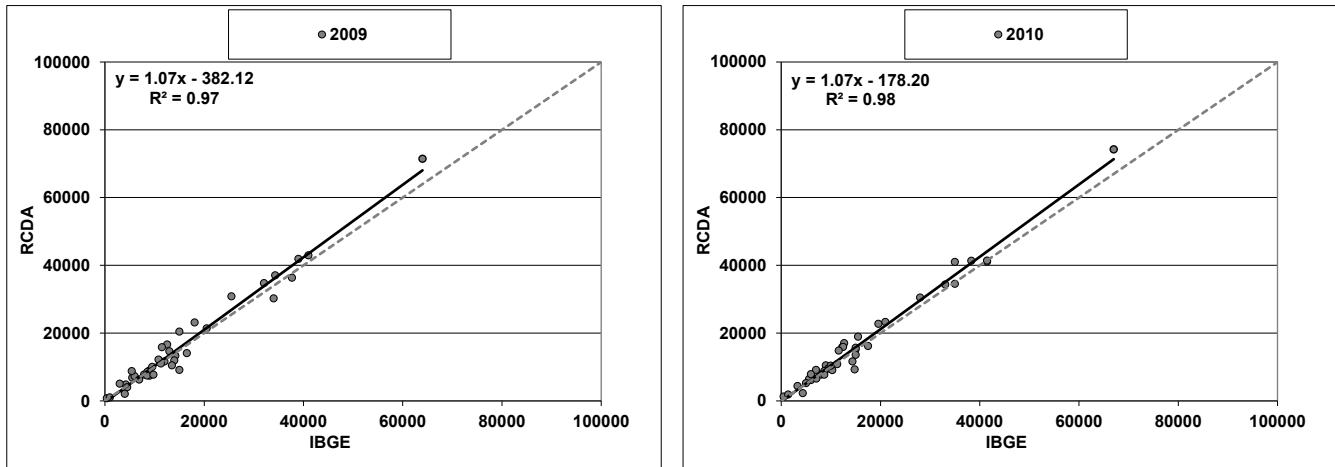
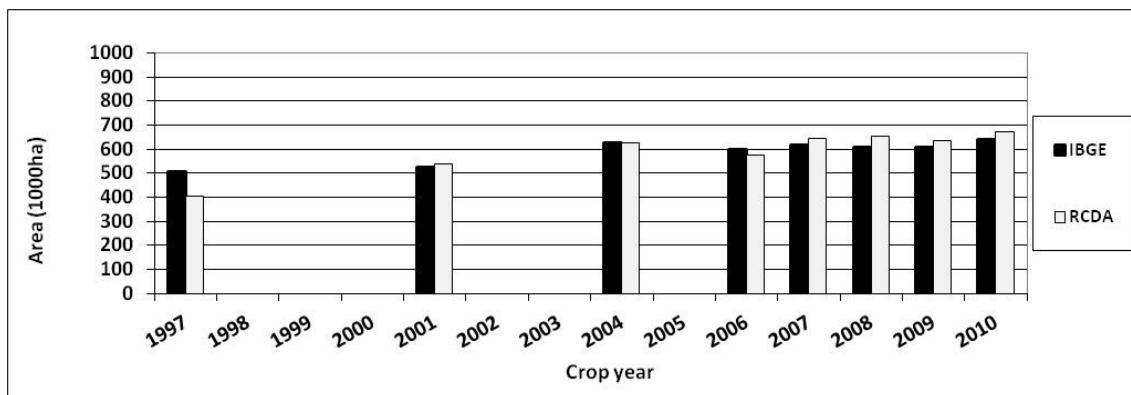


Figure 6. Cont.**Figure 7.** Comparison between RCDA and IBGE soybean area estimates for the entire study area.

5. Conclusions

The RCDA algorithm presents an objective and consistent methodology for soybean classification and provides crop areas with estimates that are comparable to the official agricultural statistics of IBGE and visual inspection methodologies. Due to the calculation chain and pre-defined parameters, RCDA is a timesaving procedure and is less vulnerable to analyst image interpretation skills and subjectivity. This is perceived by the validation step results (Section 3) and the Maximum Likelihood procedure, wherein the Kappa Index of Agreement had the same result (0.76) and the Overall Accuracy was only 0.54% greater than the RCDA. Besides, the RCDA Producer's accuracy, for soybean, is 8.7% greater than Producer's accuracy from the Maximum Likelihood procedure. Therefore, RCDA represents a considerable gain in time and accuracy of spatial information.

RCDA can assist the local agricultural management demands, providing reliable and adequate spatialized information. The RCDA approach is not species-specific and is therefore applicable with the proper calibrations to other crops besides soybean.

Acknowledgments

Sincere appreciation to the Center for Remote Sensing and Meteorological Research at the Federal University of Rio Grande do Sul (UFRGS), University of Vale do Rio dos Sinos (UNISINOS) and to the Image Processing Division at INPE for the Landsat-5 TM images provided.

References

1. Rizzi, R.; Rudorff, B.F.T.; Adami, M. Estimativa da área da soja no Estado do Rio Grande do Sul por um método de amostragem. *Ciência Rural* **2006**, *36*, 30–35.
2. Fontana, D.C.; Ducati, J.R.; Weber, E.; Berlato, M.A.; Bergamaschi, H.; Figueiredo, D.C. *Monitoramento e Previsão da Safra de Soja 1999/2000 no Brasil*; Technical Report–Nº 005/01; Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia: Porto Alegre, Brazil, 2001; p. 116.
3. Rizzi, R.; Rudorff, B.F.T. Soybean crop area estimation in Rio Grande do Sul through Landsat images. *Revista Brasileira de Cartografia* **2005**, *57*, 226–234.
4. Rudorff, B.F.T.; Berka, L.M.S.; Moreira, M.A.; Duarte, V.; Xavier, A.C.; Rosa, V.G.C.; Shimabukuro, Y.E. Imagens de satélite no mapeamento e estimativa de área de cana-de-açúcar em São Paulo: Ano-safra 2003/04. *Agricultura em São Paulo* **2005**, *52*, 21–39.
5. Projeto de Revitalização da Companhia Nacional de Abastecimento. *GEOSAFRAS-BRA/03/34–2004*. Available online: <http://www.conab.gov.br/conteudos.php?a=1079&t=2> (accessed on 5 December 2011).
6. CANASAT. *Mapeamento da Cana-de-açúcar via Imagens de Satélite de Observação da Terra, 2011*. Available online: <http://www.dsr.inpe.br/laf/canasat/> (accessed on 29 November 2011).
7. Sano, E.E.; Ferreira, L.G.; Asner, G.P.; Steinke, E.T. Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. *Int. J. Remote Sens.* **2007**, *28*, 2739–2752.
8. Sugawara, L.M.; Rudorff, B.F.T.; Adami, M. Viabilidade de uso de imagens do Landsat em mapeamento de área cultivada com soja no Estado do Paraná. *Pesquisa Agropecuária Brasileira* **2008**, *43*, 1763–1768.
9. Epiphanio, R.D.V.; Formaggio, A.R.; Rudorff, B.T.F.; Maeda, E.E.; Luiz, A.J.B. Estimating soybean crop areas using spectral-temporal surfaces derived from MODIS images in Mato Grosso, Brazil. *Pesquisa Agropecuária Brasileira* **2010**, *45*, 72–80.
10. Figueiredo, D.C. Projeto GeoSaffras: Aperfeiçoamento do sistema de previsão de safras da Conab. *Revista de Política Agrícola* **2005**, *14*, 110–120.
11. Gusso, A.; Formaggio, A.R.; Rizzi, R.; Adami, M.; Rudorff, B.T.F. Soybean area estimation by MODIS/EVI data. *Pesquisa Agropecuária Brasileira* **2012**, *47*, 425–435.
12. Lobell, D.B.; Asner, G.P. Cropland distributions from temporal unmixing of MODIS data. *Remote Sens. Environ.* **2004**, *93*, 412–422.
13. IBGE–Instituto Brasileiro de Geografia e Estatística. *Produção Agrícola Municipal–Automatic Data Recovery System–SIDRA*. Available online: <http://www.sidra.ibge.gov.br/> (accessed on 2 October 2011).

14. Cunha, G.R.; Barni, N.A.; Haas, J.C.; Maluf, J.R.T.; Matzenauer, R.; Pasinato, A.; Pimentel, M.B.M.; Pires, J.L.F. Agricultural zoning and sowing dates for soybean in Rio Grande do Sul, southern Brazil. *Revista Brasileira de Agrometeorologia* **2001**, *9*, 446–459.
15. Raabus, B.M.; Eineder, A.R.R. The shuttle radar topography mission—A new class of digital elevation models acquired by spaceborne radar. *Photogramm. Eng. Remote Sensing* **2003**, *57*, 241–262.
16. Chander, G.; Markham, B. Revised Landsat-5 TM radiometric calibration procedures and post-calibration dynamic ranges. *IEEE Geosci. Remote Sens. Lett.* **2007**, *4*, 490–494.
17. Chander, G.; Markham, B.; Helder, D.L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sens. Environ.* **2009**, *113*, 893–903.
18. Schroeder, T.A.; Cohen, W.B.; Song, C.; Canty, M.J.; Yang, Z. Radiometric correction of multi-temporal Landsat data for characterization of early successional forest patterns in western Oregon. *Remote Sens. Environ.* **2006**, *103*, 16–26.
19. Chavez, P.S., Jr. Image-based atmospheric correction—Revisited and improved. *Photogramm. Eng. Remote Sensing* **1996**, *62*, 1025–1036.
20. Ministério da Agricultura, Pecuária e do Abastecimento—MAPA. *Zoneamento Agrícola Para a Cultura de Soja no Estado do Rio Grande do Sul, Ano-Safra 2009/2010*; Ministério da Agricultura, Pecuária e do Abastecimento—MAPA: Brasília, Brazil, 2009; Pg. 15.
21. Gitelson, A.A.; Merzlyak, M.N. Signature analysis of leaf reflectance spectra: Algorithm development for remote sensing chlorophyll. *J. Plant Physiol.* **1996**, *148*, 494–500.
22. Jensen, J.R. *Remote Sensing of the Environment: An Earth Resource Perspective*, 2nd ed.; Prentice Hall: Upper Saddle River, NJ, USA, 2007; p. 592.
23. Kogan, F.N. World droughts in the new millennium from AVHRR-based vegetation health indices. *Eos Trans. AGU* **2002**, *83*, 557–564.
24. Mercante, E.; Lamparelli, R.A.C.; Uribe-Opazo, M.A.; Rocha, J.V. Características Espectrais da soja ao longo do ciclo vegetativo com imagens Landsat 5/TM em área agrícola no oeste do Paraná-Artigo Técnico. *Engenharia Agrícola* **2009**, *29*, 328–338.
25. Batistti, D.S.; Naylor, R.L. Historical warnings of future food insecurity with unprecedented seasonal heat. *Science* **2009**, *323*, 240–244.
26. Kogan, F.N.; Gitelson, A.; Zakarin, E.; Spivak, L.; Lebed, L. AVHRR-based spectral vegetation index for quantitative assessment of vegetation state and productivity: Calibration and validation. *Photogramm. Eng. Remote Sensing* **2003**, *69*, 899–906.
27. National Aeronautics and Space Administration (NASA). *Landsat Data*. Available online: <http://landsat.gsfc.nasa.gov/> (accessed on 5 December 2011).
28. United States Geological Survey. *Landsat: A Global Land-Imaging Project*. Available online: <http://pubs.usgs.gov/fs/2010/3026/pdf/FS2010-3026.pdf> (accessed on 19 July 2011).
29. United States Geological Survey. *Landsat: A Global Land-Observing Program*. Available online: <http://egsc.usgs.gov/isp/pubs/factsheets/fs02303.html> (accessed on 25 November 2011).
30. Gusso, A. Produtividade da cultura da soja no Rio Grande do Sul com dados EVI/MODIS. In *Proceedings of the 15th Brazilian Remote Sensing Symposium (SBSR 2011)*, Curitiba, PR, Brazil, 30 April 2011; pp. 55–062.

31. Gray, S.B.; Dermody, O.; de Lucia, E.H. Spectral reflectance from a soybean canopy exposed to elevated CO₂ and O₃. *J. Exp. Bot.* **2010**, *61*, 4413–4422.
32. Ismail, M.H; Jusoff, K. Satellite data classification accuracy assessment based from reference dataset. *Int. J. Comp. Inf. Eng.* **2008**, *2*, 386–392.

© 2012 by the authors; licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution license (<http://creativecommons.org/licenses/by/3.0/>).

Integração de imagens NOAA/AVHRR: Rede de cooperação para monitoramento nacional da safra de soja

Anibal Gusso¹

RESUMO

Uma avaliação inicial das condições do desenvolvimento da safra nacional, enquanto as plantas ainda estão nos campos, é altamente necessária para o cálculo correto das projeções na tomada de decisão e políticas relacionadas com o planejamento governamental e segurança alimentar. O objetivo deste trabalho foi avaliar a adequação dos dados NOAA/AVHRR (National Oceanic and Atmospheric Administration / Advanced Very High Resolution Radiometer) em detectar mudanças nas condições da vegetação, devidas à ocorrência de estresse hídrico, na soja, por meio de uma combinação do índice NDVI (Normalized Difference Vegetation Index) e da LST (Land Surface Temperature). Os dados LST e NDVI foram combinados e comparados pixel a pixel, sobre uma área de cultivo de soja, no Rio Grande do Sul. A relação teórica inversa prevista na combinação de LST e NDVI foi detectada. Foi observado que ocorre um aumento médio na LST em uma safra de ciclo normal (de 301,02 K para 308,36 K), quando comparada a uma safra sob condição de estresse hídrico, no desenvolvimento da cultura. Uma redução média do NDVI foi observada no ciclo normal (de 0,65 para 0,53), comparada com uma safra sob efeitos ocasionados pela estiagem no desenvolvimento da cultura. Foi observado maior correlação da produtividade municipal com LST ($R^2=0,78$) do que com o NDVI ($R^2 = 0,59$). Os resultados obtidos indicam que a integração de imagens do sensor AVHRR, proveniente de diferentes instituições, proporciona a adequada combinação espacial e temporal dos dados LST e NDVI, a fim de detectar a ocorrência de estresse hídrico, bem como sua intensidade, caracterizando as condições do ciclo de desenvolvimento da soja.

Palavras-chave: sensoriamento remoto, estiagem, temperatura da superfície terrestre, índice de vegetação.

ABSTRACT

Integration of NOAA/AVHRR images: Cooperation network towards national soybean crop monitoring

An early assessment of national crop development conditions while the plants are still in the fields is highly needed to calculate correctly projections for decision-making and policies related to government planning and food security. The aim of this study was to evaluate the suitability of NOAA/AVHRR (National Oceanic and Atmospheric Administration / Advanced Very High Resolution Radiometer) to detect changes in vegetation conditions, due to water stress during soybean crop, by means a combination of Land Surface Temperature (LST) and Normalized Difference Vegetation Index (NDVI). Both LST and NDVI data were combined and compared in a pixel basis over a soybean crop area in Rio Grande do Sul State. The predicted theoretical inverse relationship for the combination of LST and NDVI was detected. An average increase of LST was observed in a normal crop cycle (from 301.02 K to 308.36 K) compared to a crop cycle under water stress condition. An average reduction in NDVI was observed for normal crop cycle development (from 0.65 to 0.53) compared to a crop cycle under drought-induced effects. It was observed a higher correlation of municipality yield with LST ($R^2=0.78$) than NDVI ($R^2=0.59$). Results obtained indicate that the aggregation of AVHRR images, from

Recebido para publicação em 31/05/2011 e aprovado em 14/02/2013.

¹ Físico, Mestre. Centro de Ciências do Sistema Terrestre - Instituto Nacional de Pesquisas Espaciais (INPE), Avenida dos Astronautas, 1758, Jardim da Granja, Caixa Postal 515, 12227-010, São José dos Campos, São Paulo, Brasil. anibal.gusso@inpe.br

different institutions, provides the appropriate combination of spatial and temporal data LST and NDVI in order to detect the occurrence of drought stress, as well as its intensity, characterizing the conditions of the crop cycle development of soybean.

Key words: remote sensing, drought, land surface temperature, vegetation index.

INTRODUÇÃO

Em escala global, o gerenciamento do setor agrícola tem-se tornado cada vez mais sofisticado, exigindo informações continuamente atualizadas, de maneira a se obter levantamentos confiáveis sobre o desempenho das safras, antecipadamente ao período da colheita, estratégias de aprimoramento das políticas públicas de abastecimento e de equilíbrio entre oferta e demanda (Figueiredo, 2005; Gusso *et al.*, 2012).

Em um panorama de mudanças climáticas, parâmetros agrometeorológicos da superfície terrestre devem sofrer alterações nas próximas décadas (Siqueira *et al.*, 2000; Pinto, 2009; Batistti & Naylor, 2009; Peterson *et al.*, 2012). Períodos prolongados de baixa ocorrência de precipitação ou exposição a temperaturas elevadas produzem desequilíbrio nos sistemas ecológico e hidrológico e têm impactos severos na produção agrícola (Kogan *et al.*, 2003; Karnieli *et al.*, 2010; Board & Kahlon, 2011), com efeitos em vários níveis da organização social.

No Brasil, aumentos na frequência de eventos extremos, como a ocorrência de altas temperaturas e a redução na precipitação, deverão produzir efeitos severos na produtividade agrícola (Streck & Alberto, 2006; Lobell *et al.*, 2008), especialmente de soja e milho. Como decorrência disso, as distorções e indefinições nas políticas agrícolas devem amplificar as perdas e estabelecer barreiras na formação de metodologias para o financiamento agrícola e políticas assistenciais adequadas.

No Estado do Rio Grande do Sul (RS), a grande variabilidade interanual da precipitação, verificada em função, principalmente, dos fenômenos *El Niño* e *La Niña*, é o principal fator responsável pelas oscilações de produtividade na região sul (Buriol *et al.*, 1977; Fontana *et al.*, 2002; Melo *et al.*, 2004; Ferreira, 2006), sendo que as culturas mais afetadas geralmente são as da soja e do milho (Fontana *et al.*, 2002) na safra de verão.

O efeito prolongado da estiagem na safra da soja em 2004/2005, quando comparada com a safra de 2002/2003, apresentou uma redução de 76% na produção de grãos (IBGE, 2010). Mundialmente, a ocorrência de estiagens deverá ocasionar perdas severas na produção agrícola, com potenciais impactos na economia (UNEP, 2009). As-

sim, é de grande importância a implementação de um sistema nacional de monitoramento contínuo dos cultivos, para uma avaliação mais detalhada da vulnerabilidade e sustentabilidade dos processos adaptativos às novas condições e das futuras demandas internacionais por *commodities* agrícolas. Para tanto, são imprescindíveis estratégias de gerenciamento para redução dos impactos e melhor aproveitamento das condições climáticas favoráveis (Ferreira, 2006). Entretanto, é importante salientar que embora o aumento na frequência de estiagens e seus efeitos tenha sido o maior interesse nos últimos anos, os potenciais impactos de perdas no setor agrícola, decorrentes de sensíveis aumentos nas temperaturas sazonais, vêm ganhando interesse (Batistti & Naylor, 2009).

O sensoriamento remoto proporciona informações sistemáticas e de alta qualidade espacial e temporal sobre a superfície terrestre (Liu & Kogan, 2002). Na última década, índices espectrais de vegetação, particularmente derivados dos sensores AVHRR (*Advanced Very High Resolution Radiometer*), a bordo dos satélites da série NOAA (*National Oceanic and Atmospheric Administration*) têm demonstrado grande potencial no monitoramento do ciclo de desenvolvimento agrícola (Liu and Kogan, 2002; Kogan *et al.*, 2003; Esquerdo *et al.*, 2011). Estes dados têm sido especialmente utilizados em levantamentos do NDVI (*Normalized Difference Vegetation Index*) e da LST (*Land Surface Temperature*), para compor estudos de séries históricas (Karnieli *et al.*, 2010). Uma ampla gama de variáveis físicas e climáticas afeta o NDVI, a LST e a relação entre cobertura vegetada e temperatura (Karnieli *et al.*, 2010). Segundo Nemani & Running, (1997), diferenças na LST também têm aplicações na observação da taxa de crescimento das plantas. Sandholt *et al.* (2002) salientam que o uso do índice de vegetação e da temperatura da superfície aborda uma relação entre o vigor vegetativo e a resposta termal característica do dossel.

A estruturação de uma rede de cooperação institucional proporciona vantagens, ao gerar mapas em áreas de menor densidade de cobertura por dados agrometeorológicos, para todo o país. No Brasil, como exemplo, estão em funcionamento contínuo antenas de Brasília (Instituto Nacional de Meteorologia-INMET), Campinas (Universidade de Campinas-UNICAMP) e Porto Alegre (Universi-

dade Federal do Rio Grande do Sul-UFRGS) dentre outras instituições (Figura 1). Gusso *et al.*, (2007) e Esquerdo *et al.*, (2011) testaram a obtenção dos dados NOAA/AVHRR para estimativa do NDVI e da LST e observaram que estes sensores são adequados para o mapeamento da LST em tempo hábil à tomada de decisão, diferentemente dos dados meteorológicos pontuais, obtidos em abrigos meteorológicos ou por estações automáticas, que, frequentemente, estão incompletos ou não disponíveis, para uma avaliação em tempo hábil (Kogan, 2002; Sims *et al.*, 2008).

Este estudo apresenta uma proposta de integração de dados de satélite, por meio de uma rede de cooperação institucional, para monitoramento da produção brasileira de soja, com base no índice de vegetação e no comportamento térmico da superfície, obtidos do NOAA/AVHRR. O objetivo foi caracterizar a relação que se estabelece na combinação desses dois parâmetros físicos, em associação, como agentes agregadores das condições predominantes de desenvolvimento da vegetação, durante as safras que apresentaram maior variabilidade da produtividade no RS.

MATERIAL E MÉTODOS

Área do estudo experimental no Rio Grande do Sul

A área de estudo experimental é o Estado do RS, um dos maiores produtores e exportadores de grãos do Brasil. Nesse Estado, a área de mais intensa produção agrícola está na região norte, com aproximadamente 76700 km² (Figura 2), e abrange 223 municípios (Gusso *et al.*, 2012). O RS é dominado pelos climas subtropical e temperado, respectivamente caracterizados pelos tipos *Cfa* e *Cfb* de Köppen (1948). O mês mais quente é janeiro com temperatura média de 23,7 °C e a média de precipitação pluvial ao longo do ano é de 1.680 mm, sendo que o mês que apresenta maiores médias de precipitação pluviométrica é outubro, com 173 mm (Melo, 2003). A época de semeadura das culturas do milho e da soja no sul do Brasil começa em setembro e vai até novembro. Dependendo da época da semeadura, entre setembro e novembro, a vegetação atinge seu máximo do final de janeiro até início de março (Gusso *et al.*, 2012), quando alcança os seus valores máximos do NDVI (Fontana *et al.*, 2002).




Figura 1. Área aproximada de cobertura e a posição das antenas de recepção de dados NOAA/AVHRR sobre o território brasileiro.

Considerando o período da floração, enchimento de grãos e maturação fisiológica, que ocorre nos meses de janeiro e fevereiro para a maioria dos cultivares, foi escolhido o mês de fevereiro de cada safra, na análise da combinação do máximo NDVI e máxima LST. Com base nas composições mensais de máximo NDVI e máxima LST, obtidos na região de grande produção, foram considerados os período da safra de 2002/2003, que correspondeu a uma elevada produtividade média estadual (2800 Kg/ha); uma safra com médio efeito de estiagem em 2003/2004, com produtividade reduzida (1400 Kg/ha); e uma safra sob severo efeito da estiagem em 2004/2005, que resultou em uma produtividade média estadual muito baixa (600 Kg/ha), segundo o IBGE (2010). Foram extraídos os valores, pixel a pixel, do NDVI e LST, considerando a área de intensa produção agrícola que responde por quase 70% da produção da soja no Estado, a qual foi delimitada pelo arquivo vetorial da malha municipal oficial do IBGE, conforme Figura 2.

Dados de pré-processamento

O processamento das imagens NOAA/AVHRR e a posterior integração e quantificação dos dados multitemporais em NDVI e LST foi obtido de imagens captadas pela estação de recepção de dados NOAA, instalada no Campus do Vale da UFRGS (Universidade Federal do Rio Grande do Sul).

Para a geração de dados do NDVI, a partir dos dados NOAA/AVHRR, foi utilizado o satélite NOAA-16, com passagem em horário pouco após o meio-dia local, e por proporcionar, simultaneamente, a obtenção dos dados da LST proximamente ao horário de máxima temperatura do dia. Imagens brutas foram submetidas aos procedimentos de calibração de pós-lançamento para a obtenção dos dados de NDVI. Esse procedimento consiste na calibração dos dados dos instrumentos, nas bandas 1 e 2, por causa da degradação, pelo tempo de operação, dos sensores, e da exposição às condições severas do espaço, como, também, da geometria de imageamento da superfície terres-




Figura 2. Área de estudo e a posição das estações meteorológicas utilizadas dentro da área de intenso cultivo da soja.

tre. Esses procedimentos, descritos por Rao & Chen (1999), estão de acordo com as recomendações do NESDIS (*National Environmental Satellite, Data and Information Service*).

O NDVI é calculado pela diferença entre as reflectâncias detectadas nas bandas do visível (0,58 à 0,68 μm) e infravermelho próximo (0,725 a 1,1 μm), dividida pelas somas dessas quantidades, como definido por Rouse *et al.* (1974). Desse cálculo, em pixel, resultam valores que variam entre -1,0 e +1,0 (Chen *et al.*, 2002) e tem ele sido amplamente utilizado como medida na avaliação de parâmetros sobre as condições de desenvolvimento da vegetação. Em condições normais de desenvolvimento, a vegetação vigorosa absorve a radiação no visível para realizar a fotossíntese e a reflete, no infravermelho-próximo, por causa do espalhamento da luz pelos tecidos mesofílicos e pelo conteúdo de água interno da folha. Com base nessas propriedades, a diferença entre o infravermelho-próximo e o visível torna-se grande (Kogan, 2002). A partir das imagens individuais diárias do satélite NOAA-16, foram geradas composições de imagens de NDVI, obtidas pelo cálculo do MVC (*Maximum Value Composite*) de Holben (1986). O mesmo método foi aplicado na obtenção das composições da máxima LST. Para obtenção dos dados da LST, foram utilizados os procedimentos de transformação dos dados digitais em radiância, por meio da equação de Planck, descritos em Sullivan (1999) e Gusso *et al.* (2007).

A LST pode ser determinada a partir da detecção da radiação de ondas longas, emitida na faixa do infravermelho, que deixa a superfície terrestre e é detectada pelo AVHRR nas bandas 4 e 5 (10,3 a 11,3 μm) e (11,5 e 12,5 μm). Medidas da temperatura, obtidas por satélites, estão relacionados com a temperatura cinética da superfície irradiadora sendo esta considerada, para efeito dos cálculos iniciais, como um corpo-negro ideal (Sobrino *et al.*, 2001, Gusso *et al.*, 2007). Foram utilizados dados obtidos da temperatura de brilho da banda 4, do NOAA/AVHRR, conforme os estudos de Nemani & Running, (1997), Kogan, (2001), Kogan, (2002) e Kogan *et al.*, (2003), que aprimoraram técnicas que relacionam o NDVI e a LST no estudo do desenvolvimento da vegetação agrícola.

A precipitação pluvial e a temperatura determinam os padrões de evapotranspiração real e balanço hídrico (Board & Kahlon, 2011).

O parâmetro LST é chave nos processos físicos terrestres em escala regional e global (Wan *et al.*, 2004). Considerando-se que a atividade fisiológica está mais diretamente relacionada com a temperatura da folha, do que com a temperatura do ar circundante, a LST é a componente física da temperatura mais adequada (Sims *et al.*, 2008).

Combinação do NDVI e LST

Alguns trabalhos já exploraram uma relação entre índices de vegetação e o comportamento térmico da superfície, obtido por dados de sensoriamento remoto (Nemani *et al.*, 1993; Goetz, 1997; Gupta *et al.*, 1997; Lambin & Ehrlich, 1995; Sandholt *et al.*, 2002; Sims *et al.*, 2008). Alguns desses estudos têm sido desenvolvidos sobre firmes bases teóricas (Moran *et al.*, 1994), outros, como também no presente trabalho, estão fortemente fundamentados em parametrizações empíricas de imagens de satélite obtidas por sensores colocados em órbita (Sandholt *et al.*, 2002; Kogan, 2002; Wan *et al.*, 2004), mas exigem grande quantidade de dados para assegurar que as condições de contorno estejam adequadamente estabelecidas.

No RS, diversos trabalhos têm demonstrado a alta correlação entre o déficit hídrico e as condições meteorológicas cumulativas, durante o período de crescimento e de desenvolvimento das culturas com a produção agrícola no RS (Fontana *et al.*, 2001; Fontana *et al.*, 2002). Liu & Kogan (2002) observam que é uma condição física que estabelece a relação matemática inversa entre o NDVI e LST e que essa relação impõe que as mais altas LST, obtidas no período de máximo desenvolvimento, estão associadas às condições mais desfavoráveis de crescimento da vegetação. Nesse sentido, Liu & Kogan (2002) também observam que, de maneira simétrica, os maiores valores do NDVI, representativos do maior vigor vegetativo, devem estar associados às LST mais baixas, indicando melhores condições de crescimento da vegetação. Entretanto, o NDVI não é, preferencialmente, um indicador cumulativo do estresse hídrico, pois a vegetação pode permanecer verde após o início da condição de estresse hídrico (Sandholt *et al.*, 2002; Wan *et al.*, 2004). Goetz (1997) também observou que decorre um atraso (*lag-time*) entre a diminuição da disponibilidade hídrica e a resposta dos valores do NDVI, mas ocorre uma resposta mais imediata com o aumento da temperatura do dossel (Nemani & Running, 1997; Goetz, 1997), sendo indiretamente, um dos primeiros sinais de redução na disponibilidade hídrica.

No caso da soja, a redução das chuvas durante essas fases fenológicas exerce influência direta na produtividade final (Ferreira, 2006). Mesmo quando o NDVI indica uma característica típica da vegetação verde, uma sensível redução na disponibilidade hídrica promove o fechamento dos estômatos, o que ocasiona uma redução na capacidade das plantas de reterem a energia refletida por meio de absorção, afetando também a capacidade da realização da fotossíntese. Como resposta ao desequilíbrio no balanço do fluxo de energia, provocado pela baixa circulação de água na estrutura interna (mesofílica) da vegetação, a temperatura do dossel aumenta rapidamente (Nemani & Running, 1997; Wan *et al.*, 2004). Já na situação

oposta, em que predominam superfícies bem úmidas, a relação entre NDVI e LST está mais diretamente relacionada com a umidade da superfície, pelo aumento da inércia térmica do solo (Friedl & Davis, 1994).

Em períodos secos, um suprimento insuficiente de água no interior da planta leva ao sobreaquecimento da vegetação, o que intensifica o impacto da deficiência hídrica (Liu & Kogan, 2002) pela elevação da temperatura (Allen *et al.*, 2010). Isto ocorre por que as condições biofísicas da superfície terrestre determinam as temperaturas do solo e da vegetação, assim como a temperatura do ar próxima à superfície do solo (Ouaidrari *et al.*, 2002). Na Amazônia, Brando *et al.* (2010) analisaram os efeitos de uma severa estiagem, em 2005, e observaram que a exposição à radiação solar incidente induziu o fechamento dos estômatos, mesmo da vegetação nativa. Entretanto, aqueles autores não utilizaram dados de LST, o que não permitiu localizar temporalmente os efeitos do aumento da temperatura no dossel.

Kogan (2001), analisando a relação entre índices de vegetação e a LST, observou que o período da floração da vegetação agrícola sazonal, é mais sensível à temperatura do que ao estresse hídrico. O período de florescimento (estádios R1 ao final do R5) e enchiamento de grãos (estádios R5 ao final do R7) são os mais sensíveis às flutuações das condições físicas na superfície terrestre (Kogan *et al.*, 2003; Ferreira, 2006; Board & Kahlon, 2011), o que, no RS, normalmente ocorre nos meses de janeiro a março (Ferreira, 2006).

Em sistemas agrícolas tão homogêneos como em campos de cultivo, a radiação incidente afeta a resistência dos estômatos para transpiração, alterando a relação entre calor sensível e calor latente (Nemani & Running, 1997; Sandholt *et al.*, 2002). O estresse provocado pela ocorrência de altas temperaturas tem ação sobre a atividade fotossintética (Carmo-Silva *et al.*, 2012). Temperaturas acima de 32 °C reduzem a taxa de crescimento da planta, em especial as plantas do tipo C3, como a soja, o feijão e o café, resultando em menor produtividade (Pinto, 2009; Board & Kahlon, 2011). Temperaturas ótimas para soja, entre 26 e 36 graus centígrados (Pinto, 2009; Board & Kahlon, 2011), são as mais frequentemente citadas.

RESULTADOS E DISCUSSÃO

As Figuras 3, 4 e 5 apresentam dados da precipitação mensal acumulada de outubro a março, em relação à normal climatológica, comparados com os dados de LST e NDVI do mês de fevereiro, nas respectivas safras. Os dados de precipitação acumulada mostram as diferentes condições hídricas entre as safras analisadas. Na safra 2002/2003, o período de novembro de 2002 a fevereiro de 2003 caracterizou-se por precipitações acima da média da região. Em contraste, a precipitação acumulada, na mesma época, nas duas safras seguintes, ficou abaixo da média.

Os valores mais baixos de NDVI, tipicamente entre zero e 0,2, não foram relevantes neste experimento, pois representavam corpos d'água, solo úmido ou sem cobertura vegetal, grandes áreas urbanas ou mesmo contaminação residual de nuvens. Fontana *et al.*, (2002) geraram estatísticas a partir do mesmo tipo de dados NDVI sobre áreas agrícolas, nessa região, e observaram que durante este período as áreas analisadas exibem valor médio de 0,55, com desvio padrão de 0,023. Portanto, muito baixa probabilidade (menor que 1%) de ocorrência de valores menores que 0,2.

A Figura 3 apresenta a distribuição de 2002/2003 como representativa das melhores condições de desenvolvimento de uma safra. A partir da Tabela 1, observam-se mais de 95% dos valores do NDVI acima de 0,5 e mais de 95% valores da LST abaixo de 305 K. Analisando-se a distribuição dos pontos nas Figuras 4 e 5, em relação aos da Figura 3, é possível observar que há uma migração intensa de pontos para a direita, com a maior parte repositionando-se entre 295 e 315 K. E um maior desvio padrão da LST (1,67 na Figura 3; 3,44 na Figura 4 e 3,16 na Figura 5), configurando um efeito de espalhamento, caracterizando assim, a distribuição também observada nos trabalhos de Sandholt *et al.*, (2002). Na Figura 5, o efeito de espalhamento é intensificado. Ocorre um deslocamento generalizado dos pontos, com reagrupamento em direção às maiores LST, para a borda da região seca, assumindo a configuração do ressecamento da vegetação e elevação da LST (Sandholt *et al.*, 2002), por causa das condições prolongadas do estresse hídrico, como prevê a relação física teórica estabelecida *a priori*. As Figuras 3, 4 e 5 também exibem pequenas parcelas de pontos espalhados com NDVI abaixo de 0,4 e com LST em torno dos 300 K, nas safras 2002/2003 e 2003/2004, que correspondem a áreas úmidas e corpos d'água rasos. Na safra 2004/2005, pode ser observado um espalhamento desses pontos para maiores LST, indicando o aquecimento de toda a superfície da área estudada.

Na safra 2002/2003, LST maiores que 305 K correspondem a apenas 1% das ocorrências, conforme se pode depreender da Tabela 1. Nos meses de setembro a março de 2005, predominou uma condição de precipitação pluvial abaixo da média, sendo que, no acumulado de dezembro a março de 2005, observa-se que todas as estações meteorológicas estão sob influência de estiagem severa, com o posicionamento de mais de 85% dos 71000 pontos acima de 305 K. Entretanto, em ambas as safras sob efeito de estiagem, observa-se um grupo de pontos com NDVI acima de 0,5, mesmo tendo LST acima dos 305 K. Este resultado, na safra 2004/2005, sugere que, para algumas parcelas da área estudada a redução do índice de vegetação não foi seguida na proporção prevista de aumento da LST, possivelmente, por causa da predominância do efei-

to de sobreaquecimento generalizado da superfície vegetada por uma onda de calor e não diretamente relacionada com a forçante imposta pelas condições prolongadas de deficiência hídrica.

Nemani & Running, (1997) observam que as condições físicas de dissipação da energia entre calor latente e

calor sensível são os principais mecanismos associados à LST. Isso pode indicar que a perda de produtividade, por ocorrência de estiagem, pode estar associada ao efeito acoplado de duas forçantes distintas nas safras analisadas, ou seja, uma redução inicial na disponibilidade hídrica, seguida de um aumento da temperatura, agravada

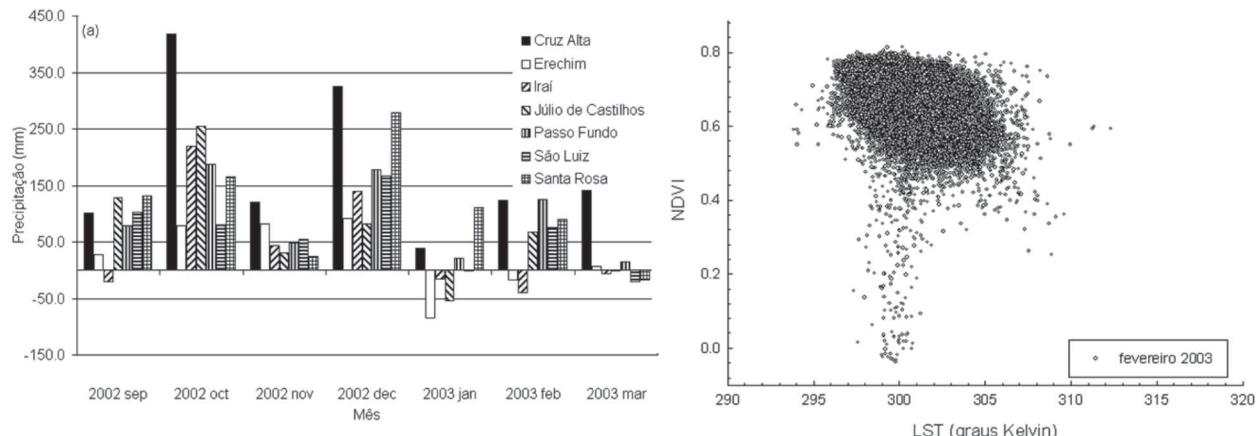


Figura 3. Diferença entre a precipitação mensal acumulada e a Normal Climatológica com o Diagrama de dispersão entre os valores de LST e NDVI, no mês de fevereiro, nas melhores condições de desenvolvimento (2002/2003).

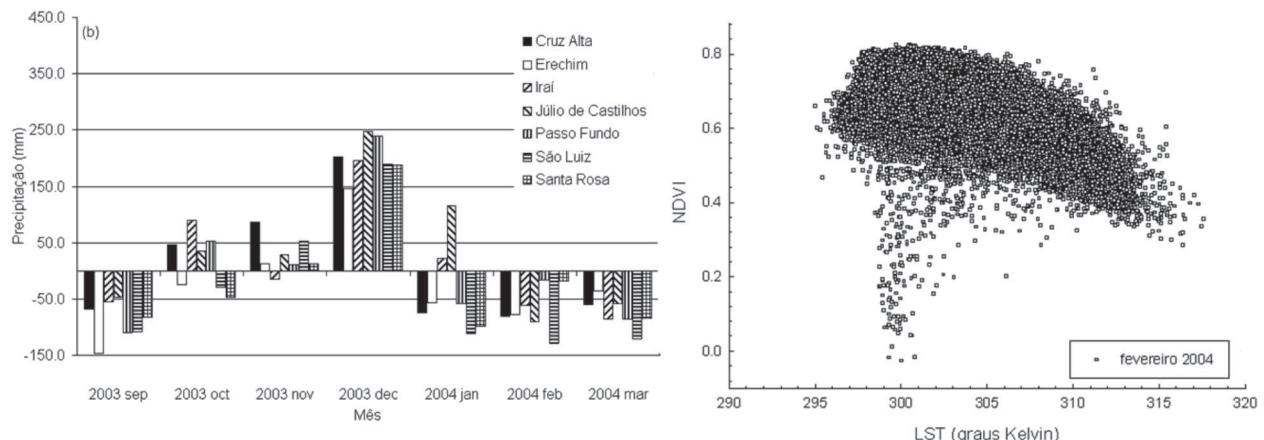


Figura 4. Diferença entre a precipitação mensal acumulada e a Normal Climatológica com o Diagrama de dispersão entre os valores de LST e NDVI, no mês de fevereiro, em condições de médio efeito de estiagem (2003/2004).

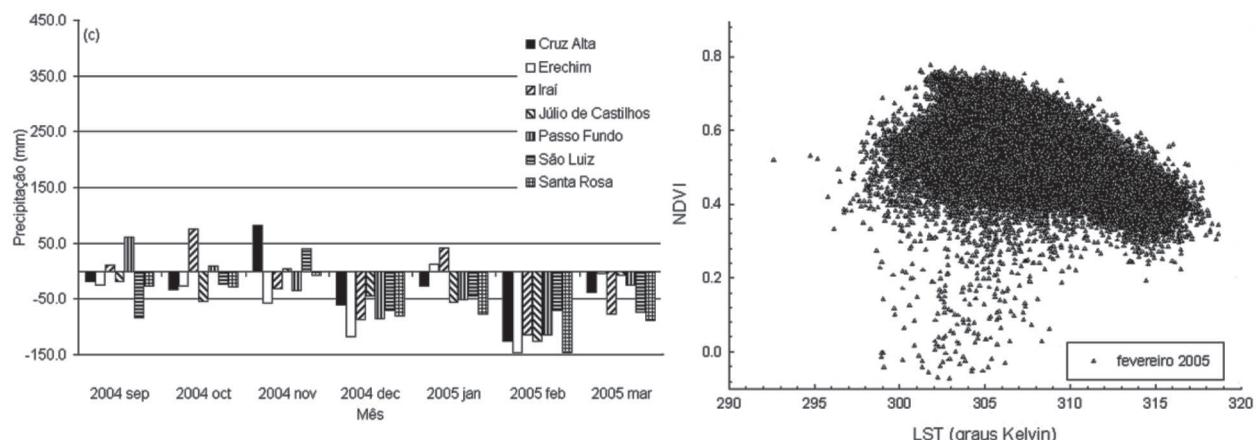


Figura 5. Diferença entre a precipitação mensal acumulada e a Normal Climatológica com o Diagrama de dispersão entre os valores de LST e NDVI, no mês de fevereiro, em condições de severo efeito de estiagem (2004/2005).

pelas condições de troca de energia, em função, principalmente, do vento, da umidade do ar e da exposição à radiação incidente (Nemani & Running, 1997; Wan *et al.*, 2004; Peterson *et al.*, 2012). Nessa situação, a implementação de estratégias e políticas públicas de planejamento, quanto a época de semeadura e à utilização de técnicas de irrigação, como apontado em Melo *et al.*, (2004), são extremamente importantes, considerando-se que ondas de calor possam ter intensidade potencializadas pela ocorrência de estiagem inibindo a atividade fotossintética (Carmo-Silva *et al.*, 2012).

Na análise da estatística geral, na Tabela 1, vê-se que, com a grande quantidade de pontos analisados em cada safra (71000 pixels), mesmo com pequenas variações dos valores médios da LST e do NDVI, de uma safra em relação à outra, essas variações devem ser consideradas relevantes. O Teste-t heterocedástico não indicou probabilidade significativa de semelhança entre os conjuntos de dados do NDVI ou LST, nas safras estudadas. Uma diferença importante no NDVI só é observada na comparação de fevereiro de 2003 com fevereiro de 2005, em que a média do NDVI (0,65) cai para 0,53. Já com relação à LST, o aumento da dispersão dos pontos, aumento nos valores médios e nos máximos, proporcionalmente à severidade da estiagem, fica bem evidenciado. Apesar disso, os valores médios e máximos do NDVI, de fevereiro de 2003 em relação a fevereiro de 2004, são praticamente iguais. Possivelmente, como um efeito positivo do sensível aumento da radiação incidente em fevereiro de 2004 sobre cultivos irrigados. Entretanto, uma análise mais detalhada é necessária. A Tabela 1 mostra que as duas safras sob efeito de estiagem, mesmo com intensidades diferentes, apresentam semelhança na dispersão dos valores de NDVI. Fica evidente, no entanto, como o aumento no desvio padrão da LST (Tabela 1), parametrizado em um período específico, é útil como indicador de um processo desfavorável de desenvolvimento da vegetação agrícola.

A Figura 6 mostra dados agregados das três safras analisadas, em uma relação da produtividade municipal da soja obtida do IBGE e comparada com a LST média municipal ($R^2=0,78$) e, a Figura 6b, ao NDVI médio municipal ($R^2=0,59$). Fica evidente que os maiores valores da LST (predominantemente da safra 2004/2005), estão as-

sociados às mais baixas produtividades, enquanto os menores valores do NDVI estão associados às menores produtividades. Os dados do NOAA/AVHRR evidenciam, nas Figuras 6a e 6b, que as médias municipais de temperaturas, acima de aproximadamente 306 K e NDVI menores que 0,5, estão associadas às mais baixas produtividades (menores que 1000Kg/ha), caracterizando uma condição específica no desenvolvimento da vegetação da cultura da soja no mês de fevereiro, com impactos na produção.

Rede de cooperação institucional: área de aplicação proposta

Dados diários, obtidos de antenas posicionadas sobre o território brasileiro, formadas por uma rede de cooperação institucional, se forem conjugados, podem fornecer informações valiosas, na tomada de decisão em tempo hábil, para aplicações agrícolas de quase todo o território agrícola nacional. A grande área abrange as Latitudes com coordenadas: 06° 00' S e 39° 00' S e as Longitudes: 65° 00' W, 36° 00' W (Figura 1). Outros estados de menor expressão agrícola e territórios estrangeiros de intensa produção de soja, como as regiões de Córdoba e Santa Fé, na Argentina, o Uruguai e o Paraguai, também poderiam ser monitorados. A área proposta de monitoramento nacional continuado abrange todos os Estados de maior expressão agrícola, como Bahia, Goiás, Mato Grosso, Mato Grosso do Sul, Minas Gerais, Paraná, Rio Grande do Sul, Santa Catarina e São Paulo.

Os mapas de variabilidade do NDVI e da LST (Figuras 7a e 7b) mostram a ampla área de aplicação proposta sobre o território brasileiro, na vigência de uma rede de cooperação institucional. Esta pode ser obtida como resultado da agregação de dados de imagens do NOAA/AVHRR. Salienta-se, na Figura 7b, a região centro norte do Estado do MT, GO e DF. Os valores moderados da LST, em novembro, são representativos de condições favoráveis de desenvolvimento da vegetação. No norte do PR, é possível observar focos de LST mais elevadas que são representativas do período de pré-plantio. A Figura 7b também mostra as amplitudes extremas da LST, em função das condições da vegetação e de cobertura do solo, notadamente em Estados do nordeste que não são evidenciadas quando analisados apenas os dados de ima-

Tabela 1. Estatística básica (média, desvio padrão, valor mínimo e máximo) da distribuição da nuvem de pontos nas safras analisadas entre LST (Land Surface Temperature) e NDVI (Normalized Difference Vegetation Index)

	Fevereiro 2003		Fevereiro 2004		Fevereiro 2005	
	LST (K)	NDVI	LST (K)	NDVI	LST (K)	NDVI
Média	301,02	0,65	303,68	0,66	308,36	0,53
Desv. Padrão	1,67	0,06	3,44	0,08	3,16	0,08
Mínimo	293,83	-0,03	295,01	-0,02	292,60	-0,07
Máximo	312,30	0,81	317,59	0,82	318,68	0,77

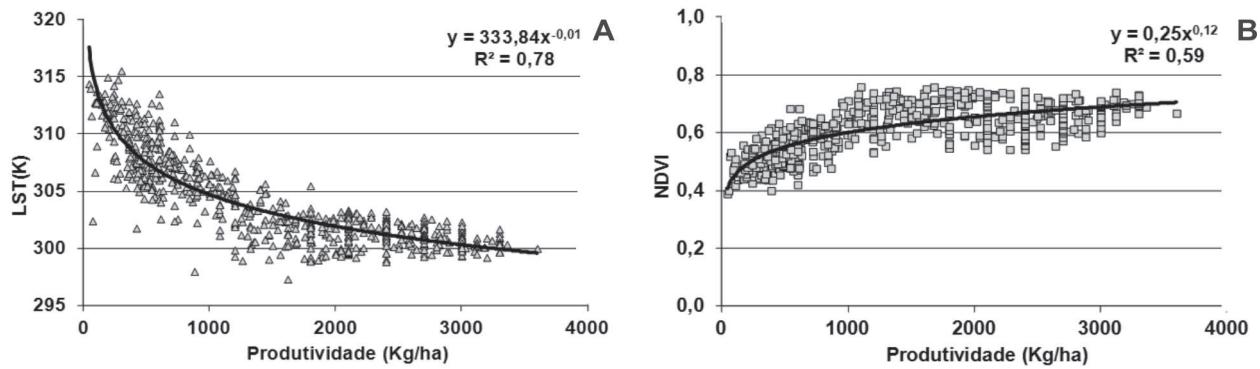


Figura 6a. Dados agregados das safras 2002/2003, 2003/2004 e 2004/2005, mostrando a variação da média municipal da LST em relação à produtividade municipal, obtida do IBGE. **Figura 6b.** Dados agregados das safras 2002/2003, 2003/2004 e 2004/2005, mostrando a variação da média municipal do NDVI em relação à produtividade municipal, obtida do IBGE.

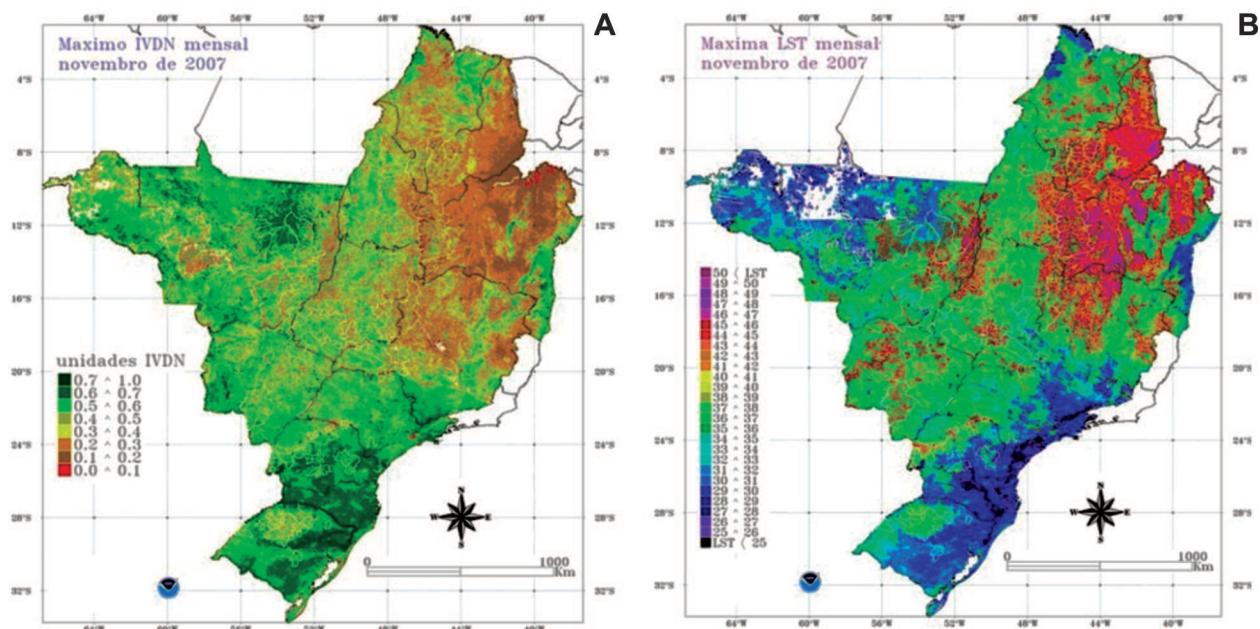


Figura 7a. Composição de máximo valor do NDVI mensal (novembro de 2007), obtidos pela agregação de imagens do INMET/Brasília e UFRGS/Porto Alegre. **Figura 7b.** Composição de máxima LST mensal (novembro de 2007), obtida com a agregação de imagens do INMET/Brasília e UFRGS/Porto Alegre.

gens de índices de vegetação. Esses aspectos térmicos da superfície terrestre e que caracterizam condições adversas para atividade rural, como as observadas na região nordeste, podem assim ser analisados mais adequadamente pelos tomadores de decisão com vistas ao desenvolvimento de políticas públicas mais eficazes.

CONCLUSÕES

A relação matemática inversa que se evidencia, neste trabalho, entre o NDVI e a LST associada à produtividade, confirma a expectativa teórica.

Sensores NOAA/AVHRR têm grande potencial na caracterização espacial e temporal das condições intermediárias de desenvolvimento das safras agrícolas.

A sensibilidade introduzida pela variável LST ($R^2=0,78$), analisada neste estudo, revela ser um indicador útil dos diferentes níveis das condições da vegetação, quando em processo desfavorável de desenvolvimento, sugerindo que esta é uma abordagem robusta e promissora. Assim, esta abordagem pode ser explorada para outras regiões produtoras do país, principalmente como indicador espacial de queda na produtividade. Entretanto, é de grande importância realizar estudos adicionais que contemplem o acompanhamento do processo de estresse hídrico, associado, ou não à ocorrência de ondas de calor a partir do início da safra, de maneira a permitir avaliação mais detalhada da vulnerabilidade frente a esse componente físico e seus impactos na sustentabilidade da produção agrícola.

AGRADECIMENTOS

À Fundação Estadual de Pesquisa Agropecuária do Rio Grande do Sul (FEPAGRO), à Universidade Federal do Rio Grande do Sul (UFRGS), ao Instituto Nacional de Meteorologia (INMET) e à Universidade de Campinas (UNICAMP). Em especial aos Editores e revisores anônimos pelas valiosas contribuições.

REFERÊNCIAS

- Allen CD, Macalady AK, Chenchouni H, Bachelet D, McDowell N, Vennetier M, Kitzberger T, Rigling A, Breshears DD, Hogg EH, Gonzalez P, Fensham R, Zhangm Z, Castro J, Demidova N, Lim J-H, Allard G, Running SW, Semerci A & Cobb N (2010) A global overview of drought and heat-induced tree mortality reveals emerging climate change risks for forests. *Forest Ecology and Management*, 259:660–684.
- Board JE & Kahlon CS (2011) Soybean yield formation: what controls it and how it can be improved. In: El-Shemy, H.A. (Ed.) *Soybean Physiology and Biochemistry*, InTech Open Access Publisher, Rijeka, Croatia, 1-36.
- Batistti DS & Naylor RL, (2009) Historical warnings of future food insecurity with unprecedeted seasonal heat. *Science*, 323:240-244.
- Brando PM, Goetz SJ, Baccini A, Nepstad DC, Beck PSA & Christman MC (2010) Seasonal and interannual variability of climate and vegetation indices across the Amazon. *Proceedings of National Academy of Science of USA*, 107:14685-14690.
- Buriol GA, Estefanel V & Ferreira M (1977) Cartas mensais e anual das chuvas do Estado do Rio Grande do Sul. *Revista do Centro de Ciências Rurais*, 7:55-82.
- Carmo-Silva AE, Gore MA, Andrade-Sanchez P, French AN, Hunsaker DJ & Salvucci ME (2012) Decreased CO₂ availability and inactivation of Rubisco limit photosynthesis in cotton plants under heat and drought stress in the field. *Environmental and Experimental Botany*, 83:1-11.
- Chen PY, Srinivasan R, Fedosejevs G & Narasimhan B (2002) An automated cloud detection method for daily NOAA-14 AVHRR data for Texas, USA. *International Journal of Remote Sensing*, 23:2939-2950.
- Esquerdo JCDM, Zullo J, & Antunes, JFG (2011) Use of NDVI/AVHRR time-series profiles for soybean crop monitoring in Brazil. *International Journal of Remote Sensing*, 32:3711-3727.
- Figueiredo DC (2005) Projeto GeoSafras - aperfeiçoamento do sistema de previsão de safras da CONAB. *Revista de Política Agrícola*, 14:110-120.
- Fontana DC, Weber E, Ducati JR, Berlato MA, Guasselli LA & Gusso A (2002) Monitoramento da cultura da soja no centro-sul do Brasil durante La Niña de 1998/2000. *Revista Brasileira de Agrometeorologia*, 10:343-351.
- Fontana DC, Berlato MA, Lauschner MH & Melo RW (2001) Modelo de estimativa de rendimento de soja no Estado do Rio Grande do Sul. *Pesquisa Agropecuária Brasileira*, 36:399-403.
- Friedl MA & Davis FW (1994) Sources of variation in radiometric surface temperature over a tallgrass prairie. *Remote Sensing of Environment*, 48:1-17.
- Goetz SJ (1997) Multi-sensor analysis of NDVI, surface temperature and biophysical variables at a mixed grassland. *International Journal of Remote Sensing*, 18:71-94.
- Gupta RK, Prasad S, Sesha-Sai MVR & Viswanadham TS (1997) The estimation of surface temperature over an agricultural area in the state of Haryana and Panjab, India, and its relationship with the Normalized Difference Vegetation Index (NDVI), using NOAA-AVHRR data. *International Journal of Remote Sensing*, 18:3729-3741.
- Gusso A, Formaggio AR, Rizzi R, Adami M & Rudorff BFT (2012) Method for soybean area estimation based on multi-temporal MODIS/EVI images. *Pesquisa Agropecuária Brasileira*, 47:425-435.
- Gusso A, Fontana DC & Gonçalves GA (2007) Mapeamento da temperatura da superfície terrestre com uso do sensor NOAA/A VHRR. *Pesquisa Agropecuária Brasileira*, 42:231-237.
- Holben BN (1986) Monitoring characteristics of maximum-value composite images from temporal AVHRR data. *International Journal of Remote Sensing*, 7:1417-1434.
- IBGE (2010). Sistema IBGE de Recuperação Automática. Disponível em: <<http://www.sidra.ibge.gov.br/>>. Acessado em: 05 de setembro de 2010.
- Karniel A, Nurit A, Pinker TR, Anderson M, Imhoff ML, Gutman GG, Panov N & Goldberg A (2010) Use of NDVI and Land Surface Temperature for Drought Assessment: Merits and Limitations. *Journal of Climate*, 23:618-633.
- Kogan FN (2001) Operational space technology for global vegetation assessment. *Bulletin of American Meteorological Society*, 82:1949-1964.
- Kogan FN (2002) World droughts in the millennium from AVHRR-based vegetation health indices. *Eos, Transactions, American Geophysical Union*, 83:557-564.
- Kogan FN, Gitelson A, Zakarin E, Spivak L & Lebed L (2003) AVHRR-Based Spectral Vegetation Index for Quantitative Assessment of Vegetation State and Productivity: Calibration and Validation. *Photogrammetric Engineering & Remote Sensing*, 69:899-906.
- Köppen W (1948) Climatología: con un Estudio de los Climas de la Tierra. Fondo de Cultura Económica. México. 466p.
- Lambin EF & Ehrlich D (1995) Combining vegetation indices and surface temperature for land-cover mapping at broad spatial scales. *International Journal of Remote Sensing*, 16:573-579.
- Lobell DB, Burke MB, Tebaldi C, Mastrandrea MD, Falcon WP & Naylor RL (2008) Prioritizing climate change adaptation needs for food security in 2030. *Science*, 319:607-609.
- Liu WT & Kogan F (2002) Monitoring Brazilian soybean production using NOAA/A VHRR based vegetation indices. *International Journal of Remote Sensing*, 23:1161-1180.
- Melo RW (2003) Desenvolvimento de um modelo agrometeorológico-espectral de estimativa do rendimento da soja para o Estado do Rio Grande do Sul. Dissertação de Mestrado. Universidade Federal do Rio Grande do Sul, Porto Alegre. 130p.
- Melo RW, Fontana DC & Berlato MA (2004) Indicadores de produção de soja no Rio Grande do Sul comparados ao zoneamento agrícola. *Pesquisa Agropecuária Brasileira*, 39:1167-1175.
- Moran MS, Clarke TR, Inoue Y & Vidal A (1994) Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. *Remote Sensing of Environment*, 49:246-263.
- Nemani R & Running S (1997) Land cover characterization using multi-temporal Red, Near-IR and thermal-IR data from NOAA/A VHRR. *Ecological Applications*, 7:79-90.
- Nemani R, Pierce L, Running S & Goward S (1993) Developing satellite-derived estimates of surface moisture status. *Journal of Applied Meteorology*, 32:548-557.

- Ouaidrari H, Goward SN, Czajkowski KP, Sobrino JA & Vermote E (2002) Land surface temperature estimation from AVHRR thermal infrared measurements: An Assessment for the AVHRR Land Pathfinder II Data Set. *Remote Sensing of Environment*, 81:114-128.
- Pinto HS (2009) Adaptation in the brazilian agricultural sector. In: Marengo, JA (Ed.) *Climate change, extreme weather and climate events in Brazil*. Lloyd's Group Report. p. 35-51.
- Peterson TC, Stott PA & Herring S (2012) Explaining extreme events of 2011 from a climate perspective. *Bulletin of the American Meteorological Society*, 93:1041-1067.
- Rao CRN & Chen J (1999) Revised post-launch calibration of the visible and near-infrared channels of the Advanced Very High Resolution Radiometer on board the NOAA-14 spacecraft. *International Journal of Remote Sensing*, 20:3485-3491.
- Rouse JW, Haas RH, Schell JA, Deering DW & Harlan JC (1974) Monitoring the vernal advancement and retrogradation (greenwave effect of natural vegetation), Report. Disponível em: <http://archive.org/details/nasa_techdoc_19740022555>. Acessado em: 27 de março de 2011.
- Sandholt L, Rasmussen K, Andersen J (2002) A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment*, 79:213-224.
- Sims DA, Rahman AF, Cordova VD, El-Masri BZ, Baldocchi DD, Bolstad PV, Flanagan LB, Goldstein AH, Hollinger DY, Misson L, Monson RK, Oechel WC, Schmid HP, Wofsy SC & Xu L (2008) A new model of gross primary productivity for North American ecosystems based solely on the enhanced vegetation index and land surface temperature from MODIS. *Remote Sensing of Environment*, 112:1633-1646.
- Siqueira OJW, Steinmetz S, Ferreira MF, Costa AC, Wozniak MA (2000) Mudanças climáticas projetadas através dos modelos GISS e reflexos na produção agrícola brasileira. *Revista Brasileira de Agrometeorologia*, 8:311-320.
- Sobrino JA, Raissouni N & Li Z-L (2001) A comparative study of land surface emissivity retrieval from NOAA data. *Remote Sensing of Environment*, 75:256-266.
- Streck NA & Alberto CM (2006) Estudo numérico do impacto da mudança climática sobre o rendimento de trigo, soja e milho. *Pesquisa Agropecuária Brasileira*, 41:1351-1359.
- Sullivan JT (1999) New radiance-based method for AVHRR thermal channel nonlinearity corrections. *Journal of Remote Sensing*, 20:3493-3502.
- UNEP (2009). The Environmental Food Crisis. Disponível em: <<http://www.grida.no/publications/rr/food-crisis/>>. Acessado em: 20 de novembro de 2011.
- Wan Z, Wang P & Li X (2004) Using MODIS Land Surface Temperature and Normalized Difference Vegetation Index products for monitoring drought in the southern Great Plains, USA. *International Journal of Remote Sensing*, 25:61-72.

Soybean crop area estimation by Modis/Evi data

Anibal Gusso⁽¹⁾, Antônio Roberto Formaggio⁽¹⁾, Rodrigo Rizzi⁽²⁾, Marcos Adami⁽¹⁾
and Bernardo Friedrich Theodor Rudorff⁽¹⁾

⁽¹⁾Instituto Nacional de Pesquisas Espaciais, Caixa Postal 515, CEP 12245-970 São José dos Campos, SP, Brazil. E-mail: anibal.gusso@inpe.br, formag@dsr.inpe.br, adami@dsr.inpe.br, bernardo@dsr.inpe.br ⁽²⁾Universidade Federal de Pelotas, Caixa Postal 354, CEP 96001-970 Capão do Leão, RS, Brazil. E-mail: rodrigo.rizzi@ufpel.edu.br

Abstract – The objective of this work was to develop a procedure to estimate soybean crop areas in Rio Grande do Sul state, Brazil. Estimations were made based on the temporal profiles of the enhanced vegetation index (Evi) calculated from moderate resolution imaging spectroradiometer (Modis) images. The methodology developed for soybean classification was named Modis crop detection algorithm (MCDA). The MCDA provides soybean area estimates in December (first forecast), using images from the sowing period, and March (second forecast), using images from the sowing and maximum crop development periods. The results obtained by the MCDA were compared with the official estimates on soybean area of the Instituto Brasileiro de Geografia e Estatística. The coefficients of determination ranged from 0.91 to 0.95, indicating good agreement between the estimates. For the 2000/2001 crop year, the MCDA soybean crop map was evaluated using a soybean crop map derived from Landsat images, and the overall map accuracy was approximately 82%, with similar commission and omission errors. The MCDA was able to estimate soybean crop areas in Rio Grande do Sul State and to generate an annual thematic map with the geographic position of the soybean fields. The soybean crop area estimates by the MCDA are in good agreement with the official agricultural statistics.

Index terms: *Glycine max*, algorithm, crop area, mapping, temporal profile.

Estimativa de áreas de cultivo de soja por meio de dados Modis/Evi

Resumo – O objetivo deste trabalho foi desenvolver uma metodologia para estimar a área plantada de soja no Estado do Rio Grande do Sul. As estimativas foram feitas com base no perfil temporal do "enhanced vegetation index" (Evi) calculado a partir de imagens "moderate resolution imaging spectroradiometer" (Modis). A metodologia desenvolvida para a classificação da soja foi denominada "Modis crop detection algorithm" (MCDA). O MCDA fornece estimativas de área da soja em dezembro (primeira previsão), com imagens do período de plantio, e em março (segunda previsão), com imagens dos períodos de plantio e de máximo desenvolvimento vegetativo. Os resultados do MCDA foram comparados às estimativas oficiais de área de soja do Instituto Brasileiro de Geografia e Estatística. Os coeficientes de determinação variaram de 0,91 a 0,95, o que indica bom ajuste entre as estimativas. Para a safra 2000/2001, o mapa da cultura da soja gerado pelo MCDA foi avaliado com um mapa da cultura da soja oriundo de imagens Landsat, e a precisão global do mapa foi de aproximadamente 82%, com erros similares de comissão e omissão. O MCDA foi capaz de estimar a área plantada com soja no Estado do Rio Grande do Sul e gerar mapas temáticos anuais com a localização geográfica dos talhões. As estimativas de área plantada a partir do MCDA estão em concordância com as estatísticas agrícolas oficiais.

Termos para indexação: *Glycine max*, algoritmo, área agrícola, mapeamento, perfil temporal.

Introduction

The globalized market of agricultural commodities requires precise and timely information on crop production for decision makers. The agricultural production of Brazil has an important role in the world commodities market. Therefore, it is relevant to develop objective methods that can provide precise and timely estimates of crop production. The Companhia Nacional de Abastecimento (Conab) and the Instituto Brasileiro

de Geografia e Estatística (IBGE) are responsible for the country's official agricultural statistics. However, these estimates are based on subjective methods.

In Brazil, remote sensing satellite data have already shown adequate performance for some routine mappings of perennial and semi-perennial crops, such as sugarcane (Rudorff et al., 2005, 2010) and coffee (Moreira et al., 2010). However, the high incidence of cloud cover during key identification periods of annual crops on Landsat-type images has hindered

its operational use in providing agricultural statistics for those crops (Sano et al., 2007; Sugawara et al., 2008). A potential solution to overcome cloud cover is to increase the temporal resolution of orbital sensors, but there may be a reduction in spatial resolution due to technical constraints. Currently, the moderate resolution imaging spectroradiometer (Modis) sensor, on board of the Terra and Aqua satellites, combines an almost-daily revisit with a moderate spatial resolution of 250 m, which are favorable characteristics to map crops, such as soybean, cultivated in large scale. In addition, the geometric quality of the images allows the composition of time series data that guarantee the correct pixel geolocation (Justice et al., 2002; Wolfe et al., 2002).

Many studies have explored the potential of Modis imagery for agricultural crop surveys and monitoring. Lobell & Asner (2004) evaluated the impact of land use heterogeneity and soil cover on the classification of agricultural crop areas with Modis data and observed that the mean square error (MSE) decreases as the field size increases, tending to stabilize for fields larger than 500 ha. These authors also concluded that Modis images have considerable advantages over Landsat ones in the characterization of extensive agricultural crops, mainly due to their higher temporal resolution.

Sakamoto et al. (2005) used time series of the enhanced vegetation index (Evi), obtained from Modis images, to monitor the phenology of rice crop in Japan and observed that the phenological stages can be determined within a mean error of 9 to 12 days. Doraiswamy et al. (2005), while assessing the quality of Modis data to provide information on both crop yield and area, estimated biophysical parameters from Modis images that were integrated into crop growth models, providing significant improvement in grain yield estimates. These authors also found that the overall mapping accuracy was 96.7%, when compared to a Landsat map. In the USA, Wardlow et al. (2007) investigated the applicability of Modis/Evi time series data to map agricultural lands and concluded that the 16-day composites of Modis images gave sufficient spatial, spectral, and temporal information to adequately separate crop fields from other land uses, and to express the phenology and climate characteristics of the region.

In Brazil, specifically in Rio Grande do Sul State, Rudorff et al. (2007) evaluated the potential of Modis images to identify and map soybean crops using the

temporal-spectral response surface method developed by Vieira (2000). These authors observed that the mapping accuracy was dependent on the mean field size, in agreement with the results obtained by Lobell & Asner (2004). Also in Brazil, Epiphanio et al. (2010) used Modis in the same temporal-spectral response surface approach (Vieira, 2000) for mapping soybean in Mato Grosso State, in a region of plain relief and large fields, and found overall accuracy of 80%. D'Arco et al. (2007) used Modis vegetation indices to classify rice crop in the municipality of Santa Vitória do Palmar, RS, Brazil, and obtained best results with images from three specific crop growth periods. However, none of these studies have yet provided timely soybean area estimates. Furthermore, most of the researches are limited to only one crop year or region, indicating the potential of Modis data for crop forecast, but not its usefulness within a routine and systematic crop forecast system.

In this sense, the relative long-term Modis/Evi time series data now available, with its valuable spatial information on spectral-temporal crop growth profile, could be used to estimate cultivated soybean area for local and regional-scale operational crop forecasts. The Modis sensor on board of the Terra satellite completed, on 12/18/2009, a ten-year history of systematic global data acquisition with high-temporal, moderate-spatial, and improved spectral resolution (Justice et al., 2002), as well as correct geolocation of image pixels (Wolfe et al., 2002).

The objective of this work was to develop a procedure to estimate soybean crop areas in Rio Grande do Sul State, Brazil, based on temporal profiles of the Evi calculated from Modis images.

Materials and Methods

Soybean production was evaluated in Rio Grande do Sul state, Brazil, using a validation area of 223 municipalities in the north of the state (Figure 1). The region's climate is subtropical with four well-defined seasons. The average annual rainfall is 1,500 mm, relatively well distributed throughout the year, but with some dry periods. The sowing calendar for soybean goes from early October to late December, based on agricultural zoning for different soils, regions, and cultivars (Cunha et al., 2001). Depending on the sowing date, maximum plant growth is observed from late January to early March.

Three test sites located in intensive soybean production areas were used to define the sowing and maximum growth periods (Figure 1), which are key information to extract the correct parameters from the Modis/Evi values for the soybean area estimation procedure proposed in the present study.

Different types of data were used: yearly rainfall data (2000 to 2009), determined by the ten-day accumulated rainfall data of 16 meteorological stations, from September to October, from the Fundação Estadual de Pesquisa Agropecuária, which were used to refine the period of initial sowing; shuttle radar topography mission (SRTM) data, to generate a slope map with a 90-m spatial resolution, according to Rabus et al. (2003), in order to exclude areas improper for mechanization (slope >15%); a soil map (Instituto Brasileiro de Geografia e Estatística, 1986) in a 1:250,000 scale, to exclude the unfavorable soils for soybean cultivation (all Planosol and Plinthosol; BT1, BT2, BT3, BT4, BT5, BT6, BT7, and BT9 sub-classes of Chernosol; Ge, GHS2, GS1, GS2, GHe1, GHe2, and GHe3 sub-classes of Gleisol; Re1, Re2, Re6, Re7, Re9, Ae1, and Ae2 sub-classes of Neosol; and V1 and V3 sub-classes of Vertisol); annual soybean agricultural statistics, in state and municipality level (Instituto Brasileiro de Geografia e Estatística, 2009)

for the entire study area, which were used to compare and evaluate the results obtained from the proposed soybean area estimation procedure; a soybean reference thematic map, available for the 2000/2001 crop year (Rizzi & Rudorff, 2005), obtained from multitemporal TM/Landsat images analysis, in a 30-m spatial resolution, to evaluate the Modis/Evi soybean thematic map developed in this procedure; Evi data from 2000 to 2009, derived from the Modis sensor on board of the Terra satellite, product MOD13Q1-collection 5; and TM images, obtained from the Instituto Nacional de Pesquisas Espaciais (2010).

The Evi data were chosen due to their potential ability to reduce atmospheric and soil background effects (Huete et al., 2002; Justice et al., 2002). The Evi is part of the MOD13Q1-V005 product, which comprises the best radiometric and geometric pixels selected within a 16-day period. The Evi formulation is $2.5(\text{Nir} - \text{Red}) / (\text{Nir} + 6\text{Red} - 7.5\text{Blue} + 1)$, in which: Nir, Red, and Blue are atmospherically or partially-atmospherically corrected surface reflectance of near infrared, red, and blue bands, respectively (Huete et al., 2002). The Modis images and its products were preprocessed by the National Aeronautics and Space Administration (Nasa) and are available at no charge at the National Aeronautics and Space Administration (2009).

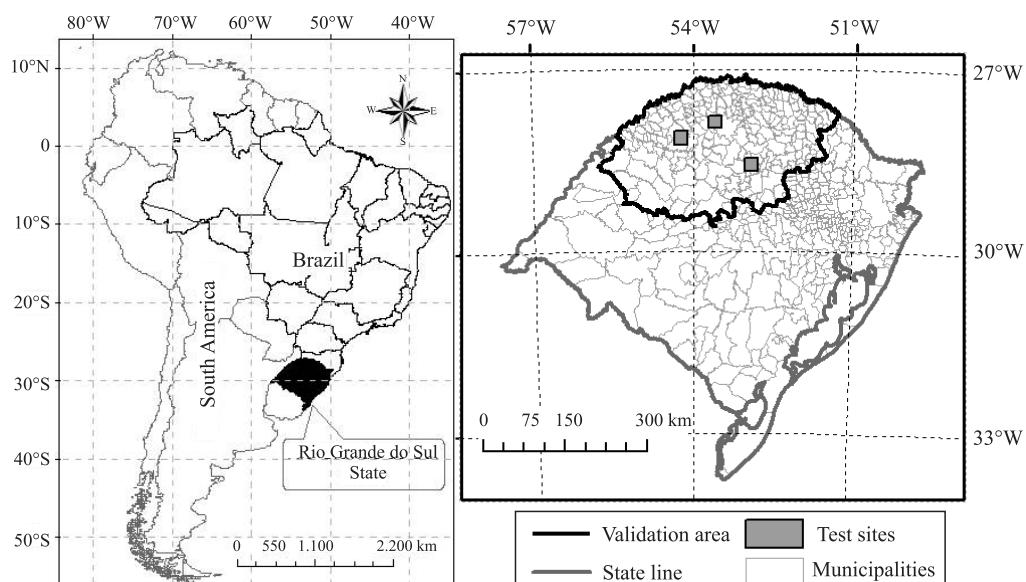


Figure 1. Rio Grande do Sul state, Brazil, and its 497 municipalities, indicating the validation area (223 municipalities) and the three test sites.

The SRTM data were used to generate the land slope variable in order to exclude all areas with slope greater than 15% from the analysis, since soybean is a highly mechanized crop and requires relative smooth land to allow the traffic of farm implements. Areas from hydromorphic soils were also excluded from the analysis because they are mainly recommended for flooded rice cultivation (D'Arco et al., 2007).

In the present study, the procedure developed for soybean classification was named Modis crop detection algorithm (MCDA), for which a diagrammatic flowchart was created (Figure 2). According to this procedure, a pixel is classified as soybean if it adheres to both A and B conditions. To establish these two conditions, the soybean Evi temporal profile is expected to have low values during the sowing period and high values at maximum crop development.

The set of initial parameters was obtained from the Modis/Evi images of three test sites of 100x100 pixels (Figure 1), during two specific periods: sowing (day of year, DOY, 273 to 337) and maximum crop development (DOY 1 to 65). The sowing period for each crop year was also defined based on rainfall data, in agreement with the soybean zoning provided by Brasil (2010). In the study area, the sowing period normally starts in October.

Two Modis/Evi images from the sowing period were averaged to obtain the minimum mean Evi image (Figure 3), which was used to define the lower (L_{min}) and upper (U_{min}) thresholds of the Evi values for each crop year. Pixels below L_{min} are typically associated to cloud shadows or water bodies. U_{min} was set at the convergence between minimum and maximum mean Evi images (Figure 3). Pixels above U_{min} will start to

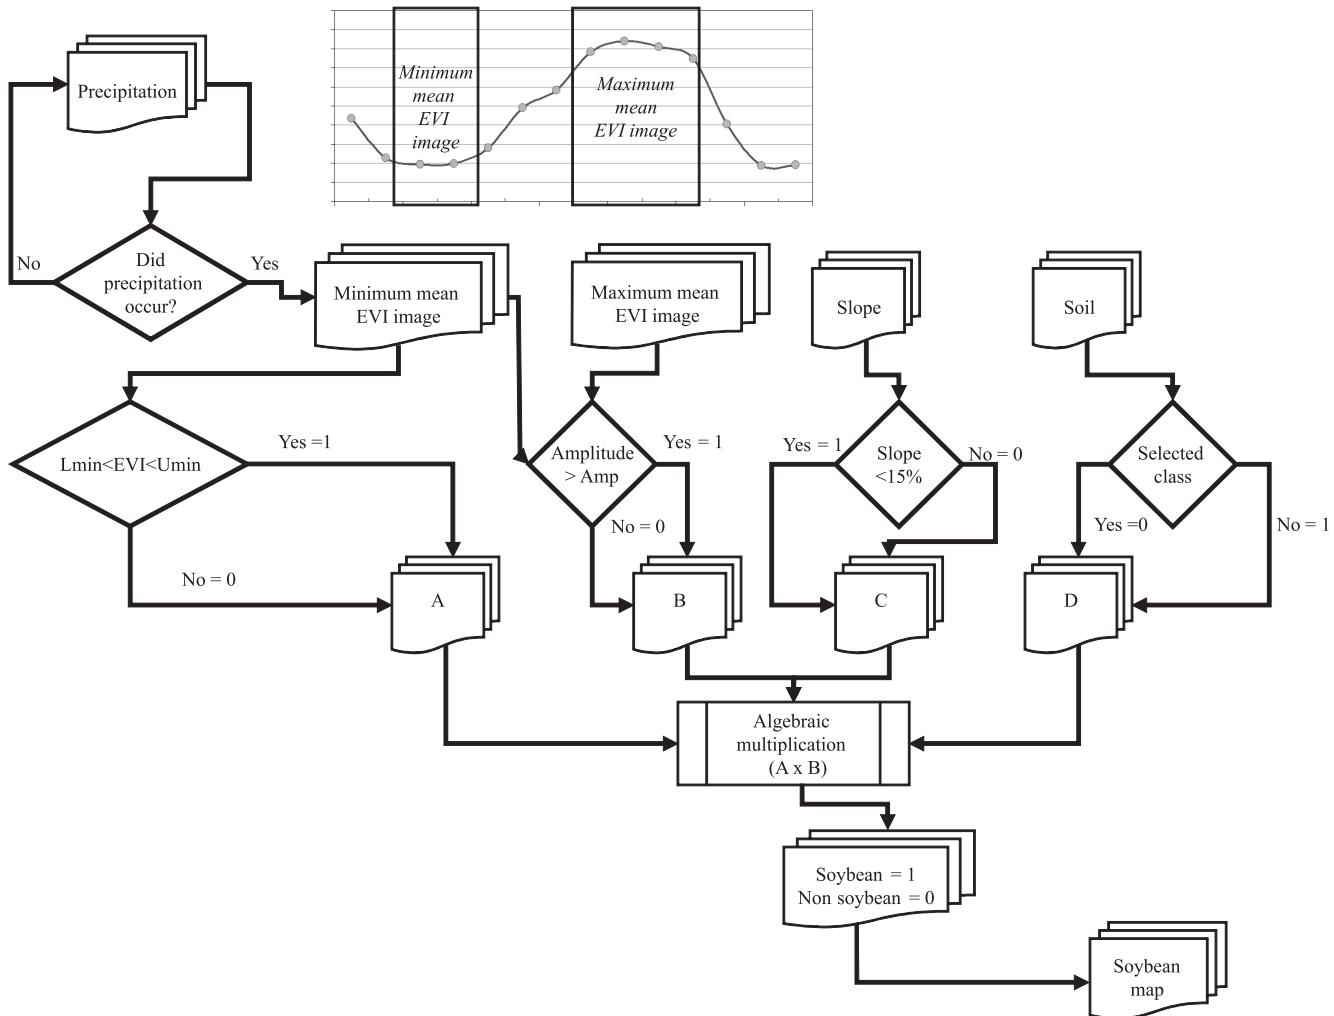


Figure 2. Flowchart of the MCDA classification based on the Modis/Evi images.

overlap with pixels that are not from annual crops. The initial nine Lmin and Umin values from 2000/2001 to 2008/2009 and the average value that was used in the MCDA are shown in Table 1. Pixels with Evi values between Lmin and Umin were tagged as soybean, according to the A condition (Figure 2).

Following the sowing period, a rapid increase of the Modis/Evi values was observed due to intense plant growth, reaching maximum values in a relative short period (Wardlow et al., 2007). Three consecutive Evi images from the plant growth period (DOY 1 to 65; Figure 4) were used to obtain the maximum mean Evi image. The difference between the maximum and minimum mean Evi images was used to obtain the Evi amplitude image (Amp). The challenge is to obtain the best Amp value that includes not only pure soybean pixels with high values in the maximum Evi image and low values in the minimum Evi image, but also mixed pixels located at the border of soybean fields. The Amp value for each crop year was chosen at the convergence region between minimum and maximum Evi values in the scatterplots (Figure 3), i.e., the minimum difference

between maximum and minimum mean Evi values to which a mixed soybean pixel can be tagged as soybean. The initial nine selected Amp values from 2000/2001 to 2008/2009 and the average value used in the MCDA procedure are shown in Table 1. Pixels with amplitude values greater than Amp were tagged as soybean, according to the B condition of the MCDA procedure (Figure 2).

After the first run of the MCDA procedure, Landsat satellite images (Table 2), in which soybean fields are easily identified, were used to interactively refine the most appropriate values of Lmin, Umin, and Amp in order to minimize omission and commission errors.

Since the soybean area was overestimated for the first run of the MCDA, when the Landsat images and the classification maps were overlapped, a second run was performed, adjusting the values of Umin and Amp. For each combination of Amp and Umin, new soybean classifications were generated, which were visually compared with the correspondent available Landsat images (Table 2). After several interactions, for several crop years, and comparing the results of each new

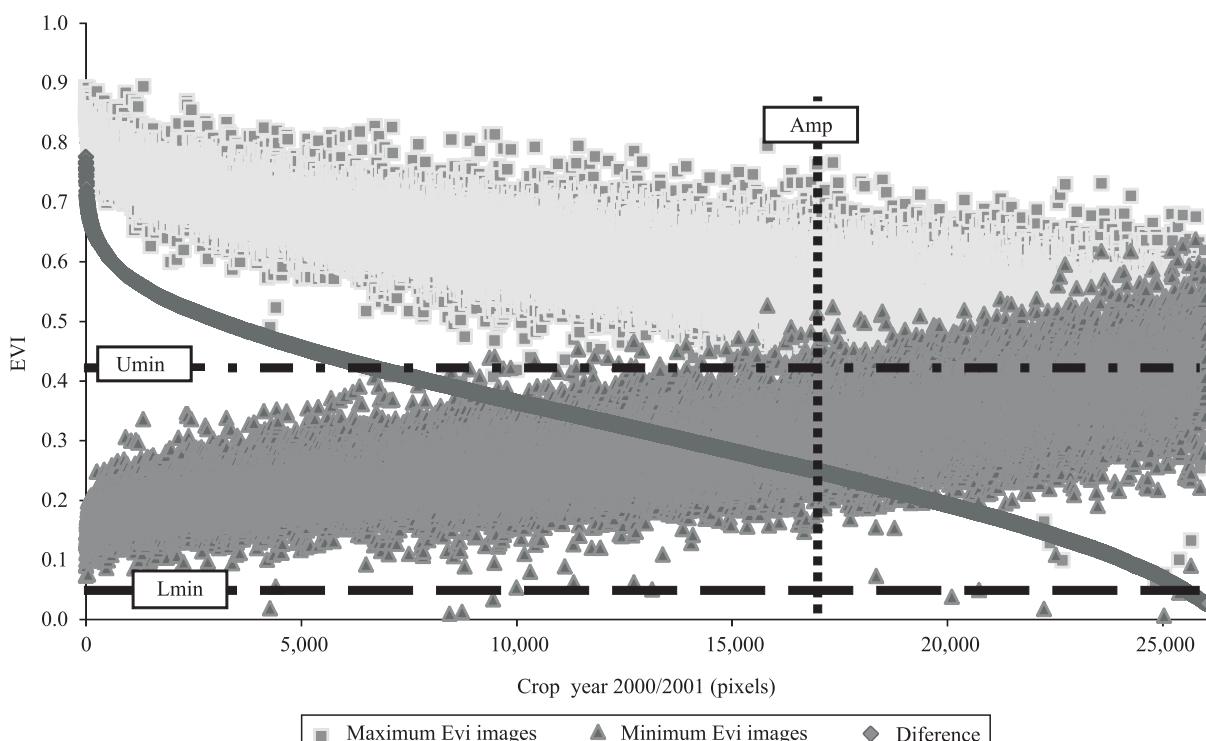


Figure 3. Scatterplot of 2000/2001 with minimum and maximum Evi values from the three test sites (30,000 pixels), showing symmetry and intersection lines to estimate the initial values of upper (Umin) and lower (Lmin) thresholds, and amplitude image (Amp), sorted downhill by difference.

MCDA classification faced with Landsat images, the combination with best performance to define the final values of the MCDA were 0.05, 0.47, and 0.21 for Umin, Lmin, and Amp, respectively. It should be emphasized that the parameters defined in the MCDA are the same for all of the analyzed crop years.

Soybean area estimation can be provided right after the maximum mean Evi image is available, which normally occurs in early February. A delay of about 20 days is expected in order to acquire the MOD13Q1 product, and, therefore, soybean estimation should be

Table 1. Annual values of lower (Lmin) and upper (Umin) thresholds, and amplitude image (Amp) extracted from the minimum and maximum Evi values from the three test sites (30,000 pixels), and average values initially used in the MCDA procedure.

Crop year	Lmin	Umin	Amp
2001	0.05	0.42	0.24
2002	0.05	0.44	0.25
2003	0.05	0.45	0.25
2004	0.05	0.49	0.29
2005	0.05	0.51	0.32
2006	0.05	0.46	0.25
2007	0.05	0.47	0.24
2008	0.05	0.47	0.28
2009	0.05	0.48	0.27
Average	0.05	0.47	0.26

released no later than early March (second forecast of the MCDA). However, as an alternative to forecast the soybean area, a first estimate can be provided in mid-December of each crop year, based on the minimum mean Evi image of the current crop year and the maximum mean Evi image of a previous crop year (first forecast of the MCDA). If no usable images are found or a water deficit is observed (30 days without rainfall above 10 mm), images from previous normal crop years can be used to generate the maximum mean Evi image. For the 2000/2001 crop year, there was no first forecast of the MCDA due to unavailable Modis data. In order to generate the maximum mean Evi image in each crop year, 16-day Modis/Evi composites were selected (Table 3). The mean temporal Evi was determined for profiles of soybean, corn, and rice acquired over crop fields, which coexist in the evaluated area (Figure 4).

Soybean area was also estimated by municipality from 2000/2001 to 2008/2009 and compared to the official estimates provided by the Instituto Brasileiro de Geografia e Estatística (2009), using regression analysis. The performance of the MCDA was evaluated using a thematic soybean map elaborated from multitemporal Landsat images for the 2000/2001 crop year (Rizzi & Rudorff, 2005). The confusion matrix and the overall map accuracy were provided.




Figure 4. Mean and standard deviation of Modis/Evi data for selected points of soybean, corn, and rice crops.

Results and Discussion

The MCDA soybean area estimates for the first and second forecasts agreed well with the IBGE estimates, with a maximum difference of 5.5%, from 2001/2002 to 2008/2009 (Figure 5). The MCDA soybean area estimates provided at a municipal level, due to the spatial distribution of the classified soybean area, were compared to the IBGE municipal statistics, which are only published about a year after the end of the soybean season. No early estimate could be provided for the 2000/2001 crop season, as this was the first crop year in which the Modis data became available. Therefore, compared to the current official methods for soybean area estimation in Brazil, the MCDA procedure represents a considerable improvement in time and in spatial information.

The linear least squares regression analysis was done for the municipal soybean estimates obtained from the MCDA (dependent variable) and from IBGE (independent variable) for the 2000/2001 to the 2006/2007 crop years, since the municipal

information for 2007/2008 and 2008/2009 had not yet been released by IBGE (Table 4). The coefficients of determination (R^2) ranged from 0.91 to 0.94, indicating good agreement between the estimates. The test of $b_0 = 0$ indicated that b_0 was significantly different from zero ($\alpha = 0.05$) for all tested crop years. Generally, this value was around -700 ha, indicating that municipalities with small soybean area are underestimated by the MCDA in relation to the IBGE statistics. The test of $b_1 = 1$ indicated that b_1 was significantly different from 1 ($\alpha = 0.05$) for all tested crop years, with most values around 1.10, which indicates that the MCDA overestimated the soybean area in relation to IBGE for municipalities with large soybean areas. The root mean square error (RMSE) for both forecasts of the MCDA, in all crop years, was around 4,000 ha, indicating that the MCDA estimates are consistent. Chang et al. (2007) compared soybean area estimates generated by Modis and by the National Agricultural Statistics Service of the United States Department of Agriculture and observed R^2 values ranging from 0.44 to 0.94 and RMSE varying from 41,465 to 120,955 ha for the entire USA.

When comparing the MCDA estimates with the results obtained by Rizzi & Rudorff (2005), which used Landsat satellite images to estimate the soybean area in Rio Grande do Sul, Brazil, for the 2000/2001 crop year, it was noted that the two estimates are in good agreement with an overestimation of 5% by the MCDA. The soybean map obtained by Rizzi & Rudorff (2005) (Figure 6 A) and by the MCDA for the second forecast, for the 2000/2001 crop year (Figure 6 B), were overlapped (Figure 6 C and D), indicating the areas of agreement (green), omission (black) and commission errors (red). The major errors are associated with the field boundaries that were mapped

Table 2. Dates of selected Landsat images for visual inspection during the interactive fitting phase.

Crop year	Path/Row	
	222/79	221/80
2001	Jan. 1 and Feb. 25	-
2002	-	-
2003	-	-
2004	Feb. 2	Jan. 26 and Feb. 27
2005	Feb. 20	-
2006	Feb. 23	-
2007	Feb. 26	Feb. 3
2008	Feb. 13 and Mar. 16	Mar. 9
2009	Mar. 3	Mar. 28

Table 3. Selected Modis/Evi for each crop year.

Crop year	Minimum Evi images				Maximum Evi images					
	Year	DOY ⁽¹⁾	Year	DOY	Year	DOY	Year	DOY	Year	DOY
2000/2001	2000	257	2000	273	2000	49	2001	17	2001	49
2001/2002	2001	257	2001	273	2001	17	2001	49	2002	49
2002/2003	2002	273	2002	289	2002	49	2003	33	2003	49
2003/2004	2003	273	2003	289	2003	33	2003	49	2004	33
2004/2005	2004	273	2004	289	2003	33	2003	49	2004	33
2005/2006	2005	257	2005	273	2003	49	2004	33	2006	17
2006/2007	2006	257	2006	273	2004	33	2006	17	2007	33
2007/2008	2007	273	2007	289	2006	17	2007	33	2008	33
2008/2009	2008	273	2008	289	2007	33	2008	33	2009	33

⁽¹⁾DOY, day of year.

in greater detail by Rizzi & Rudorff (2005), due to the much better spatial resolution of Landsat in comparison to Modis images (Figure 6 D). In fact, fields with smaller areas were more subject to errors than those with larger areas, in agreement with Lobell & Asner (2004) and Rudorff et al. (2007).

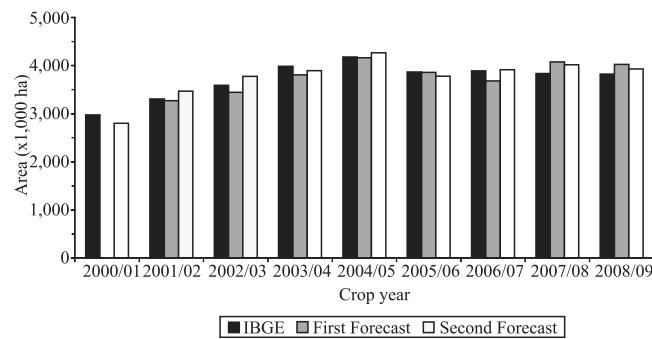


Figure 5. Comparison between the MCDA (first and second forecasts) and the IBGE soybean area estimates for Rio Grande do Sul State, Brazil.

The comparison between the mapping provided by Rizzi & Rudorff (2005) and the MCDA procedure generated with Modis/Evi data, in the second forecast, resulted in a confusion matrix (Table 5). Despite the moderate spatial resolution of the Modis and the soybean field size heterogeneity, the overall map accuracy was approximately 82%, which indicates good agreement between those maps. The user's (commission) and producer's (omission) accuracy for the soybean class are similar, which indicates that these errors tend to cancel each other and that the estimates of total areas by municipality are near the actual value. Similar results were obtained by Rudorff et al. (2007) in the same study area.

It is important to point out that the parameters defined in the MCDA for the detection of crop areas are constant, as a fixed criteria, independently of the soybean crop area increases and of the dynamics of the crop years in Rio Grande do Sul State during the evaluated period, from the 2000/2001 to the 2008/2009 crop years.

Table 4. Regression analysis between the MCDA procedure forecasts and the IBGE data for the 2000/2001 to the 2006/2007 crop years.

Crop year	Estimates	Coefficients	p-value	Lower 95%	Upper 95%	Adjusted R ²	RMSE ⁽¹⁾ (ha)
First forecast							
2001/2002	b0	-690.24	0	-1,053.95	-326.52	0.93	3,586.25
	b1	1.09	0	1.07	1.12		
2002/2003	b0	-837.11	0	-1,189.28	-484.94	0.94	3,468.89
	b1	1.07	0	1.05	1.10		
2003/2004	b0	-830.68	0	-1,227.26	-434.11	0.93	3,872.49
	b1	1.06	0	1.03	1.08		
2004/2005	b0	-867.19	0	-1,272.64	-461.73	0.94	3,962.32
	b1	1.10	0	1.07	1.12		
2005/2006	b0	-682.20	0	-1,160.81	-203.60	0.91	4,715.49
	b1	1.09	0	1.06	1.12		
2006/2007	b0	-894.25	0	-1,306.79	-481.70	0.93	4,065.60
	b1	1.06	0	1.03	1.09		
Second forecast							
2000/2001	b0	-659.53	0	-986.08	-332.99	0.92	3,228.08
	b1	1.05	0	1.02	1.08		
2001/2002	b0	-676.89	0	-1,061.83	-291.96	0.93	3,795.47
	b1	1.15	0	1.12	1.18		
2002/2003	b0	-735.28	0	-1,078.34	-392.22	0.95	3,379.14
	b1	1.15	0	1.13	1.18		
2003/2004	b0	-820.67	0	-1,234.61	-406.74	0.93	4,041.97
	b1	1.08	0	1.05	1.11		
2004/2005	b0	-896.61	0	-1,334.73	-458.48	0.93	4,281.58
	b1	1.13	0	1.10	1.15		
2005/2006	b0	-794.29	0	-1,254.61	-333.97	0.91	4,535.33
	b1	1.08	0	1.05	1.11		
2006/2007	b0	-774.44	0	-1,203.14	-345.73	0.93	4,224.83
	b1	1.10	0	1.08	1.13		

⁽¹⁾RMSE, root mean square error.

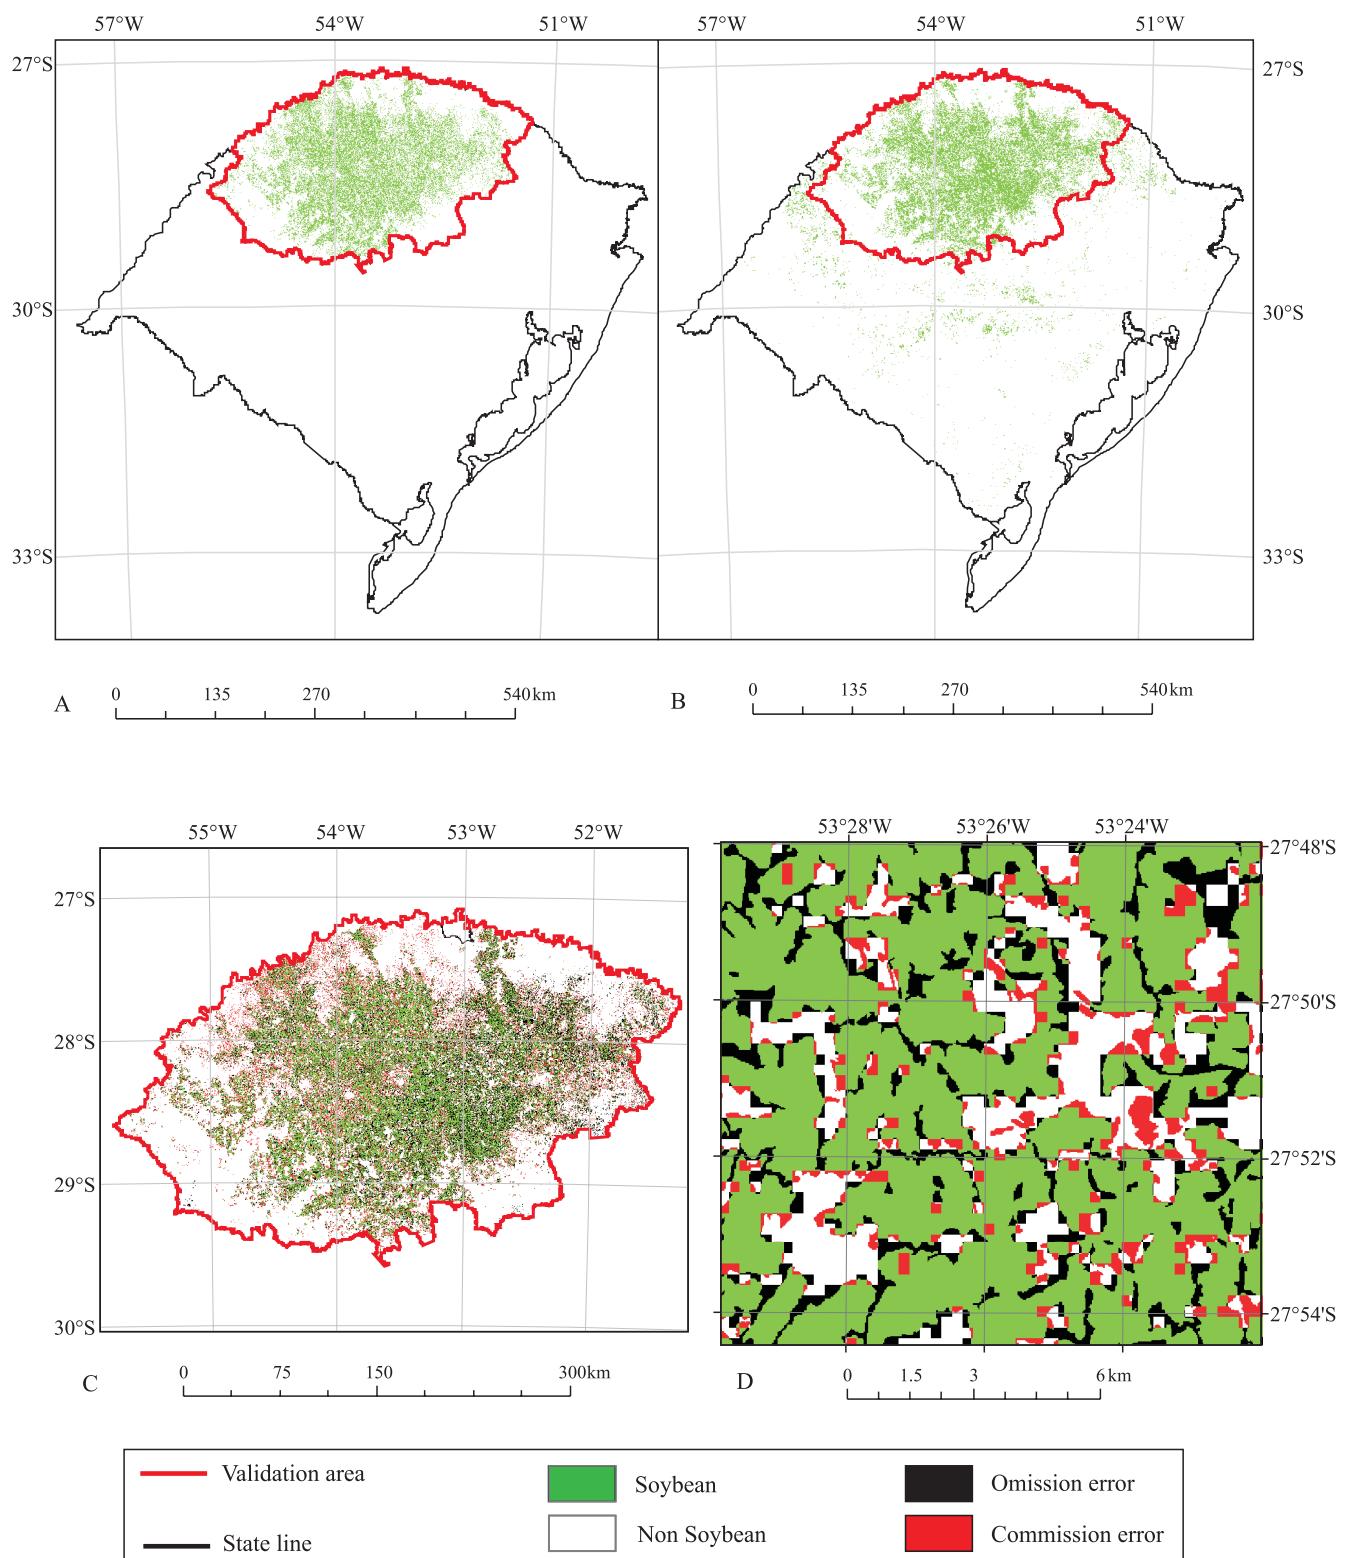


Figure 6. Soybean map of the 2000/2001 crop year obtained by Rizzi & Rudorff (2005) (A) and by the MCDA procedure for the second forecast (B); validation between A and B (C); and enlargement of a validation sector (D).

Table 5. Confusion matrix resulting from the comparison between the MCDA and the Rizzi & Rudorff (2005) maps.

Classification	Soybean ----- (ha)	Non soybean ----- (ha)	Total classified	User's accuracy (%)
Soybean	1,652,942	685,601	2,338,543	70.68
Non soybean	683,666	4,582,658	5,266,325	87.02
Reference total	2,336,608	5,268,260	7,604,869	-
Producer's accuracy (%)	70.74	86.99	-	-
Overall accuracy (%)	81.99	-	-	-

The MCDA can also be applied to corn and rice crops, but further adaptations to their respective agricultural calendars, parameters, and variables are necessary. In addition, soybean field size caused considerable differences in the classification results. Therefore, the MCDA should generate better results over the soybean producers of the Brazilian states where crop fields are much larger than the ones in the evaluated area (Lobell & Asner, 2004; Rudorff et al., 2007).

Conclusions

1. The Modis crop detection algorithm (MCDA) procedure is based on an adequate and objective methodology for estimating soybean crop areas, using moderate resolution imaging spectroradiometer (Modis) images and enhanced vegetation index (Evi) data.

2. The MCDA approach can assist the official soybean crop area estimates, providing reliable spatialized information, prior to the crop harvest period.

3. The proposed methodology is able to provide annual thematic soybean maps, forecasting the planted area of soybean in Rio Grande do Sul State, Brazil, with estimates that are in good agreement with the official agricultural statistics of Instituto Brasileiro de Geografia e Estatística.

Acknowledgements

To the Laboratory for Remote Sensing in Agriculture and Forestry from the Instituto Nacional de Pesquisas Espaciais, to the Fundação Estadual de Pesquisa Agropecuária, and to the Geoprocessing Laboratory of the Ecology Center of the Universidade Federal do Rio Grande do Sul, for support.

References

- BRASIL. Ministério da Agricultura, Pecuária e do Abastecimento. Portaria nº 126, de 20 de julho de 2009. Aprova o zoneamento agrícola para a cultura de soja no Estado do Rio Grande do Sul, ano-safra 2009/2010. **Diário Oficial [da] República Federativa do Brasil**, 10 fev. 2010. Seção 1, p.15.
- CHANG, J.; HANSEN, M.C.; PITTMAN, K.; CARROLL, M.; DIMICELI, C. Corn and soybean mapping in the United States using MODIS time-series data sets. **Agronomy Journal**, v.99, p.1654-1664, 2007.
- CUNHA, G.R. da; BARINI, N.A.; HAAS, J.C.; MALUF, J.R.T.; MATZENAUER, R.; PASINATO, A.; PIMENTEL, M.B.M.; PIRES, J.L.F. Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v.9, p.446-459, 2001.
- D'ARCO, E.; RUDORFF, B.F.T.; RIZZI, R. Índices de vegetação para estimativa de área plantada com arroz irrigado. 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.123-131.
- DORAISWAMY, P.C.; SINCLAIR, T.R.; HOLLINGER, S.; AKHMEDOV, B.; STERN, A.; PRUEGER, J. Application of MODIS derived parameters for regional crop yield assessment. **Remote Sensing of Environment**, v.97, p.192-202, 2005.
- EPIPHANIO, R.D.V.; FORMAGGIO, A.R.; RUDORFF, B.T.F.; MAEDA, E.E.; LUIZ, A.J.B. Estimating soybean crop areas using spectral-temporal surfaces derived from MODIS images in Mato Grosso, Brazil. **Pesquisa Agropecuária Brasileira**, v.45, p.72-80, 2010.
- HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.P.; GAO, X.; FERREIRA, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v.83, p.195-213, 2002.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Folha SH 22 Porto Alegre e parte da folha SH 21 Uruguaiana e SI 22 Lagoa Mirim: geologia, geomorfologia, pedologia, vegetação, uso potencial da terra**. Rio de Janeiro: IBGE, 1986. 809p.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **SIDRA**: sistema IBGE de recuperação automática. Disponível em: <<http://www.sidra.ibge.gov.br/>>. Acesso em: 12 out. 2009.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Divisão de Geração de Imagens (DGI)**. Disponível em: <<http://www.dgi.inpe.br/>>. Acesso em: 12 jul. 2010.
- JUSTICE, C.O.; TOWNSHEND, J.R.G.; VERMOTE, E.F.; MASUOKA, E.; WOLFE, R.E.; SALEOUS, N.; ROY, D.P.; MORISSETTE, J.T. An overview of MODIS Land data processing and product status. **Remote Sensing of Environment**, v.83, p.3-15, 2002.
- LOBELL, D.B.; ASNER, G.P. Cropland distributions from temporal unmixing of MODIS data. **Remote Sensing of Environment**, v.93, p.412-422, 2004.

- MOREIRA, M.A.; RUDORFF, B.F.T.; BARROS, M.A.; FARIA, V.G.C.; ADAMI, M. Geotecnologias para mapear lavouras de café nos Estados de Minas Gerais e São Paulo. **Engenharia Agrícola**, v.30, p.1123-1135, 2010.
- NATIONAL AERONAUTICS AND SPACE ADMINISTRATION . **Warehouse inventory search tool**. Available at: <<https://wist.echo.nasa.gov/api/>>. Accessed on: 13 Apr. 2009.
- RABUS, B.; EINEDER, M.; ROTH, A.; BAMLER, R. The shuttle radar topography mission – a new class of digital elevation models acquired by spaceborne radar. **Journal of ISPRS Photogrammetric Engineering and Remote Sensing**, v.57, p.241-262, 2003.
- RIZZI, R.; RUDORFF, B.F.T. Estimativa da área plantada com soja no Rio Grande do Sul por meio de imagens Landsat. **Revista Brasileira de Cartografia**, v.57, p.226-234, 2005.
- RUDORFF, B.F.T.; AGUIAR, D.A.; SILVA, W.F.; SUGAWARA, L.M.; ADAMI, M.; MOREIRA, M.A. Studies on the rapid expansion of sugarcane for ethanol production in São Paulo State (Brazil) using Landsat data. **Remote Sensing**, v.2, p.1057-1076, 2010.
- RUDORFF, B.F.T.; BERKA, L.M.S.; MOREIRA, M.A.; DUARTE, V.; XAVIER, A.C.; ROSA, V.G.C.; SHIMABUKURO, Y.E. Imagens de satélite no mapeamento e estimativa de área de cana-de-açúcar em São Paulo: ano-safra 2003/04. **Agricultura em São Paulo**, v.52, p.21-39, 2005.
- RUDORFF, C. de M.; RIZZI, R.; RUDORFF, B.F.T.; BERKA, L.M.S.; VIEIRA, C.A.O. Superfícies de resposta espectro-temporal de imagens do sensor MODIS para classificação de área de soja no Estado do Rio Grande do Sul. **Ciência Rural**, v.37, p.118-125, 2007.
- SAKAMOTO, T.; YOKOZAWA, M.; TORITANI, H.; SHIBAYAMA, M.; ISHITSUKA, N. OHNO, H. A crop phenology detection method using time-series MODIS data. **Remote Sensing of Environment**, v.96, p.366-374, 2005.
- SANO, E.E.; FERREIRA, L.G.; ASNER, G.P.; STEINKE, E.T. Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, v.28, p.2739-2752, 2007.
- SUGAWARA, L.M.; RUDORFF, B.F.T.; ADAMI, M. Viabilidade de uso de imagens do Landsat em mapeamento de área cultivada com soja no Estado do Paraná. **Pesquisa Agropecuária Brasileira**, v.43, p.1763-1768, 2008.
- VIEIRA, C.A.O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. 2000. 323p. Thesis (Doctor) – University of Nottingham, Nottingham.
- WARDLOW, B.D.; EGBERT, S.L.; KASTENS, J.H. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. **Remote Sensing of Environment**, v.108, p.290-310, 2007.
- WOLFE, R.E.; NISHIHAMA, M.; FLEIG, A.J.; KUYPER, J.A.; ROY, D.P.; STOREY, J.C.; PATT, F.S. Achieving sub-pixel geolocation accuracy in support of MODIS land science. **Remote Sensing of Environment**, v.83, p.31-49, 2002.

Received on February 3, 2011 and accepted on February 5, 2012

Spectral Model for Soybean Yield Estimate Using MODIS/EVI Data*

Anibal Gusso^{1#}, Jorge Ricardo Ducati², Mauricio Roberto Veronez³, Damien Arvor⁴,
Luiz Gonzaga da Silveira Jr.⁵

¹Environmental Engineering, UNISINOS, São Leopoldo, Brazil

²Remote Sensing Center and Astronomy Department, UFRGS, Porto Alegre, Brazil

³Graduate Program in Geology, UNISINOS, São Leopoldo, Brazil

⁴Institut de Recherche Pour le Développement (IRD), Montpellier, France

⁵Graduate Program in Applied Computing, UNISINOS, São Leopoldo, Brazil

Email: [#]anibal@unisinos.br, ducati@if.ufrgs.br, veronez@unisinos.br, damien.arvor@ird.fr, gonzaga@unisinos.br

Received August 17, 2013; revised September 18, 2013; accepted October 16, 2013

Copyright © 2013 Anibal Gusso *et al.* This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

ABSTRACT

Attaining reliable and timely agricultural estimates is very important everywhere, and in Brazil, due to its characteristics, this is especially true. In this study, estimations of crop production were made based on the temporal profiles of the Enhanced Vegetation Index (EVI) obtained from Moderate Resolution Imaging Spectroradiometer (MODIS) images. The objective was to evaluate the coupled model (CM) performance of crop area and crop yield estimates based solely on MODIS/EVI as input data in Rio Grande do Sul State, which is characterized by high variability in seasonal soybean yields, due to different crop development conditions. The resulting production estimates from CM were compared to official agricultural statistics of Brazilian Institute of Geography and Statistics (IBGE) and the National Company of Food Supply (CONAB) at different levels from 2000/2001 to 2010/2011 crop years. Results obtained with CM indicate that its application is able to generate timely production estimates for soybean both at municipality and local levels. Validation estimates with CM at State level obtained $R^2 = 0.95$. Combining all cropping years at municipality level, estimates were highly correlated to official statistics from IBGE, with $R^2 = 0.91$ and RMSD = 10,840 tons. Spatially interpolated comparisons of yield maps obtained from the CM estimates and IBGE data also showed visual similarity in their spatial distribution. Local level comparisons were performed and presented $R^2 = 0.95$. Implications of this work point out that time-series analysis of production estimates are able to provide anticipated spatial information prior to the soybean harvest.

Keywords: Remote Sensing; Coupled Model; Soy Yield; Forecast; Satellite Images

1. Introduction

Agricultural monitoring and forecast is a major issue for agricultural market, in order to expand the management capacity in several levels of social and government organization [1]. Precise information on agricultural production, prior to the crop year period, also provides focused planning strategies for public policies improvement and for maintaining the balance of pricing between supply and demand [2].

Currently, efforts to harmonize remote sensing-based crop monitoring systems are being carried out in the GEO-GLAM (Global Agriculture Monitoring) project in order to continue providing agricultural statistics at dif-

ferent spatial and temporal scales. However, the case of Brazil remains atypical due to its current methodology.

Although Brazil is currently considered as a world's granary, and therefore, it plays an important role in global markets as a main producer of agricultural commodities, official agricultural statistics released by two Brazilian agencies, namely CONAB (Companhia Nacional de Abastecimento—National Company of Food Supply) and IBGE (Instituto Brasileiro de Geografia e Estatística—Brazilian Institute of Geography and Statistics), suffer from two main issues: 1) municipality statistics are not timely available, but nearly eighteen months after the end of the soybean season; and 2) there is a confidence issue, because the methodology used is partly subjective and do not present an associated error measurement to estimates

*Simplified model for soybean yield based solely on MODIS/EVI data.
#Corresponding author.

[3,4].

In Brazil, several studies [2,5,6] were focused primarily on soybean production forecasting and crop mapping using remote sensing imagery. However, these studies were designed for few cropping years and/or for a limited region. For example, remote sensing imagery has been implemented for mapping soybean (see Geo Safras Project—BRA/03/034). Although some experiences confirmed the efficiency of crop mapping, the monitoring of annual crops such as soybean remains an issue.

Intense cloud cover during key identification periods usually hinders the operational implementation of Landsat-based methodologies for providing agricultural statistics of summer crops [7,8]. Typically, imagery from Terra satellite, as EOS-MODIS (Earth Observing System-Moderate Resolution Imaging Spectroradiometer) and from NOAA (National Oceanic and Atmospheric Administration) has been directly used in studies for crop cycle monitoring and primary productivity estimates [1,9-14].

The MODIS sensor provides an adequate imaging configuration for crop monitoring, due to 1) almost-daily revisit rate, combined with, 2) spatial resolution of 250 m, considered as being adequate for mapping large-scale agricultural fields [15], and 3) a good geometric quality, which allows time series analysis and crop development [16]. In recent years, many studies have used MODIS imagery for agricultural crop surveys and monitoring. In the USA, [17] investigated the applicability of MODIS/EVI time series data to map agricultural lands, and concluded that 16-day composites of MODIS images gave sufficient spatial information to adequately express the phenology and climate characteristics of the region. Reference [12] assessing the quality of MODIS data to provide information on both crop productivity and area, in USA, derived biophysical parameters that were further integrated into crop growth models.

1.1. Accurate Crop Area Estimation Problem

Reliable estimates of production requires to know first the crop area extent [6,14,18-20], in order to obtain crop yield from an independent approach. Regarding to area estimation of soybean crops in Brazil, some studies have addressed the problem by using different methodologies [3,19,21-23]. Even when MODIS is not a viable option for detailed cropland mapping due to its limitation to resolve smaller field sizes, it still can reveal cropland presence over large areas [24]. However, most of these studies are modeled to few crop years and/or for a limited region, indicating good potential of MODIS data for crop forecast, but not actually proving its usefulness within a routine and systematic crop forecast system in an operational mode [3].

Classification methods used in previous works are supervised methodologies that require training samples.

The MODIS Crop Detection Algorithm (MCDA) is a systematic crop area forecast method which is not a user-defined procedure and does not require specific skills in remote sensing [3]. The MCDA coefficients of determination ranged from 0.91 to 0.95, for all crop years from 2000/2001 to 2008/2009, indicating good agreement between the estimates. For the 2000/2001 crop year, the MCDA soybean crop map was evaluated using a crop map derived from Landsat images, and the overall map accuracy was approximately 82%, with similar commission and omission errors. The Root-Mean-Square-Deviation (RMSD) ranged from 3228 to 4715 ha. The mapping accuracy dependence from the mean field size was also found, as observed in [15] and [24], due to 250 meters spatial-resolution.

1.2. Crop Yield Estimation and Prediction

Agricultural crop production is characterized by large variability in yield, as a result of the main agrometeorological parameters [9], and especially for Rio Grande do Sul State, due to dry periods during summer crops, both in spatial and annual basis. More recently, yield estimate models usually consider agricultural practices, weather or climatological conditions as the predominant physically-driven conditions (PDC) in the representation of the cycle of agricultural development [18], especially precipitation [5,10,14,25], but are also impacted by crop canopy temperature extremes as heat-waves [1,26,27]. Usually, vegetation indices correlated well with soybean yield because they are mainly associated with biomass evolution [9,10]. Spectral profiles of vegetation can also be associated with its health condition [28] because spectral temporal alterations, described by a vegetation index during the crop cycle, are closely associated to vegetation development characteristics [14].

In Brazil, [6] used crop area data from IBGE to evaluate a forecast system for soybean crop yield based on regional empirical models. They performed low accuracy yield forecast in some States as RS, Mato Grosso do Sul and Bahia. [10] obtained an accurate crop yield estimate with an agrometeorological-spectral model in RS, which aggregated the meteorological variables and image data. However, the spatial resolution of the input data was not able to describe adequately the spatial variations and provide the resulting total production in a municipality level. Currently, the majority of meteorological data are often not available at the same spatial scale as the remote sensing imagery, and the aggregation of agrometeorological components, even with low spatial resolution, results in increased complexity or can introduce substantial errors into the models [1,6,11,29,30] and so, can have low predictive power for support in decision making. In doing so, although it is known to be possible to improve accuracy using climate forecasts models to soybean yield

estimates [31], it is worthwhile to develop simplified models as an alternative for crop production estimate in advance to the crop harvest. Simplified models based on spectral behavior of crop cycle can be a good alternative [32]. In this context, a model that is able to relate the PDC in a simplified manner by mean vegetation index can significantly contribute for providing productivity and decision making information.

In this study, we are taking a step further, by developing a model, which is able to measure crop production by means of remotely sensing data using the moderate spatial resolution of 250 meters, primarily based on the crop cycle development.

The aim of this study is to evaluate the Coupled Model (CM) performance, which is entirely based on EVI/MODIS images, to estimate soybean production in Rio Grande do Sul (RS hereafter) at State and municipal level, prior to the crop harvest. A simplified-based model can help understanding the mechanisms associated to climate that trigger low soybean yield occurrences and for future adaptive management practices.

2. Methodology

2.1. Study Area

In 2011, RS State accounted for almost 15% of total soybean production in Brazil, with more than 11.0 million metric tons. Currently, RS is the third major soybean producer in Brazil with total crop area greater than 4.0 million ha [33].

This study analyzed 496 municipalities located between the approximate coordinates at latitudes 27° and 34° South and longitudes 49° and 58° west, for crop years from 2000/2001 to 2010/2011. The region's climate is subtropical with four well-defined seasons. The average annual rainfall is 1500 mm, but with some dry periods. However, rainfall is relatively well distributed throughout the year, especially in the northern half of RS State where soybean cultivation is dominant.

RS State is characterized by high variability in seasonal soybean yield due to different crop development conditions. There has been three droughts in the studied period, occurred in 2001/2002, 2003/2004 and the most severe one in 2004/2005 which has caused about 75% loss in soybean production [1]. In 2006, RS State had nearly 984,000 ha irrigated especially in the southern half where rice flooded cultivation is dominant, with around 82% of total irrigated areas. Rice crops excepted, RS State is almost completely rain-fed and irrigation systems to soybean crop areas only cover about 170,000 ha [34,35]. This represented less than 4.5% of total soybean areas in RS State in 2006 [33].

The average calendar for sowing soybeans goes from early October to late December based on agricultural

zoning for different soils, regions, and cultivars [36].

Depending on the sowing date, maximum plant growth is observed from late January to early March [3]. The prevailing management practices in the last years is *Plantio Direto*, which is a low tillage planting and sowing (also called no-tillage farming), avoiding soil erosion and organic matter degradation. **Figure 1** shows the study area.

These dynamic-induced changes were modulated into a stepwise procedure by CM approach for which two types of data were used across this study, *i.e.* input data for classification and validation data. Different layers of information and types of data were used, in order to accurately represent the main physical conditions and management practices found in RS.

2.2. Material

- Input data:
- MODIS EVI data: EVI data from 2000 to 2011 were extracted from MODIS sensor on board of Terra satellite, product MOD13Q1-collection 5 for two image tiles (H13V11, H13V12) covering all RS State. The EVI data are obtained from the MOD13Q1-V005 product, which is a 16-days composition with the best radiometric and geometric pixels selected. MODIS images and products were pre-processed by the National Aeronautics and Space Administration (NASA) and are available at no charge at https://lpdaac.usgs.gov/data_access/data_pool;
- SRTM: Shuttle Radar Topography Mission (SRTM) data were used to generate a slope map with 90 meters spatial resolution, according to [37], in order to exclude improper areas for mechanization (slope >




Figure 1. Location of RS in Brazil.

- 15%), once soybean is a highly mechanized crop and requires relatively smooth land to allow the traffic of farm implements [38];
- Precipitation data: yearly rainfall data (2000 to 2011) in 30 days accumulated precipitation from 16 meteorological stations, during the period from October to February. These data, from FEPAGRO (Fundação Estadual de Pesquisa Agropecuária—State Foundation for Agriculture and Livestock Research) were used to refine the period of initial sowing and evaluation of total precipitation during crop development.
 - Validation data:
 - Annual soybean agricultural statistics, at State and municipality level from [39] for the entire study area. These official statistics were used to compare and evaluate the production results obtained from CM;
 - A second source of information, annual soybean agricultural statistics, at State level from [33] was used for the entire study area. These data were used also to compare and evaluate the results obtained from the present soybean production estimation procedure together with IBGE official statistics data;
 - Crop level data obtained from Technical Report [40] on 2008/2009 crop year were used for spatial validation process. For each one of crop sample points, the crop type and yield were identified.

The input data for the CM are the Enhanced Vegetation Index (EVI). The EVI is part of the MOD13Q1-V005 product, which comprises the best radiometric and geometric pixels selected within a 16-day period. EVI is an indicator of vegetation vigor which is based on canopy reflectance characteristics of vegetation, and was developed to minimize ground influence and atmospheric effects in order to accurately represent vegetated areas by means of satellite measures [41]. EVI data were chosen due to their potential ability to reduce atmospheric and soil background effects [16,42]. The EVI formulation is $2.5(\text{Nir}-\text{Red})/(\text{Nir} + 6 \text{ Red} - 7.5 \text{ Blue} + 1)$, in which: Nir, Red, and Blue are atmospherically or partially-atmospherically corrected surface reflectance of near infrared, red, and blue bands, respectively [42]. The MODIS images and its products were preprocessed by the National Aeronautics and Space Administration (NASA) and are available at no charge at the [43].

2.3. CM: Methodological Approach

An operational crop yield model should be based on adaptations to specific regional agricultural calendars in a knowledge-driven approach, instead of a data-driven approach which is based on data samples for training classification algorithms [18]. The profile of the crop cycle development related to crop vigor is parameterized from EVI data. The methodology developed for soybean yield estimate, in a pixel basis, was named MODIS Productiv-

ity Detection Model (MPDM). MPDM is a mathematical approach for soybean yield estimate based on identifying the main PDC acting in the crop development profile of vegetation [1,18] which modulates the EVI from sowing/planting to maximum vegetation development. CM is a coupled model obtained by combining MCDA for area estimate and MPDM for yield. According to CM procedure, soybean EVI profile is expected to have low values during the sowing period and high values at maximum vegetation development. Following the sowing period, a rapid increase of the MODIS/EVI values is observed due to intense plant growth, reaching maximum values in a relative short period [17]. This crop development pattern, as a primary concept, was postulated considering that the complete vegetation development profile is representative of the total agrometeorological conditions and management practices acting during development of plants. This approach is based primarily on the following Vegetation Physical Concepts (VPC):

- 1) A complete crop development profile is representative of crop vegetation vigor;
- 2) The area calculated between the crop profile graph described as a function of EVI, and above zero, is proportional to the maximum crop production, in order that different crop development conditions sweep out different areas during equal time windows in the same period. So, the calculated area is representative of the maximum crop yield possible to the soybean culture, in the specific crop year, in the studied region;
- 3) Considering as truth points 1 and 2, crop development in RS reaches its maximum within a fixed window period, from 017 to 049 day-of-year (DOY).

Once the crop profile reaches its maximum, and flattens off, the calculation of maximum EVI value of current crop is obtained by averaging it in the fixed time window (according to item 3 of VPC).

Based on these concepts, the remaining challenge is to understand the main PDC related to factors that do not cause detectable effects on vegetation growth but do constrain the grain production. Reference [27] observed that the flowering period of seasonal agricultural vegetation is more sensitive to temperature than to water stress. In this way, the selected time window covers the flowering period to grain filling and can be calculated by a simple Riemann Integration, and is fundamental to a knowledge-driven approach concept.

Figure 2 shows a trend line with standard deviation markers of crop yield as function of integrated EVI profile of soybean crop from 2000/2001 to 2010/2011. Integrated EVI was obtained from the average of the time window of maximum vegetation development. Three consecutive EVI images from the maximum plant growth were used to obtain integrated EVI which is referred as max EVI window. The resulting max EVI window image

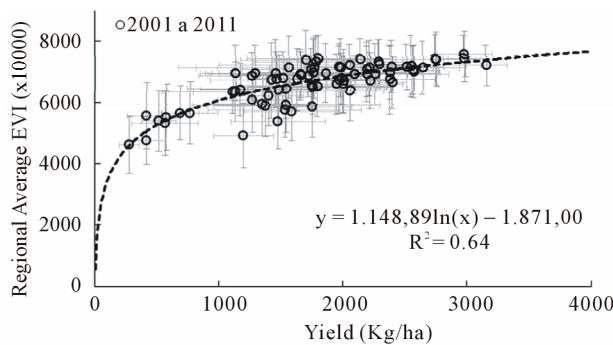


Figure 2. Regional averages of integrated EVI as function of regional averages of soybean yield from 2000/2001 to 2010/2011.

is the average from the three consecutive images. Each crop year has eight administrative regions.

Coupling the two processes (MCDA and MPDM) generate results, at a pixel basis that can be described by a single non-linear mathematical function that relates the integrated value to yield. Output values that were obtained by applying this approach are representative of integrating physical conditions of the crop vegetation development through time.

Based on this approach, parameterizations were performed during the development cycle of culture that can be best represented by images of vegetation index [3] using statistical data from official agricultural institutions of Brazil and crop campaign data.

The mathematical relation that links crop vigor profile development to grain production, at the plant level through time, is used to link spatial distribution of EVI at intra-annual basis by means of a simple associative transfer property.

CM estimation is obtained by using a simplified approach which is based solely on EVI images as input parameter. Soybean yield estimation can be provided right after a set of EVI images become available, which normally occurs in early February. CM works on calculating the soybean yield, in a per pixel basis, by means the mathematical rule which relates the vegetation vigor from EVI values to yield in the entire max EVI window. However, only the EVI values associated to soybean crop area selected from MCDA will be considered. In this way, pixels which fall out from soybean crop areas are tagged as zero yield.

A delay of about 20 days is expected in order to acquire the MOD13Q1 product; and therefore, soybean estimation should be released no later than early March.

It is important to emphasize that the parameters defined in CM for crop production estimate are constant as a fixed criteria of CM equation, during the period we studied (eleven crop years between 2000/2001 and 2010/2011) independently of the soybean crop development or

multi-year dynamics in RS State. When any further adjustment of parameters is needed, in order to plot a better fitting of the seasonal crop yield during the calibration procedure, a new test cycle is started for all crops. It means that by considering the main PDC as representative of soybean crop development profile, revealing the correlation between crop vigor and total municipal production, it is expected that a set of constants parameters will be able to be adjusted as fixed criteria. Therefore, once identified the mathematical parameters related to the PDC, no post-adjustment was allowed.

3. Results

Soybean production in RS State was compared to official estimates from IBGE and CONAB at State and municipality level from 2000/2001 to 2010/2011. **Figures 3 and 4** show the high variability in production and yield due to seasonal agrometeorological conditions in RS. Interpolated maps were obtained from averages in the period from 2000/2001 to 2010/2011, since the most recent municipal information for 2011/2012 had not yet been released by IBGE. **Table 1** presents the crop level estimates using local level data.

Table 1. Location of the sample points obtained in 2008/2009 crop year from Dotto and Rosinha (2009) [40].

Point [#]	Lat.	Long.	Report ^a -Yield	CM ^b -Yield	Diff. (%)
1	30°17'35"S	52°57'52"W	3158	3048	-3.48
2	30°20'16"S	54°10'02"W	1570	1423	-9.36
3	28°24'16"S	54°45'43"W	4456	4106	-7.85
4	27°53'18"S	53°51'30"W	2708	2848	5.17
5	29°10'28"S	53°41'49"W	2313	2136	-7.65
6	28°08'33"S	52°12'59"W	1875	2146	14.45
7	28°20'57"S	51°03'10"W	2186	2405	10.02




Figure 3. Comparison of total production estimates between IBGE and CM for each crop year, from 2000/2001 to 2010/2011.




Figure 4. Scatterplot showing the trend line of soybean yield between IBGE and CM estimates, for each crop year, from 2000/2001 to 2010/2011.

3.1. State Level Analysis

Linear least squares regression analysis was done for State level soybean yield estimates obtained from IBGE and CM for 2000/2001 to 2010/2011 crop years. **Figure 3** compares the total soybean production in the State from IBGE and CM.

Production estimates with CM is obtained for each pixel multiplying yield by pixel area (*pixel of 250 m is 6.25 ha*). CM exhibits trend to underestimate yield when comparing to IBGE. Results obtained by Melo *et al.* (2008) [10], analyzing the performance modeling using images of low spatial resolution (9 km), between 1975 and 2000, obtained a correlation coefficient (Pearson correlation) $R = 0.96$, when they considered fitting to all points. Reference [13] evaluated several regions of Brazil. In RS, they found a correlation coefficient of $R = 0.26$. In **Figure 4**, it is observed the most pronounced point positioned below the linear least squares regression function. Where IBGE declares a yield average of 1708 Kg/ha, CM yield estimate is 1068 Kg/ha, which represents a difference of -37.1% in the crop year 2001/2002.

Analysis of precipitation distribution in 2001/2002 shows a lower than normal trend from southwestern region of the State towards the north region, where is the most intensive soybean crop fields.

Figure 5 shows the percent deviation of cumulative precipitation in 2001/2002, based in the climatological normal (1971 to 2000) obtained with analysis of interpolated maps.

By comparing these maps, a large difference is revealed not only in the distribution of precipitation, but also in the total amount all over the State. This result leads to an interpretation of overestimated IBGE production in 2001/2002 because the amount of precipitation that occurred in summer crop of 2001/2002 was not suitable to the resulting yield from IBGE.

Figure 6 shows the yield deviation of CM from IBGE in summer crop of 2001/2002.




Figure 5. Percent deviation of cumulative precipitation in the crop year 2001/2002, starting from normal climatological conditions (1971 to 1990).

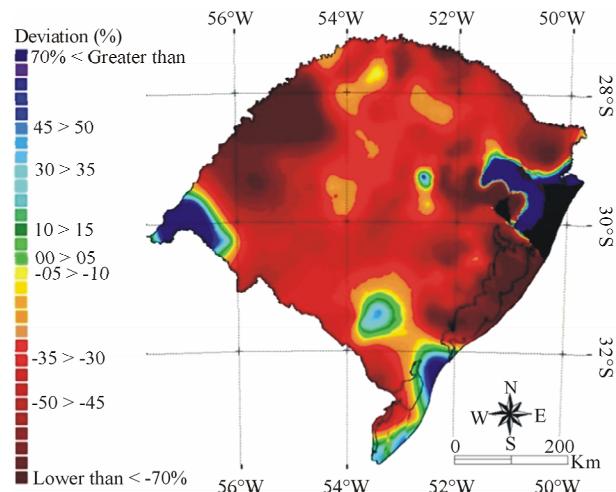


Figure 6. Percent deviation of soybean yield with CM in the crop year 2001/2002, starting from municipality data of IBGE.

The deviation trend do not shows the expected increasing in the yield deviation towards the north, which is related to deviations of precipitation greater than 30%, as shown in **Figure 5**. Also, it is important to note in **Figure 6** the great dark-red area in the north-west region in RS State. This region showed the most pronounced negative yield differences where CM estimates are more than 50% below IBGE in 2001/2002. Usually, this is the most affected area by droughts in RS, which results in a soybean yield lower than average for longer periods. The dark-blue regions are related to small farms with high soybean yield. As a result, interpolated maps of yield estimates from CM, compare centroids which does not has any soybean production to another ones which has above average yields.

In **Figure 4**, the coefficient of determination is $R^2 =$

0.82. Considering previous observations from IBGE, the soybean yield distribution in 2001/2002, it is an outlier, and so, it has to be extracted from validation crop years. The new coefficient of determination found is $R^2 = 0.91$ indicating that CM trend is in good agreement with total production of State level estimates.

3.2. Municipality Level Estimates

Figure 7 presents CM map of soybean yield in 2010/2011 crop year. CM map is able to generate data at municipal scale or intra-municipal scale due to its 250 m full resolution. At municipality level, scatterplot in **Figure 8** shows the grouping of points along the symmetry line in the inter-comparison between total production obtained from CM and obtained from the IBGE, in all crop years from 2000/2001 to 2010/2011.

There is a trend of CM to overestimate production in comparison to IBGE which is not observed in the State level analysis of yield (**Figure 4**). The same is observed at municipality level. At yearly based analysis, coefficients of determination (R^2) ranged from 0.90 to 0.95 indicating

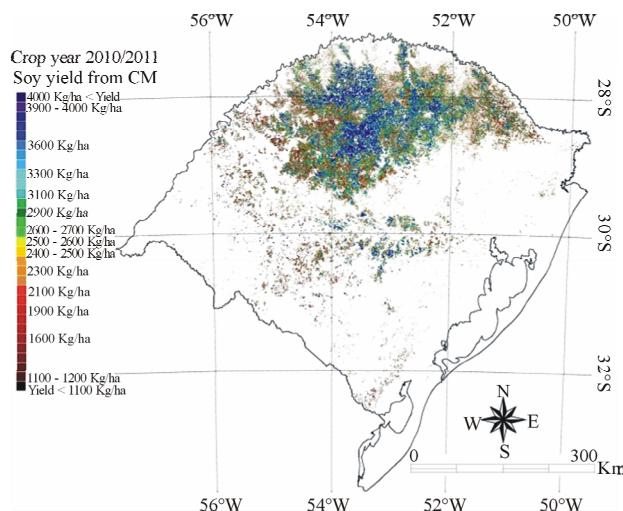


Figure 7. Soybean yield in 2010/2011 crop year from CM.

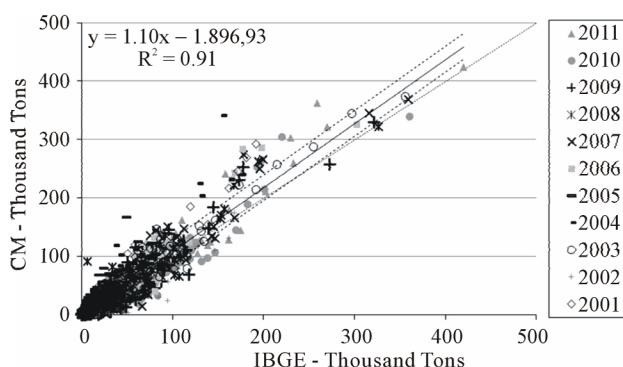


Figure 8. Scatterplot comparing municipality estimates of production in RS, between IBGE and CM, from 2000/2001 to 2010/2011.

good agreement between estimates. The majority of slope coefficients values ranged around 1.10, which indicates that CM overestimated the soybean production in relation to IBGE for municipalities with highest production.

In **Figure 8**, the four points placed above 350,000 tons are representative of soybean production in the municipality of Tupanciretã, which already in 2003 was the major producer in RS with more than 355,000 tons [39]. The RMSD is 10,840 tons for all aggregated data of crop years. Considering a double RMSD from trend line, 95% of occurrences are in between dashed lines indicating that CM estimates are consistent.

3.3. Local Level Analysis

The local level analysis was performed by using yield estimates in the 2008/2009 crop year from the Crop Production Report, by [40]. Local level comparison must be evaluated carefully due to the nature of different scales measures in this comparison. It is expected a high spatial variability of plant level analysis which may not be representative of the large scale crop yield, and so, when comparing moderate resolution (250 m) and crop level data (plant yield). Results obtained from the CM approach shows that the CM estimations adhere to spatial variability of yield obtained from the seven sampled points in different locations with coordinates presented in **Table 1**. The obtained coefficient of determination (R^2) is 0.95 and the slope coefficient is 0.86.

4. Conclusions

The CM approach is based on a consistent and objective methodology for regional estimation of soybean production using MODIS/EVI imagery.

Implementing operational crop yield forecasts in advance to crop harvest remains a challenge at regional scale, since it implies to model different scale levels. Also, it implies to take into account a large set of local level data, which is not commonly available or easily provided.

By using pre-defined parameters, CM approach demonstrated to be able to provide complementary information of yield and production forecasts in advance to crop harvest, being less subjected to complex time-expensive analytical methodologies and image interpretation.

Further analysis and developments for CM must be undertaken in Mato Grosso State, Brazil, where far different ecoregions characteristics from Rio Grande do Sul State prevail. Additionally, local level data are subject to different impacts of physically-driven components as crop variety and local agrometeorology.

5. Acknowledgements

The authors are thankful to Fundação Estadual de Pes-

quisa Agropecuária do Rio Grande do Sul (FEPAGRO). Special thanks are due to Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

REFERENCES

- [1] A. Gusso, "Integração de imagens NOAA/AVHRR: Rede de Cooperação Para Monitoramento Nacional da Safra de Soja," *Revista Ceres*, Vol. 60, No. 2, 2013, pp. 194-204. <http://dx.doi.org/10.1590/S0034-737X2013000200007>
- [2] D. C. Figueiredo, "Projeto GeoSafras: Aperfeiçoamento do Sistema de Previsão de Safras da Conab," *Revista de Política Agrícola*, Vol. 14, 2005, pp. 110-120.
- [3] A. Gusso, A. R. Formaggio, R. Rizzi, M. Adami and B. T. F. Rudorff, "Soybean Crop Area Estimation by MODIS/EVI Data," *Pesquisa Agropecuária Brasileira*, Vol. 47, No. 3, 2012, pp. 425-435. <http://dx.doi.org/10.1590/S0100-204X2012000300015>
- [4] J. A. Johann, J. V. Rocha, D. G. Duft and R. A. C. Lamparelli, "Estimativa de Áreas com Culturas de Verão no Paraná, por Meio de Imagens Multitemporais EVI/MODIS," *Pesquisa Agropecuária Brasileira*, Vol. 47, No. 9, 2012, pp. 1295-1306. <http://dx.doi.org/10.1590/S0100-204X2012000900015>
- [5] R. Rizzi and B. T. F. Rudorff, "Imagens do Sensor MODIS Associadas a um Modelo Agronômico para Estimar a Produtividade de Soja," *Pesquisa Agropecuária Brasileira*, Vol. 42, No. 1, 2007, pp. 73-80. <http://dx.doi.org/10.1590/S0100-204X2007000100010>
- [6] E. D. Assad, F. R. Marin, S. R. Evangelista, F. G. Pilau, J. R. B. Farias, H. S. Pintoand and J. Zullo, "Sistema de Previsão da Safra de Soja para o Brasil," *Pesquisa Agropecuária Brasileira*, Vol. 42, No. 5, 2007, pp. 615-625. <http://dx.doi.org/10.1590/S0100-204X2007000500002>
- [7] E. E. Sano, L. G. Ferreira, G. P. Asner and E. T. Steinke, "Spatial and Temporal Probabilities of Obtaining Cloud-Free Landsat Images over the Brazilian Tropical Savanna," *International Journal of Remote Sensing*, Vol. 28, No. 12, 2007, pp. 2739-2752. <http://dx.doi.org/10.1080/01431160600981517>
- [8] L. M. Sugawara, B. F. T. Rudorff and M. Adami, "Viabilidade de Uso de Imagens do Landsat em Mapeamento de área Cultivada com Soja no Estado do Paraná," *Pesquisa Agropecuária Brasileira*, Vol. 43, No. 12, 2008, pp. 1763-1768. <http://dx.doi.org/10.1590/S0100-204X2008001200019>
- [9] J. C. D. M. Esquerdo, J. Zullo and J. F. G. Antunes, "Use of NDVI/AVHRR Time-Series Profiles for Soybean Crop Monitoring in Brazil," *International Journal of Remote Sensing*, Vol. 32, No. 13, 2011, pp. 3711-3727. <http://dx.doi.org/10.1080/01431161003764112>
- [10] R. W. De Melo, D. C. Fontana, M. A. Berlato and J. R. Ducati, "An Agrometeorologica-Spectral Model to Estimate Soybean Yield, Applied to Southern Brazil," *International Journal of Remote Sensing*, Vol. 29, No. 14, 2008, pp. 4013-4028. <http://dx.doi.org/10.1080/01431160701881905>
- [11] D. A. Sims, A. F. Rahman, V. D. Cordova, B. Z. El-Masri, D. D. Baldocchi, P. V. Bolstad, L. B. Flanagan, A. H. Goldstein, D. Y. Hollinger, L. Misson, R. K. Monson, W. C. Oechel, H. P. Schmid, S. C. Wofsy and L. Xu, "On the Use of MODIS EVI to Assess Gross Primary Productivity of North American Ecosystems," *Journal of Geophysical Research*, Vol. 111, No. G4, 2006, pp. 1-16. <http://dx.doi.org/10.1029/2006JG000162>
- [12] P. C. Doraiswamy, T. R. Sinclair, S. Hollinger, B. Akhmedov, A. Stern and J. Prueger, "Application of MODIS Derived Parameters for Regional Crop Yield Assessment," *Remote Sensing of Environment*, Vol. 97, No. 2, 2005, pp. 192-202. <http://dx.doi.org/10.1016/j.rse.2005.03.015>
- [13] W. T. Liu and F. Kogan, "Monitoring Brazilian Soybean Production Using NOAA/AVHRR Based Vegetation Indices," *International Journal of Remote Sensing*, Vol. 23, No. 3, 2002, pp. 1161-1180.
- [14] D. C. Fontana, E. Weber, J. R. Ducati, M. A. Berlato, L. A. Guasselli and A. Gusso, "Monitoramento da Cultura da Soja no Centro-Sul do Brasil Durante La Niña de 1998/2000," *Revista Brasileira de Agrometeorologia*, Vol. 10, No. 6, 2002, pp. 343-351. <http://dx.doi.org/10.1080/01431160110076126>
- [15] D. B. Lobell and G. P. Asner, "Cropland Distributions from Temporal Unmixing of MODIS Data," *Remote Sensing of Environment*, Vol. 93, No. 3, 2004, pp. 412-422. <http://dx.doi.org/10.1016/j.rse.2004.08.002>
- [16] C. O. Justice, J. R. G. Townshend, E. F. Vermote, E. Masuoka, R. E. Wolfe, N. Saleous, D. P. Roy and J. T. Morisette, "An Overview of MODIS Land Data Processing and Product Status," *Remote Sensing of Environment*, Vol. 83, No. 1-2, 2002, pp. 3-15. [http://dx.doi.org/10.1016/S0034-4257\(02\)00084-6](http://dx.doi.org/10.1016/S0034-4257(02)00084-6)
- [17] B. D. Wardlow, S. L. Egbert and J. H. Kastens, "Analysis of Time-Series MODIS 250m Vegetation Index Data for Crop Classification in the US Central Great Plains," *Remote Sensing of Environment*, Vol. 108, No. 3, 2007, pp. 290-310. <http://dx.doi.org/10.1016/j.rse.2006.11.021>
- [18] A. Gusso and J. R. Ducati, "Algorithm for Soybean Classification Using Medium Resolution Satellite Images," *Remote Sensing*, Vol. 4, No. 10, 2012, pp. 3127-3142. <http://dx.doi.org/10.3390/rs4103127>
- [19] D. Arvor, M. Jonathan, M. S. P. Meirelles, V. Dubreuil and L. Durieux, "Classification of MODIS EVI Time Series for Crop Mapping in the State of Mato Grosso, Brazil," *International Journal of Remote Sensing*, Vol. 29, No. 22, 2011, pp. 1-25.
- [20] R. Rizzi and B. F. T. Rudorff, "Estimativa da Área de Plantada com Soja no Rio Grande do Sul por Meio de Imagens Landsat," *Revista Brasileira de Cartografia*, Vol. 57, No. 3, 2005, pp. 226-234.
- [21] R. D. V. Epiphanius, A. R. Formaggio, B. T. F. Rudorff, E. E. Maeda and A. J. B. Luiz, "Estimating Soybean Crop Areas Using Spectral-Temporal Surfaces Derived from MODIS Images in Mato Grosso, Brazil," *Pesquisa Agropecuária Brasileira*, Vol. 45, No. 1, 2010, pp. 72-80. <http://dx.doi.org/10.1590/S0100-204X2010000100010>
- [22] D. C. Morton, R. S. DeFries, Y. E. Shimabukuro, L. O. Anderson, E. Arai, F. D.-B. Espírito-Santo, R. Freitas and J. Morissette, "Cropland Expansion Changes Deforesta-

- tion Dynamics in the Southern Brazilian Amazon," *Proceedings of the National Academy of Sciences*, Vol. 103, No. 39, 2006, pp. 14637-14641.
- [23] M. N. Macedo, R. S. DeFries, D. C. Morton, C. M. Stickler, G. L. Glatford and Y. E. Shimabukuro, "Decoupling of Deforestation and Soy Production in the Southern Amazon during the late 2000s," *Proceedings of the National Academy of Sciences*, Vol. 109, No. 4, 2006, pp. 1341-1346. <http://dx.doi.org/10.1073/pnas.1111374109>
- [24] K. Pittman, M. C. Hansen, I. Becker-Reshef, P. V. Potapov and C. O. Justice, "Estimating Global Cropland Extent with Multi-Year MODIS Data," *Remote Sensing*, Vol. 2, No. 7, 2010, pp. 1844-1863. <http://dx.doi.org/10.3390/rs2071844>
- [25] D. B. Ferreira, "Análise da Variabilidade Climática e Suas Consequências Para a Produtividade da Soja na Região Sul do Brasil," Ph.D. Thesis, INPE, São José dos Campos, 2010.
- [26] W. Schlenker and M. Roberts, "Nonlinear Temperature Effects Indicate Severe Damages to US Crop Yields under Climate Change," *Proceedings of the National Academy of Sciences*, Vol. 106, No. 37, 2009, pp. 15594-15598. <http://dx.doi.org/10.1073/pnas.0906865106>
- [27] F. N. Kogan, "Operational Space Technology for Global Vegetation Assessment," *Bulletin of American Meteorological Society*, Vol. 82, No. 9, 2001, pp. 1949-1964. [http://dx.doi.org/10.1175/1520-0477\(2001\)082<1949:OS_TFGV>2.3.CO;2](http://dx.doi.org/10.1175/1520-0477(2001)082<1949:OS_TFGV>2.3.CO;2)
- [28] C. O. Justice, G. Dugdale, J. R. G. Townshend, A. S. Naracott and M. Kumar, "Synergism between NOAA-AVHRR and Meteosat Data for Studying Vegetation Development in Semi-Arid West Africa," *International Journal of Remote Sensing*, Vol. 12, No. 6, 1991, pp. 1349-1368. <http://dx.doi.org/10.1080/01431169108929730>
- [29] D. A. Sims, A. F. Rahman, V. D. Cordova, B. Z. El-Masri, D. D. Baldocchi, P. V. Bolstad, L. B. Flanagan, A. H. Goldstein, D. Y. Hollinger, L. Misson, R. K. Monson, W. C. Oechel, H. P. Schmid, S. C. Wofsy and L. Xu, "A New Model of Gross Primary Productivity for North American Ecosystems Based Solely on the Enhanced Vegetation Index and Land Surface Temperature from MODIS," *Remote Sensing of Environment*, Vol. 112, No. 4, 2008, pp. 1633-1646. <http://dx.doi.org/10.1016/j.rse.2007.08.004>
- [30] F. N. Kogan, "World Droughts in the Millennium from AVHRR-Based Vegetation Health Indices," *Eos, Transactions, American Geophysical Union*, Vol. 83, No. 48, 2002, pp. 557-564. <http://dx.doi.org/10.1029/2002EO0000382>
- [31] A. O. Cardoso, A. M. H. de Avila, H. S. Pinto and E. D. Assad, "Use of Climate Forecasts to Soybean Yield Estimates," In: H. El-Shemy, Ed., *Soybean Physiology and Biochemistry*, InTech, 2011, p. 489. <http://www.intechopen.com/books/soybean-physiology-and-biochemistry/>
- [32] E. Mercante, R. A. C. Lamparelli, M. A. Uribe-Opazo and J. V. Rocha, "Modelos de Regressão Lineares Para Estimativa de Produtividade da Soja no Oeste do Paraná, Utilizando Dados Espectrais," *Engenharia Agrícola*, Vol. 30, No. 3, 2010, pp. 504-517. http://www.scielo.br/scielo.php?pid=S0100-69162010000300014&script=sci_arttext
- [33] CONAB, "Companhia Nacional de Abastecimento. Historical Series," 2011. [http://www.conab.gov.br/conteudos.php?a=1252&t=2&Página_objcmsconteudos=3#A_objcmsconteudos](http://www.conab.gov.br/conteudos.php?a=1252&t=2&Pagina_objcmsconteudos=3#A_objcmsconteudos)
- [34] K. R. Saraiva and F. Souza, "Estatísticas Sobre Irrigação nas Regiões Sul e Sudeste do Brasil Segundo o Censo Agropecuário 2005-2006," *Revista Irriga*, Vol. 16, No. 2, 2012, pp. 168-176.
- [35] J. Paulino, M. V. Folegatti, C. A. Zolin, R. M. Sánchez-Román and J. V. J. Unesp, "Situação da Agricultura Irrigada no Brasil de Acordo com o Censo Agropecuário 2006," *Irriga*, Vol. 16, No. 3, 2011, pp. 163-176.
- [36] G. R. da Cunha, N. A. Barni, J. C. Haas, J. R. T. Maluf, R. Matzenauer, A. Pasinato, M. B. M. Pimentel and J. L. F. Pires, "Zoneamento Agrícola e Época de Semeadura Para Soja No Rio Grande do Sul," *Revista Brasileira de Agrometeorologia*, Vol. 9, No. 3, 2001, pp. 446-459.
- [37] B. M. Rabus and A. R. R. Eineder, "The Shuttle Radar Topography Mission—A New Class of Digital Elevation Models Acquired by Spaceborne Radar," *Photogrammetric Engineering & Remote Sensing*, Vol. 57, No. 4, 2003, pp. 241-262. [http://dx.doi.org/10.1016/S0924-2716\(02\)00124-7](http://dx.doi.org/10.1016/S0924-2716(02)00124-7)
- [38] E. Jasinski, D. Morton, R. DeFries, Y. Shimabukuro, L. Anderson and M. Hansen, "Physical Landscape Correlates of the Expansion of Mechanized Agriculture in Mato Grosso, Brazil," *Earth Interactions*, Vol. 9, No. 16, 2005, pp. 1-18. <http://dx.doi.org/10.1175/EI143.1>
- [39] Instituto Brasileiro de Geografia e Estatística (IBGE), "Produção Agrícola Municipal—Automatic Data Recovery System—SIDRA," 2011. www.sidra.ibge.gov.br
- [40] S. R. Dotto and R. C. Rosinha, "Desempenho de Cultivares de Soja Indicadas Para o RS-Relatório de Produtividade, Resultados 2008/2009," *Fundação Pró-Sementes/Sistema FARSLU*, 2009.
- [41] P. M. Brando, S. J. Goetz, A. Baccini, D. C. Nepstad, P. S. A. Beck and M. C. Christman, "Seasonal and Interannual Variability of Climate and Vegetation Indices across the Amazon," *Proceedings of the National Academy of Sciences of the United States of America*, Vol. 107, No. 33, pp. 14685-14690. <http://dx.doi.org/10.1073/pnas.0908741107>
- [42] A. Huete, K. Didan, T. Miura, E. P. Rodriguez, X. Gao and L. G. Ferreira, "Overview of the Radiometric and Biophysical Performance of the MODIS Vegetation Indices," *Remote Sensing of Environment*, Vol. 83, No. 1-2, 2002, pp. 195-213. [http://dx.doi.org/10.1016/S0034-4257\(02\)00096-2](http://dx.doi.org/10.1016/S0034-4257(02)00096-2)
- [43] National Aeronautics and Space Administration (NASA), "Warehouse Inventory Search Tool," 2009.

Monitoring Heat Waves and Their Impacts on Summer Crop Development in Southern Brazil*

Anibal Gusso^{1,2,3#}, Jorge Ricardo Ducati^{2,4}, Mauricio Roberto Veronez^{3,5}, Victor Sommer⁶, Luiz Gonzaga da SilveiraJunior^{3,7}

¹Environmental Engineering, Vale do Rio dos Sinos University (UNISINOS), São Leopoldo, Brazil

²Center for Remote Sensingand Meteorological Research, Federal Universityof Rio Grande do Sul (UFRGS), Porto Alegre, Brazil

³VizLab-Advanced Visualization Laboratory, Vale do Rio dos Sinos University (UNISINOS), São Leopoldo, Brazil

⁴Astronomy Department, Federal Universityof Rio Grande do Sul (UFRGS), Porto Alegre, Brazil

⁵Graduate Program in Geology, Vale do Rio dos Sinos University (UNISINOS), São Leopoldo, Brazil

⁶CropBreeding Foundation (Fundação Pró-Sementes), Passo Fundo, Brazil

⁷Graduate Program in Applied Computing, Vale do Rio dos Sinos University (UNISINOS), São Leopoldo, Brazil

Email: # anibalg@unisinos.br

Received **** 2014

Copyright © 2014 by authors and Scientific Research Publishing Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

Abstract

Periods in the soybean summer cycle that are sensitive to the occurrence of high temperatures were studied. An analysis was performed on the variability of soybean yields associated with crop canopy temperatures during key development periods. A land surface temperature (LST) data series from MODIS (Moderate Resolution Imaging Spectroradiometer) on the Aqua satellite was processed between 2003 and 2012 that covered the entire state of Rio Grande do Sul, in Brazil. Enhanced vegetation index (EVI) data from MODIS on the Terra satellite were used to monitor the LST during different phenological stages. Spatially interpolated maps of soybean yield distributions were generated using data obtained from Instituto Brasileiro de Geografia e Estatística (IBGE) at state and municipality levels. The results indicate that canopy-LST occurrence in mid-February, during the grain filling, is most correlated to yield reduction ($R^2 = 0.82$ and $RMSD = 14.4\%$). At the state level, the average yield is $2003 \text{ kg}\cdot\text{ha}^{-1}$ with a standard deviation of $308 \text{ kg}\cdot\text{ha}^{-1}$. The overall average of the canopy-LST is 305.0 K (31.8°C) with a standard deviation of 1.9 K . The slope of the downward linear relationship between canopy-LST and yield was -28.7% . These results indicate that monitoring heat wave events can provide important information for characterising agriculture vulnerability.

*Measurements are inclusive of drought and heatwave effects.

#Corresponding author.

Keywords

Land Surface Temperature; Soybean; Remote Sensing; Canopy; Vegetation Index; MODIS Data

1. Introduction

Weather fluctuations and other associated extreme events can cause severe losses to agricultural production with potential worldwide economic impacts [1] [2]. In Brazil, increases in the frequency of extreme events, such as the occurrence of high temperatures and reduced rainfall, are prone to produce severe effects on agricultural yields [3] [4], especially soybeans and maize [5]. As a result, distortions and uncertainties in agricultural policies may increase losses and establish barriers for agricultural financing [6] due to unpredictable government policies which are a more important cause of domestic price volatility than world market price fluctuations [1].

Under a climate change scenario, the physical parameters of the earth's surface, such as temperature, water availability and evapotranspiration, will change over the future decades [7] [8]. These changes can restrict crop development and reduce yields, which could be adversely affected as canopy temperature fluctuations often exceed the optimum range [9]. Thus, a better understanding of plant responses to the combined effect of drought and heat stress is pertinent [10] to the management of potential regional climate risks in the coming decades [3] [11] [12].

The stress caused by high temperature occurrences has impacts on agricultural yields, even when the average temperature reaches one or two degrees above the ideal for the culture [13]-[15]. However, the quantitative assessment of production losses and impacts on yields from the duration and intensity of heat waves is still an issue [16] [17].

Rio Grande do Sul State (RS hereafter) is the third largest producer of soybeans in Brazil and accounted for approximately 18% of the national production in 2012 [18]. Although the production was 11.62 million tons in 2011, it reached a yield average at the state level of $2845 \text{ kg}\cdot\text{ha}^{-1}$. The historical average from 2003 to 2012 was only $2097 \text{ kg}\cdot\text{ha}^{-1}$ [18]. During most years, the frequency and intensity of rainfall from sowing to harvest have been variable and often insufficient for the full development of culture [19]. For this purpose, improvements in the management capacity and strategies are essential to benefit from favourable weather conditions and mitigate impacts of non-favourable conditions [20] [21].

In the Rio Grande do Sul State (RS), the large inter-annual variability of rainfall is mainly due to El Niño and La Niña occurrences, which cause yield fluctuations in southern Brazil [20]-[22]; there, the most impacted crops are usually soybean and maize [20] in the summer. Prolonged drought effects on the summer crop in 2005 caused a decrease of approximately 75% in the soybean grain production [23]. Although weather fluctuations, such as high temperature occurrences and water stress, are not always problematic [16], heat waves that may or may not be associated with droughts are increasingly gaining interest in scientific publications [24] due to the need for sustainable agriculture management and an assessment of the vulnerability to future international demands [4].

The crop development profile of vegetation can be studied as an integrated function of the weather conditions [20]. Usually, vegetation indices correlate well with soybean yields because they are mainly associated with biomass evolution [25] [26].

Remote sensing data associated with geostatistics tools have been applied in agricultural studies. Typically, EOS-MODIS (Earth Observing System-Moderate Resolution Imaging Spectroradiometer) satellite imagery data have been applied in the monitoring and modelling of bioclimatic processes, crop cycle development, agricultural production and biophysical parameter estimates [27]-[30].

Several studies have confirmed the potential of MODIS sensors for crop mapping. However, a few challenges remain to confirm its role as an alternative to traditional official agricultural estimation methods, especially for crop development conditions. Earlier studies [31]-[33] used temperature measurements from NOAA satellite data to evaluate global vegetation conditions and drought-induced effects on vegetation.

Recent studies that use satellite data series have indicated that yield vulnerability would be caused by heat waves via plant damage and inhibited crop growth [17] [24] [32] [34], even when the average temperature reaches one or two degrees above the optimal temperature for the culture [13]-[15]. These effects are induced by

reductions in canopy photosynthesis at the time of heat stress [10] [35], by evaporative demand increases [32] [36] or the flowering period duration changes [37]. Currently, although it is known that the flowering period is more sensitive to temperature than that to water stress, which especially affects the grain number [4] [34] [35] [38] [39], heat wave impacts on crop growth are not well understood [16] [17].

Using satellite data [27], observed that vegetation vigour decreases are able to be linked to yield by means of the vegetation index. A close relationship exists between the canopy-LST of soybeans and yields in February during drought occurrence [24]. In the present paper, we propose the following: 1) temperature fluctuations around the optimum level in the crop canopy have an inverse effect on soybean yields during the summer crop in Rio Grande do Sul State; 2) heat waves that may or may not be associated with droughts can occur; thus, it is possible to detect a decrease in yields due to heat waves, even if a drought has not occurred; 3) considering that heat waves can potentially intensify a drought effect during crop cycle development, it is expected that the most severe decrease in yields occurs when those effects are combined; 4) in this study, we define a heat wave as any registered land surface temperature (LST) occurrence that exceeds the average conditions of summer crops during a specific time window with a resulting yield decrease.

To evaluate the above mentioned hypothesis, we are investigating the effects of canopy temperature on soybean yield during crop development from early flowering to the grain filling period in RS/Brazil using satellite imagery.

2. Material and Methods

2.1. Study Area

This study analysed 496 municipalities in RS State/Brazil that are located between approximately 27° and 34° South and 49° and 58° West, which covers a soybean crop area of ~4.19 million ha during the crop years from 2003 to 2012. **Figure 1** displays the study area in Brazil.

Recently, the prevailing management practice is zero till age farming (in Portuguese, *Plantio Direto*), which is a low tillage planting and sowing practice that greatly reduces soil erosion and organic matter degradation [27]. A moist subtropical mid-latitude climate (*Cfa* and *Cfb* types) and four well-defined seasons prevail in this region [40]. Rainfall is relatively well distributed throughout the year, especially in the northern half of RS where soybean cultivation is dominant. The cumulative average rainfall during the year is 1554 mm; no dry period occurs. The cumulative average rainfall during the five-month summer crop (October to February) is 651 mm [41]. The annual average temperature is 291.2 K (18.1°C) which the absolute maximum temperatures occur in January (315.3 K or 42.2°C), February (312.7 K or 39.6°C) and March (311.8 K or 38.7°C) [41].

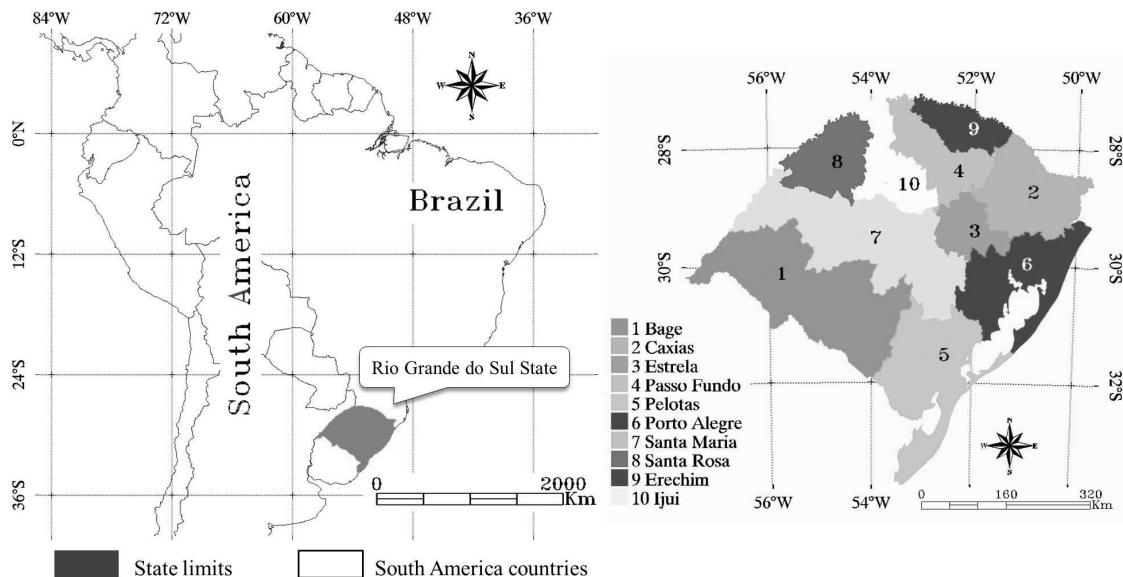


Figure 1. Rio Grande do Sul State and regional study areas from EMATER.

Three droughts occurred in the study period, which severely affected the summer crops of 2004, 2005 and 2012. The most severe drought in 2005 caused a 75% loss of the soybean production [18] when the temperature averages over the crop canopy were approximately 7 K higher than the ideal conditions [24].

Typically, RS is rain-fed, and the irrigation systems designed for soybean crop areas cover only 170,000 ha [42] [43], which comprised less than 4.5% of the total soybean areas in the state in 2006 [18].

2.2. Crop Area Analysis

The soybean crop areas have been identified by application of the MCDA (MODIS Crop Detection Algorithm), which was developed for crop area estimation and is fully described by [29]. A crop area map for ten different crop years was generated from a map composition that combines each crop year map from 2003 to 2012. The resulting crop area map composition tagged all soybean crop pixels at a frequency equal to or greater than two events, which totalled 5.37 million hectares. **Figure 2** shows the resulting soybean map using the MCDA procedure.

2.3. Data Type and Resolution

Several sources of data were used in this study: 1) annual soybean agricultural statistics at the state and municipality levels [23] for the entire study area were used to compare and evaluate the results obtained from our soybean area estimation procedure; 2) soybean cropping calendars were provided by the State Agency EMATER (*Associação Riograndense de Empreendimentos de Assistência Técnica de Extensão Rural*) for the crop years of 2003, 2004 and 2005; 3) LST data from 2003 to 2012 derived from the MODIS sensor on board the Aqua satellite (product MYD11A2-collection 5) were used to derive temperatures over the soybean canopy (canopy-LST) in the crop years between 2003 and 2012. This product was preferred because it is obtained during the afternoon passage. Collection 5 products had a mean and standard deviation of the LST differences of less than 0.2 K and 0.5 K, respectively [44]; 4) official data reports and historical statistics of soybean crop production from IBGE were obtained; 6) official data reports and historical statistical data of soybean crop areas from IBGE were used to calculate soybean yields over the entire study area; 6) Enhanced Vegetation Index (EVI) data from 2003 to 2012 derived from the MODIS sensor on board the Terra satellite (product MOD13Q1-collection 5), which is composed of the best radiometric and geometric pixels selected within a 16-day period, were used to classify the canopy-LST as an auxiliary data because the vegetation index and LST interpret opposite extreme weather events [45]. The EVI data are representative of vegetation vigour. EVI is based on canopy reflectance characteristics and is designed to minimise the influence of soil and atmospheric effects on satellites [46] [47].




Figure 2. Soybean crop area map composition for crop years 2003 to 2012.

The EVI expression is $2.5 * (\text{Nir} - \text{Red}) / (\text{Nir} + 6 \text{ Red} - 7.5 \text{ Blue} + 1)$, where Nir, Red and Blue are atmospherically or partially atmospherically corrected surface reflectance of near infrared, red and blue bands, respectively [46]. The MODIS images and products were pre-processed by the National Aeronautics and Space Administration [48] and are available at no charge at https://lpdaac.usgs.gov/data_access/data_pool.

2.4. Vegetation Development

Agricultural crop production is characterised by a large variability in yield as a result of the main agrometeorological parameters [25]. This is particularly evident in Rio Grande do Sul State, where agrometeorological conditions during the summer are known to vary spatially and annually causing different impacts on yield.

Recently, yield estimation models have considered agricultural practices, weather or climatological conditions as the predominant physically driven conditions that represent the cycle of agricultural development [24], especially precipitation [20] [21] [26]. In RS State, [27] calculated the relationship between soybean yields and vegetation vigour from EVI; they obtained an $R^2 = 0.91$ for a municipality level analysis by considering an integrative window of the soybean crop cycle. However, agriculture is also impacted by crop canopy temperature extremes, such as heat waves [17] [24] [49]. **Figure 3** presents the high variability of yield in RS.

The preferred period of soybean sowing in RS is from mid-October to mid-December, according to agricultural zoning for lower climatic risk within various soils, regions and cultivars [50]. Depending on the sowing date, maximum plant growth is observed from late January to early March [29]. The flowering period is typically reached between late January and early March (EMATER), as observed during the 2003 to 2005 period. **Figure 4** present the mean agricultural calendar for soybean in RS.

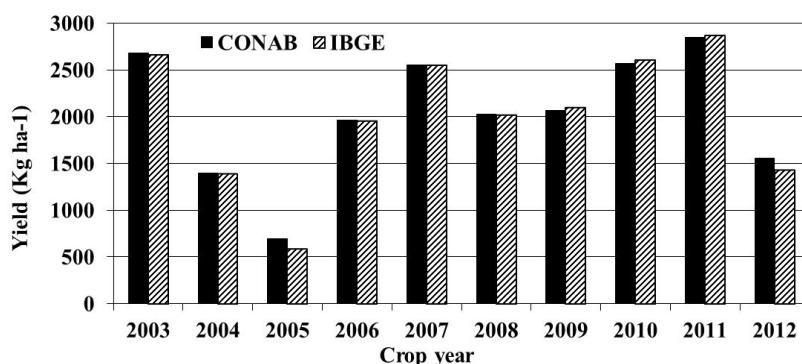


Figure 3. Soybean yield averages in Rio Grande do Sul State from 2003 to 2012.

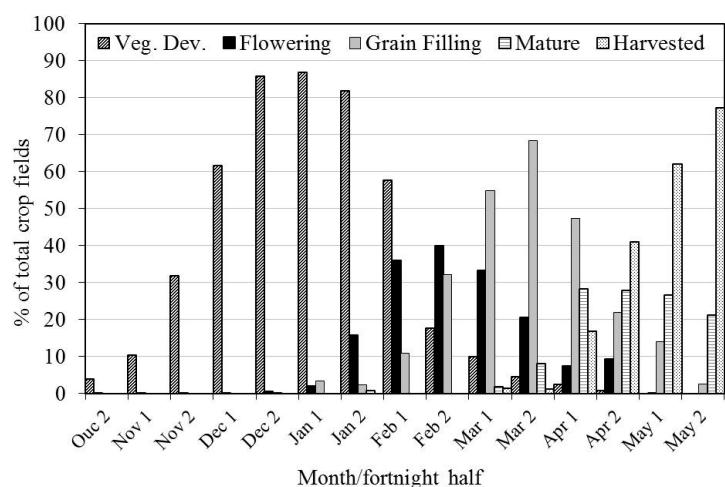


Figure 4. Average agricultural calendar for soybean crops in Rio Grande do Sul, from EMATER-RS (2003-2005).

2.5. Canopy-LST and Soybean Crop Yield

LST is a measure of surface temperature (also known as skin temperature), rather than air temperature, which is more commonly applied in physiological studies [51]. The theoretical basis is Planck's Law of Radiation, which describes that radiating energy from a black-body, as predict by Stefan-Boltzmann's Law, is distributed in the electromagnetic spectrum as a function of its temperature [52]. Thus, the LST is the internal manifestation of the random translational energy of the molecules constituting a body [53] [54]. Several applications of thermal radiation have used the black-body radiation theory for temperature estimations since the pioneer studies of Dick, Penzias and Wilson in the 1950s [54]. For Earth Science studies, the external manifestation of an object's energy can be detected by remotely sensed devices into an orbital path way using thermal scanning technology [55]. Therefore, it is possible to obtain a physical measure from the vegetation that covers the surface.

Considering that physiological activities of leaves are closely related to their actual temperature (canopy temperature), rather than air temperature, the LST can be used as a reliable measure of physiological activity of a vegetation canopy [51] [56], because the vegetation structures of soybeans with planophile canopies are prone to preserve spectral emissivity information [57]. Canopy-LST can exert a direct effect on plant photosynthesis. Among the main impacts of heat stress, the effect on photosynthesis is the most important on yields due to the inhibition of the crop growth rate [17]. Canopy temperatures between 298 K (25°C) and 309 K (35°C), with an ideal average near 303 K (30°C), are most frequently considered the ideal conditions for soybean development [14] [17] [35]. Nevertheless, studies have demonstrated that the combined use of the LST and vegetation index assumes an inverse mathematical relationship [24] [36] [58].

2.6. Satellite Data Retrieval and Processing

To generate the yield map, spatially interpolated maps were obtained using the spherical/ordinary kriging method, which is based on the trend of the variability in the sample's values and the distance between them [59]. This technique is adequate for the conditions identified in the present study, where a limited number of meteorological stations were available. To generate spatially interpolated maps, average yield values for each municipality were placed at their centroids. Then they were defined at the regional scale to generate regional averages of yield, EVI and accumulated rainfall.

First, we acquired MODIS/Terra data (MOD13Q1 product-collections 5) and MODIS/Aqua data (MYD11A2) that covered the entire RS State (image tiles: H13V11 and H13V12) for the 2003–2012 study period. The 496 municipalities were grouped into ten regional areas of EMATER. It is important to note that the analysis of deviations from the smoothed maps was only performed on the areas mapped as soy cultivation between 2003 and 2012. The original LST data product (MYD11A2), as distributed by NASA, corresponds to composites of eight-day averages. The original vegetation index product (MOD13Q1) is distributed for 16-day maximum value composites. Thus, to match the LST product to the EVI product, we rearranged data and grouped them as follows:

- 1) MOD13Q1 already represents a maximum composite of 16 days; thus, any further calculation was performed within 16 days of EVI, starting from DOY 001;
- 2) To retrieve the most representative LST data from the crop canopy, the first step was to obtain the maximum LST composition over 16 days by combining two MYD11A2 products (an average of eight days) that cover the same DOY period from item 1;
- 3) After that, steps 1 and 2 were also performed for the subsequent 16-day composites of MYD11A2 and MOD13Q1;
- 4) By combining two LST composites of 16 days as a function of the maximum EVI, the canopy-LST composite of 32 days is obtained. Therefore, the resulting product at DOY 001 is representative of the temperatures over crop canopies that occurred when the EVI was maximum between DOY 001 and 032. Canopy-LST at DOY 017 is representative of the temperatures over crop canopies that occurred when the EVI was maximum between DOY 017 and 056, and so on. An earlier analysis of canopy-LST (prior to DOY 001) was not performed due to the heterogeneous surface, which characterises the initial phenological stage. Such conditions can induce spatial variations of several degrees in the near surface air temperature [60] and consequently in the canopy-LST because of the absence of the soybean vegetation canopy in the initial development period;
- 5) Canopy-LST maps are generated for different time periods of the phenological stage, which cover a time window of 32 days (DOY 001; 017; 033; 049) (as presented in **Figure 5(b)**). All Canopy-LST maps and Yield

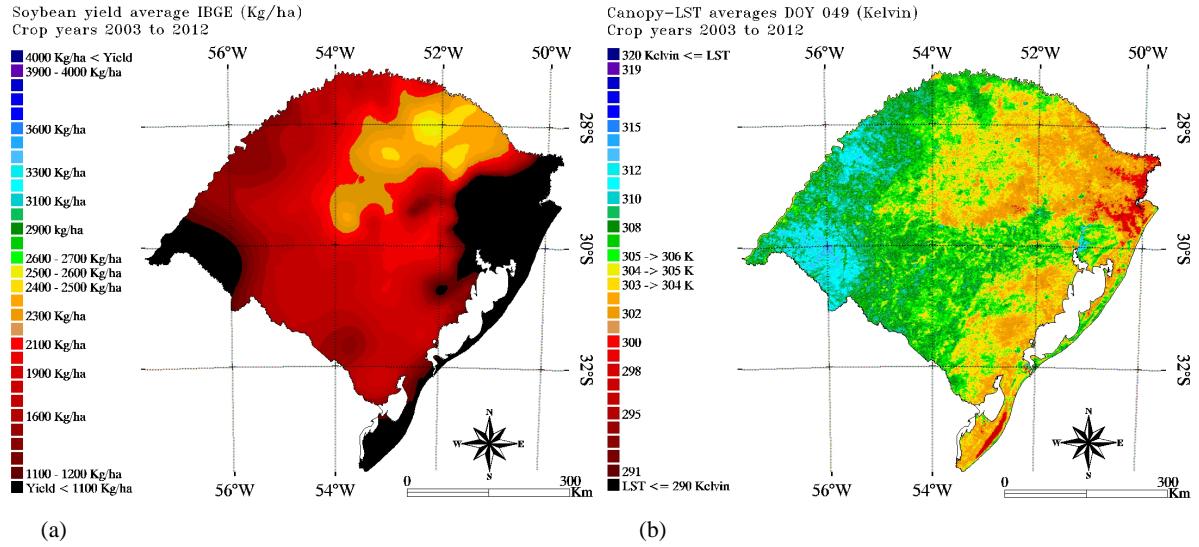


Figure 5. Distribution of the yield average (a) obtained between 2003 and 2012 and (b) canopy-LST map in DOY 049.

map were merged with the crop area map from MCDA;

6) Finally, the percentage variation of each regional average canopy-LST composite was compared to its average from 2003 to 2012 in the same time window. This calculation is performed such that the generated LST is associated with the maximum EVI that occurs in one of the two 16-day composites. The detailed procedure is important because we are not interested in the maximum LST registered in the time window of 32 days, but rather we were valuing the LST associated with the best vegetation coverage of the time window, which is considered the canopy-LST in order to avoid a previous moisture background and/or drought effects. Here we note that the concept of the former mentioned calculation is completely different from the latter.

Although studies of crop modelling that use LST data very often do not adequately adhere to these fundamentals, for cold or heat effects on vegetation, the physical concepts in the previously mentioned review sections must be seriously considered before processing the imagery.

3. Results

Soybean yields in RS State obtained from IBGE were compared to the canopy-LST at various development stages at the state and regional scales from 2003 to 2012. Spatially interpolated maps of the yield average distribution (**Figure 5(a)**) and the canopy-LST distribution for DOY 001, 017, 033, 049 and 065 (**Figure 5(b)**) were obtained. Linear least square regression analysis was performed for state level soybean production estimates that were obtained from IBGE for the same period. A LST analysis was performed on the Kelvin scale; therefore, each 1% percent deviation from the average corresponds to approximately 3 K. **Figure 6** presents the relative yield distribution as a function of the relative canopy-LST in RS.

The soybean yield deviations from each crop year were compared to the canopy-LST deviation. An analysis of the data shows a well-defined trend for higher yields and below average canopy-LST occurrences and lower yields for above average LST (**Figures 6(c)** and **(d)**).

To better understand the canopy-LST impacts and its correlation to yields, all of the data were analysed as deviations from the averages between 2003 and 2012. Through a non-linear relationship, it was observed that variations in the canopy-LST averages from DOY 033 (between February 2nd and March 5th), which is fully related to the flowering period in **Figure 4** (Feb. 1-Feb. 2), are characterised by $R^2 = 0.68$ and RMSD = 19.3%. However, a linear relationship with $R^2 = 0.82$ and RMSD = 14.4% is obtained at DOY 049 (between February 18th and March 21st), which is more closely related to the grain filling period (Feb. 2-Mar. 1).

The dense group of points placed in the inferior right quadrant of **Figure 6(f)** represent points with a relative canopy-LST above 2% in all ten regions in the summer crop year of 2005. As observed by [24], these higher canopy-LST deviations in 2005 are linked to the most severe drought occurrence of the study period. Considering a minimum yield of $1000 \text{ kg}\cdot\text{ha}^{-1}$, the overall yield average inside the crop areas from 2003 to 2012 was

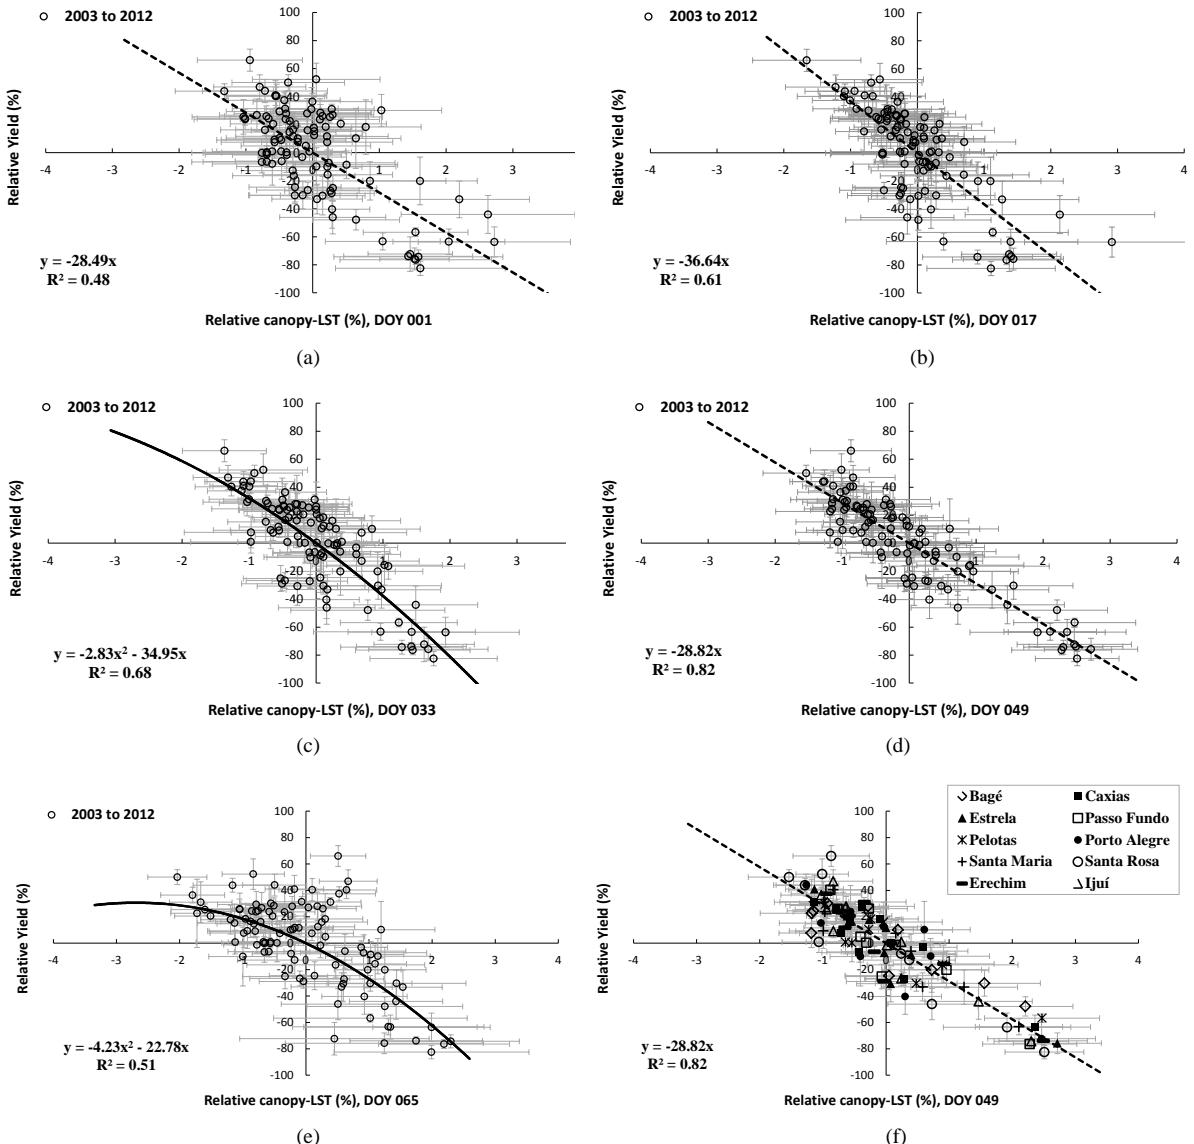


Figure 6. Scatter grams that compare the relative yield distribution as a function of the relative canopy-LST obtained from crop years 2003 to 2012.

2003 kg·ha⁻¹ with a standard deviation of 308 kg·ha⁻¹. Considering DOY 049, the overall average canopy-LST is 305.0 K (31.8°C) with a standard deviation of 1.9 K, the minimum is 296.4 K (23.2°C), and the maximum is 315.0 K (41.8°C). These physically driven conditions led to a linear decreasing relationship of -28.7%. However, when considering drought-free crop years (without 2005 and 2012), the new overall yield average is 2260 kg·ha⁻¹ with a standard deviation of 326 kg·ha⁻¹. Under these conditions, the new overall average canopy-LST is 303.6 (30.4°C) with a standard deviation of 1.8 K, the minimum is 295.8 (22.6°C), and the maximum is 313.0 K (39.8°C), which are close to the suggested limit of the ideal temperature conditions.

4. Discussion

The heat stress that occurs during flowering and pod formation (R1-R5) affects grain numbers, which is closely related to the yield [35] [38] where as stress during grain filling (R5-R7) reduces the grain size [38]. When energy and water conditions are non-limiting for plant growth, considering complete canopy conditions, crops can present elevated canopy-LST due to aerodynamic resistances that suppress sensible heat transfer [32]. When

evaluated cotton plant (C3 plant as soybean) development under stress conditions and [10] observed that the direct effects of temperature on reproductive processes (flowering) are difficult to distinguish from metabolic processes because the inhibition of photosynthesis can also be caused by overheating the canopy, even under well-watered conditions. However, in the present investigation, considering the drought-induced crop years of 2005 and 2012 (**Figures 3** and **6(f)**), yield loss may be associated with the coupled effect of two different physically driven conditions: an initial reduction in the water availability followed by a temperature increase, which is probably exacerbated by the energy exchange mainly due to wind, humidity and exposure to incident radiation [32] [61] [62].

As presented in **Figure 4**, the average agricultural calendar for ten different regions in the state presents three maxima of the flowering period from the first half of February to the first half of March that are greater than 30%. Although DOY 049 also covers the flowering period, similar to DOY 033, we note that the results for DOY 049 are more correlated. However, this result is possibly linked to the computational redundancy of the canopy-LST data to yield losses due to drought. As the canopy-LST in the DOY 049 window covers the last end of the crop development profile, the damaging effects due to heat waves may overlap with early drought effects that may have begun several weeks prior, especially for crop years 2005 and 2012. In this situation, the implementation of strategies and policy planning for the region, such as a sowing calendar and the use of irrigation techniques [22], are extremely important. Heat waves can potentially increase drought effects by overheating the vegetation canopy, which inhibits photosynthesis [10] [63] and intensifies plant damage (**Figure 6(f)**). Furthermore, it is important to note that, considering the mean agriculture calendar (**Figure 4**), DOY049 does not correlate as well as DOY 033 with the flowering period (**Figure 6(c)**), but it does correlate better to grain filling (**Figure 6(f)**). This suggests that, although higher temperatures can occur in the earlier phenological stages (as during flowering), severe impacts on yields are prone to be observed during the grain filling stage, especially when the elevated canopy-LST is associated with drought(e.g., crop years 2005 and 2012) (**Figure 3**).

The relatively smaller correlations between canopy-LST and yield for the 32-day composite windows presented in **Figures 6(a)** and **(b)** can be linked to background effects. The periods covered are DOY 001 between January 1st and February 1st (Jan 1-Jan 2 in **Figure 4**) and DOY 017 between January 17th and February 17th (Jan 2-Feb 1 in **Figure 4**). Soil cover by vegetation during this stage is sparse, which increases surface temperature and may be confused with an unrealistic rise in the canopy-LST.

5. Conclusions

We observed that variations of the averages of canopy-LST during flowering/grain filling periods of summer crops are closely associated with variations in soybean yields.

The results indicate that heat waves that are slightly warmer than the optimal conditions for growth can potentially increase drought effects and yield loss by overheating the vegetation canopy and intensifying plant damage.

Finally, we concluded that future studies on canopy-LST monitoring can significantly contribute to the regional characterisation of agriculture vulnerability and management of potential climate conditions and fluctuations.

Acknowledgements

We wish to thank Vale do Rio dos Sinos University (UNISINOS). Additionally, we thank the National Aeronautical and Space Administration (NASA) for the Terra and Aqua/MODIS data. We especially thank the Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) for their support.

References

- [1] UNEP—United Nations Environment Programme. Environmental Food Crisis (2009) The Environment's Role in Averting Future Food Crises. http://www.unep.org/pdf/foodcrisis_lores.pdf
- [2] Masuda, T. and Goldsmith, P.D. (2009) World Soybean Production: Area Harvested, Yield, and Long-Term Projections. *International Food and Agribusiness Management Review*, **12**, 143-163.
- [3] Lobell, D.B., Burke, M.B., Tebaldi, C., Mastrandrea, M.D., Falcon, W.P. and Naylor, R.L. (2008) Prioritizing Climate Change Adaptation Needs for Food Security in 2030. *Science*, **319**, 607-610. <http://dx.doi.org/10.1126/science.1152339>

- [4] Batistti, D.S. and Naylor, R.L. (2009) Historical Warnings of Future Food Insecurity with Unprecedented Seasonal Heat. *Science*, **323**, 240-244. <http://dx.doi.org/10.1126/science.1164363>
- [5] Streck, N.A. and Alberto, C.N. (2006) Estudo numérico do impacto da mudança climática sobre o rendimento de trigo, soja e milho. *Pesquisa Agropecuária Brasileira*, **41**, 1351-1359. <http://dx.doi.org/10.1590/S0100-204X2006000900002>
- [6] FAO—Food and Agriculture Organization (2011) The State of Food Insecurity in the World. <http://www.fao.org/docrep/013/i2050e/i2050e07.pdf>
- [7] Meehl, G.A., Stocker, T.F., Collins, W.D., Friedlingstein, P., Gaye, A.T., Gregory, J.M., Kitoh, A., Knutti, R., Murphy, J.M., Noda, A., Raper, S.C.B., Watterson, I.G., Weaver, A.J. and Zhao, Z.-C. (2007) Global Climate Projections. In: Solomon, S., Qin, D., Manning, M., Chen, Z., Marquis, M., Averyt, K.B., Tignor, M. and Miller, H.L., Eds., *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*, Cambridge University Press, Cambridge and New York, 747-846.
- [8] Gorman, P.A. and Schneider, T. (2009) The Physical Basis for Increases in Precipitation Extremes in Simulations of 21st-Century Climate Change. *Proceedings of the National Academy of Sciences*, **106**, 14773-14777. <http://dx.doi.org/10.1073/pnas.0907610106>
- [9] Rosenzweig, C., Iglesias, A., Yang, X.B., Epstein, P. and Chivian, E. (2001) Climate Change and Extreme Weather Events: Implications for Food Production, Plant Diseases, and Pests. *NASA Publications-Paper* **24**, 2, 90-104.
- [10] Carmo-Silva, A.E., Gore, M.A., Andrade-Sánchez, P., French, A.N., Hunsaker, D.J. and Salvucci, M.E. (2012) Decreased CO₂ Availability and Inactivation of Rubisco Limit Photosynthesis in Cotton Plants under Heat and Drought Stress in the Field. *Environmental and Experimental Botany*, **83**, 1-11. <http://dx.doi.org/10.1016/j.envexpbot.2012.04.001>
- [11] Howden, S.M., Soussana, J.-F., Tubiello, F.N., Chhetri, N., Dunlop, M. and Meinke, H. (2007) Adapting Agriculture to Climate Change. *Proceedings of the National Academy of Sciences*, **104**, 19691-19696.
- [12] Wheeler, T.R., Craufurd, P.Q., Ellis, R.H., Porter, J.R. and Prasad, P.V.V. (2000) Temperature Variability and the Yield of Annual Crops. *Agriculture, Ecosystems and Environment*, **82**, 159-167. [http://dx.doi.org/10.1016/S0167-8809\(00\)00224-3](http://dx.doi.org/10.1016/S0167-8809(00)00224-3)
- [13] Sediama, T. (2009) Tecnologias de produção e usos da soja. Mecenas, Londrina, 314.
- [14] Khan, A.Z., Shah, P., Khan, H., Nigar, S., Perveen, S., Shah, M.K., Amanullah, A., Khalil, S.K., Munir, S. and Zubair, M. (2011) Seed Quality and Vigor of Soybean Cultivars as Influenced by Canopy Temperature. *Pakistan Journal of Botany*, **43**, 643-648.
- [15] Lobell, D.B. and Asner, G.P. (2003) Climate and Management Contributions to Recent Trends in US Agricultural Yields. *Science*, **229**, 1032. <http://dx.doi.org/10.1126/science.1077838>
- [16] Meerburg, B.G., Verhagen, A., Jongschaap, R.E.E., Franke, A.C., Schaap, B.F., Dueck, T.A. and van der Werf, A. (2009) Do Nonlinear Temperature Effects Indicate Severe Damages to US Crop Yields under Climate Change? *Proceedings of the National Academy of Sciences*, **106**, 120. <http://dx.doi.org/10.1073/pnas.0910618106>
- [17] Schlenker, W. and Roberts, M. (2009) Nonlinear Temperature Effects Indicate Severe Damages to US Crop Yields under Climate Change. *Proceedings of the National Academy of Sciences*, **106**, 15594-15598. <http://dx.doi.org/10.1073/pnas.0906865106>
- [18] CONAB—Companhia Nacional de Abastecimento (2012) Acompanhamento da safra brasileira de grãos. CONAB/DIPAI/SUINF/GEASA. *Conab*: Brasília. http://www.conab.gov.br/OlalaCMS/uploads/arquivos/12_09_06_09_18_33_boletim_graos - setembro_2012.pdf
- [19] Matzenauer, R., Barni, N.A. and Maluf, J.R.T. (2003) Estimative of the Relative Water Consumption of Soybean in Rio Grande do Sul State, Brazil. *Ciência Rural*, **33**, 1013-1019. <http://dx.doi.org/10.1590/S0103-84782003000600004>
- [20] Fontana, D.C., Weber, E., Ducati, J.R., Berlato, M.A., Guasselli, L.A. and Gusso, A. (2002) Monitoramento da cultura da soja no centro—Sul do Brasil durante La Niña de 1998/2000. *Revista Brasileira de Agrometeorologia*, **10**, 343-351.
- [21] Ferreira, D.B. (2010) Análise da variabilidade climática e suas consequências para a produtividade da soja na região sul do Brasil. Ph.D. Thesis, INPE, São José dos Campos.
- [22] Melo, R.W., Fontana, D.C. and Berlato, M.A. (2004) Indicadores de produção de soja no Rio Grande do Sul comparados ao zoneamento agrícola. *Pesquisa Agropecuária Brasileira*, **39**, 1167-1175. <http://dx.doi.org/10.1590/S0100-204X2004001200002>
- [23] IBGE—Instituto Brasileiro de Geografia e Estatística (2012) SIDRA: Sistema IBGE de recuperação automática. <http://www.sidra.ibge.gov.br/>
- [24] Gusso, A. (2013) Integration of NOAA/AVHRR Images: Cooperation Network towards National Soybean Crop

- Monitoring. *Revista Ceres*, **60**, 43-52.
- [25] Esquerdo, J.C.D.M., Zullo, J. and Antunes, J.F.G. (2011) Use of NDVI/AVHRR Time-Series Profiles for Soybean Crop Monitoring in Brazil. *International Journal of Remote Sensing*, **32**, 3711-3727. <http://dx.doi.org/10.1080/01431161003764112>
- [26] De Melo, R.W., Fontana, D.C., Berlato, M.A. and Ducati, J.R. (2008) Anagrometeorological-Spectral Model to Estimate Soybean Yield, Applied to Southern Brazil. *International Journal of Remote Sensing*, **29**, 4013-4028. <http://dx.doi.org/10.1080/01431160701881905>
- [27] Gusso, A., Ducati, J.R., Veronez, M.R., Arvor, D. and Silveira Jr., L.G. (2013) Spectral Model for Soybean Yield Estimate Using MODIS/EVI Data. *International Journal of Geosciences*, **4**, 1233-1241. <http://dx.doi.org/10.4236/ijg.2013.49117>
- [28] Junges, A.H., Fontana, D.C. and Melo, R.W. (2012) Caracterização do cultivo de trigo na região norte do Estado do Rio Grande do Sul através das estimativas oficiais de área cultivada, produção e rendimento de grãos. *Ciência Rural*, **42**, 31-37. <http://dx.doi.org/10.1590/S0103-84782011005000153>
- [29] Gusso, A., Adami, M., Formaggio, A.R., Rizzi, R. and Rudorff, B.T.F. (2012) Soybean Area Estimation and Mapping by Means MODIS/EVI Data. *Pesquisa Agropecuária Brasileira*, **47**, 425-435. <http://dx.doi.org/10.1590/S0100-204X2012000300015>
- [30] Mabilana, H.A., Fontana, D.C. and Fonseca, E.L. (2012) Desenvolvimento de modelo agrometeorológico espectral para estimativa de rendimento do milho na Província de Manica-Moçambique. *Revista Ceres*, **59**, 337-349. <http://dx.doi.org/10.1590/S0034-737X2012000300007>
- [31] Seiler, R.A., Kogan, F. and Sullivan, J. (1998) AVHRR-Based Vegetation and Temperature Condition Indices for Drought Detection in Argentina. *Advances in Space Research*, **21**, 481-484. [http://dx.doi.org/10.1016/S0273-1177\(97\)00884-3](http://dx.doi.org/10.1016/S0273-1177(97)00884-3)
- [32] Nemani, R. and Running, S. (1997) Land Cover Characterization Using Multitemporal Red, Near-Ir and Thermal-Ir Data from NOAA/AVHRR. *Ecological Applications*, **7**, 79-90. [http://dx.doi.org/10.1890/1051-0761\(1997\)007\[0079:LCCUMR\]2.0.CO;2](http://dx.doi.org/10.1890/1051-0761(1997)007[0079:LCCUMR]2.0.CO;2)
- [33] Running, S.W., Loveland, T.R., Pierce, L.L., Nemani, R.R. and Hunt, E.R. (1995) A Remote Sensing Based Vegetation Classification Logic for Global Land Cover Analysis. *Remote Sensing of Environment*, **51**, 39-48. [http://dx.doi.org/10.1016/0034-4257\(94\)00063-S](http://dx.doi.org/10.1016/0034-4257(94)00063-S)
- [34] Liu, W.T. and Kogan, F. (2002) Monitoring Brazilian Soybean Production Using NOAA/AVHRR Based Vegetation Indices. *International Journal of Remote Sensing*, **23**, 1161-1179. <http://dx.doi.org/10.1080/01431160110076126>
- [35] Board, J.E. and Kahlon, C.S. (2007) Soybean Yield Formation: What Controls It and How It Can Be Improved. In: El-Shemy, H.A., Ed., *Soybean Physiology and Biochemistry*, InTech Open Access, Rijeka, 1-36.
- [36] Hope, A.S., Petzold, D.E., Goward, S.N. and Ragan, R.M. (1986) Simulated Relationships between Spectral Reflectance Thermal Emissions and Evapotranspiration of a Soybean Canopy. *Journal of the American Water Resources Association*, **22**, 1011-1019. <http://dx.doi.org/10.1111/j.1752-1688.1986.tb00772.x>
- [37] Rodrigues, O., Didonet, A.D., Lhamby, J.C.D., Bertagnolli, P.F. and Luz, J.S. (2001) Resposta quantitativa do florescimento da soja à temperatura e ao fotoperíodo. *Pesquisa Agropecuária Brasileira*, **36**, 431-437. <http://dx.doi.org/10.1590/S0100-204X2001000300006>
- [38] Gibson, L.R. and Mullen, R.E. (1996) Soybean Seed Quality Reductions by High Day and Night Temperature. *Crop Science*, **36**, 1615-1619. <http://dx.doi.org/10.2135/cropsci1996.0011183X003600060034x>
- [39] Craufurd, P.Q. and Wheeler, T.R. (2009) Climate Change and the Flowering Time of Annual Crops. *Journal of Experimental Botany*, **60**, 2529-2539. <http://dx.doi.org/10.1093/jxb/erp196>
- [40] Koppen, W. (1948) Climatologia. Fondo de Cultura Económica, Mexico, 71.
- [41] INMET-Instituto Nacional de Meteorología. Normais Climatológicas do Brasil de 1961 a 1990. (2009) http://www.inmet.gov.br/portal/index.php?r=bdm_ep/bdmepr
- [42] Saraiva, K.R. and Souza, F. (2012) Estatísticas sobre irrigação nas regiões sul e sudeste do Brasil segundo o censo agropecuário 2005-2006. *Revista Irriga*, **17**, 168-176.
- [43] Paulino, J., Folegatti, M.V., Zolin, C.A., Sánchez-Román, R.M. and José, J.V. (2011) Situação da agricultura irrigada no Brasil de acordo com o censo agropecuário 2006. *Revista Irriga*, **16**, 163-176.
- [44] Wan, Z.M. (2008) New Refinements and Validation of the MODIS Land-Surface Temperature/Emissivity Products. *Remote Sensing of Environment*, **112**, 59-74. <http://dx.doi.org/10.1016/j.rse.2006.06.026>
- [45] Seiler, R.A. and Kogan, F. (2002) Monitoring ENSO Cycles and Their Impacts on Crops in Argentina from NOAA-AVHRR Satellite Data. *Advances in Space Research*, **30**, 2489-2493. [http://dx.doi.org/10.1016/S0273-1177\(02\)80316-7](http://dx.doi.org/10.1016/S0273-1177(02)80316-7)
- [46] Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X. and Ferreira, L.G. (2002) Overview of the Radiometric and Biophysical Performance of the MODIS Vegetation Indices. *Remote Sensing of Environment*, **83**, 195-213.

[http://dx.doi.org/10.1016/S0034-4257\(02\)00096-2](http://dx.doi.org/10.1016/S0034-4257(02)00096-2)

- [47] Justice, C.O., Townshend, J.R.G., Vermote, E.F., Masuoka, E., Wolfe, R.E., Saleous, N., Roy, D.P. and Morisette, J.T. (2002) An Overview of MODIS Land Data Processing and Product Status. *Remote Sensing of Environment*, **83**, 3-15. [http://dx.doi.org/10.1016/S0034-4257\(02\)00084-6](http://dx.doi.org/10.1016/S0034-4257(02)00084-6)
- [48] NASA-National Aeronautics and Space Administration. (2014) Land Processes Distributed Active Archive Center (LPDAAC). https://lpdaac.usgs.gov/data_access/data_pool
- [49] Kogan, F. (2001) Operational Space Technology for Global Vegetation Assessment. *Bulletin of the American Meteorological Society*, **82**, 1949-1964. [http://dx.doi.org/10.1175/1520-0477\(2001\)082<1949:OSTFGV>2.3.CO;2](http://dx.doi.org/10.1175/1520-0477(2001)082<1949:OSTFGV>2.3.CO;2)
- [50] Cunha, G.R., Barni, N.A., Haas, J.C., Maluf, J.R.T., Matzenauer, R., Pasinato, A., Pimentel, M.B.M. and Pires, J.L.F. (2001) Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. *Revista Brasileira de Agrometeorologia*, **9**, 446-459.
- [51] Sims, D.A., Rahman, A.F., Cordova, V.D., El-Masri, B.Z., Baldocchi, D.D., Bolstad, P.V., Flanagan, L.B., Goldstein, A.H., Hollinger, D.Y., Misson, L., Monson, R.K., Oechel, W.C., Schmid, H.P., Wofsy, S.C. and Xu, L. (2008) A New Model of Gross Primary Productivity for North American Ecosystems Based Solely on the Enhanced Vegetation Index and Land Surface Temperature from MODIS. *Remote Sensing of Environment*, **112**, 1633-1646. <http://dx.doi.org/10.1016/j.rse.2007.08.004>
- [52] Hecht, E. (1998) Optics. 3rd Edition, Addison-Wesley, Reading, 694.
- [53] Lillesand, T.M., Kiefer, R.W. and Chipman, J.W. (2003) Remote Sensing and Image Interpretation. 5th Edition, John Wiley & Sons, Hoboken.
- [54] Eisberg, R. and Resnik, R. (1985) Quantum Physics of Atoms, Molecules, Solids, Nuclei and Particles. 2nd Edition, Wiley, Hoboken, 928.
- [55] Elachi, C. (1987) Introduction to the Physics and Techniques of Remote Sensing. 1st Edition, Wiley, New York.
- [56] Diak, G.R. and Whipple, M.S. (1993) Improvements to Models and Methods for Evaluating the Land-Surface Energy Balance and Effective Roughness Using Radiosonde Reports and Satellite-Measured Skin Temperature Data. *Agricultural and Forest Meteorology*, **63**, 189-218. [http://dx.doi.org/10.1016/0168-1923\(93\)90060-U](http://dx.doi.org/10.1016/0168-1923(93)90060-U)
- [57] Salisbury, J.W. (1986) Preliminary Measurements of Leaf Spectral Reflectance in the 8-14 um Region. *International Journal of Remote Sensing*, **7**, 1879-1886. <http://dx.doi.org/10.1080/01431168608948981>
- [58] Sandholt, L., Rasmussen, K. and Andersen, J. (2002) A Simple Interpretation of the Surface Temperature/Vegetation Index Space for Assessment of Surface Moisture Status. *Remote Sensing of Environment*, **79**, 213-224. [http://dx.doi.org/10.1016/S0034-4257\(01\)00274-7](http://dx.doi.org/10.1016/S0034-4257(01)00274-7)
- [59] Jian-Guo, L. and Mason, P.J. (2009) Essential Image Processing and GIS for Remote Sensing. Wiley-Blackwell, 460.
- [60] Anderson, M.C., Norman, J.M., Diak, G.R., Kustas, W.P. and Mecikalski, J.R. (1997) A Two-Source Time-Integrated Model for Estimating Surface Fluxes Using Thermal Infrared Remote Sensing. *Remote Sensing of Environment*, **60**, 195-216. [http://dx.doi.org/10.1016/S0034-4257\(96\)00215-5](http://dx.doi.org/10.1016/S0034-4257(96)00215-5)
- [61] Wan, Z., Wang, P. and Li, X. (2004) Using MODIS Land Surface Temperature and Normalized Difference Vegetation Index Products for Monitoring Drought in the Southern Great Plains, USA. *International Journal of Remote Sensing*, **25**, 61-72. <http://dx.doi.org/10.1080/0143116031000115328>
- [62] Peterson, T.C., Stott, P.A. and Herring, S. (2012) Explaining Extreme Events of 2011 from a Climate Perspective. *American Meteorological Society*, **93**, 1041-1067.
- [63] Salvucci, M.E. (2008) Association of Rubisco Activase with Chaperonin-60 β : A Possible Mechanism for Protecting Photosynthesis during Heat Stress. *Journal of Experimental Botany*, **59**, 1923-1933. <http://dx.doi.org/10.1093/jxb/erm343>

Assessing the MODIS crop detection algorithm for soybean crop area mapping and expansion in the Mato Grosso State, Brazil

Anibal Gusso,^{a,d,g} Damien Arvor,^b Jorge Ducati,^{c,d} Mauricio Roberto Veronez,^{e,g} and Luiz Gonzaga da Silveira Jr.^{f,g}

^a Environmental Engineering, Vale do Rio dos Sinos University (UNISINOS), São Leopoldo-RS, CP275, Brazil; E-Mail: anibalg@unisinos.br (A.G.)

^b IRD UMR ESPACE-DEV 228, 500, rue Jean-François Breton, 34093 Montpellier Cedex 5-France; E-Mail: damien.arvor@ird.fr (D.A.)

^c Astronomy Department, Federal University of Rio Grande do Sul (UFRGS), Porto Alegre, Brazil; E-Mail: ducati@if.ufrgs.br (J.D.)

^d Center for Remote Sensing and Meteorological Research, Federal University of Rio Grande do Sul (UFRGS), 15044, Porto Alegre, Brazil

^e Graduate Program in Geology, Vale do Rio dos Sinos University (UNISINOS), São Leopoldo-RS, CP275, Brazil, Email: veronez@unisinos.br (M.R.V.)

^f Graduate Program in Applied Computing, Vale do Rio dos Sinos University (UNISINOS), São Leopoldo-RS, CP275, Brazil, Email: gonzaga@unisinos.br (L.G.)

^g VizLab - Advanced Visualization Laboratory - Vale do Rio dos Sinos University (UNISINOS), São Leopoldo, Brazil

Abstract. In this study, estimations of crop area were made based on the temporal profiles of the Enhanced Vegetation Index (EVI) obtained from Moderate Resolution Imaging Spectroradiometer (MODIS) images. Evaluation of the ability of the MODIS Crop Detection Algorithm (MCDA) to estimate soybean crop areas was performed for fields in the Mato Grosso State, Brazil. Using the MCDA approach, soybean crop area estimations can be provided for December (first forecast) using images from the sowing period and for February (second forecast) using images from the sowing period and the maximum crop development period. The area estimates were compared to official agricultural statistics from the Brazilian Institute of Geography and Statistics (IBGE) and from the National Company of Food Supply (CONAB) at different crop levels from 2000/2001 to 2010/2011. At the municipality level, the estimates were highly correlated, with $R^2=0.97$ and $RMSD=13,142$ ha. The MCDA was validated using field campaign data from the 2006/2007 crop year. The overall map accuracy was 88.25%, and the Kappa Index of Agreement was 0.765. By using pre-defined parameters, MCDA is able to provide the evolution of annual soybean maps, forecast of soybean cropping areas and the crop area expansion in the Mato Grosso State.

Keywords: agriculture; satellite; soybean mapping; MCDA; crop area expansion.

Address all correspondence to: Anibal Gusso, Vale do Rio dos Sinos University (UNISINOS), Environmental Engineering, São Leopoldo, RS, Brazil, Tel.: +55-51-3591-1122; E-mail: anibalg@unisinos.br

1. Introduction

Crop monitoring is a major concern for food safety and the regulation of the agricultural market. Many programs have been established by agricultural agencies to regularly provide agricultural statistics at different spatial and temporal scales (e.g., the MARS project in Europe or GeoSafras in Brazil). The GEO-GLAM (Global Agriculture Monitoring) project is working to harmonize remote sensing-based crop monitoring systems. In that context, the case of Brazil remains atypical. Brazil is currently considered to be one of the world's granaries and plays an

important role in global markets as a main producer of agricultural commodities. However, official agricultural statistics released by two Brazilian agencies, namely CONAB (Companhia Nacional de Abastecimento - National Company of Food Supply) and IBGE (Instituto Brasileiro de Geografia e Estatística - Brazilian Institute of Geography and Statistics), suffer from two main issues: 1) municipality statistics are not released shortly after harvest, but rather, they are released nearly 18 months after the end of the soybean season; and 2) there is a lack of confidence in the production estimates because they are based on subjective methods and are associated with error measurements [1; 2; 3]

Remote sensing data has the potential to address these issues because enhanced temporal resolution allows producing near-real time estimates of agricultural statistics. In Brazil, several studies led by governmental and non-governmental organizations have focused on crop mapping and forecasting [3; 4; 5]. However, most of these studies were designed for a few cropping years and/or for a limited region. For example, remote sensing images (such as Landsat TM or CBERS) have been used for mapping sugarcane in the CANASAT project by INPE (Instituto Nacional de Pesquisas Espaciais – Brazilian Space Agency) and for mapping soybean in the GeoSafras Project by CONAB. Although these projects confirmed the efficiency of satellite images for mapping perennial and semi-perennial crops, the monitoring of annual crops, such as soybean, corn or cotton, remains an issue. The high incidence of cloud cover during key identification periods of annual crops and the 16-day temporal resolution hindered the operational implementation of Landsat- or CBERS-based methodologies for calculating agricultural statistics [6; 7].

Overcoming the cloud cover challenge requires an increased temporal resolution of the orbital sensors, often at the expense of the spatial resolution. The Moderate-Resolution Imaging Spectroradiometer (MODIS) sensor on board the Terra satellite provides an adequate imaging configuration for crop monitoring based on 1) an almost-daily revisit time; 2) a moderate spatial resolution of 250 m, considered adequate for mapping large-scale agricultural fields [8]; and 3) geometric quality that is high enough for image time series analysis [9].

In the USA, the quality of MODIS data was evaluated for its potential to provide information on both crop yield and crop area [10]. In another study [11], the applicability of MODIS/EVI time series data for mapping agricultural lands was investigated; the study concluded that 16-day composites of MODIS images gave sufficient spatial, spectral and temporal information to

perform the following: 1) adequately separate crop fields from other land uses and 2) express the phenology and climate characteristics of the region. In Brazil, many works have highlighted the efficiency of MODIS time series of vegetation indices for mapping croplands, crop expansion [12; 13], and cropping systems [15; 16; 17].

Although all studies have confirmed the potential of MODIS sensors for crop mapping, a few challenges remain to be solved to confirm its role as an alternative to traditional official agricultural estimate methods. First, most MODIS-based analyses were tested and validated at a local or state scale, and their validity for mapping crops in other agricultural areas remains uncertain. For example, many classification methods consist of supervised approaches based on training samples, which implies the following: 1) it is laborious and costly to get training samples for large-scale areas and 2) agricultural calendars vary drastically between different agricultural areas and over time, especially in frontier areas such as the Amazon, where agricultural practices are evolving rapidly [16; 18; 19; 20]. These challenges have hindered the use of vegetation index time series for large-scale crop mapping. Consequently, implementing an operational system at a nation-wide scale represents a huge challenge; it requires the development of a robust method that accounts for the spatial variability of environmental conditions and agricultural practices across Brazil. Second, most classification systems are based on a complete vegetation index time series, a process that makes the production of near-real time or forecast estimates slow or difficult, which reduces the benefits of using remote sensing data compared with traditional agricultural statistics.

In the present paper, we argue that an operational crop monitoring model should be 1) adapted to specific regional agricultural calendars and 2) based on subsets of vegetation time series to allow an early release of agricultural statistics. To evaluate this hypothesis, we assessed the efficiency of the MODIS Crop Detection Algorithm (MCDA) as proposed by Gusso et al. (2012) [1], which is an example of an operational crop monitoring model. This method has been initially validated for mapping soybean crops in southern Brazil (State of Rio Grande do Sul), and we now demonstrate its efficiency for crop mapping in the Amazonian state of Mato Grosso, which is characterized by different environmental conditions and agricultural practices. MCDA was validated here in a completely different region (southern Amazon) with different crop calendars, double cropping systems that might affect the accuracy of the model for detecting soybean crops

and intense spatial dynamics because soybean cropping has expanded significantly in the last decade.

2. Materials and Methods

2.1. Study Area

The State of Mato Grosso ($906,000 \text{ km}^2$, 146 municipalities) is located in the southern portion of the Amazon basin and is characterized by three main biomes: the Brazilian Cerrado, the Amazon rainforest and the Pantanal. Since the 1970s, a crop expansion process led Mato Grosso to be the largest soybean producer in Brazil (approximately 30% of the national soybean production occurs in Mato Grosso) [21]. In the last decade, intensive practices, such as double cropping, have been widely adopted in Mato Grosso, which is an additional challenge for accurate crop area mapping [19]. Usually, soybean remains the main crop, while maize or cotton is planted after the soybean harvest [16]. Typically, the sowing period for soybean lasts from mid-September to late October and depends mainly on the sowing dates, which are determined according to the onset of the rainy season, which lasts from October to May.

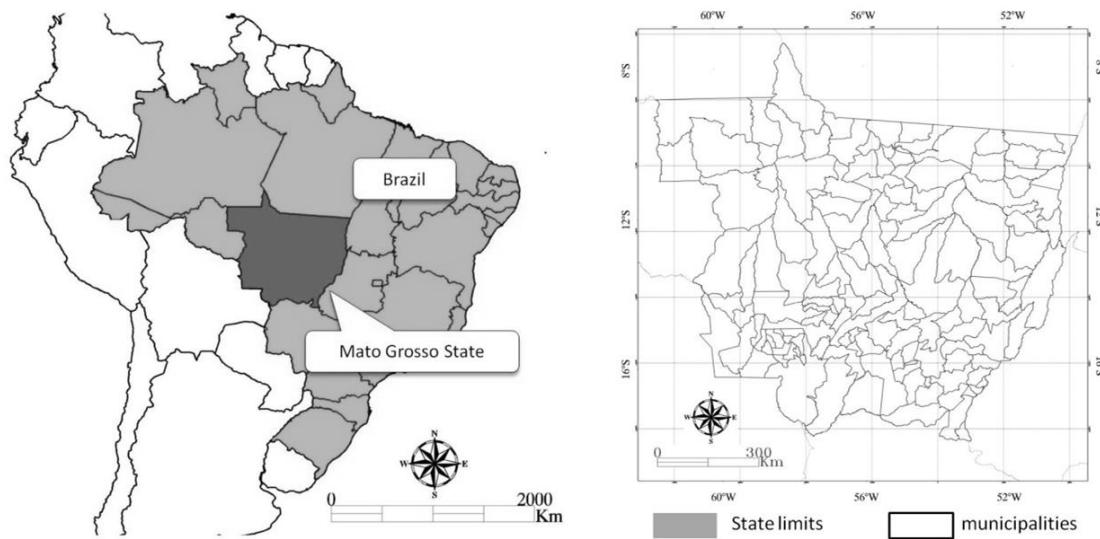


Fig. 1 . Mato Grosso State in Brazil and its 146 municipalities.

2.2. Materials

2.2.1. Input data for applying the MCDA procedure

We used several datasets to represent the main physical conditions and management practices found in Mato Grosso. First, we acquired MODIS EVI data (MOD13Q1 product, collections 5 and 6) covering all of the Mato Grosso State (image tiles: H11V09, H11V10, H12V09, H12V10, H13V09 and H13V10) for the 2000-2011 study period. The EVI data were chosen for their potential to mitigate cloud cover effects and atmospheric and soil background effects [23; 9]. The EVI data are a 16-day composite with high radiometric and geometric corrections. The MODIS images and products were pre-processed by the National Aeronautics and Space Administration (NASA) and are available at no charge at <https://wist.echo.nasa.gov/api/>.

Second, Shuttle Radar Topography Mission (SRTM) data [24] were used to generate a slope map with a 90-meter spatial resolution according to the method described by Gusso et al. (2012). This map was used to exclude areas inappropriate for mechanization (slope >12%); soybean in Mato Grosso is a highly mechanized crop and requires relatively smooth land to allow the use of farm machinery [25].

Third, we acquired 10-day accumulated precipitation data from September to October at 11 meteorological stations for each year of the study period (2000-2011) to determine the initial sowing period. These data were acquired from INMET (Instituto Nacional de Meteorologia - Brazilian Institute of Meteorology).

2.2.2. Validation data

Two types of datasets were acquired to validate our approach at different scales, i.e., state- and municipality-level datasets and pixel-level datasets. First, we used annual soybean agricultural statistics at the state and municipality levels from [21] and [26] for the entire study area. Second, a field campaign was carried out in 2006 and 2007 to collect validation data at the crop field scale. A total of 76 farms were visited and mapped in 13 municipalities representing the two main agricultural regions (in central and western Mato Grosso, along the BR163 road and on the Chapada dos Parecis, respectively). A complete map of the visited municipalities is introduced in [16]. For each farm, information about crop types, yields, sowing and harvesting dates were collected. In this study, we only considered the crop type information for the 2006/2007 season's harvest. For that specific cropping season, only 38 farms were considered (information on other farms were not available for that season), representing 1,078 fields for a total area of 196,929 ha (i.e., a total of 31,508 MODIS pixels and a mean field area of 182.7 ha).

2.3. MCDA calibration for Mato Grosso

The MODIS Crop Detection Algorithm (MCDA) was used to classify soybean crops in this study; a diagrammatic flowchart is presented in Figure 2. This procedure classifies a pixel as soybean if it adheres to conditions A and B in Figure 2. Conditions A and B are related to the regional soybean calendar and vegetation development characteristics starting from the sowing period. Conditions C and D are related to terrain characteristics and management, which are not expected to vary from one cropping year to another. The present work aimed to adapt and to test the MCDA; specifically, we evaluated how MCDA adheres to conditions A and B described in [1]. To establish these two conditions, three parameters need to be defined: Amp (amplitude, which is the difference between maximum and minimum EVI values); Lmin (the lower minimum EVI value in a minimum image) and Umin (the maximum EVI value in a minimum image). These parameters are defined based on the analysis of the observed EVI time series for cropping areas. The time series are characterized by low EVI values during the pre-sowing period (September-October) and high EVI values during the maximum crop development period (January-February) [16]. Adjustments of MCDA parameters will be referred to as the MCDA calibration.

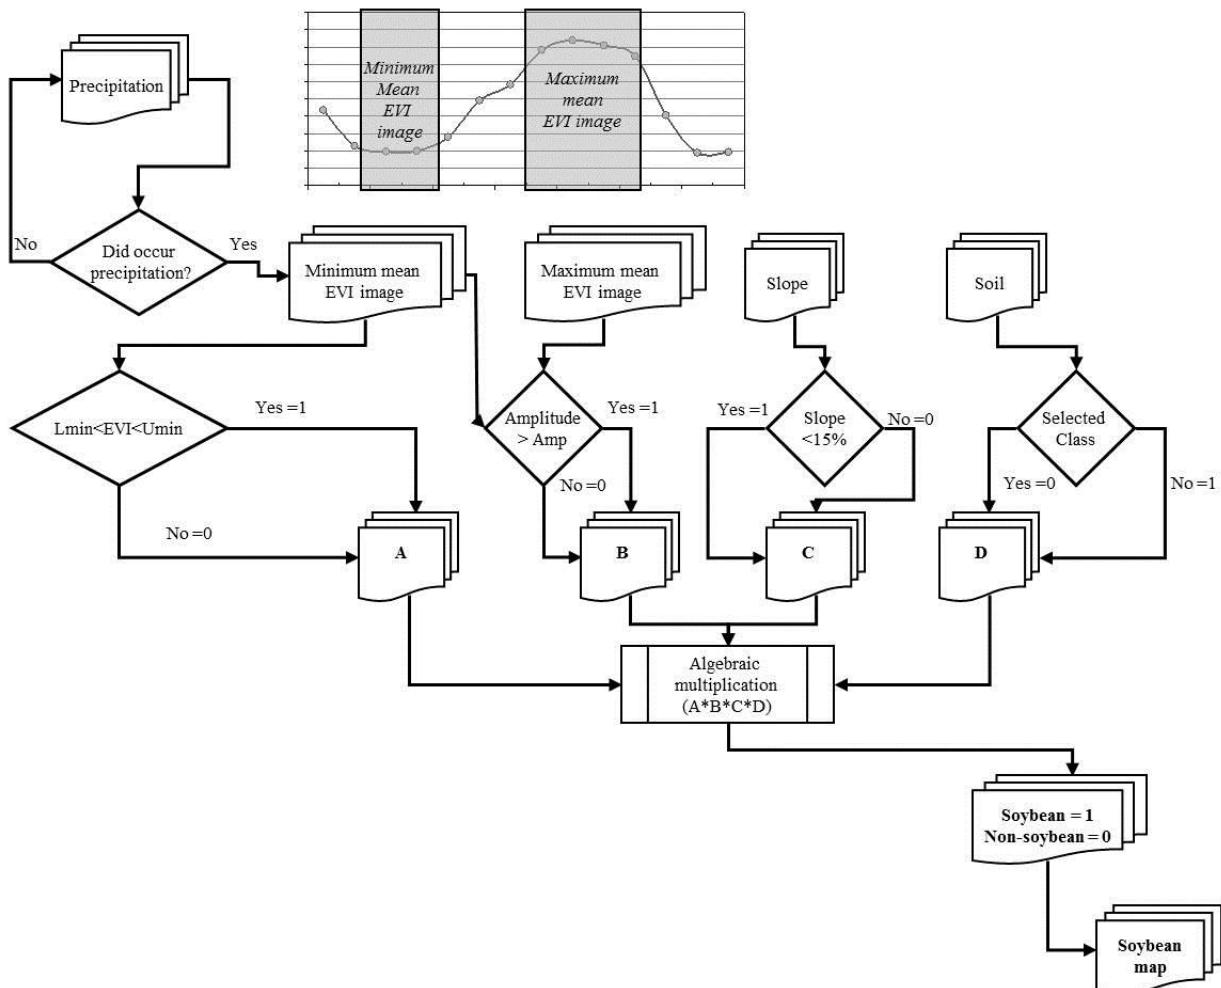


Fig. 2. Flowchart of the MCDA classification [1] based on MODIS/EVI images.

The set of initial parameters of three test sites of 100 x 100 pixels in Mato Grosso were obtained from MODIS/EVI images; the parameters are from two specific periods for each crop year according to the methodology developed in [1]. The periods are as follows: sowing (Day Of Year (DOY) 225 to 337) and maximum crop development (DOY 353 to 033). The sowing period often starts in September, but the beginning of the sowing period is determined by the rainfall in each crop year, in agreement with the soybean zoning provided by [22].

Figure 3 presents the mean EVI time series acquired over the crop fields that coexist. The natural vegetation cover in the region is typical of the Cerrado biome; this vegetation cover causes some confusion with detecting soybean development during the rainy season [16; 3]. For the EVI time series, two major classes can be identified: single and double cropping systems. Single cropping systems refer to soybean or cotton that is sown without any other crop being planted before or after the main crop. Soybean and cotton can thus be differentiated based on the agricultural calendar because cotton is sown in December and harvested in June. For double cropping systems, another crop (usually cotton, maize, millet or sorghum) is sown after the soybean harvest.

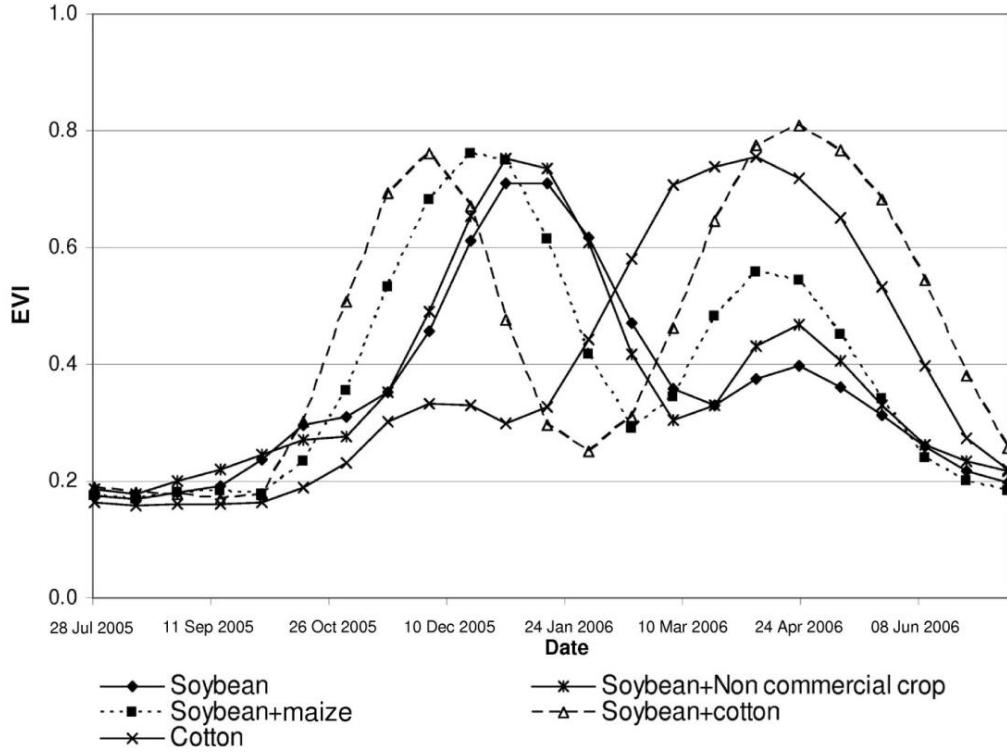


Fig. 3. Mean MODIS/EVI time series for selected points of agricultural plots [16].

Two MODIS/EVI images from the sowing period are first averaged two by two to obtain the minimum mean EVI image (MinMeanEVI), which smooths the EVI profile for a relatively short time window. This MinMeanEVI image then defines the Lmin and Umin parameters, i.e., the lower and upper EVI values for each cropping year, respectively. Pixels below Lmin are typically associated with cloud shadows or water bodies. According to the methodology developed in [1], Umin is set as the convergence between the minimum and maximum mean EVI images, and pixels above Umin are not from annual crops. Pixels with EVI values between Lmin and Umin are designated as soybean crop pixels in accordance with condition A in Figure 2.

During the sowing period, increasing MODIS/EVI values are observed because of rapid and intense plant growing; maximum values are reached after a relatively short period [11]. To characterize the maximum mean EVI image (MaxMeanEVI), four consecutive EVI images from this period (DOY 353 to 033; Figure 2) are averaged. The difference between MaxMeanEVI and MinMeanEVI is computed to produce the EVI amplitude image (AmpEVI) for each cropping year, according to the procedure outlined in [1]. However, the remaining challenge is to obtain the best Amp value that includes not only pure soybean pixels (with high values in the maximum

EVI image and low values in the minimum EVI image) but also mixed pixels located at the border of the soybean fields. The optimal Amp value for each cropping year can be obtained from the convergence region between the minimum and maximum EVI values in the scatterplots, as described in [1]. The Amp value is the minimum difference between the maximum and the minimum mean EVI values to which a mixed soybean pixel can be designated as a soybean pixel. Pixels with amplitude values greater than Amp are tagged as soybean according to condition B of the MCDA procedure (Figure 2).

The soybean area can be estimated after the maximum mean EVI image (MaxMeanEVI) is available, which normally occurs in January, because the MCDA approach uses the half-phase of the crop development. The MOD13Q1 product is often available after a delay of approximately 20 days. Therefore, the soybean estimation should be released no later than early February (from now on referred as the 2nd forecast of the MCDA). However, as an alternative to forecasting the soybean area, a first estimate can be provided in early December of each crop year based on the MinMeanEVI image. This image is strongly related to the sowing period of the current crop year, and the MaxMeanEVI image of a previous crop year (referred as the 1st forecast of the MCDA). The same procedure as the first forecast can be performed if no usable images were found or if a water deficit is empirically observed (30 days without a rainfall event over 10 mm); in that case, images from previous normal crop years are used to generate the maximum mean EVI image. However, for crop year 2000/2001, no 1st forecast of MCDA was available because there were no MODIS data before 2000.

2.4. Adjustment of management practices

MCDA was developed to provide an objective and automated tool for soybean classification. The MCDA accuracy was validated in one step. However, the MCDA calibration procedure is not complete until the same Mato Grosso input parameters, which were chosen to represent the physically driven components defined in the MCDA, can be used for all of the evaluated crop years. Therefore, once identified, the parameters from the physically driven components cannot be adjusted after the fact; this constrains the dynamical adjustment process of the algorithm [1]. If some further adjustment is needed to improve the fit of the crop areas with statistics from IBGE for one or more crop years, then this new parameter value must be used for all of the tested crops. After several iterations for all crop years, the adjusted combination with the best

performance to define the final values of MCDA, were found to be 0.05, 0.39 and 0.36 for Umin, Lmin and Amp, respectively.

3. Results

Based on the previously described analysis, the soybean area was estimated at the municipality level for 141 municipalities in Mato Grosso State from 2000/2001 to 2010/2011 and was compared to the official estimates provided at <http://www.sidra.ibge.gov.br> [21] using a regression analysis. The MCDA soybean area estimates are provided at state and municipal levels due to the spatial distribution of the classified soybean area. Therefore, these estimates can be compared to the IBGE and CONAB municipal statistics. No prior year estimate could be provided for the 2000/2001 because this was the first crop year in which MODIS data became available. No further MCDA maps were generated after 2010/2011 because the data from crop years 2011/2012 and 2012/2013 had not yet been released by IBGE at the municipal level.

3.1. State Area Estimates

The MCDA second forecast estimates for Mato Grosso were compared to IBGE and CONAB statistics. The maximum difference observed across the study period was 7.85% above MCDA for the 2000/2001 crop season.

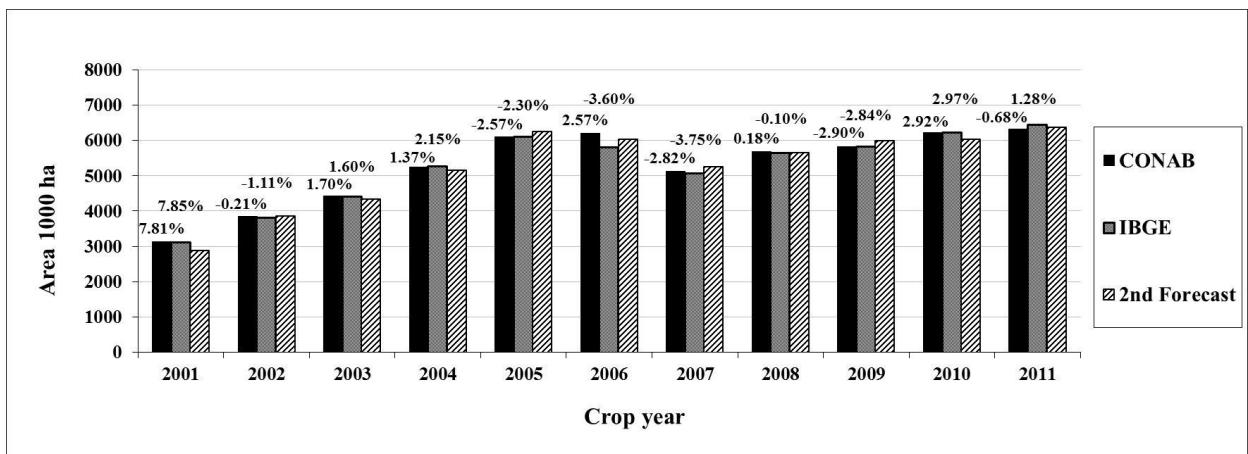


Fig. 4 Comparison of the MCDA (2nd forecast), IBGE and CONAB soybean area estimates for the Mato Grosso State and percent difference from MCDA.

3.2. Municipality Area Estimates

Soybean area was estimated at the municipality level from the crop season 2000/2001 to 2010/2011 and was compared to official estimates provided by IBGE

(<http://www.sidra.ibge.gov.br>) using a regression analysis. Quickly updating the current crop year is challenging because the IBGE municipality data are published approximately one year after the end of the soybean season. Figure 5 presents the linear least squares regression analysis for the municipal soybean estimates from the MCDA procedure and from IBGE for crop years 2000/2001 to 2010/2011 with $R^2=0.97$. Therefore, for the average of the eleven crop years studied, the MCDA explains 97% of the variation of the data estimated by IBGE, which indicates a good agreement between the estimates. The group of points above 500,000 ha represents the crop area of Sorriso municipality, which had 483,000 ha of soybean crop area in 2004 [21]. Overall, the MCDA results slightly underestimated the soybean crop area in comparison to municipal data from IBGE. The intercept value in the overall linear regression was 4416 ha, which indicates that municipalities with small soybean areas are slightly overestimated by the MCDA in comparison to the IBGE estimates. The positive intercept value indicates that, in general, the overestimated municipalities are typically <50,000 ha. The slope value in the overall linear regression was 0.88. The Root-Mean-Square Deviation (RMSD) for the second forecast of the MCDA was approximately 13,142 ha for all crop years; the thin dashed lines are the double RMSD (above and below the regression line) and contain 95% of the data points. USA soybean area estimates from [28] were generated by MODIS and by the USDA/NASS, and for these estimates, the R^2 values ranging from 0.44 to 0.94, and the RMSD varied from 41,465 to 120,955 ha for the entire USA.

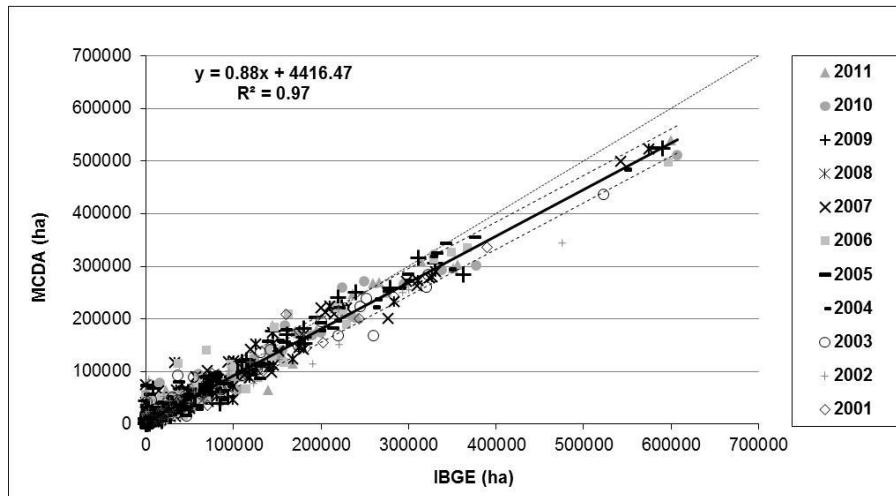


Fig. 5. Regression analysis between soybean area estimates by MCDA (second forecast) and IBGE for the Mato Grosso State for all crop years (2000/2001 to 2010/2011).

3.3. Crop level estimates

The 2006-2007 MCDA crop map was compared to the field data collected during that specific harvest to validate the classification accuracy. Based on the field data introduced in Section 2.2.2, we randomly selected 400 MODIS pixels (200 soybean pixels and 200 non-soybean pixels). Table 1 shows the confusion matrix resulting from the comparison between these randomly selected pixels and the crop map produced by MCDA for the cropping year 2006/2007. The overall map accuracy was approximately 88.25%, and the Kappa Index of Agreement was 0.765, a satisfactory value, because for the assessment of classification maps, Kappa values greater than 0.5 are considered satisfactory [27]. Soybean area estimates from [29], generated by MODIS and by the USDA/NASS for different ecoregions in the Great Lakes - USA, obtained overall accuracy of 82%.

Table 1 Confusion matrix from the comparison of MCDA and field campaign mapping.

		Reference (Pixels)			User's Accuracy
MCDA		Soybean	Non Soybean	Total classified	
Soybean		153	0	153	100%
Non soybean		47	200	250	76.50%
				400	
Reference total		200	200		
Producer's accuracy		80.97%	100%		
Overall accuracy		88.25%			
Kappa Index		0.765			

4. Discussion

The MCDA model was developed with a focus on soybean crop area identification. However, the validation of large area mapping still presents a difficult challenge [29]. The MCDA approach establishes the input parameters as fixed criteria; therefore, the same input parameters are used independent of crop year dynamics during the evaluated period, from 2000/2001 to

2010/2011. This is an important consideration for the analysis of the 80.97% Producer's accuracy result.

According to field campaign data used for the crop level evaluation of MCDA, the resulting User's accuracy, almost 100%, strongly indicates that the MCDA detection of soybean crop area is reliable. However, the 80.97% obtained from Producers' accuracy analysis is related to 47 misidentifications highlighted in Section 3.3, and this result deserves further analysis.

Direct visual inspection of the data indicates that the pixels misidentifications presented in Table 1 can be explained as follows: the majority of the cases in the 2006/2007 crop (31 over 47 pixels) came from double crop system practices in which cotton came after soybean. As cotton is a valuable commodity and tends to have a longer cycle, it is worthwhile for the producer to plan the soybean cycle to provide sufficient time for the cotton crop (as seen in Figure 3). According to the summer crop calendar, this schedule shift is significant (usually begins by the first half of December as seen Figure 3), and it introduces a detuning with respect to the timings used at MCDA in the MaxMeanEVI image. This results in a value lower than Amp, which leads to zero for condition B in Figure 2. An additional cause of misidentification (4 over 47 pixels) came from double crop system practices in which maize came after soybean. For maize, the crop cycle is shorter, and there are a variety of choices for short-period cultivars. Therefore, the displacement of the sowing date for soybean is smaller. MCDA performs well with a single crop soybean system; even in the cases when farmers plant two successive crops and thus have to anticipate the soybean sowing time, the model performs fairly well.

As expected, we noticed that the soybean field size caused considerable differences in the classification results. MCDA generated better results where crop fields were larger than the area in which the MCDA was developed, the State of Rio Grande do Sul. Fields with smaller areas were more subject to errors than those with larger areas; this is consistent with a previous analysis in Mato Grosso [18] and also with work from [8] and [19].

An accurate annual soybean crop area map is an efficient tool for surveying the deforestation drivers linked to soybean cultivation in this region. Figure 6 shows the total area expansion of soybean in red; the overall trend is for expansion toward the north-northeast of Mato Grosso, which was also observed in [18;20;30], causing pressure on the Amazon biome.

By comparing MCDA maps from 2001 to 2011, we obtained the total soybean crop area in Mato Grosso. Figure 6 shows a map of the total soybean crop area with 11,544,000 ha of

soybean crops and it demonstrates the expansion of the soybean crop area during the studied period.




Fig. 6 Total soybean crop area expansion in Mato Grosso State after 2000/2001.

4. Conclusions

The MCDA procedure is based on a consistent and objective methodology for estimating soybean crop areas using Moderate-Resolution Imaging Spectroradiometer (MODIS) images and Enhanced Vegetation Index (EVI) data in the Mato Grosso State. By using pre-defined parameters, MCDA provides the evolution of annual thematic soybean maps, directly forecasting the soybean cropping areas and area expansion in the state. This is a timesaving procedure and is independent of analyst skills and image interpretation. Our results indicate that, when compared to current official methods for soybean area estimation in Brazil, the MCDA procedure provides a reduction in analysis time, and it is a simple and effective method for providing spatial information.

The total soybean crop expansion area that intrudes into the Amazon biome for the study period (3,463,000 ha) represents more than 55% in Mato Grosso and approximately 14.3% of the total soybean area cultivated in Brazil, based on the crop area for the 2010/2011 crop year.

Implementing operational crop monitoring systems on large areas such as Brazil remains a challenge because it requires accounting for the spatiotemporal variability of environmental conditions and agricultural practices. In this paper, we assessed the efficiency of the MODIS Crop Detection Algorithm (MCDA), which had initially been validated in Southern Brazil, for mapping soybean crop areas in the Amazonian State of Mato Grosso. We validated our approach for two states: Rio Grande do Sul and Mato Grosso (present paper). Additional research would need to be carried out to apply this method to all of Brazil. However, Mato Grosso and Rio Grande do Sul are two important study areas because they present the most extreme cases for cultivating soybean (specifically, different ecoregions, different calendars, different cropping systems). Therefore, our results suggest that the MCDA is likely to be successful in other regions as well.

Acknowledgments

Thanks are due to the Instituto Nacional de Meteorologia (INMET) for the data provided and to the National Aeronautical and Space Administration for the free and easily accessible MODIS data products available for environmental and agricultural science research around the world.

References and Notes

1. Gusso, A.; Formaggio, A.R.; Rizzi, R.; Adami, M.; Rudorff, B.T.F. Soybean crop area estimation by MODIS/EVI data. *Pesquisa Agropecuária Brasileira* 2012, 47, 425-435.
2. Johann, J.A.; Rocha, J.V.; Duft, D.G.; Lamparelli, R.A.C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. *Pesquisa Agropecuária Brasileira* 2012, 47, 1295-1306.
3. Epiphanio, R.D.V.; Formaggio, A.R.; Rudorff, B.T.F.; Maeda, E.E.; Luiz, A.J.B. Estimating soybean crop areas using spectral-temporal surfaces derived from MODIS images in Mato Grosso, Brazil. *Pesquisa Agropecuária Brasileira* 2010, 45, 72-80.

4. Rizzi, R.; Risso, J.; Epiphanio, R.D.V.; Rudorff, B.F.T.; Formaggio, A.R.; Shimabukuro, Y.E.; Fernandes, S.L. Estimativa da área de soja no Mato Grosso por meio de imagens MODIS. In *Proceedings of the 14th Brazilian Remote Sensing Symposium (SBSR 2009)*, Natal, RN, Brazil, April 2009; INPE: São José dos Campos, SP, Brazil, 2009; pp. 387–394.
5. Figueiredo, D.C. Projeto GeoSafras: aperfeiçoamento do sistema de previsão de safras da Conab. *Revista de Política Agrícola* **2005**, *14*, 110–120.
6. Sano, E.E.; Ferreira, L.G.; Asner, G.P.; Steinke, E.T. Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. *International Journal of Remote Sensing* **2007**, *28*, 2739–2752.
7. Sugawara, L. M.; Rudorff, B.F.T.; Adami, M. Viabilidade de uso de imagens do Landsat em mapeamento de área cultivada com soja no Estado do Paraná. *Pesquisa Agropecuária Brasileira* **2008**, *43*, 1763–1768.
8. Lobell, D.B.; Asner, G.P. Cropland distributions from temporal unmixing of MODIS data. *Remote Sensing of Environment* **2004**, *93*, 412–422.
9. Justice, C.O.; Townshend, J.R.G.; Vermote, E.F.; Masuoka, E.; Wolfe, R.E.; Saleous, N.; Roy, D. P.; Morisette, J.T. An overview of MODIS Land data processing and product status. *Remote Sensing of Environment* **2002**, *83*, 3–15.
10. Doraiswamy, P.C.; Sinclair, T.R.; Hollinger, S.; Akhmedov, B.; Stern, A.; Prueger, J. Application of MODIS derived parameters for regional crop yield assessment. *Remote Sensing of Environment* **2005**, *97*, 192–202.
11. Wardlow, B.D.; Egbert, S.L.; Kastens, J.H. Analysis of time-series MODIS 250m vegetation index data for crop classification in the U.S. Central Great Plains. *Remote Sensing of Environment* **2007**, *108*, 290–310.

12. Morton, D.C.; DeFries, R.S.; Shimabukuro, Y.E.; Anderson, L.O.; Arai, E.; Espirito-Santo, F. d-B.; Freitas, R.; Morissette, J. Cropland expansion changes deforestation dynamics in the southern Brazilian Amazon. *Proceedings of the National Academy of Sciences* **2006**, *103*, 14637–14641.
13. Macedo, M.N.; DeFries, R.S.; Morton, D.C.; Stickler, C.M.; Galford, G.L.; Shimabukuro, Y.E. Decoupling of deforestation and soy production in the southern Amazon during the late 2000s. *Proceedings of the National Academy of Sciences* **2006**, *109*, 1341–1346.
14. Pittman, K.; Hansen, M.C.; Becker-Reshef, I.; Potapov, P.V.; Justice, C.O. Estimating Global Cropland Extent with Multi-year MODIS Data. *Remote Sensing* **2010**, *2*, 1844–1863.
15. Galford, G.L.; Mustard, J.F.; Melillo, J.; Gendrin, A.; Cerri, C.C.; Cerri C.E.P. Wavelet analysis of MODIS time series to detect expansion and intensification of row crop agriculture in Brazil. *Remote Sensing of Environment* **2008**, *112*, 576–587.
16. Arvor, D.; Jonathan, M.; Meirelles, M.S.P.; Dubreuil, V.; Durieux, L. Classification of MODIS EVI time series for crop mapping in the State of Mato Grosso, Brazil. *International Journal of Remote Sensing* **2011**, *29*, 1–25.
17. Brown, J.C.; Kastens, J.H.; Coutinho, A.C.; Victoria, D.C.; Bishop, C.R. Classifying multiyear agricultural land use data from Mato Grosso using time-series MODIS vegetation index data. *Remote Sensing of Environment* **2013**, *130*, 39 – 5029.
18. ABIOVE - Brazilian Vegetable Oils Industry Association. *Soy Moratorium Report: Mapping & Monitoring of Soy Plantings in the Amazon Biome in the Third Year*. Available on line: www.abiove.com.br/english/sustent/relatorio09/moratoria09_relatorio_jul10_us.pdf (accessed 1st Jun. 2013).
19. Kehl, T.N.; Todt, V.; Veronez, M.R.; Cazella, S.C. Amazon Rainforest Deforestation Daily Detection Tool Using Artificial Neural Networks and Satellite Images. *Sustainability* **2012**, *4*, 2566 – 2573.
20. Rudorff, B.F.T.; Adami, M.; Aguiar, D.A.; Moreira, M.A.; Mello, M.P.; Fabiani, L.; Amaral, D.F.; Pires, B.M. The Soy Moratorium in the Amazon Biome Monitored by Remote Sensing Images. *Remote Sensing* **2011**, *4*, 1853 – 202.

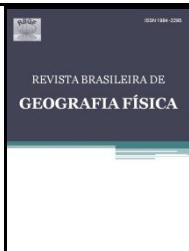
21. IBGE - Instituto Brasileiro de Geografia e Estatística. Produção agrícola municipal - *Automatic Data Recovery System – SIDRA*. Available online: www.sidra.ibge.gov.br/ (accessed on October 2nd, 2012).
22. Brazil, Ministério da Agricultura, Pecuária e do Abastecimento - MAPA (2009). Zoneamento Agrícola para a cultura de soja no Estado do Mato Grosso, ano-safra 2009/2010. In (p. 1): D.O.U., July, Diário Oficial da União 21/07/2009.
23. Huete, A.; Didan, K.; Miura, T.; Rodriguez, E.P.; Gao, X.; Ferreira, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment* **2002**, *83*, 195-213.
24. Rabus, B.M.; Eineder, A.R.R.; The Shuttle Radar Topography Mission - a new class of digital elevation models acquired by spaceborne radar. *Photogrammetric Engineering & Remote Sensing* **2003**, *57*, 241-262.
25. Jasinski, E.; Morton, D.; DeFries, R.; Shimabukuro, Y.; Anderson, L.; Hansen, M. Physical Landscape Correlates of the Expansion of Mechanized Agriculture in Mato Grosso, Brazil. *Earth Interactions* **2005**, *9*, 1-18.
26. CONAB - Companhia Nacional de Abastecimento. *Historical Series*. Available online: www.conab.gov.br/conteudos.php?a=1252&t=2&Pagina_objcmsconteudos=3#A_objcmsconteudos (accessed on October 1st, 2011).
27. Ismail, M.H; Jusoff, K. Satellite data classification accuracy assessment based from reference dataset. *Int. J. Comp. Inf. Eng.* **2008**, *2*, 386–392.
28. Chang, J.; Hansen, M.C.; Pittman, K.; Carroll, M.; Di Miceli C. Corn and Soybean Mapping in the United States Using MODIS Time-Series Data Sets. *Agronomy Journal* **2007**, *99*, 1654-1664.
29. Shao, Y.; Lunetta, R.S.; Ediriwickrema, J.; Liames, J. Mapping Cropland and Major Crop Types across the Great Lakes Basin using MODIS-NDVI Data; EPA: USA, 2009; Available online: http://maps6.epa.gov/ami/documents/Crop_Type_Validation_Article.pdf. (accessed on 27 July 2013).

30. Arvor, D.; Meirelles, M.; Dubreuil, V.; Begue, A.; Shimabukuro, Y. E. Analyzing the agricultural transition in Mato Grosso, Brazil, using satellite-derived indices. *Applied Geography* 2012, 32, 702-713



ISSN:1984-2295

Revista Brasileira de Geografia Física



Homepage: www.ufpe.br/rbgfe

Avaliação do Impacto de Ondas de Calor em Safras de Verão por Integração de Dados dos Satélites Aqua e Terra/MODIS

Aníbal Gusso^{1,2,4}, Jorge Ricardo Ducati², Mauricio Roberto Veronez^{3,4}, Leonardo Campos Inocêncio⁴

¹ Engenharia Ambiental, UNISINOS, Email: anibalg@unisinos.br

² Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, UFRGS, Email: ducati@if.ufrgs.br

³ Programa de Pós-Graduação em Geologia, UNISINOS, Email: veronez@unisinos.br

⁴ Vizlab, Advanced Visualization Laboratory, UNISINOS, Email: lcinocencio@unisinos.br

Artigo recebido em 19/11/2013 e aceite em xx/xx/2014

RESUMO

Este estudo aborda o efeito da ocorrência de temperaturas elevadas sobre a variabilidade da produtividade da soja. São estudadas as safras entre o período de 2003 a 2012 no Estado do Rio Grande do Sul. Para a análise da temperatura no dossel da vegetação, em área agrícola, foram utilizadas séries temporais de LST (Land Surface Temperature), produto MYD11A2, coleção-5 do sensor MODIS (Moderate-Resolution Imaging Spectroradiometer) no satélite Aqua. A identificação de áreas agrícolas e o monitoramento da evolução dos estádios fenológicos foram efetuados com a aplicação do EVI (Enhanced Vegetation Index), produto MOD13Q1 do MODIS no satélite Terra. Foram gerados mapas obtidos da interpolação espacial pelo método de krigagem ordinária para suavizar os dados em nível municipal da produção da soja provenientes do IBGE (Instituto Brasileiro de Geografia e Estatística) e de precipitação ocorrida, acumulada entre outubro e fevereiro, provenientes de 15 estações pluviométricas da FEPAGRO (Fundação Estadual de Pesquisa Agropecuária do Rio Grande do Sul). A média geral da LST sobre o dossel ocorrida no período foi de 31,9 °C com desvio padrão de 2,1 °C. A média geral da produtividade suavizada foi de 2003 kg ha⁻¹ com desvio padrão de 309 kg ha⁻¹. A média da precipitação acumulada foi de 775 mm com desvio padrão de 38 mm. Em nível estadual, os resultados apontam que eventos de queda severa de produtividade estão associados à ocorrência de LST-dossel acima da média, em fevereiro (DOY 033), conjugada com precipitação abaixo da média, por uma relação inversa não linear, tendo R²=0,73 e RMSD=17,8%.

Palavras-chave: Sensoriamento remoto; Vulnerabilidade; Agricultura; Soja; Temperatura; Estiagem.

Integrating Aqua and Terra/MODIS satellite Data for the Evaluation of Heat Stress Impacts on Summer Crops

ABSTRACT

In this study we analyze the relationship between the occurrence of high temperatures and the variability of soybean yield. The study covers the crop years from 2003 to 2012 in Rio Grande do Sul State. For the analysis of temperature over the vegetation canopy in agricultural areas, we used a LST (Land Surface Temperature) time series, product MYD11A2 collection -5 of sensor MODIS (Moderate-Resolution Imaging Spectroradiometer) on board the Aqua satellite. Crop area mapping, identification and monitoring of development during phenological stages were performed with application of EVI (Enhanced Vegetation Index) data series product MOD13Q1, collection-5 of MODIS on board the Terra satellite. Ordinary kriging methodology was used for data smoothing of spatial distribution of soybean yield at municipal level, obtained from IBGE; accumulated rainfall, between October and February, came from data of 15 meteorological stations from FEPAGRO (Fundação Estadual de Pesquisa Agropecuária). The overall average LST over crop canopy in the studied period was 31.9 °C with standard deviation 2.1 °C. The overall average of the smoothed yield was 2003 kg ha⁻¹ with standard deviation 309 kg ha⁻¹. The average of cumulative rainfall was 775 mm with a standard deviation of 38 mm. At the state level analysis, results indicate that severe decreases in productivity are coupled events effect of canopy-LST above average during February (DOY 033), associated to below average rainfall by means an inverse nonlinear relationship with R² = 0.73 and RMSD = 17,8%.

Keywords: Remote sensing; Vulnerability; Agriculture; Soybean; Temperature; Drought.

Introdução

O monitoramento e o gerenciamento agrícola têm um papel importante frente ao aumento da demanda por produtos agrícolas e as incertezas quanto às flutuações das condições ambientais. Na última década, intensas flutuações das condições agrometeorológicas causaram efeitos severos na produção de alimentos e na economia, principalmente no sul do país. As culturas mais afetadas foram as de soja e milho, sendo que na safra da soja em 2005 a produção apresentou uma redução de 75% na produção de grãos, quando comparada à safra de 2002/2003 (IBGE, 2012). Liu e Kogan (2002), em uma análise da produção brasileira com imagens de satélite, salientam que mesmo com clima geralmente favorável na maior parte das áreas de cultivo ocorrem grandes variações na produção agrícola de um ano para outro. No Estado do Rio Grande do Sul (RS) a frequência e a intensidade das chuvas, no período que vai da semeadura até a colheita, têm sido variáveis e frequentemente são insuficientes para o pleno desenvolvimento da cultura (MATZENAUER *et al.*, 2002). A grande variabilidade interanual da precipitação, verificada principalmente em função dos fenômenos El Niño e La Niña, é o principal fator responsável pelas oscilações de produtividade na região sul (FERREIRA, 2010), sendo que as culturas mais afetadas geralmente são as da soja e do milho (FONTANA *et al.*, 2002) na safra de verão.

Entretanto, a ocorrência de altas temperaturas e ondas de calor, associadas ou não à ocorrência de estiagem, vêm ganhando interesse em publicações científicas (BATISTTI e NAYLOR, 2009) devido à necessidade de caracterização da vulnerabilidade e sustentabilidade dos processos agrícolas (GUSSO, 2013). Lobell e Asner (2003), analisando um período de 17 anos entre 1982 a 1998, observaram que a perda de produtividade das culturas agrícolas de verão nos Estados Unidos da América (EUA) esteve associada ao aumento das temperaturas durante o período de desenvolvimento da safra, indicando a ocorrência de stress térmico sobre as culturas. Em um panorama de risco na produção de alimentos em decorrência de flutuações do clima, parâmetros físicos da superfície terrestre como disponibilidade hídrica e evapotranspiração devem sofrer alterações nas próximas décadas (SIQUEIRA *et al.*, 2000; PETERSON *et al.*, 2012) restringindo as condições de evolução dos cultivos e a produção (LOBELL *et al.*, 2008; UNEP, 2009). Como resultado, distorções e incertezas nas políticas agrícolas devem acentuar perdas e estabelecer barreiras para o financiamento agrícola (FAO, 2011), pela imprevisibilidade de políticas agrícolas governamentais que têm maior influência na volatilidade dos preços nos países do que as flutuações do mercado internacional (UNEP, 2009). Desta maneira, a aplicação de

metodologias simplificadas para o monitoramento das condições de evolução dos cultivos proporciona uma caracterização mais detalhada sobre a vulnerabilidade e sustentabilidade da agricultura no Brasil (GUSSO *et al.*, 2013). Tais desenvolvimentos são necessários frente à probabilidade e intensidade da ocorrência de altas temperaturas (WHEELER *et al.*, 2000), para a elaboração de prognósticos mais precisos (LOBELL e ASNER, 2003), e no aumento da capacidade de gerenciamento na produção das *commodities* agrícolas (SCHLENKER e ROBERTS, 2009; GUSSO *et al.*, 2013). Dados de sensoriamento remoto associados a ferramentas geoestatísticas têm sido aplicados em estudos agrícolas. Tipicamente, dados de imagens dos satélites Terra e Acqua do programa EOS-MODIS (Earth Observing System - Moderate Resolution Imaging Spectroradiometer) têm sido aplicados no monitoramento e modelagem de processos bioclimáticos, de ciclos de desenvolvimento das culturas, e em estimativa da produção agrícola (HUETE *et al.*, 2002; SHIMABUKURU *et al.*, 2009; GUSSO *et al.*, 2012). Trabalhos recentes têm evidenciado o efeito da ocorrência de temperaturas elevadas sobre a queda de produtividade das principais *commodities* agrícolas, como soja, milho e algodão. Estudos com séries temporais de dados de satélites têm evidenciado que os danos causados às plantas, com diminuição do desenvolvimento da cultura, podem estar associados à vulnerabilidade frente a

ocorrência de ondas de calor (NEMANI e RUNNING, 1997; LIU e KOGAN, 2002; SCHLENKER e ROBERTS, 2009; GUSSO, 2013). Prejuízos na produtividade da soja ocorrem mesmo quando as temperaturas médias atingem apenas um ou dois graus acima do ideal para a cultura (LOBELL e ASNER, 2003; SEDIYAMA, 2009), seja pela redução na atividade fotossintética no dossel da vegetação em situação de estresse térmico (BOARD e KAHILON, 2007; CARMO-SILVA *et al.*, 2012), seja pelo aumento da demanda evaporativa (HOPE *et al.*, 1986; NEMANI e RUNNING, 1997), ou pela alteração na duração do período de florescimento (RODRIGUES *et al.*, 2001). Mesmo tendo sido observado que o período de florescimento é mais sensível à temperatura do que ao estresse hídrico (LIU e KOGAN, 2002; BOARD e KAHILON, 2007; CRAUFURD e WHEELER, 2009; BATISTTI e NAYLOR, 2009; CARMO-SILVA *et al.*, 2012), os impactos de ondas de calor na produtividade ainda não são bem conhecidos (SALVUCCI, 2008; MEERBURG *et al.*, 2009; SCHLENKER e ROBERTS, 2009). Neste sentido, este estudo tem como objetivo investigar a relação entre a ocorrência de temperaturas elevadas no dossel da vegetação e a queda na produtividade na cultura da soja no Rio Grande do Sul, utilizando dados dos sensores MODIS a bordo dos satélites Terra e Aqua.

Material e Métodos

A área estudada foi o território do Estado do Rio Grande do Sul (RS) com 496 municípios agrupados em dez regiões definidas pela EMATER (Empresa de Assistência Técnica e Extensão Rural). O clima predominante é subtropical úmido (Cfa e Cfb) com quatro estações bem definidas (Köppen, 1948). A Figura 1 mostra a área de estudo.

O período analisado foi os meses de outubro a fevereiro das safras de 2003 até 2012. A precipitação acumulada é relativamente bem distribuída ao longo do ano com média de 1554 mm e sem período seco, especialmente na metade norte do estado onde o cultivo da soja é dominante. A temperatura média anual é 18.1 °C, mas ocorrem máximas absolutas elevadas em janeiro com 42.2 °C, 39.6 °C em fevereiro e 38.7 °C em março (INMET, 2009). Tipicamente, a precipitação acumulada neste período, que compreende a safra de verão é 647 mm, com desvio padrão 106 mm (INMET, 2009). No período entre as safras de 2003 e 2012 houve três ocorrências de estiagens nas safras de verão de 2004, 2005 e 2012, que afetaram a produtividade em diferentes níveis de intensidade.




Figura 1. Área de estudo, Estado do Rio Grande do Sul com suas áreas administrativas regionais da EMATER.

Nesse sentido, vários níveis de informação aliados aos dados de satélite foram aplicados de maneira a configurar adequadamente a distribuição espacial das grandezas evolvidas, conforme segue:

- i) dados do índice de vegetação EVI obtidos do sensor MODIS a bordo do satélite Terra, o produto MOD13Q1-coleção 5, foram utilizados na seleção das áreas agrícolas e posterior análise da temperatura sobre o dossel da vegetação (LST-dossel). Neste estudo, os dados EVI em 250 metros também são utilizados como dados de entrada para o algoritmo de estimativa de área de soja MCDA (MODIS Crop Detection Algorithm) na seleção dos pixels representativos sobre áreas de cultivo agrícola com soja. Na coleção 5, o EVI é obtido por uma composição de máximo valor MVC (Maximum Value Composite) associada aos menores ângulos de visada do imageamento (DIDAN e HUETE,

2006). O EVI é representativo do vigor da vegetação, por estar fundamentado na reflectância característica do dossel da vegetação, e foi desenvolvido de maneira a minimizar os efeitos de contaminação da reflectância residual do solo e da influência atmosférica em observações feitas por satélites (HUETE *et al.* 2002; JUSTICE *et al.* 2002). Este produto está inserido no produto MOD13Q1-V005 que é estruturado como uma combinação das melhores medidas radiométricas e geométricas dos pixels que formam a imagem na composição de 16 dias. A equação que calcula o valor de EVI é dado por: $2.5 * (\text{Nir} - \text{Red}) / (\text{Nir} + 6 \text{ Red} - 7.5 \text{ Blue} + 1)$, onde Nir, Red, e Blue são as reflectâncias superficiais corrigidas atmosfericamente das bandas de detecção posicionadas sobre as faixas do infravermelho próximo, do vermelho e do azul respectivamente (HUETE *et al.*, 2002);

ii) dados de temperatura da superfície terrestre LST (Land Surface Temperature) produto MYD11A2, coleção-5 do sensor MODIS (Moderate-Resolution Imaging Spectroradiometer) a bordo do satélite Aqua do mês de fevereiro, tipicamente associado ao período da floração no Rio Grande do Sul (Pinto e Fontana, 2011), foram utilizados para a obtenção das médias e derivação dos desvios da temperatura sobre o dossel nas safras de 2003 a 2012. Os dados de LST do satélite Aqua foram escolhidos por serem coletados durante a passagem da tarde,

momento do dia em que são registradas as maiores temperaturas;

- iii) Normal Climatológica, utilizada na parametrização do modelo para localizar espacialmente as áreas com maior disponibilidade hídrica no período das safras de verão e seus desvios;
- iv) dados de precipitação ocorrida no RS, obtidos da Fundação Estadual de Pesquisa Agropecuária (FEPAGRO) para a análise dos desvios em relação à Normal Climatológica;
- v) dados estatísticos oficiais e históricos de área ocupada, obtidos do IBGE, foram utilizados para comparação com a variabilidade na produtividade da soja;
- vi) dados estatísticos oficiais e históricos da produção de soja e área municipal, do IBGE, para geração dos dados de produtividade municipal.

Extração dos dados

Os produtos MODIS são extraídos pelo aplicativo MODIS Reprojection Tool (MRT) que permite aos usuários ler e converter arquivos de dados no formato distribuído pela NASA (HDF-EOS) e especificar um recorte geográfico e o conjuntos de dados/produtos específicos. Este aplicativo também permite executar a transformação para um diferente sistema de coordenadas e projeção cartográfica (LPDAAC, 2011). Os produtos EVI e LST são distribuídos em formato de 16 bits e é necessário convertê-los para os valores de índice de vegetação e temperatura. Para a obtenção da área de cobertura do Estado do Rio grande do Sul o MRT realiza

um processo de mosaicagem de dois recortes de imagens (Tiles H13V11 e H13V12) com base em um geóide de Datum WGS84. Após o processamento dos dados de imagens pelo MRT o EVI deve ser escalonado para valores entre -1 e 1. Os dados LST são inicialmente escalonados para uma distribuição em valores de temperatura em Kelvin. Após estes procedimentos iniciais, todas as imagens foram reprojetadas segundo a Projeção Cônica de Albers para Cálculo de Áreas Iguais, pois existe a necessidade de uma maior precisão espacial ao serem aplicadas metodologias auxiliares de estimativa de área da soja em ambos os produtos.

Assim, os dados da LST são representativos das médias máximas das temperaturas ocorridas no período de 32 dias a partir do dia juliano 033 do produto MYD11A2 (de 2 de fevereiro até 6 de março) tipicamente associado ao período da floração, em acordo com o calendário agrícola médio da cultura da soja no Rio Grande do Sul (PINTO e FONTANA, 2011).

Interpolação espacial de dados

A geração de dados espaciais interpolados foi obtida por meio da aplicação do método de krigagem esférica/ordinária do programa SPRING 5.2.1 distribuído pelo INPE (Instituto Nacional de Pesquisas Espaciais) que é baseada na tendência de variabilidade do valor das amostras e da distância entre elas (JIAN-GUO e MASON, 2009). A krigagem destaca-se em especial por ser um método

efetivo quando os dados a serem interpolados são esparsos, aplicando-se perfeitamente à situação encontrada no presente trabalho, no qual um número reduzido de estações meteorológicas estavam disponíveis. Foram gerados mapas interpolados de produtividade e precipitação para análise em relação às imagens de LST e EVI.

Para cada município, foi obtido o centróide ao qual foi atribuído o valor de produtividade do município e, em seguida, geradas as médias regionais. Dados dos 496 municípios foram agrupados pelas áreas administrativas regionais da EMATER. É importante observar que a análise dos desvios, decorrente dos mapas suavizados, foi realizada somente sobre as áreas mapeadas como cultivo de soja, entre 2003 e 2012. Também é importante notar que os dados LST foram agrupados em composições de 32 dias. Estes foram obtidos do produto MYD11A2, que corresponde à composição de médias de oito dias, conforme distribuído pela NASA. Os dados de índice de vegetação EVI também foram agrupados em composições de 32 dias, pela combinação de duas composições de 16 dias.

Os dados de precipitação foram obtidos por meio da distribuição suavizada da precipitação obtida do período de outubro a fevereiro de cada safra, entre 2003 e 2012, obtidos da FEPAGRO. Os mapas de cada safra foram comparados ao mapa interpolado com 33 estações pluviométricas obtido das Normais Climatológicas. Os dados de produtividade de cada safra foram

comparados às médias obtidas do IBGE, de 2003 a 2012. As Figuras 2a e 2b mostram a distribuição da produtividade, obtida da média entre 2003 e 2012, e a distribuição das normais de precipitação (1971-2000) na região.

Validação dos mapas interpolados

A validação dos mapas interpolados de precipitação e produtividade foi realizada comparando-se com os dados oficiais obtidos do IBGE e INMET.

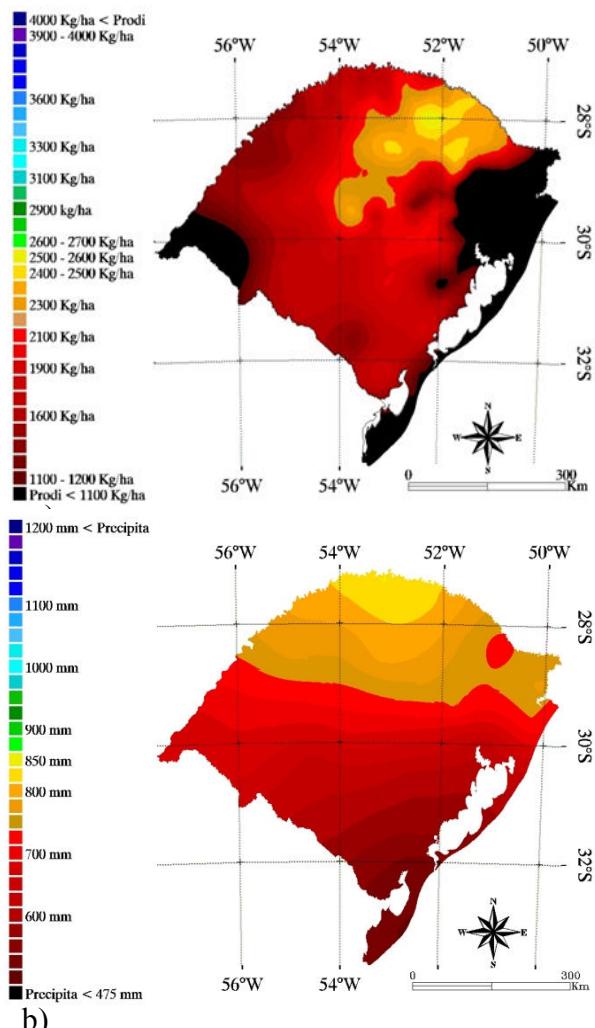


Figura 2. Distribuição da produtividade média (a), obtida do período entre 2003 e 2012 e precipitação acumulada de outubro a fevereiro, obtida da Normal Climatológica (1971-2000).

Os dados de precipitação foram comparados a partir dos totais por safra e acumulados no período. Segundo dados tabelados da Normal Climatológica (1961-1990) a precipitação pluvial acumulada média no período estudado foi de aproximadamente 647 mm, com desvio padrão 106 mm (INMET, 2009), enquanto a média ocorrida no mesmo período, obtida de 14 estações meteorológicas foi 763 mm, com desvio padrão 249 mm. A precipitação pluvial acumulada média, no estado, obtida por meio da interpolação espacial de dados da Normal Climatológica (1971-2000) foi aproximadamente 678 mm, com desvio padrão 83 mm, enquanto a média ocorrida estadual obtida da interpolação espacial no mesmo período foi 731 mm, com desvio padrão 47 mm (Figura 2b) o que evidencia um bom ajuste entre os mapas interpolados e dados tabelados das estações meteorológicas utilizadas. A Figura 2a mostra a distribuição da produtividade média no período obtida por meio da interpolação espacial de dados do IBGE. Considerando um limite mínimo de produtividade em 500 kg ha^{-1} a média geral da produtividade suavizada foi 2003 kg ha^{-1} com desvio padrão 309 kg ha^{-1} .

Estimativa da área agrícola

A delimitação adequada da área agrícola é necessária, pois buscamos analisar principalmente o comportamento da LST representativa da temperatura sobre o dossel da vegetação agrícola de soja. Desta maneira, o levantamento da área da cultura da soja foi

obtido pela aplicação do MCDA (MODIS Crop Detection Algorithm), desenvolvido por Gusso *et al.* (2012), e calculado para cada ano-safra. A geração do mapa de cultivo da soja para as dez diferentes safras foi realizado considerando uma composição que é resultado da combinação de cada um dos mapas de área estimada das safras entre 2003 e 2012. O mapa obtido com esta composição média inclui todos os pixels selecionados como soja em que sua identificação como área de soja ocorre pelo menos duas vezes nas dez safras. Assim, os dados obtidos das Normais Climatológicas de precipitação normal, precipitação ocorrida, LST e produtividade da soja também são representativos de áreas onde houve cultivo da soja pelo menos duas vezes no período estudado. Tal procedimento resultou em um mapa com 5,37 milhões de hectares, 37,7% maior que a área média de soja no período entre 2003 a 2012, com aproximadamente 3,9 milhões de hectares (CONAB, 2012).

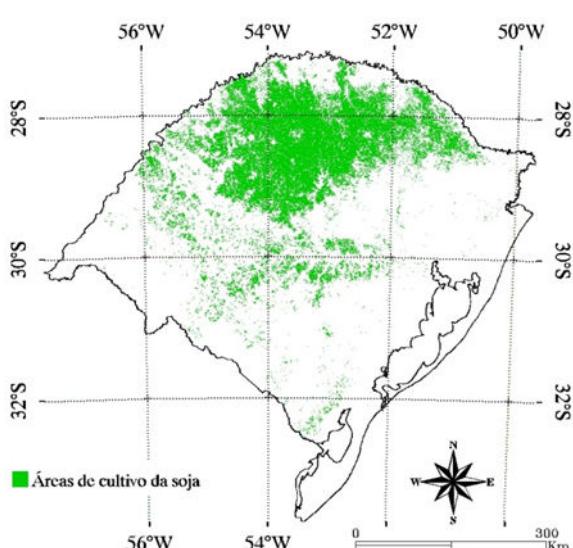


Figure 3. Mapa de área de soja obtido com aplicação do MCDA compondo as safras 2003 a 2012.

Relação entre temperatura do dossel e produtividade

No Brasil, a maioria das cultivares adaptadas para as condições locais apresentam ciclo de 90 a 150 dias (SEDIYAMA, 2009). O calendário predominante de plantio da soja vai do final de outubro a meados de dezembro, segundo o zoneamento agrícola de menor risco climático para diferentes solos, regiões e cultivares (CUNHA *et al.*, 2001; MAPA, 2010), normalmente atingindo o período da floração em meados de fevereiro (PINTO e FONTANA, 2011). A LST-dossel entre 25 °C e 35 °C, quando a indução floral é ótima, e uma média ideal para seu desenvolvimento próximo a 30 °C são as temperaturas mais frequentemente mencionadas como as condições ideais para a soja (BOARD e KAHLOM, 2007; SEDYIAMA, 2009; SCHLENKER e ROBERTS, 2009; KHAN *et al.*, 2011).

Em geral, as plantas têm a capacidade de manter o conteúdo de água nos tecidos independentemente da temperatura, quando a umidade é suficiente; no entanto, altas temperaturas prejudicam severamente essa tendência quando o suprimento de água é limitado (Machado e Paulsen, 2001). Em sistemas agrícolas tão homogêneos como em

campos de cultivo, mesmo quando as condições de disponibilidade hídrica não são limitantes para o crescimento e desenvolvimento das plantas, a radiação incidente também afeta a capacidade dos estômatos para transpiração, alterando a relação entre calor sensível e calor latente (NEMANI e RUNNING, 1997; SANDHOLT *et al.*, 2002; KHAN *et al.*, 2011). A ocorrência de estresse por temperaturas elevadas durante o período de floração e formação das vagens (R1-R5) afeta o número de sementes (GIBSON e MULLEN, 1996), e está fortemente associado às variações na produtividade (BOARD e KAHLON, 2007), tendo efeito cumulativo no desenvolvimento da vegetação (GUSSO *et al.*, 2013). Dessa maneira, o uso combinado da LST e índice de vegetação supõe uma relação matemática inversa entre vigor vegetativo e a resposta termal característica do dossel (HOPE *et al.*, 1986; SANDHOLT *et al.*, 2002; GUSSO, 2013), iniciando processo de estresse térmico com perda de produtividade quando ocorrem temperaturas mais elevadas que este limite (SCHLENKER e ROBERTS, 2009). Entretanto, índices de vegetação, tipicamente fundamentados na relação entre as bandas do vermelho e infravermelho próximo, não são bons indicadores do estresse hídrico, pois a vegetação pode permanecer verde após o estresse hídrico inicial (SANDHOLT *et al.*, 2002). Goetz (1997) salienta esta característica observando que existe um período mínimo de resposta entre a

diminuição da disponibilidade hídrica e alteração dos valores do índice de vegetação, mas uma resposta mais imediata é dada pelo aumento da temperatura do dossel, como efeito de redução na disponibilidade hídrica. Neste sentido, mesmo quando o índice de vegetação ainda indica uma característica típica da vegetação verde, uma sensível redução na disponibilidade hídrica promove o fechamento dos estômatos, o que ocasiona uma redução na capacidade das plantas em reter a energia refletida por meio de absorção (Khan *et al.*, 2013), afetando também a capacidade da realização da fotossíntese e ocasionando perda do potencial de produtividade (Salvucci e Crafts-Brendner, 2004). Em resposta à baixa circulação de água na estrutura interna (mesofílica) da vegetação, a temperatura do dossel aumenta rapidamente (GOETZ, 1997). Já na situação oposta, em que predominam superfícies bem úmidas, a relação entre índice de vegetação e LST-dossel está mais diretamente relacionada à umidade da superfície, pelo aumento da inércia térmica do solo (FRIEDL e DAVIS, 1994).

A LST-dossel tem efeito direto sobre a capacidade de realização da fotossíntese, e entre os principais impactos que são promovidos por altas temperaturas o efeito sobre a fotossíntese é o mais importante porque inibe o crescimento da planta afetando a produtividade (SALVUCCI e CRAFTS-BRANDNER, 2004; BOARD e KAHLON, 2007; GUSSO *et al.*, 2014). Vários autores

(JORDAN e OGREN, 1984; SALVUCCI e CARFTS-BRENDNER, 2004; SALVUCCI, 2008; KHAN *et al.*, 2013) têm investigado o processo de inibição da fotossíntese de plantas do tipo C3 (soja e trigo), como uma consequência da dependência da molécula RuBisCO (ribulose 1,5-bisfosfato carboxilase/oxigenasse) às condições de temperatura do ambiente. Em geral, para plantas do tipo C3, a capacidade de tolerância ao estresse térmico envolve a manutenção da capacidade de aumentar a demanda evaporativa para evitar o sobreaquecimento do dossel (Machado e Paulsen, 2001). O fechamento dos estômatos é a resposta mais imediata da planta ao estresse hídrico minimizando a perda de água pela evapotranspiração, mas principalmente, reduzindo o fluxo de CO₂. Desta diminuição decorre uma severa limitação da taxa de realização da fotossíntese em função da baixa afinidade natural da enzima Rubisco pela assimilação do CO₂. A transpiração reduzida em condições de aquecimento e incidência de radiação direta ocasiona a diminuição da capacidade de resfriamento da folha elevando a temperatura, o que consequentemente leva ao estresse térmico. Adicionalmente, a fotossíntese é extremamente sensível mesmo à ocorrência de estresse térmico moderado por estar associado entre outros fatores a uma instabilidade da molécula Rubisco, em associação a outros processos que, em última análise, evitam a denaturação da molécula Rubisco, mas que como efeito reduzem a

atividade fotossintética da planta (SALVUCCI e CRAFTS-BRANDNER, 2004; SALVUCCI, 2008; KHAN *et al.*, 2013). A formação das vagens está associada aos eventos de estresse predominantes que ocorrem antes do período da floração, e o enchimento de grãos e a maturação são sensíveis ao estresse causado por temperaturas elevadas durante o desenvolvimento (KHAN *et al.*, 2011).

Resultados e Discussão

A partir dos dados da distribuição da produtividade média (Figura 2a) e da precipitação média, gerados por krigagem (Figura 2b), e dados de imagens da LST e EVI obtidos do MODIS/Aqua e MODIS/Terra, respectivamente, dados das safras foram comparados individualmente e gerados gráficos de dispersão relativa. A média geral da LST sobre o dossel, ocorrida no período foi 31,9 °C com desvio padrão 2,1 °C. A média da precipitação acumulada foi 775 mm com desvio padrão de 38 mm. A Tabela 1 apresenta as médias regionais da LST-dossel e produtividade da soja por safra.

Tabela 1. Médias estaduais e desvio padrão da produtividade da soja, da LST-dossel e precipitação obtidos pela interpolação espacial dos dados no período entre 2003 e 2012.

A análise dos dados estaduais por safra evidencia a associação da variabilidade da produtividade em função das condições agrometeorológicas predominantes, com uma tendência bem marcada entre a ocorrência de LST-dossel mais elevadas, acima da média, com a redução da disponibilidade hídrica.

Ano/Safra	Médias estaduais					
	Produtividade (Kg ha ⁻¹)	Desvio Padrão	LST-dossel, DOY033 (°C)	Desvio padrão	Precipitação acumulada (mm)	Desvio Padrão
2003	2687	392	30.7	2.5	1228	86
2004	1549	295	31.3	3.4	840	99
2005	695	125	35.9	3.9	463	10
2006	2138	486	32.4	4.1	592	68
2007	2543	325	30.3	2.5	761	55
2008	2191	245	33.3	3.3	650	52
2009	2217	290	30.4	2.9	798	84
2010	2620	348	30.8	2.3	1194	126
2011	2895	388	28.4	2.8	725	110
2012	1601	466	35.4	3.8	500	43

O gráfico da Figura 4 mostra a variabilidade na distribuição dos pontos em nível estadual da produtividade média em função da LST-dossel média.

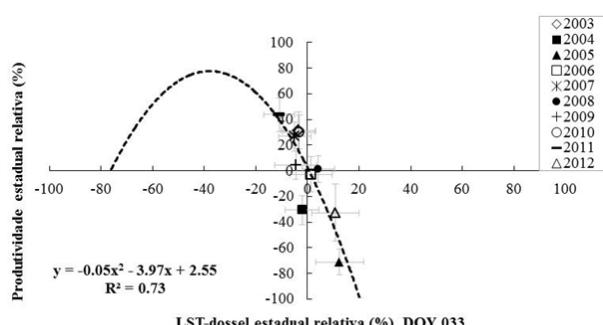


Figura 4. Gráficos de dispersão comparando a variação da produtividade média estadual como função da LST-dossel média das safras 2003 a 2012.

Eventos de queda severa de produtividade como 2005 e 2012, estão associados à ocorrência de LST-dossel acima da média, conjugada com precipitação abaixo da média e produtividades acima da média com LST-dossel abaixo da média, por uma relação inversa não linear, tendo $R^2=0,73$ e $RMSD=17,8\%$.

O gráfico da Figura 5 mostra a distribuição dos pontos referentes às regionais com ocorrência de produtividade média em função da LST-dossel.

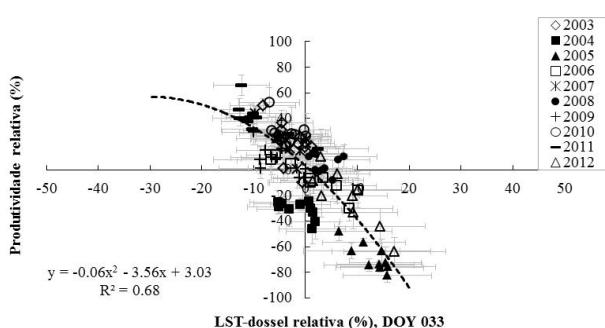


Figura 5. Gráficos de dispersão comparando a variação da produtividade média regional como função da LST-dossel média das safras 2003 a 2012.

A melhor relação de ajuste foi obtida por meio de uma relação não linear, ocorrida no dossel da vegetação no mês de fevereiro, com $R^2=0,68$ e $RMSD=18,8\%$. Analisando a Figura 4 em associação com a Tabela 1, é possível observar máximas LST-dossel associados com safras em que ocorreu perda de produtividade, especialmente as safras 2005 e 2012. Também podemos observar que existe a tendência de maior produtividade quando ocorre LST-dossel abaixo da média estadual. Liu e Kogan (2002) observaram que as mais baixas ocorrências de LST no dossel estão associadas às melhores condições de crescimento da vegetação. Entretanto, em períodos secos, o impacto da deficiência hídrica se intensifica pelo sobreaquecimento da temperatura da vegetação devido ao suprimento insuficiente de água no interior da planta (LIU e KOGAN, 2002; SANDHOLT *et al.*, 2002; GUSSO, 2013;). Em condições

normais, a LST-dossel mantém a temperatura das folhas abaixo da temperatura do ar pela demanda evaporativa das folhas. Entretanto, a restrição de água ocasiona processos que levam ao aumento da temperatura no dossel e consequentemente da LST-dossel. Assim, o efeito de elevação da temperatura é amplificado pela estiagem (GUSSO, 2013) fazendo com que a LST-dossel exceda facilmente a faixa ótima de temperaturas, inibindo a atividade fotossintética e levando à perda de produtividade. Dessa maneira, a relação entre LST-dossel e produtividade da soja não está plenamente estabelecida uma vez que as mais altas temperaturas estão geralmente mais relacionadas ao fechamento dos estômatos pelo estresse hídrico do que ao aumento da temperatura das folhas do dossel decorrente de onda de calor.

A Figura 6 mostra a relação que se estabelece entre as diferentes condições hídricas na safra de verão no Rio Grande do Sul e a produtividade, destacando que os períodos de ocorrência de maior precipitação acumulada estão associados às maiores produtividades. Assim, as variações na precipitação acumulada são em relação às Normais Climatológicas acumuladas no mesmo período, entre outubro e fevereiro.

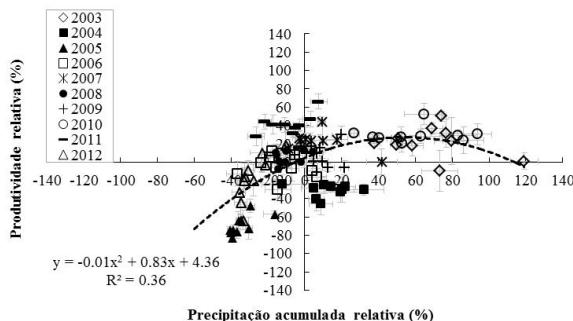


Figura 6. Gráficos de dispersão comparando a variação da produtividade regional como função da variação da precipitação acumulada, de outubro a fevereiro, das safras 2003 a 2012.

Considerando as safras mais afetadas por estresse hídrico conforme apresentado na Tabela 1 e Figura 6, podemos redefinir os pontos no gráfico da Figura 5 extraíndo as regionais mais afetadas por estresse hídrico no período estudado. A identificação do efeito conjugado de ocorrência de estiagem e altas LST-dossel na safra 2005, por meio da análise de desvio da precipitação e desvio de temperaturas, indicam a ocorrência de sobreaquecimento do dossel como resultado da diminuição da evaporação pelo fechamento dos estômatos e uma consequente redução severa da atividade fotossintética levando a perda severa de produtividade da safra da soja.

A relação espacial entre as regionais estabelecida na Figura 1 está em acordo com a tendência temporal observada na Tabela 1, em

que as condições acima da média, e também normais, de disponibilidade hídrica mostram uma tendência de aumento da produtividade. Dessa maneira, realizamos a seleção das regionais somente com ocorrência de precipitação relativa acima da média, em cada regional, delimitando os eventos sem ocorrência de estresse hídrico. O gráfico da Figura 7 mostra a distribuição dos pontos referentes às regionais com ocorrência de precipitação acima da normal climatológica. A projeção da linha de tendência indica o efeito das temperaturas sobre a vegetação da safra de verão sem efeito associado de estresse hídrico estabelecendo uma relação linear inversa entre produtividade e LST-dossel.

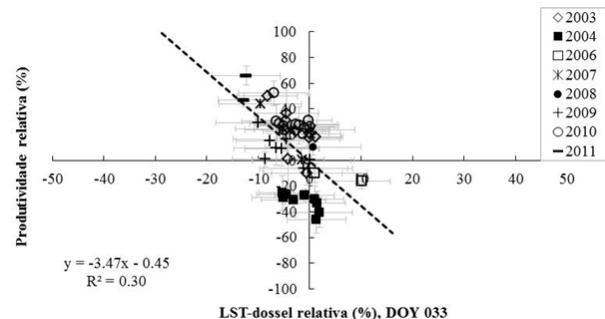


Figura 7. Gráficos de dispersão comparando a variação da produtividade média regional como função da LST-dossel média de safras com precipitação acumulada acima da Normal.

A Figura 7 analisada em relação à Figura 6, e também em relação à Tabela 1, sugere que produtividade acima da média, em algumas regionais, é favorecida quando ocorre LST-dossel abaixo da média. Com exceção das

safras 2003 e 2010, a maior parte das regionais tem precipitação em torno da média e com pequenos desvios (Figura 6), mas tem produtividade bem acima da média. Entretanto, como mostra a Figura 6, um caso particular é a safra 2004. Mesmo com precipitação acumulada acima da média, o efeito da má distribuição espacial e temporal da precipitação acumulada pode ser notado. Como também observado por Gusso, (2013), que analisou a relação entre índice de vegetação e LST em 2004, houve perda importante de produtividade, mas houve ocorrência moderada de estresse hídrico com flutuação das LST-dossel em torno da média. O impacto da deficiência hídrica se intensifica pelo sobreaquecimento da temperatura no dossel da vegetação (LIU e KOGAN, 2002; SANDHOLT *et al.* 2002; GUSSO, 2013). Com base em 48 dos 100 pontos anteriores (Figura 6), o resultado ajustado obtido gerou $R^2=0,3$ e $RMSD=22,02\%$ com coeficiente angular $b_1=-3,47$. Nos EUA, Lobell e Asner, (2003) encontraram uma relação linear com $R^2=0,32$.

Conclusão

A crescente demanda por *commodities* agrícolas e as incertezas quanto às flutuações das condições do ambiente em médio prazo impõem o desenvolvimento de metodologias e tecnologias de auxílio ao gerenciamento da produção agrícola. O monitoramento da LST-dossel, na análise das condições de desenvolvimento agrícola, constitui uma

importante ferramenta na compreensão da vulnerabilidade regional e sustentabilidade das culturas agrícolas de verão.

Por meio de uma relação não linear foi observado que as variações relativas à LST-dossel média ocorrida no mês de fevereiro, tanto em nível regional quanto estadual, estão associadas às variações na produtividade da cultura da soja no Rio Grande do Sul. Neste sentido, os resultados sugerem que a ocorrência de LST-dossel abaixo da média, conjugada com precipitação acumulada acima da média, favorece maior produtividade. Perdas na produtividade são amplificadas quando ocorre a conjugação de altas temperaturas no dossel da vegetação com estiagem, após o inicio do período de florescimento no Estado do Rio Grande do Sul. Entretanto, no caso da cultura da soja, os resultados sugerem que a influência de altas temperaturas no dossel da vegetação é reduzida quando a disponibilidade hídrica é maior que a média regional.

Agradecimentos

À Fundação Estadual de Pesquisa Agropecuária do Rio Grande do Sul (FEPAGRO), e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Os produtos MODIS foram obtidos através do acesso *online* ao Data Pool do NASA Land Processes Distributed Active Archive Center (LP DAAC), USGS/Earth Resources Observation and Science (EROS)

Center, Sioux Falls, South Dakota
(https://lpdaac.usgs.gov/data_access).

Referências

- Batistti, D.S., Naylor, R.L. (2009) Historical warnings of future food insecurity with unprecedented seasonal heat. *Science*, v. 323, p. 240-244.
- Board, J.E. & Kahlon, C.S. (2007) Soybean yield formation: what controls it and how it can be improved. In: *Soybean Physiology and Biochemistry*, El-Shemy, H.A. Ed., pp. 1-36, InTechOpen Access, Rijeka, Croatia.
- Carmo-Silva, A. E.; Gore, M. A.; Andrade-Sánchez, P.; French, A. N.; Hunsaker, D. J. & Salvucci, M. E. (2012). Decreased CO₂ availability and inactivation of Rubisco limit photosynthesis in cotton plants under heat and drought stress in the field. *Environmental and Experimental Botany*, v. 83, p. 1-11.
- CONAB - Companhia Nacional de Abastecimento (2012). Acompanhamento da safra brasileira de grãos. CONAB/DIPAI/SUINF/GEASA. Conab: Brasília.
- Craufurd, P.Q. & Wheeler, T.R. (2009) Climate change and the flowering time of annual crops. *Journal of Experimental Botany*, v. 60, p. 2529–2539.
- Cunha, G.R., Barni, N.A., Haas, J.C., Maluf, J.R.T., Matzenauer, R., Pasinato, A., Pimentel, M.B.M. & Pires, J.L.F. (2001) Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul, *Revista Brasileira de Agrometeorologia*, 9, 446-459.
- Didan, K. & Huete, A. (2006). MODIS Vegetation Index Product Series: Collection 5 Change Summary. TBRS Laboratories. The University of Arizona.
- FAO – Food and Agriculture Organization. The State of Food Insecurity in the World (2011). <http://www.fao.org/docrep/013/i2050e/i2050e07.pdf> (accessed on November, 29th 2012).
- Ferreira, D. B. Análise da variabilidade climática e suas consequências para a produtividade da soja na região sul do Brasil, Ph.D. Thesis, INPE, São José dos Campos, 2010.
- Fontana, D. C.; Weber, E.; Ducati, J. R.; Berlato, M. A.; Guasselli, L. A. & Gusso, A. (2002). Monitoramento da cultura da soja no centro-sul do Brasil durante La Niña de 1998/2000. *Revista Brasileira de Agrometeorologia*, v. 10, p. 343-351.
- Friedl, M.A. & Davis, F.W. (1994). Sources of Variation in Radiometric Surface Temperature over a Tallgrass Prairie. *Remote Sensing of Environment*, v.48, p.1-17.
- Gibson, L.R. & Mullen, R.E. (1996). Soybean seed quality reductions by high day and night temperature. *Crop Sci.*, v..36, p. 1615–1619.
- Goetz, S. J. (1997). Multisensor analysis of NDVI, surface temperature and biophysical variables at a mixed grassland site. *International Journal of Remote Sensing*, 18, 71– 94.
- Gusso, A. (2013) Integração de imagens NOAA/AVHRR: Rede de cooperação para monitoramento nacional da safra da soja. *Revista Ceres*, v. 60, p. 43-52.
- Gusso, A., Ducati, J.R., Veronez, M.R., Arvor, D. & Silveira Jr, L.G. (2013) Spectral model for soybean yield estimate using MODIS/EVI data. *International Journal of Geosciences*, 4, 1233-1241.
- Gusso, A., Ducati, J.R., Veronez, M.R., Sommer, V. e Silveria-Junior, L.G. (2014). Monitoring heat waves and their impacts on summer crop development in southern Brazil. *Agricultural Sciences*, v.3, aguardando publicação.
- Gusso, A.; Adami, M.; Formaggio, A. R.; Rizzi, R. & Rudorff, B. T. F. (2012). Soybean area estimation and mapping by means MODIS/EVI data. *Pesquisa Agropecuária Brasileira*, v. 47, p. 425-435.

- Hope, A. S., Petzold, D. E., Goward, S. N. & Ragan, R. M. (1986) Simulated relationships between spectral reflectance thermal emissions and evapotranspiration of a soybean canopy. *Water Resources Bulletin*, v.22, p.1011–1019.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X. & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, v. 83, p. 195-213.
- INMET - Instituto Nacional de Meteorologia – Normais Climatológicas do Brasil de 1961 a 1990, (2009) http://www.inmet.gov.br/portal/index.php?r=bdm_ep/bdmep (accessed on 30th March 2012).
- Instituto Brasileiro de Geografia e Estatística. SIDRA: sistema IBGE de recuperação automática. Disponível em: <<http://www.sidra.ibge.gov.br/>>. Acessado em: 12 de outubro de 2012.
- Jian-Guo, L. & Mason, P. J. (2009) Essential Image Processing and GIS for Remote Sensing. Wiley-Blackwell, p. 460.
- Justice, C. O.; Townshend, J. R. G.; Vermote, E. F.; Masuoka, E.; Wolfe, R. E.; Saleous, N.; Roy, D. P. & Morisette, J. T. (2002). An overview of MODIS Land data processing and product status. *Remote Sensing of Environment*, v. 83, p. 3-15.
- Khan, A.Z., Shah, P. Khan, H., Nigar, S., Perveen, S., Shah, M.K., Amanullah, A., Khalil, S.K., Munir, S., Zubair, M. (2011) Seed quality and vigor of soybean cultivars as influenced by canopy temperature. *Pak. J. Bot.*, 43, 643-648.
- Khan, M.I.R., Asgher, M. & Khan, N.A. (2013). Rising temperature in the changing environment: A serious threat to plants. *Climate Change and Environmental Sustainability*, 1, 25-36.
- Köppen, W. (1948). *Climatología*. Fondo de Cultura Económica, p. 71.
- Liu, W. T. & Kogan, F. (2002). Monitoring Brazilian soybean production using NOAA/AVHRR based vegetation indices. *International Journal of Remote Sensing*, v. 23, p. 1161-1180.
- Lobell, D.B. & Asner, G.P. (2003). Climate and management contributions to recent trends in U.S. agricultural yields. *Science*, v. 229, p. 1032.
- Lobell, D.B., Burke, M.B., Tebaldi, C., Mastrandrea, M.D., Falcon, W.P. & Naylor, R.L. (2008). Prioritizing Climate Change Adaptation Needs for Food Security in 2030. *Science*, 319, 607-610. <http://dx.doi.org/10.1126/science.1152339> (accessed on November 17th, 2011).
- Machado, S. & Paulsen, G.M. (2001). Combined effects of drought and high temperature on water relations of wheat and sorghum. *Plant and Soil*, 233, 179–187.
- MAPA - Ministério da Agricultura, Pecuária e do Abastecimento (2010). Portaria nº 126, de 20 de julho de 2009. Aprova o zoneamento agrícola para a cultura de soja no Estado do Rio Grande do Sul, ano safra 2009/2010. Diário Oficial [da] República Federativa do Brasil. Seção 1, p.15.
- Matzenauer, R., Bergamaschi, H., Berlato, M. A., Maluf, J. R. T., Barni, N. A., Bueno, A. C., Didone, I. A., Anjos, C. A., Machado, F. A. & Sampaio, M. R. (2002). Consumo de água e disponibilidade hídrica para milho e soja no Rio Grande do Sul (Water consumption and water availability for corn and soybean in Rio Grande do Sul), FEPAGRO, p. 105.
- Meerburg, B.G., Verhagen, A., Jongschaap, R.E.E., Franke, A.C., Schaap, B.F., Dueck, T.A., and van der Werf, A. (2009) Do nonlinear temperature effects indicate severe damages to US crop yields under climate change? *Proc. of the Nat. Acad. of Sci.*, 106, 120. <http://dx.doi.org/10.1073/pnas.0910618106>.
- NASA - National Aeronautics and Space Administration. Land Processes Distributed

Active Archive Center (LPDAAC). https://lpdaac.usgs.gov/data_access/data_pool (accessed on January 5th, 2014).

Nemani, R. & Running, S. (1997) Land cover characterization using multitemporal red, near-ir, and thermal-ir data from NOAA/AVHRR. *Ecological Applications*, v. 7, p. 79–90.

Nemani, R. and Running, S. (1997) Land cover characterization using multitemporal red, near-ir, and thermal-ir data from NOAA/AVHRR. *Ecological Applications*, v. 7, p. 79–90.

Peterson, T.C., Stott, P.A. & Herring, S. (2012) Explaining extreme events of 2011 from a climate perspective. American Meteorological Society, 1, 1041-1067. <http://dx.DOI:10.1175/BAMS-D-11-00021.1>.

Pinto, D. G.; Fontana, D. C. Inferências sobre o calendário agrícola da soja a partir de perfis temporais de NDVI em imagens MODIS. SBSR, 2011, Curitiba.

Rodrigues, O., Didonet, A.D., Lhamby, J.C.D., Bertagnolli, P.F. & Luz, J.S. (2001) Resposta quantitativa do florescimento da soja à temperatura e ao fotoperíodo. *Pesquisa Agropecuária Brasileira*, v. 36, p. 431-437.

Salvucci, M. & S.J. Crafts-Brandner, (2004). Relationship between the Heat Tolerance of Photosynthesis and the Thermal Stability of Rubisco Activase in Plants from Contrasting Thermal Environments. *Plant Physiology*, v. 134, p. 1460–1470.

Salvucci, M. (2008). Association of Rubisco activase with chaperonin-60b: a possible mechanism for protecting photosynthesis during heat stress. *Journal of Experimental Botany*, v.59, p. 1923–1933.

Sandholt, I., Rasmussen, K. & Andersen, J. (2002). A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment*, v.79, p. 213-224.

Schlenker, W. & Roberts, M. (2009) Nonlinear tem-perature effects indicate severe damages to U.S. crop yields under climate change. *Proceedings of the National Academy of Sciences*, 106, 15594-15598.

Schlenker, W. & Roberts, M. (2009). Nonlinear temperature effects indicate severe damages to U.S. crop yields under climate change. *Proceedings of the National Academy of Sciences*, v. 106, p. 15594-15598.

Sediyama, T. (Org.). *Tecnologias de produção e usos da soja*. 1. ed. Londrina, PR: Mecenas, 2009, v. 1. 314 p.

Shimabukuru, Y. E.; Maeda, E. E. & Formaggio, A. R. (2009). Sensoriamento Remoto e Sistemas de Informações Geográficas aplicados ao estudo dos recursos agronômicos e florestais. *Revista Ceres*, v. 56, p. 399-409.

Siqueira, O. J. W. ; Steinmetz, S.; Ferreira, M. F.; Costa, A. C. & Wozniak, M. A. (2000) Mudanças climáticas projetadas através dos modelos GISS e reflexos na produção agrícola brasileira. *Revista Brasileira de Agrometeorologia*, v. 8, p. 311-320.

UNEP - United Nations Environment Programme. Environmental Food Crisis. The environment's role in averting future food crises. (2009). Available online: http://www.unep.org/pdf/foodcrisis_lores.pdf. (accessed on March 1st, 2010).

Wheeler, T.R., Carufurd, P.Q., Ellis, R.H., Porter, J.R. & Prasad, P.V.V. (2000). Temperature variability and the yield of annual crops. *Agriculture, Ecosystems and Environment*, 82, 159–167.



IMPACTS OF HIGH TEMPERATURES OVER SUMMER CROPS IN MATO GROSSO STATE, BRAZIL

Journal:	<i>International Journal of Climatology</i>
Manuscript ID:	Draft
Wiley - Manuscript type:	Research Article
Date Submitted by the Author:	n/a
Complete List of Authors:	Gusso, Anibal; UNISINOS, Earth Sciences Ducati, Jorge; UFRGS, Astronomy Veronez, Mauricio; UNISINOS, Geology Junio, Luiz; UNISINOS, Graduate Program in Applied Computing
Keywords:	temperature, yield, agriculture

SCHOLARONE™
Manuscripts

1
2
3
4 **IMPACTS OF HIGH TEMPERATURES OVER SUMMER CROPS**
5
6 **IN MATO GROSSO STATE, BRAZIL**
7
8
9
10
11

12 *Anibal Gusso^{1,2,*} Jorge Ricardo Ducati^{2,4} Mauricio Roberto Veronez^{3,5}*
13

14 *and Luiz Gonzaga da Silveira Junior^{3,6}*
15

16 *¹ Environmental Engineering, UNISINOS, São Leopoldo, Brazil; *anibalg@unisinos.br*
17

18 *² Center for Remote Sensing and Meteorological Research, UFRGS, Porto Alegre, Brazil*
19

20 *³ VizLab - Advanced Visualization Laboratory, UNISINOS, São Leopoldo, Brazil*
21

22 *⁴ Astronomy Department, UFRGS, Porto Alegre, Brazil*
23

24 *⁵ Graduate Program in Geology, UNISINOS, São Leopoldo, Brazil*
25

26 *⁶ Graduate Program in Applied Computing, UNISINOS, São Leopoldo, Brazil*
27

28 **ABSTRACT.** Increase in the frequency of extreme events, such as the occurrence of high
29 temperatures, is highly probable to cause destructive effects on summer crop yields especially
30 soybeans and maize. Although it is known that the flowering period is more sensitive to temperature
31 than to water stress that specifically affects the grain number. The elevated temperature impacts on
32 crop growth are not well understood. Under the current climate change scenario, the physical
33 parameters of the Earth's surface, such as temperature, water availability, and evapotranspiration,
34 are expected to change over the next few decades leading to uncertainty in crop yield. We have
35 investigated the variability of soybean yields associated with crop canopy temperatures during key
36 development periods that are sensitive to high temperatures in Mato Grosso State, Brazil. Mato
37 Grosso State is the largest producer of soybeans in Brazil and accounted for approximately 28% of
38 the national production in 2011. In the present paper, we propose that the temperature fluctuations
39 around the optimum level in the crop canopy can cause favorable effects on soybean yields in MT
40 State/Brazil. In order to evaluate the mentioned hypothesis, we have investigated the effects of
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60

1
2
3
4 canopy temperature on soybean yield during the flowering to the grain filling periods using Aqua
5 and Terra/MODIS (Moderate Resolution Imaging Spectroradiometer) satellite data, between 2003
6 and 2010. Comparison of the spatially interpolated maps shows that the yield variations are
7 positively related to canopy-LST during of flowering period, with $R^2=0.60$ and RMSD=6.2%.
8 Overall results show that increase in canopy-LST temperature in Mato Grosso State, during the
9 flowering/grain filling periods, are related to higher soybean yield.
10
11
12
13
14
15
16

1. INTRODUCTION

1
2 Extreme weather fluctuations and climate conditions can cause severe losses to agricultural
3 production with potential worldwide economic impacts (UNEP, 2009; Masuda and Goldsmith,
4 2009). In Brazil, increase in the frequency of extreme events, such as the occurrence of high
5 temperatures and reduced rainfall, is able to cause severe effects on agricultural yields (Lobell et al.,
6 2008; Batistti and Naylor, 2009), especially soybeans and maize (Streck and Alberto, 2006). Under
7 the scenario of climate change, the physical parameters of the Earth's surface, such as temperature,
8 water availability and evapotranspiration, will change over the future decades (Gorman and
9 Schneider, 2009). Such changes can inhibit and adversely affect the crop development, since
10 canopy temperature fluctuations often exceed the optimum range (Rosenzweig et al., 2001). The
11 sensitivity toward temperature is a critical factor in bringing uncertainty in crop yield (Lobell and
12 Burke, 2008). Mato Grosso State (MT hereafter) is the first largest producer of soybeans in Brazil
13 and accounted for approximately 28% of the national production in 2011 (IBGE, 2012). Soybean
14 production was almost 21 million tons in 2011, reaching a state yield of $3,220 \text{ kg ha}^{-1}$, with yield
15 average of $2,930 \text{ kg ha}^{-1}$ between 2003 and 2010 (IBGE, 2012).

16
17 Typically, EOS-MODIS (Earth Observing System-Moderate Resolution Imaging
18 Spectroradiometer) satellite imagery data have been applied in the monitoring and modeling of the
19 bioclimatic processes, crop cycle development, agricultural production, and biophysical parameter
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60

estimates (Gusso et al., 2012). In the southern Brazil, Gusso et al. (2014a) observed that grain filling period is more sensitive to temperature than flowering during analysis of time-series data from Aqua and Terra MODIS obtained between 2003 and 2012. Although it is known that the flowering period is more sensitive to temperature than to water stress, which especially affects the grain number (Gibson and Mullen, 1996; Craufurd and Wheeler, 2009). The heat wave impacts on crop growth are not well understood (Meerburg et al., 2009). In the present article, we propose that temperature fluctuations around the optimum level in the crop canopy can affect soybean yields which are linked to water availability in MT State/Brazil. In order to evaluate the mentioned hypothesis, we have investigated the effects of canopy temperatures on soybean yield during the flowering to the grain filling periods using satellite data.

2. MATERIAL AND METHODS

2.1. Study Area

Mato Grosso State is located between approximately 6° and 19° South and 50° and 62° West, which covered a soybean crop area of almost 6.5 million ha (IBGE, 2012) in the crop year 2011. In this study, we have analyzed densely occupied soybean crops in MT State/Brazil, between 2003 and 2010. Figure 1 displays the study area.

MT State is mostly rainfed and the sowing period for soybean lasts from mid-September to late October, depending on the sowing dates, which are determined according to the onset of the rainy season from October to May. The prevailing management practice is zero tillage farming (in Portuguese, *Plantio Direto*), which is a low tillage planting and sowing practice that greatly reduces soil erosion and organic matter degradation. Usually, soybean remains the main crop, while maize or cotton is planted after the soybean harvest (Arvor et al., 2011).




Figure 1. Mato Grosso State location in Brazil and its 141 municipalities.

2.2 Crop area analysis

The soybean crop areas were identified by application of the MCDA (MODIS Crop Detection Algorithm), which was developed for crop area estimation. At the municipality level, MCDA estimates were highly correlated to IBGE data, with $R^2=0.97$ and $RMSD=13,142$ ha. The application of the algorithm for Mato Grosso conditions and ecoregion was tested by Gusso et al., (2014b) and its development was described by Gusso et al. (2012). A crop area map for seven different crop years, from 2003 to 2010, was generated from a map composition that combines each crop year map. Resulting crop area map composition tagged all soybean crop pixels at a frequency equal to or greater than two events, whose total is 7,122 million hectares, but only seven densely occupied regions of soybean crops were studied, covering 93% of total soybean crop area.

2.3 Data type and resolution

Data from several sources were used in this study such as: i) annual soybean agricultural statistics at the state and municipality levels (IBGE, 2012) for the entire study area were used to compare and

evaluate the results obtained from our soybean area estimation procedure; ii) MODIS/Terra data (MOD13Q1 product-collections 5) and MODIS/Aqua data (product MYD11A2-collection 5) covering the entire MT (image tiles: H11V09, H11V10, H12V09, H12V10, H13V09 and H13V10) for the study period; iii) official data reports and historical statistics of soybean crop production from IBGE were obtained; iv) official statistical reports and historical data of soybean from IBGE were used to evaluate soybean development profile in the study area. The MODIS image data and products are freely available at https://lpdaac.usgs.gov/data_access/data_pool.

2.4 Canopy-LST and soybean crop yield

LST is a measure of surface temperature (also known as skin temperature) rather than air temperature; it is more commonly applied in physiological studies (Sims et al., 2008). The theoretical basis is Planck's Law of Radiation, which describes that radiating energy from a black-body, as predicted by Stefan-Boltzmann's Law, is distributed in the electromagnetic spectrum as a function of its temperature (Hecht, 1998). Thus, the LST is the internal manifestation of the random translational energy of the molecules constituting a body (Elachi, 1987). Considering that physiological activities of leaves are closely related to their actual temperature (canopy temperature) rather than air temperature, the LST can be used as a reliable measure of physiological activities of a vegetation canopy (Diak and Whipple, 1993).

3. RESULTS

Spatially interpolated maps of soybean yields in MT State, using kriging methodology with data obtained from IBGE, were compared to the canopy-LST at the main developmental stage at state and regional scales. Considering a minimum yield of 1000 kg ha^{-1} , the overall yield average, inside the crop areas from 2003 to 2010, was $2,735 \text{ kg ha}^{-1}$ with a standard deviation of 263 kg ha^{-1} . As shown in Figure 2, the soybean yield deviations from each crop year were compared to the canopy-

LST deviation during the maximum vegetation development cycle according to Arvor et al., (2012) and Gusso et al., (2014b). At regional level analysis, the comparison of spatially interpolated maps of yield and canopy-LST did not follow a trend. Although the data measurements were considering only those pixels which were identified as soybean crop areas from MCDA method, the small regional extension regarding the entire State are prone to smooth canopy-LST fluctuations.




Figure 2. Scattergrams that compare the relative yield distribution at regional scale as a function of the relative canopy-LST obtained from crop years 2003 to 2010.

Considering the entire State, which can reduce the scale effect, our data analysis showed a positive trend, well defined for higher canopy-LST occurrence, above average indicating a significant increase in yield (Figure 3).

Comparison of spatially interpolated maps showed that yield variations in DOY 001 (between January 1st and February 2nd) were positively related to canopy-LST during the flowering period, with $R^2=0.60$ and RMSD=6.2%, which corresponded to the end of flowering period (Figure 2A). The comparison of tabled data (not interpolated) with the same trend is shown in Figure 2B. However, no relationship was observed for DOY 017 (between January 17th and February 17th), which is more closely related to the grain filling (Figure 2C). At DOY 033 (between February 3rd and March 5th), an inverse relationship from DOY 001 was found, with $R^2=0.50$ and RMSD=5.3%. However, this period is more related to the beginning of vegetation senesce in MT.




Figure 3. Scattergrams that compare the relative yield distribution as a function of the relative canopy-LST, obtained from crop years 2003 to 2010.

The obtained canopy-LST average in each time window in the studied period was 28.7 °C (SD=±1.95), 29.5 °C (SD=±1.92), and 31.1 °C (SD=±2.03) for DOY 001, 017, and 033 respectively. For soybean, usually the total amount of evapotranspiration water use is around 625 mm. The accumulated rainfall in the main growing stages is 2491 mm (SD=±414), between September and January in Mato Grosso State (INMET, 2009). In this sense, although crop water requirements depend on other factors like soil and management practices, increased evaporative demand promoted by increase in average temperature does not result in water stress.

4. CONCLUSION

Our analysis using thermal remote sensing and vegetation index data compared to spatially interpolated maps of soybean yield suggests that increase in canopy-LST temperature in MT during flowering/grain filling periods can induce higher soybean yield averages. State level analysis of

1
2
3
4 climatological crop water requirements indicate that these results are due to quite favorable
5 conditions for summer crops.
6
7

8 The prevailing temperature fluctuations nearby the optimum values and the non-limiting water
9 availability during grain filling/formation are favorable conditions. However, studies considering
10 soil management, economic drivers, and larger time series are required for further elaboration.
11
12
13
14
15
16

17 5. REFERENCES 18 19

20 Arvor D, Jonathan M, Meirelles MSP, Dubreuil V, Durieux L. 2011. Classification of MODIS EVI
21 time series for crop mapping in the state of Mato Grosso, Brazil. *International Journal of Remote*
22
23 *Sensing* **32**: 7847–7871. DOI: 10.1080/01431161.2010.531783.

24
25 Batistti DS, Naylor RL. 2009. Historical warnings of future food insecurity with unprecedented
26 seasonal heat. *Science* **323**: 240-244. DOI: 10.1126/science.1164363.

27
28 Craufurd PQ, Wheeler TR. 2009. Climate change and the flowering time of annual crops. *Journal*
29
30 *of Experimental Botany* **60**: 2529–2539. DOI: 10.1093/jxb/erp196.

31
32 Diak GR, Whipple MS. 1993. Improvements to models and methods for evaluating the land-surface
33 energy balance and effective roughness using radiosonde reports and satellite-measured skin
34 temperature data. *Agricul. Forest Meteorol.* **63**: 189-218. DOI: 10.1016/0168-1923(93)90060-U.

35
36 Elachi C. 1987. *Introduction to the Physics and Techniques of Remote Sensing*. NY, Wiley, 1st Ed.

37
38 Gibson LR, Mullen RE. 1996. Soybean seed quality reductions by high day and night temperature.
39
40 *Crop Sci.* **36**: 1615–1619. DOI: 10.2135/cropsci1996.0011183X003600060034x.

41
42 Gorman PA, Schneider T. 2009. The physical basis for increases in precipitation extremes in

1
2
3
4 simulations of 21st-century climate change. *Proceedings of the National Academy of Sciences*
5
6 **106:** 14773–14777. DOI: 10.1073/pnas.0907610106.
7
8
9

10 Gusso A, Adami M, Formaggio AR, Rizzi R, Rudorff BTF. 2012. Soybean area estimation and
11 mapping by means MODIS/EVI data. *Pesq. Agrop. Bras.* **47:** 425-435. DOI: 10.1590/S0100-
12 204X2012000300015.
13
14

15
16
17 Gusso A, Ducati J, Veronez M, Sommer V, Silveira Junior LG. 2014a. Monitoring heat waves
18 and their impacts on summer crop development in southern Brazil. *Agricultural Sciences*. **5:** 353-
19 364. DOI: 10.4236/as.2014.54037.
20
21

22
23
24 Gusso A, Arvor D, Ducati JR, Veronez MR, Silveira Junior LG. 2014b. Assessing the MODIS
25 Crop Detection Algorithm for Soybean Crop Area Mapping and Expansion in the Mato Grosso
26 State, Brazil. *The World Scientific Journal*, 1-9. DOI: [10.1155/2014/863141](https://doi.org/10.1155/2014/863141).
27
28
29

30
31 Hecht E. 1998. *Optics*. 3rd ed. Reading: Addison-Wesley.
32
33

34
35
36 IBGE - Instituto Brasileiro de Geografia e Estatística. SIDRA: sistema IBGE de recuperação
37 automática. <http://www.sidra.ibge.gov.br/>. (accessed on November 3rd, 2012).
38
39

40
41 Lobell DB. and Burke MB. (2008). Why are agricultural impacts of climate change so uncertain?
42 The importance of temperature relative to precipitation. *Environ. Res. Lett.* **3:** 1-8. DOI:
43 10.1088/1748-9326/3/3/034007 (accessed on March 26th, 2012).
44
45

46
47 Lobell DB, Burke MB, Tebaldi C, Mastrandrea MD, Falcon WP, Naylor RL. (2008). Prioritizing
48 Climate Change Adaptation Needs for Food Security in 2030. *Science* **319:** 607-610. DOI:
49 [10.1126/science.1152339](https://doi.org/10.1126/science.1152339) (accessed on November 17th, 2011).
50
51
52
53
54
55
56
57
58
59
60

Masuda T, Goldsmith, PD. 2009. World Soybean Production: Area Harvested, Yield, and Long-Term Projections. *Int. Food Agrib. Manag. Review*, **12**, 143-163.
http://ageconsearch.umn.edu/bitstream/92573/2/20091023_Formatted.pdf (accessed on October 4th, 2013).

Meerburg BG, Verhagen A, Jongschaap REE, Franke AC, Schaap BF, Dueck TA, van der Werf A. 2009. Do nonlinear temperature effects indicate severe damages to US crop yields under climate change? *Proc. of the Nat. Acad. of Sci.* **106**: 120. DOI: [10.1073/pnas.0910618106](https://doi.org/10.1073/pnas.0910618106).

Nemani R, Running S. 1997. Land cover characterization using multitemporal red, near-ir, and thermal-ir data from NOAA/AVHRR. *Ecol. Applic.* **7**: 79–90. DOI: 10.1890/1051-0761(1997)007.

Rosenzweig C, Iglesias A, Yang XB, Epstein P, Chivian E. 2001. Climate change and extreme weather events: Implications for food production, plant diseases, and pests. *NASA Publications-Paper 24* **2**: 90-104.

Sims DA, Rahman AF, Cordova VD, El-Masri BZ, Baldocchi DD, Bolstad PV, Flanagan LB, Goldstein AH, Hollinger DY, Misson L, Mon-son RK, Oechel WC, Schmid HP, Wofsy SC, Xu L. 2008. A new model of gross primary productivity for North American ecosystems based solely on the enhanced vegetation index and land surface temperature from MODIS. *Rem. Sen. of Env.* **112**: 1633-1646. DOI: [10.1016/j.rse.2007.08.004](https://doi.org/10.1016/j.rse.2007.08.004).

Streck NA, Alberto C.N. 2006. Estudo numérico do impacto da mudança climática sobre o rendimento de trigo, soja e milho. *Pesq. Agropec. Bras.* **41**: 1351-1359. DOI: 10.1590/S0100-204X2006000900002.

UNEP - United Nations Environment Programme. Environmental Food Crisis. 2009.
http://www.unep.org/pdf/foodcrisis_lores.pdf. (accessed on March 1st, 2010).