



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**UTILIZAÇÃO DE SÉRIES TEMPORAIS DE IMAGENS DE
MODERADA RESOLUÇÃO ESPACIAL PARA MONITORAMENTO
DAS MUDANÇAS DO USO DO SOLO E COBERTURA VEGETAL DO
BIOMA PAMPA**

Tese de Doutorado

Vagner Paz Mengue

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

VAGNER PAZ MENGUE

UTILIZAÇÃO DE SÉRIES TEMPORAIS DE IMAGENS DE MODERADA
RESOLUÇÃO ESPACIAL PARA MONITORAMENTO DAS MUDANÇAS
DO USO DO SOLO E COBERTURA VEGETAL DO BIOMA PAMPA

Porto Alegre
2018

VAGNER PAZ MENGUE

UTILIZAÇÃO DE SÉRIES TEMPORAIS DE IMAGENS DE MODERADA
RESOLUÇÃO ESPACIAL PARA MONITORAMENTO DAS MUDANÇAS
DO USO DO SOLO E COBERTURA VEGETAL DO BIOMA PAMPA

Tese de Doutorado apresentada como requisito
parcial para obtenção do Título de Doutor em
Sensoriamento Remoto.

Orientadora: Denise Cybis Fontana
Co-orientadora: Tatiana S. da Silva

Porto Alegre

2018

CIP - Catalogação na Publicação

paz mengue, vagner

Utilização de séries temporais de imagens de moderada resolução espacial para monitoramento das mudanças do uso do solo e cobertura vegetal do Bioma Pampa / vagner paz mengue. -- 2018.

122 f.

Orientadoras: Denise Cybis Fontana, Tatiana Silva da Silva.

Tese (Doutorado) -- Universidade Federal do Rio Grande do Sul, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Programa de Pós-Graduação em Sensoriamento Remoto, Porto Alegre, BR-RS, 2018.

1. MODIS, Landsat. 2. Classificação Uso do Solo . 3. Bioma Pampa. 4. Série temporal. 5. GWR. I. Cybis Fontana, Denise, orient. II. , Tatiana Silva da Silva, orient. III. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os dados fornecidos pelo(a) autor(a).

FOLHA DE APROVAÇÃO

Vagner Paz Mengue

**UTILIZAÇÃO DE SÉRIES TEMPORAIS DE IMAGENS DE MODERADA
RESOLUÇÃO ESPACIAL PARA MONITORAMENTO DAS MUDANÇAS DO USO
DO SOLO E COBERTURA VEGETAL DO BIOMA PAMPA**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto para obtenção do título de Doutor em Sensoriamento Remoto.

Área de Concentração: Sensoriamento Remoto aplicado.

Aprovado em 27 de abril de 2018.

Prof. Dr. Rafael Medeiros Sperb - FURG

Prof. Dr. Marcos Wellausen Dias de Freitas - GEOCIÊNCIAS/UFRGS

Prof. Dr. Carlos Gustavo Tornquist – PPGSR/UFRGS

Prof.^a Dr.^a Denise Cybis Fontana – UFRGS (Orientadora)

Prof.^a Dr.^a Tatiana Silva da Silva – UFRGS (Co-orientadora)

Dedico esta tese ao meu avô Juareu
Mendes Paz (*In memoriam*)

AGRADECIMENTOS

- À minha orientadora Prof. ^a Denise Cybis Fontana, pelos ensinamentos, paciência e apoio ao longo da caminhada;
- À minha co-orientadora Tatiana Silva pela apoio e ensinamento para conseguir realizar este trabalho;
- Ao Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia pela oportunidade de realização deste trabalho;
- A Universidade Federal do Rio Grande do Sul pela excelência de ensino público no país;
- Ao Professor Daniel Zanotta pela brilhante ajuda e apoio nos momentos mais tensos com o MATLAB;
- Ao Professor Marcos Freitas pelo apoio e ensinamento nos modelos de regressão espacial;
- Aos meus amigos do tempo de graduação em Santa Maria, Magno, Lúcio (Bidê), Riffel, e Alan;
- Ao meu grande amigo e parceiro de trabalho Fernando Scottá;
- Aos meus pais e toda a família pelo apoio, compreensão e companhia;
- Aos meus cachorros Max e Pitchula pelos momentos de descontração.

UTILIZAÇÃO DE SÉRIES TEMPORAIS DE IMAGENS DE MODERADA RESOLUÇÃO ESPACIAL PARA MONITORAMENTO DAS MUDANÇAS DO USO DO SOLO E COBERTURA VEGETAL DO BIOMA PAMPA

Autor: Vagner Paz Mengue

Orientadora: Denise Cybis Fontana

Co-orientadora: Tatiana S. da Silva

O objetivo da pesquisa foi verificar a aplicabilidade do uso de séries temporais de imagens de moderada resolução espacial para o mapeamento do uso do solo e cobertura vegetal no Bioma Pampa no Estado do Rio Grande do Sul e identificar os principais processos de transformação da paisagem. O estudo foi conduzido no limite do Bioma Pampa Gaúcho, definido pelo IBGE. Foram utilizadas imagens EVI (*Enhanced vegetation index*) do Sensor MODIS, imagens noturnas do DMSP-OLS (*Defence Meteorological Satellite Program - Operational Linescan System*), dados SRTM (*Shuttle Radar Topography Mission*) e imagens Landsat 5 e 8, associados ao classificador hierárquico por Árvore de Decisão (AD), construído utilizando o algoritmo C4.5. Para investigar os processos de transformação da paisagem, foram utilizadas variáveis ambientais, que incluem dados geomorfométricos, métricas da paisagem, dados climáticos e variáveis socioeconômicas. Foram utilizados modelos de regressão linear local (GWR) e global, além de procedimentos de agrupamentos espaciais (SKATER) implementado no *software TerraView*. Os resultados da metodologia de mapeamento do uso do solo e cobertura vegetal mostraram uma Exatidão Global (EG) que variou entre 89 e 90%. As maiores similaridades espectrais foram encontradas nas classes com cobertura vegetal, como Campo, Floresta e Silvicultura. Com relação aos principais processos de transformação da paisagem, foi verificado uma diminuição em torno de 25% da classe Campo num intervalo de 15 anos, de 10.252.740 ha para 7.676.208 ha. Em contrapartida áreas agrícolas, como a classe Soja, obteve um aumento de 145 % do total de sua área, de 855.087 ha em 2000, para 2.099.837 ha em 2014. A classe Silvicultura também teve um aumento de mais de 167 % da sua área total. Para o processo de expansão da soja os principais fatores que contribuíram foram: topográficos (elevação, declividade e modelo HAND), fatores educacionais como taxa de analfabetismo, fatores climáticos (precipitação anual e sazonalidade da precipitação) e fatores de proximidade com áreas degradadas. Já para o processo de expansão da silvicultura foram: topográficos (declividade), rendimento médio mensal (R\$), taxa de analfabetismo, precipitação anual e proximidade com áreas degradadas de campo. Este estudo permitiu identificar, através de utilização de técnicas de sensoriamento remoto e geoprocessamento, que o padrão de degradação da vegetação campestre é um processo complexo e que envolve uma série de fatores, e que tende a ocorrer muito próximo de áreas já previamente degradadas. O principal processo de degradação da vegetação campestre é a atividade antrópica, em especial a agricultura mecanizada, com o cultivo de soja e áreas de silvicultura.

USE OF TIME SERIES OF MODERATE IMAGES SPACE RESOLUTION
FOR MONITORING OF LAND USE CHANGES AND COVERAGE VEGETABLE IN
THE BRAZILIAN PAMPA BIOME

Author: Vagner Paz Mengue

Advisor: Denise Cybis Fontana

Co-advisor: Tatiana S. da Silva

The objective of the research was to verify the applicability of use the time series of moderate images space resolution for the mapping of land use changes and coverage vegetable in the Pampa biome in the State of Rio Grande do Sul and to identify the main processes of landscape transformation. The study was conducted at the boundary of the Pampa Biome, defined by IBGE. We used the images EVI (*Enhanced vegetation index*) of MODIS sensor, DMSP-OLS night images (*Defence Meteorological Satellite Program - Operational Linescan System*), SRTM data (*Shuttle Radar Topography Mission*) and Landsat images 5 and 8, associated with the hierarchical classifier by Decision tree (AD), constructed using the algorithm C4.5. To investigate the landscape transformation processes, we used environmental variables, which include geomorphometric data, landscape metrics and climatic data and socioeconomic variables. Through local linear regression (GWR) and global models, in addition to spatial grouping procedures (SKATER) implemented in the TerraView software. The results of the methodology of mapping of land use and vegetation coverage with MODIS images and DMSP-OLS night images, Global Accuracy ranged from 89 to 90%. The highest spectral similarities were found in the vegetation cover classes, such as grassland, Forest and Forestry. In relation to the main transformation processes of the landscape, there was a decrease of around 25% of the Grassland class in the 15-year interval, from 10,252,740 ha to 7,676,208 ha, in contrast to agricultural areas, such as the Soybean class, an increase of 145.56% of its total area, from 855,087 ha in 2000 to 2,099,837 ha in 2014. The forestry class also had an increase of over 167% of its total area. For the soybean expansion process the main contributing factors were: topographic (elevation, slope and HAND models), educational factors such as illiteracy rate, climatic factors (annual precipitation and precipitation seasonality) and proximity factors with degraded areas. For the expansion process of silviculture were: topographic (slope), average monthly income (R\$), illiteracy rate, annual precipitation and proximity to degraded areas of the grassland. This study allowed to identify, through the use of techniques of remote sensing and geoprocessing, that the pattern of degradation of the country vegetation is a complex process involving a series of factors, which tends to occur very close to previously degraded areas. The main process of degradation of the grassland vegetation is the anthropic activity, especially the mechanized agriculture, with the cultivation of soybean and forestry areas.

SUMÁRIO

Apresentação da estrutura da tese.....	12
Capítulo I – Aspectos introdutórios.....	14
I.1. Introdução	14
I.1.1 Premissa e objetivos	15
I.2. Fundamentação Teórica.....	17
I.2.1. Características do Bioma Pampa.....	17
I.2.2. Utilização do sensoriamento remoto para estimativas de safras agrícolas e mapeamento do uso do solo e cobertura vegetal	21
I.2.3. Modelagem da dinâmica da paisagem: Modelos de simulação baseados em Autômato Celular	23
I.2.4. Classificação digital de séries temporais para mapeamento do uso do solo	25
I.2.4.1. Arvore de decisão e algoritmo C4.5.....	27
I.2.5. Redes Neurais Artificiais	28
I.2.6. Sensores orbitais e a detecção de mudanças do uso do solo e cobertura vegetal.	30
I.2.7.1. Imagens de Índices de Vegetação do sensor MODIS	33
I.2.7.2. Imagens Noturnas DMSP-OLS para classificação de áreas urbanas.....	34
I.2.8. Principais causas das mudanças do uso do solo e cobertura vegetal	36
I.2.9. Modelo de regressão linear local (GWR) aplicados na detecção de mudanças do uso do solo e cobertura vegetal	38
Bibliografia	39
Capítulo II – Resultados na forma de artigos científicos submetidos ou a serem submetidos para publicação.....	50
II.2. Artigo 1: DETECÇÃO E PREDIÇÃO DE MUDANÇAS ESPACIAIS RELACIONADAS À EXPANSÃO DA FRONTEIRA AGRÍCOLA SOBRE CAMPOS NATIVOS NO BIOMA PAMPA.....	51
II.2. Artigo 2: METODOLOGIA PARA CLASSIFICAÇÃO DE USO E COBERTURA VEGETAL DO BIOMA PAMPA UTILIZANDO SÉRIES TEMPORAIS MODIS-EVI	65
II.3. Artigo 3: MUDANÇAS DO USO DO SOLO E COBERTURA VEGETAL NO BIOMA PAMPA E A RELAÇÃO COM DADOS AMBIENTAIS E SOCIOECONÔMICOS	90
Capítulo III - Considerações finais.....	119

LISTA DE ILUSTRAÇÕES

Figura 1: Área de abrangência do bioma Pampa no Rio Grande do Sul. Fonte: Atlas Socioeconômico do Rio Grande do Sul (2012)	17
Figura 2 : Perfis espectro-temporais médio de NDVI para o Estado do Rio Grande do Sul: Fonte: (CORDEIRO et al., 2017).	21
Figura 3:Imagem Landsat 5/TM de 2001 (A) Landsat 8/OLI 2014 (B) ilustrando mudanças de uso do solo, áreas campestres convertidas em áreas agrícolas com o cultivo de soja (verde claro na imagem B), nas proximidades do município de Tupanciretã. Fonte: Elaborado pelo autor.	26
Figura 4: Modelo de um neurônio artificial.....	29
Figura 5: Rede de múltiplas camadas.	30

Apresentação da estrutura da tese

Esta Tese de Doutorado, intitulada “**UTILIZAÇÃO DE SÉRIES TEMPORAIS PARA MONITORAMENTO DAS MUDANÇAS DO USO DO SOLO E COBERTURA VEGETAL DO BIOMA PAMPA**”, foi desenvolvida entre setembro de 2013 a março de 2018 no Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM), na Universidade Federal do Rio Grande do Sul.

A tese é composta das seguintes partes:

- **Capítulo I – Aspectos introdutórios**

Abordam sinteticamente aspectos fundamentais para a construção da tese, buscando a compreensão do contexto acerca da proposta de monitoramento de mudanças de uso do solo e cobertura vegetal, além dos objetivos gerais e justificativas.

- **Capítulo II – Resultados na forma de artigos científicos submetidos ou a serem submetidos para publicação**

II.1. Artigo 1: DETECÇÃO E PREDIÇÃO DE MUDANÇAS ESPACIAIS RELACIONADAS À EXPANSÃO DA FRONTEIRA AGRÍCOLA SOBRE CAMPOS NATIVOS NO BIOMA PAMPA: Trata de avaliar a expansão da fronteira agrícola sobre campos nativos do Bioma Pampa, no município de Tupanciretã. Este foi um trabalho experimental de aplicação de técnicas de classificação e utilização do módulo *Land Change Modeler* (LCM), do *software* IDRISI, para análise de mudanças do uso do solo. A ideia era testar a metodologia numa área de menor abrangência (municipal), na etapa seguinte implementar em todo o Bioma Pampa Gaúcho.

Enviado para a Revista Brasileira de Cartografia – Brazilian Journal of Cartography

Submetido em 4 maio de 2016 – aceito em 20 de junho de 2017

II.2. Artigo 2: METODOLOGIA PARA CLASSIFICAÇÃO DE USO E COBERTURA VEGETAL DO BIOMA PAMPA UTILIZANDO SÉRIES TEMPORAIS MODIS-EVI: Este artigo tratou de desenvolver uma metodologia de mapeamento do uso do solo e cobertura vegetal, utilizando séries temporais do sensor MODIS no Bioma Pampa Gaúcho. A etapa subsequente foi aplicar esta metodologia em outros anos e analisar os principais processos de transformação da paisagem no Bioma Pampa Gaúcho.

II.3. Artigo 3: MUDANÇAS DO USO DO SOLO E COBERTURA VEGETAL NO BIOMA PAMPA E A RELAÇÃO COM DADOS AMBIENTAIS E SOCIOECONÔMICOS: Este é o artigo de fechamento do trabalho. Neste, é analisado os processos de uso do solo e cobertura vegetal no Bioma Pampa Brasileiro, gerados a partir de séries temporais do sensor MODIS, incluindo os principais processos de transformação da paisagem. Também, neste artigo foram investigados os principais fatores que contribuem para a transformação da paisagem.

- **Considerações finais:** Nesta parte do trabalho é feito uma análise global do trabalho realizado.

Capítulo I – Aspectos introdutórios

I.1. Introdução

O Pampa integra, juntamente com o Cerrado, a Caatinga e o Pantanal, um conjunto de biomas continentais brasileiros caracterizados pelo predomínio de fisionomias de vegetação não florestal. O Bioma Pampa corresponde à porção brasileira dos pampas sul-americanos que se estendem pelos territórios do Uruguai e da Argentina e que, no conjunto, foram denominados de Campos da Região do Rio da Prata. Possui uma área de aproximadamente 176.496 km², ocupando 2,07% do território brasileiro e 63% do Estado do Rio Grande do Sul.

Na busca de atendimento à demanda mundial de alimentos e da própria expansão agrícola, entretanto, este bioma tem tido grandes áreas de sua cobertura vegetal alterada. Especialmente nos últimos tempos, tem se observado uma tendência de mudança de uso do solo e da sua cobertura vegetal (USCV), marcadamente pela conversão das áreas campestres para a agricultura de grãos (arroz irrigado e soja) e silvicultura (*Pinus sp.*, *Acácia spp.* e *Eucalyptus spp.*). Existe uma grande preocupação em termos de sustentabilidade ambiental para o Bioma Pampa, principalmente devido a esta conversão, a qual pode causar perdas de solos por erosão, contaminação do lençol freático por agrotóxicos e fertilizantes, entre outras. Há, portanto, necessidade de monitoramento contínuo das transformações do uso do solo e da sua cobertura vegetal neste bioma.

Dados oriundos de sensoriamento remoto, em conjunto com técnicas de geoprocessamento, podem proporcionar melhorias no monitoramento contínuo das transformações das paisagens, dimensionar por exemplo, mudanças nas fronteiras agrícolas e o impacto delas sobre os biomas naturais, como é o caso do Bioma Pampa. Através do uso de séries temporais podemos compreender as transformações das fronteiras agrícolas sobre os biomas naturais e buscar entender a estrutura e dinâmica recente das paisagens.

O mapeamento do USCV do Bioma Pampa tem sido realizado principalmente com base na análise de um mosaico de imagens do satélite Landsat. O uso de imagens com periodicidade a cada 16 dias, como é o caso do Landsat, apresenta algumas limitações devido à dificuldade de aquisição de imagens livres da cobertura de nuvens, impedindo a aquisição de várias imagens ao longo do ano, o que compromete em parte a interpretação e mapeamento de algumas classes de USCV, principalmente as classes vegetais que apresentam padrões espectrais distintos devido a sazonalidade climática.

Uma alternativa para contornar essa limitação do satélite Landsat é o monitoramento USCV por meio de séries temporais obtidas pelo sensor MODIS. Apesar de possuir uma

resolução mais baixa (250m), quando comparada ao Landsat (30 m), sua resolução temporal é maior, com uma frequência de 1 dia nas latitudes que ocorrem o bioma Pampa. O sensor MODIS disponibiliza ainda produtos derivados de composição de imagens de 16 dias sob a forma de índices de vegetação, permitindo uma melhor análise da dinâmica do uso do solo e da cobertura vegetal da área de estudo. Cabe destacar que séries temporais do sensor MODIS possuem uma cobertura temporal contínua apropriada para caracterizar as dinâmicas de cada tipo de paisagem do Bioma Pampa, o que com as imagens Landsat este procedimento pode ficar comprometido, principalmente devido a cobertura de nuvens.

A maioria dos estudos desenvolvidos não contemplam todo o bioma ou não analisam os fatores determinantes dada a complexidade da dinâmica das mudanças na paisagem, alguns trabalhos utilizaram dados de sensores orbitais para analisar a influência dos elementos do clima na vegetação campestre a partir dos índices de vegetação. No entanto, o Bioma Pampa carece de metodologias robustas, que utilizem técnicas de modelagem espacial para quantificar por meio de séries temporais de sensores orbitais a conversão de áreas campestres em áreas de uso agrícola ou de silvicultura, que integrem dados de diferentes bases e que sejam aplicáveis em grandes áreas.

O trabalho desta tese irá contribuir para entender a dinâmica dos processos transformadores da paisagem no Bioma Pampa Brasileiro e poderá agregar informações importantes para futuros projetos de modelagem do uso do solo e cobertura vegetal para biomas brasileiros, em especial o Pampa.

I.1.1 Premissa e objetivos

O presente trabalho busca contribuir para avançar no que tange à geração de conhecimento sobre o potencial dos métodos de mapeamento e monitoramento do USCV para o Bioma Pampa Brasileiro. Esta pesquisa assumiu como premissa que, as mudanças de USCV no Bioma Pampa Brasileiro, como por exemplo, a expansão da soja e da silvicultura sobre áreas campestres, podem ser detectadas e mapeadas devido à variação espectro-temporal dos índices de vegetação, e que estas podem estar relacionadas com fatores socioeconômicos, geomorfométricos e ambientais.

Esta abordagem constitui-se de uma valiosa contribuição para a definição de estratégias mais eficientes sobre o ordenamento territorial e pode servir como subsídio para tomada de políticas públicas.

Com base nessa motivação, o objetivo geral desta tese foi propor uma metodologia para identificar os processos de USCV no Bioma Pampa Brasileiro através de séries temporais

MODIS, e investigar quais fatores são responsáveis pelos processos transformadores da paisagem.

Os objetivos específicos desta pesquisa são:

- Testar abordagens e propor uma metodologia para mapeamento dos principais USCV através de uma combinação de séries temporais MODIS/EVI, imagens de iluminação noturna e dados de elevação do relevo;
- Construir e avaliar os perfis espectros-temporais dos principais usos do USCV do Bioma Pampa;
- Propor um método para identificar e separar a soja de outras culturas, como o arroz irrigado, a fim de analisar sua expansão sobre áreas campestres;
- Dimensionar as transformações da paisagem e identificar os principais processos de USCV que são responsáveis pela conversão da vegetação campestre;
- Investigar quais fatores (socioeconômicos, geomorfométricos e ambientais) são responsáveis pelos processos de transformação da paisagem na área de estudo;
- Identificar e avaliar a heterogeneidade dos processos de uso do solo e cobertura vegetal na área de estudo;
- Propor agrupamentos espaciais dos principais processos de USCV para o Bioma Pampa.

I.2. Fundamentação Teórica

I.2.1. Características do Bioma Pampa

A região do estudo da tese está inserida dentro do Bioma Pampa Brasileiro. Possui uma área de aproximadamente 176.496 km², ocupando 2,07% do território brasileiro (IBGE, 2012) e 63% do Estado do Rio Grande do Sul (OVERBECK et al., 2007). Também possui continuidade em todo o Uruguai e parte da Argentina (BOLDRINI, 2009). Esse bioma (Figura 1) é dominado por vegetação campestre, porém também apresenta vegetação arbustiva e áreas florestais (OVERBECK et al., 2007).



Figura 1: Área de abrangência do bioma Pampa no Rio Grande do Sul. Fonte: Atlas Socioeconômico do Rio Grande do Sul (2012)

Com relação a clima no Bioma Pampa, conforme a classificação de Köppen (ALVARES et al 2013), é predominantemente do tipo Cfa. A temperatura média anual é de 18,4°C, sendo janeiro o mês mais quente, com temperatura média de 23,9°C, e junho o mais frio, com temperatura média de 13,1°C. A precipitação pluvial total anual é de 1.405 mm, sendo abril o mês com menor precipitação acumulada, com 90,3 mm, e o mês de março e setembro os meses mais chuvosos, com precipitação acumulada de 137 mm (INMET, 1992). A temperatura apresenta evidente sazonalidade, com verão e inverno bem definidos, mas a

amplitude da variação anual da precipitação pluvial mensal não caracteriza período seco ou chuvoso. Existe ainda uma considerável variabilidade interanual da precipitação pluvial e da temperatura, em grande parte associada à ocorrência dos fenômenos El Niño e La Niña. O Estado encontra-se nas estações da primavera e verão sob o domínio da Massa Tropical Marítima, responsável por chuvas intensas e de curta duração. Nas estações outono e inverno, aumenta a frequência dos anticiclones migratórios polares associados à Massa Polar Marítima, trazendo chuvas durante de duração mais prolongada (HASENACK & FERRARO, 1989).

Quanto à geomorfologia do bioma Pampa é dominado por relevo suavemente ondulado, cobertas principalmente por vegetação de campos naturais, de acordo com a RadamBrasil (BRASIL, 1986), esta região estaria incluída nas regiões geomorfológicas do planalto da campanha e da depressão central gaúcha, mais especificamente nas unidades geomorfológicas do planalto de Uruguaiana e da depressão do rio Ibicuí.

A geologia do Bioma Pampa compreende uma diversidade de litologias que incluem rochas graníticas, areníticas e basálticas da Era Mesozóica e depósitos sedimentares da Era Cenozóica. O relevo do bioma Pampa varia de plano a ondulado, e apresenta altitudes que vão de menos 10 m, nas planícies de inundação dos maiores rios e na planície costeira, na porção leste, com topos de mais de 400 m, de algumas formações graníticas do Planalto Sul-Riograndense. A combinação da diversidade de litologias, altitudes e declividades gera diversas formas de relevo, as quais correspondem a várias unidades geomorfológicas (IBGE, 1986).

Com relação ao uso do solo e cobertura vegetal, o Bioma Pampa integra, juntamente com o Cerrado, Pantanal e a Caatinga, um conjunto de biomas continentais brasileiros caracterizados pelo predomínio de fisionomias de vegetação não florestal. Os campos possuem como fisionomia característica a presença de gramíneas, apresentando diversidade na ordem de 2.200 espécies (BOLDRINI, 2009), sendo 450 espécies forrageiras (NABINGER et al., 2009). Uma característica peculiar dos campos no Rio Grande do Sul é a coexistência de espécies dos grupos fotossintéticos C3 e C4 (OVERBECK et al., 2007). As espécies do grupo C4 possuem como característica o crescimento no período das estações quentes do ano (período estival), enquanto o grupo C3 apresenta crescimento no período de estações frias (período hibernal). Apesar da coexistência desses dois grupos de espécies, o predomínio de espécies do grupo C4 é maior (BOLDRINI, 2009; MARASCHIN, 2009), explicando o característico aumento de biomassa nas estações quentes do ano (BETTOLLI et al., 2010; MARASCHIN, 2009; NABINGER et al., 2009; GOMES, 1996).

A distribuição espacial da vegetação foi fator preponderante na ocupação do território do Estado do Rio Grande do Sul durante seu povoamento. Os ecossistemas campestres do Bioma Pampa foram os primeiros a serem ocupados. Chomenko (2016) afirmou que na Metade

Sul do Estado do RS, o principal modelo de ocupação esteve historicamente ligado à pecuária extensiva. A partir da segunda metade do século XX, houve no Rio Grande do Sul um forte incremento da agricultura intensiva, principalmente para produção de grãos, como o arroz irrigado, cultivado principalmente nas áreas de várzeas. Em várias regiões houve e continua havendo a introdução da fruticultura, dando origem a processos industriais que vem modificando o perfil de desenvolvimento local (vitivinicultura, oliveiras, além da produção de espécies nativas) (CHOMENKO, 2016).

Em fins do século XX e no início do século XXI, inaugurou-se um novo ciclo econômico no Pampa, com a chegada da silvicultura e do cultivo de soja, sendo registrados a cada ano expansão significativa. Outras atividades, como a exploração de recursos minerais, a produção de energia elétrica, o extrativismo predatório, a introdução de espécies exóticas invasoras, a ocupação de áreas de preservação permanente (APPs) e o próprio processo de urbanização acelerado são ameaças graves às condições ambientais dos espaços naturais do Estado.

Embora o clima do Bioma Pampa Brasileiro não apresente período seco sistemático, a frequência de frentes polares e temperaturas negativas no período do inverno produzem estacionalidade fisiológica típica de clima frio (WAGNER, 2013). Os resultados obtidos neste trabalho mostraram que o que determina o padrão temporal no vigor vegetativo da vegetação campestre do Bioma Pampa, avaliado pelos índices de vegetação NDVI (*Normalized Difference Vegetation Index*) e EVI (*Enhanced Vegetation Index*), é a condição hídrica. A composição florística e o tipo de solo participam na modulação das intensidades deste padrão, enquanto que as condições meteorológicas são as responsáveis pela alta variabilidade interanual observada. Existe uma relação negativa entre os índices de vegetação e as variáveis de temperatura máxima do ar, amplitude térmica e evapotranspiração potencial e positiva com a precipitação pluvial e temperatura mínima do ar, em quase todos os meses do ano. Apesar de não haver restrição na disponibilidade hídrica ao longo do ano, a sazonalidade da temperatura induz a vegetação campestre a comportamento fisiológico semelhante à de climas com estação seca definida.

Desta forma, é importante compreender a fenologia para tentar distinguir diferentes tipos de vegetação, como áreas agrícolas, vegetação campestre, áreas florestais naturais e áreas de silvicultura por meio de imagens de satélite. Entender a dinâmica da vegetação ao longo do ano, como as fases de crescimento, máxima produção de biomassa e senescência de cada tipo de vegetação nativa ou cultivada, torna-se crucial para um bom mapeamento e detecção dos diferentes tipos vegetais.

A vegetação campestre (Campo) durante o período do outono, inicia o declínio da produção fotossintética da vegetação herbácea, que atinge o nível mais baixo no inverno,

quando boa parte da biomassa foliar encontra-se em estágio senescente (MACHADO, 1999) (Figura 2). No fim do inverno, as espécies anuais germinam e as espécies perenes iniciam o processo de rebrote com a emissão de novas folhas, dando início a um progressivo aumento da biomassa fotossinteticamente ativa, que atinge o ápice no verão (RIZZI & FONSECA, 2001). Importante mencionar que a vegetação florestal no bioma Pampa, é classificada na maior parte como Floresta Estacional Decidual, e em menor parte como Semidecidual (IBGE, 2004). É possível, ainda na Figura 2, perceber que a vegetação Campo e Floresta apresenta pouca amplitude do índice de vegetação NDVI ao longo do ano, quando comparado as áreas agrícolas (agricultura 2 uso intensivo no verão e inverno). De fato, apenas uma fração pequena de espécies das comunidades vegetais arbóreas apresenta perda de folhas durante o período do inverno, motivo pelo qual se espera que as florestas do Bioma Pampa apresentem pouca variação do índice de vegetação ao longo do ano.

Já as áreas destinadas para agricultura apresentam padrão sazonal bem definido, característico desse tipo de atividade. As culturas de verão, identificadas na Figura 2 como agricultura 1 uso intensivo no verão, são áreas tradicionalmente ocupadas, predominantemente, com o cultivo de arroz irrigado e nos últimos anos com soja, no período primavera-verão e pousio com campos no período outono-inverno (CORDEIRO et al., 2017). Durante o final do inverno e início da primavera ocorre o preparo do solo, que em função de diferentes técnicas agrônômicas de manejo de manejo resulta em diferentes respostas espectrais, como no solo exposto (plantio convencional), em aplicação de agentes de secagem da biomassa aérea da vegetação existente, eliminando a vegetação fotossinteticamente ativa (plantio direto) ou ainda as áreas de inundação do solo para o plantio de arroz (SOSBAI, 2014). Nas áreas destinadas para agricultura de verão, após a colheita no fim do verão e início do outono é usual a semeadura de pastagens de inverno, como técnica de cobertura do solo e complemento de forragem para a pecuária. Como isso, nesse período pode haver similaridade espectral entre essas manchas de pastagens com áreas de vegetação campestre (campo).

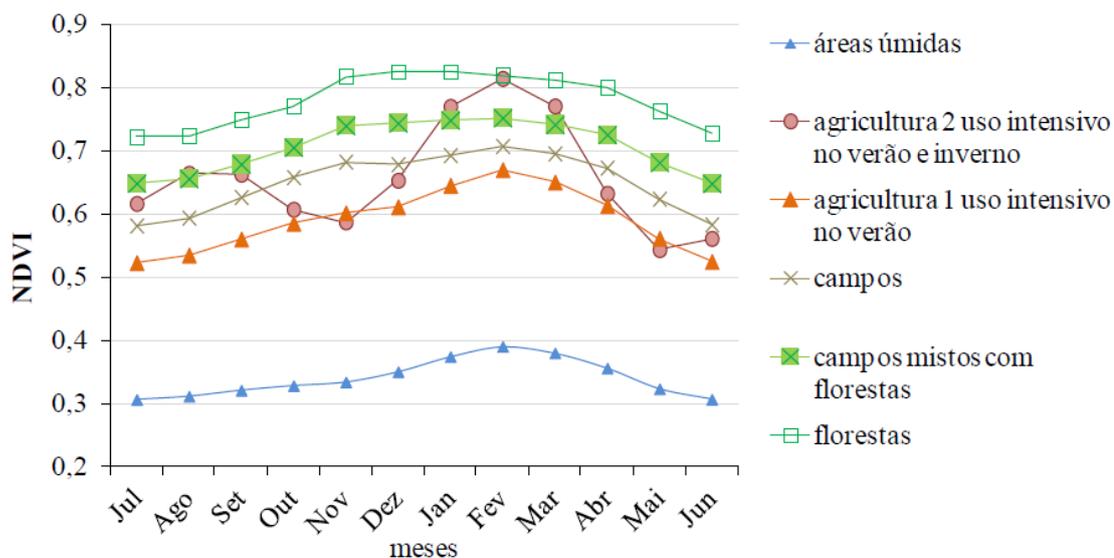


Figura 2 : Perfis espectro-temporais médio de NDVI para o Estado do Rio Grande do Sul: Fonte: (CORDEIRO et al., 2017).

I.2.2. Utilização do sensoriamento remoto para estimativas de safras agrícolas e mapeamento do uso do solo e cobertura vegetal

Atualmente o sensoriamento remoto tem se mostrado uma ferramenta importante para as estimativas de safras agrícolas, devido à facilidade de obtenção de dados, como por exemplo, a aquisição de imagens de satélites de forma cada vez mais rápida e muitas vezes distribuída de forma gratuita. O uso do sensoriamento remoto na agricultura se deve principalmente pelo grande potencial para obtenção de informações sobre: estimativa de produção agrícola, estimativa de área cultivada, vigor vegetativo das culturas e manejo agrícola em escala regional e local.

A utilização do sensoriamento remoto na agricultura em escala global teve seu uso de forma mais intensa a partir do lançamento dos primeiros satélites ambientais a partir da década de 70. Os Estados Unidos foram pioneiros no uso do sensoriamento remoto para estudo de áreas agrícolas. Com o lançamento, em 1972, do Earth Resource Technological Satellites (ERTS-1), posteriormente denominado Landsat 1, foi estabelecido o que certamente foi o programa mais bem-sucedido de sensoriamento remoto para fins de mapeamento da vegetação e monitoramento sistemático da superfície terrestre (SALOVAARA et al., 2005; WOODCOCK et al., 2001). Através deste programa passou-se a utilizar os dados do sensoriamento remoto orbital para o aprimoramento dos métodos de amostragem, o que contribuiu para demonstrar o valor das imagens, tanto para a construção dos painéis amostrais, como para o desenvolvimento de um estimador de área cultivada (ALLEN & HANUSCHAK, 1998).

Em 1974 os Estados Unidos deram início ao LACIE (*Large Area Crop Inventory Experiment*) com o objetivo de assimilar a tecnologia de sensoriamento remoto, aplicar a metodologia dos levantamentos por amostragem para monitorar a produção de trigo ao redor do mundo e demonstrar a praticidade técnica e financeira de um sistema de monitoramento agrícola global (HOUSTON & HALL, 1984). Na Europa a partir do esforço conjunto de vários países em 1989, surgiu o projeto MARS (*Monitoring Agriculture with Remote Sensing*), cujos objetivos iniciais eram distinguir, identificar e medir a área das culturas agrícolas mais importantes e, em seguida, estimar a produção a tempo de permitir a tomada de decisões (KLERSY, 1992).

No âmbito nacional na década de 90, o Brasil e a China firmaram um acordo de cooperação tecnológica para a produção de uma série de satélites de observação da Terra, conhecido como CBERS (*China-Brazil Earth Resources Satellite*). Em 1999 é lançado o CBERS 1, onde o país entrou para o seleto grupo de países detentores da tecnologia. Munido de três sensores concebidos para o monitoramento da cobertura vegetal em diferentes escalas, entre eles, destaca-se o CCD (*Charge Coupled Device*), com 20 m de resolução, uma banda pancromática e bandas no azul, verde, vermelho e infravermelho próximo (EPIPHANIO, 2005). Vários estudos foram desenvolvidos utilizando estes satélites, entre os quais destacam-se o monitoramento da vegetação na floresta amazônica e a detecção e monitoramento das atividades agrícolas em regiões no Brasil (RUDORFF & SUGAWARA, 2007; JESUS & EPIPHANIO, 2010)

Em dezembro de 2014 foi lançado o CBERS 4, que está em fase de calibração dos sensores, o satélite conta com um módulo de carga útil de quatro câmeras, dentre elas, destaque para o uso agrícola da Câmera Multiespectral Regular – MUX, com 20 metros de resolução espacial e 4 bandas espectrais, incluindo o infravermelho próximo. Essas câmeras possuem desempenhos geométricos e radiométricos melhorados, em relação aos seus antecessores.

Com relação a projeto e estudos no Brasil em monitoramento e previsão de safras agrícolas, destaques para algumas iniciativas importantes como o Projeto Geosafra e o Projeto MAPAGRI (Metodologia para o Monitoramento da Atividade Agrícola Brasileira). Diversos outros projetos de pesquisa ou mesmo operacionais tem sido desenvolvidos no Brasil, mas os projetos GeoSafras e MAPAGRI têm em comum o fato de desenvolver atividade em rede de instituições e apresentarem abrangência nacional. A partir de 2003 teve início o Projeto GeoSafras, liderado pela Companhia Nacional de Abastecimento (Conab), contando com a cooperação e união de esforços de diversas instituições de ensino e pesquisa e muitas outras

entidades de apoio e extensão rural, que em conjunto tem trabalhado para aprimorar as estimativas de safras brasileiras, possibilitando a aplicação em escalas regionais e nacionais. O Projeto tem focado prioritariamente alguns produtos, tais como: café, cana-de-açúcar, soja, arroz e milho e, atualmente em uma segunda fase, está operacionalizado dentro da Conab.

Importante destacar um novo projeto chamado MapBiomias, que utiliza imagens históricas do satélite Landsat, com resolução de 30 metros, aborda o mapeamento anual da cobertura e uso do solo em todo o território nacional, uma iniciativa que envolve uma rede colaborativa com especialistas de diversas instituições do País. O projeto utiliza classificadores automatizados desenvolvidos e operados a partir da plataforma Google Earth Engine. Atualmente o projeto está na fase 2, cobrindo o período de 2000-2016, o objetivo com a última etapa do projeto (etapa 3) deverá cobrir o período de 1985 – 2017, com previsão de finalizar em 2018, irá ser uma importante ferramenta de análise das mudanças da cobertura e uso do solo ao longo do anos para todo o País, em especial o Bioma Pampa, que é o foco deste estudo, mais informações no site <http://mapbiomas.org/>.

I.2.3. Modelagem da dinâmica da paisagem: Modelos de simulação baseados em Autômato Celular

Modelos de simulação se tornaram um promissor campo de pesquisa, recebendo especial atenção por parte de pesquisadores de diversas áreas. A importância da simulação advém de sua capacidade de multiplicar a nossa imaginação individual, permitindo que grupos de pessoas compartilhem, através de uma experiência comum, modelos mentais de uma certa realidade, independente de sua complexidade (SOARES-FILHO et al. 2001).

Alguns tipos de modelos de simulação são representados pelos métodos espaciais ou modelos de paisagem, que simulam mudanças dos atributos do meio-ambiente através do território geográfico. O uso de tais modelos visa auxiliar o entendimento dos mecanismos causais e processos de desenvolvimento de sistemas ambientais, e assim determinar como eles evoluem diante de um conjunto de circunstâncias, que são as condições circunjacentes ou de contorno e representam cenários traduzidos por diferentes quadros sócio-econômicos, políticos e ambientais.

Modelos espaciais de simulação têm se tornado um importante instrumento de auxílio ao ordenamento territorial, considerando que qualquer planejamento regional ou estratégia de conservação ambiental que não leve em conta o fator tempo está fadado ao insucesso. Além disso, modelos de simulação podem ser usados para promover ideias comuns, como por exemplo das mudanças globais e suas consequências ao planeta. Portanto, modelos espaciais

de simulação, que realisticamente reproduzem padrões espaciais de mudanças, são hoje requisitos para o entendimento e avaliação de complexas questões ambientais em escalas local, regional e global (SOARES-FILHO et al. 2001).

Conforme Freitas (2013) o estudo da dinâmica da paisagem e seus processos associados pode ser realizado, em parte, com a utilização de modelos de mudanças de uso e cobertura da terra, fator fundamental para a apreciação da dinâmica e dos processos da paisagem. Estes modelos utilizam métodos, incluindo concepções dos estudos da complexidade (por exemplo, autômatos celulares, fractais, teoria hierárquica e outros), para a simulação de cenários baseados em variáveis físicas, ecológicas e sociais e com o fim de aplicação na tomada de decisões relacionada ao planejamento territorial (COSTANZA; VOINOV, 2004)

Autômatos celulares são compostos por conjuntos de células que imprimem determinados movimentos, assemelhando-se a seres animados. Em geral, o mecanismo de autômatos celulares consiste num arranjo n-dimensionais de células, no qual o estado de cada célula depende de seu estado prévio e de um conjunto de regras de transição, de acordo com um arranjo específico de uma certa vizinhança, sendo todas as celas atualizadas simultaneamente a passos discretos de tempo. O algoritmo que faz as células interagir localmente é conhecido como regra local do autômato celular (SIRAKOULIS et al., 2000).

Os autômatos celulares foram desenvolvidos no princípio da computação digital por Jonh Von Neumann e Alan Turing e utilizados em diversas aplicações nos mais diferentes campos científicos (WOLFRAN, 2002). De modo mais preciso, os autômatos celulares podem ser definidos por quatro características principais (BATTY, 2000): a) são células com relações espaciais de vizinhança e proximidade, b) cada célula apresenta um único estado em cada instante de tempo e o conjunto de estados define os atributos do sistema, c) o estado de cada célula depende dos estados e configurações das células vizinhas, d) existem regras de transição uniformes e locais que controlam as mudanças de cada célula.

Talvez o exemplo mais simples e característico de autômato celular seja o “jogo da vida”. Tendo sido desenvolvido pelo matemático John Conway em 1970, foi assim denominado devido à analogia com ascensão, queda e alternância de sociedades de organismos. John Conway escolheu, como regras locais de transição, arranjos espaciais que evitassem que colônias de células morressem ou expandissem rapidamente. Dessa forma, ele pertence à classe de jogos de simulação que se assemelham a processos da vida real, sendo um belo exemplo de sistemas auto-organizáveis.

Modelos de simulação espacial baseados em autômatos celulares estão disponíveis em *softwares* comerciais e também em *softwares* livres de sistemas de informações geográficas.

Como exemplo de softwares comerciais o IDRISI (EASTMAN, 2001), devido à sua facilidade de implementação, habilidade em mimetizar formas e capacidade de serem readaptados para reproduzir vários tipos de fenômenos espaciais, como em trabalhos com queimadas (KARAFYLLIDIS & THANAILAKIS, 1997; HARGROVE et al., 2000), difusão de epidemia (SIRAKOULIS et al., 2000), dinâmica florestal (LETT et al., 1999) crescimento urbano (WHITE et al., 2000; CLARKE & GAYDOS, 1998, ALMEIDA et al., 2003), e mudanças de uso e cobertura do solo (WU, 1998; WHITE et al., 2000; SOARES-FILHO et al., 2002, SOARES-FILHO et al., 2003).

Como exemplo de modelo de simulação espacial do tipo autômato celular existe o *software* livre DINAMICA (SOARES-FILHO et al., 2002, SOARES-FILHO et al., 2003).

I.2.4. Classificação digital de séries temporais para mapeamento do uso do solo

As primeiras classificações de uso e cobertura do solo baseavam-se em trabalhos de campo. A partir da década de 50, um grande número de pesquisadores em várias partes do mundo dedicou-se à identificação detalhada de culturas agrícolas em fotografias aéreas (STEINER, 1970). Em meados da década de 70 o monitoramento das mudanças do uso do solo começou a ser detectado e analisado através das imagens de satélite por meio de técnicas de classificação.

A análise e a quantificação dos padrões de mudanças de uso do solo, através de dados advindos do sensoriamento remoto, como por exemplo, imagens de satélite, permite realizar o mapeamento do uso do solo e da cobertura vegetal. Como exemplo, pode-se destacar o uso dos índices de vegetação (EVI e NDVI), em diferentes escalas temporais e espaciais, com dados provenientes de diferentes sensores orbitais, os quais atualmente já encontram-se disponíveis para pesquisas de forma gratuita. Conforme Silva (2008), embora vários pesquisadores envolvidos na detecção de mudanças do uso do solo utilizem os dados de sensoriamento remoto de forma qualitativa, através da análise de mapas de cobertura e uso do solo gerados por processos de classificação, aspectos do arranjo e distribuição espacial dos tipos de uso do solo podem ser quantificados através de medidas da paisagem (*landscape metrics*) e índices de vegetação (NDVI ou EVI).

Paralelamente, os sistemas de informação geográfica (SIG) surgiram como uma ferramenta que possibilita a manipulação de dados de diversas origens, como em estudos do meio ambiente, agricultura e com novas ferramentas e novos módulos de modelagem espacial para pesquisas de previsão ou simulação de determinados fenômenos ou no apoio a decisões de planejamento (DIAS, 2011). As técnicas de processamento digital de imagens buscam detectar

e identificar fenômenos importantes em determinada cena, como por exemplo, a detecção de mudanças do uso do solo. Neste sentido, o sensoriamento remoto é especialmente útil no monitoramento da atividade do homem através do tempo, indicando um caminho promissor para o desenvolvimento sustentável e para as decisões governamentais (JENSEN, 2009).

A Figura 3 traz um exemplo de mudança do uso do solo no Bioma Pampa, com a utilização de imagens Landsat é possível identificar a conversão da vegetação campestre em áreas agrícolas com o cultivo de soja (verde claro na imagem B) num intervalo de 14 anos (2001-2014). Uma das chaves de identificação de espécies vegetais é o período de aquisição das imagens de satélite, no exemplo da Figura 3, é possível identificar as áreas de cultivo de soja, porque a aquisição da imagem foi em fevereiro, mês de máximo vigor vegetativo da cultura, onde possui máxima reflectância na banda do infravermelho próximo. Portanto, séries temporais extraídas de imagens de satélite podem prover informações não somente sobre a área de cada classe mapeada, mas também fornecer indicações sobre crescimento e desenvolvimento da cobertura vegetal, que podem ser elementos chave na discriminação espectral de diferentes espécies vegetais (APAN e POTGIETER, 2002). A utilização de imagens adquiridas em diferentes datas permite, portanto, diferenciação dos alvos em função da variação da resposta espectral dos mesmos ao longo do tempo, melhor representando a variabilidade espectro-temporal de alvos agrícolas e florestais (FREITAS et al., 2007).

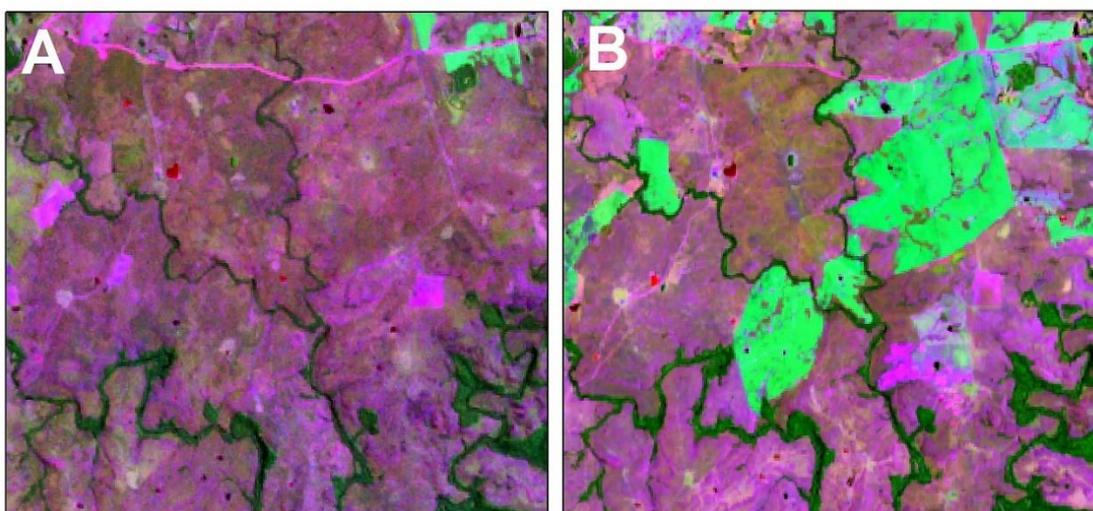


Figura 3: Imagem Landsat 5/TM de 2001 (A) Landsat 8/OLI 2014 (B) ilustrando mudanças de uso do solo, áreas campestres convertidas em áreas agrícolas com o cultivo de soja (verde claro na imagem B), nas proximidades do município de Tupanciretã. Fonte: Elaborado pelo autor.

Existem diversos estudos que utilizaram como base o atributo espectro-temporal para o mapeamento do uso do solo, em especial do sensor MODIS (CLARK et al 2010; COLDITZ et al 2012; ZHOU et al 2013), e mais especificamente em áreas agrícolas (CHANG et al., 2007;

EIPHANIO et al., 2010; VICTORIA et al., 2012; JOHANN et al., 2012; BROWN et al., 2013; SANTOS et al., 2014). Entre os métodos de classificação de imagens podemos citar as redes neurais, máquina de vetor suporte e por árvore de decisão (AD).

I.2.4.1. Arvore de decisão e algoritmo C4.5

Uma abordagem que vem ganhando bastante espaço em trabalhos de mapeamento do uso do solo é a classificação por AD. Os classificadores por AD apresentam vantagens para a classificação do uso do solo e cobertura vegetal, como por exemplo, a facilidade de interpretação dos resultados, o baixo tempo de processamento, a capacidade do modelo trabalhar com dados medidos em distintas escalas, o fato de não demandar distribuição normal dos dados e a capacidade de processar as relações não lineares entre os preditores e as classes de cobertura da terra (FRIEDL & BRODLEY, 1997). Estudos comprovam a eficácia desse classificador em dados de sensoriamento remoto, como no trabalho de Friedl & Brodley (1997) que comparam AD com os algoritmos de máxima verossimilhança e com a função discriminante linear, os resultados apontaram as maiores acurácias para o classificador AD.

Estudos utilizando árvores de decisão têm se mostrado favoráveis no mapeamento do uso e cobertura do solo, como o mapeamento da cobertura global terrestre utilizando dados MODIS (FRIEDL et al., 2002), na identificação de culturas utilizando índices de vegetação (PEÑA-BARRAGÁN et al., 2011), no mapeamento de cana-de-açúcar em grandes áreas (VIEIRA et al., 2012) e em estudo de detecção de desmatamento na Amazônia (ZANOTTA, 2014). A ideia básica do algoritmo é que na árvore de decisão binária, sucessivas perguntas vão sendo feitas a respeito do dado, em suas diferentes camadas de informação, até que se chegue uma conclusão de classe. Os locais onde as perguntas são feitas são conhecidos como nós, enquanto os destinos correspondentes às classes são conhecidos como folhas. Na árvore de decisão, em cada nó deve ser associado o atributo preditivo que se supõe ser o mais informativo entre os atributos considerados no caminho a partir da raiz.

Os três principais algoritmos para indução de árvores de decisão, são eles: ID3 (QUINLAN, 1986), C4.5 (QUINLAN, 1993) E CART (BREIMAN et al., 1984). Na literatura, existem novos algoritmos para indução de árvores de decisão, inclusive alguns que fogem do algoritmo básico TDIDT. Como exemplos, podemos mencionar: NBTree (KOHAVI, 1996), ADTree (FREUND & MASON, 1999), LMT (LANDWEHR et al., 2005) e BFTree (SHI, 2007).

No trabalho vamos abordar apenas o algoritmo C4.5 que foi utilizado no trabalho. O algoritmo C4.5 representa uma significativa evolução do ID3. As principais contribuições em

relação ao ID3 são: Lida tanto com atributos categóricos (ordinais ou não-ordinais) com atributos contínuos. Para lidar com atributos contínuos, o algoritmo C4.5 define um limiar e então divide os exemplos de forma binária: aqueles cujo valor do atributo é maior que o limiar e aqueles cujo valor do atributo é menor ou igual ao limiar.

Trata valores desconhecidos e permite que os valores desconhecidos para um determinado atributo sejam representados como '?', tratando esses valores de forma especial. Esses valores não são utilizados nos cálculos de ganho e entropia. Utiliza a medida de razão de ganho para selecionar o atributo que melhor divide os exemplos. Essa medida se mostrou superior ao ganho de informação, gerando árvores mais precisas e menos complexas.

O algoritmo também apresenta um método de pós-poda das árvores geradas, fazendo uma busca na árvore, de baixo para cima, e transforma em nós folha aqueles ramos que não apresentam nenhum ganho significativo.

I.2.5. Redes Neurais Artificiais

Redes neurais artificiais são técnicas que, através de procedimentos matemáticos específicos (tais como: otimização discreta, minimização de erros, clusterização de vetores), procuram resolver problemas complexos de “maneira inteligente”, ou seja, similarmente à maneira pela qual o cérebro humano resolveria (MATHER, 1999; SCHOWENGERDT, 1997). Ainda conforme Haykin (2001) uma rede neural artificial (RNA) é definida como um processador massivo e paralelamente distribuído, constituído de unidades de processamento simples, que tem a capacidade para armazenar conhecimento experimental e torná-lo disponível para uso.

A unidade básica do cérebro é o neurônio, que é composto por dendritos, axônio, corpo celular e sinapse, um neurônio é excitado quando recebe sinais de outros neurônios através dos dendritos. Se ativado, caso o estímulo recebido ultrapasse seu limiar de excitação, irá disparar um impulso para outros neurônios através dos axônios. Entre o axônio e os dendritos existe um ponto de contato chamado sinapse onde não existe contato físico, mas sim uma liberação temporária de neurotransmissores; esta liberação ocorre em função do impulso elétrico disparado. Com a existência de uma nova diferença de potencial, um novo impulso elétrico é transmitido para o corpo celular sucessivo, dando sequência à propagação (HAGAN et al., 1996).

Podemos fazer uma analogia de forma bem simplificada do funcionamento de transmissão e processamento de um sinal por uma RNA com o funcionamento de um neurônio biológico. A Figura 4 representa um neurônio artificial que é um modelo matemático de forma

análoga ao funcionamento de um neurônio biológico, descrito anteriormente. Podemos descrever que o neurônio K recebe os sinais de $X_1, X_2, X_3, \dots, X_n$ e que esses sinais são ponderados pelos pesos $W_{1j}, W_{2j}, W_{3j}, \dots, W_{nj}$ de maneira excitatória ou inibitória. Ainda neste processo ocorre a entrada do bias (θ_j), cuja função é aumentar ou diminuir a entrada líquida na função de ativação. Desta maneira, as entradas no neurônio K são ponderadas pelos respectivos pesos e somadas juntamente com o bias, o resultado dessa soma é aplicado à função de ativação que determina o sinal de saída do neurônio.

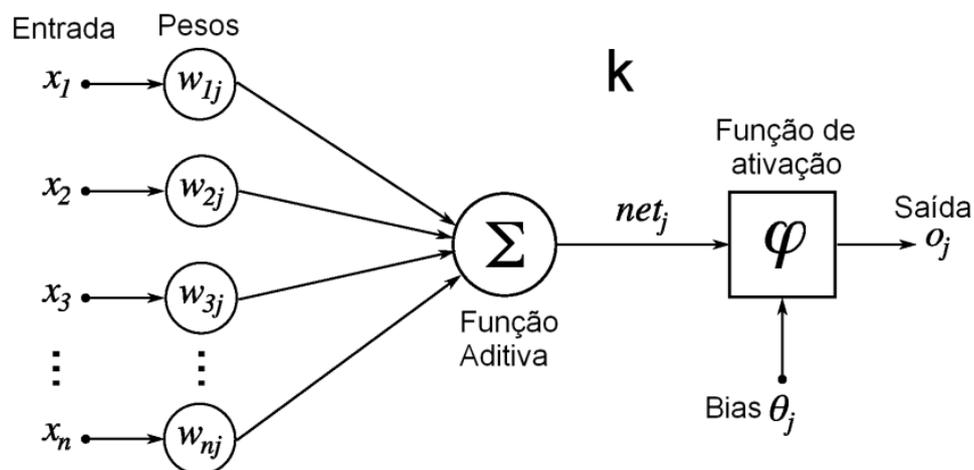


Figura 4: Modelo de um neurônio artificial.
Fonte: Adaptado de HAYKIN (2001).

Existem diversos modelos de redes neurais, como por exemplo, as redes *Perceptrons* de Múltiplas Camadas (MLP) que são constituídas por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (Figura 5). A alimentação dessas redes é progressiva, onde o sinal é propagado camada por camada e processado por funções matemáticas (HAYKIN, 2001). As redes MLP foram desenvolvidas para resolver problemas complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico (LIPMANN, 1987; HAYKIN, 2001). Em sensoriamento remoto as redes neurais MLP têm sido usadas amplamente, principalmente como classificadores de imagens digitais (KANELLOPOULOS & WILKINSON, 1997; ATKINSON & TATNALL, 1997).

Como classificadores de imagens digitais, as redes neurais podem ser aplicadas no nível de *pixel* ou de regiões, considerando características espectrais e diversas outras fontes de dados, tais como: declividade, orientação de encostas, altitude, características da rede de drenagem, textura, índice de vegetação, entre outras. As Redes Neurais podem ser também utilizadas em uma etapa de pré-processamento (como por exemplo, para a segmentação de

imagens multiespectrais), na etapa de classificação propriamente dita ou até mesmo durante a etapa pós-classificatória, como filtros passa-baixa (HAYKIN, 2001).

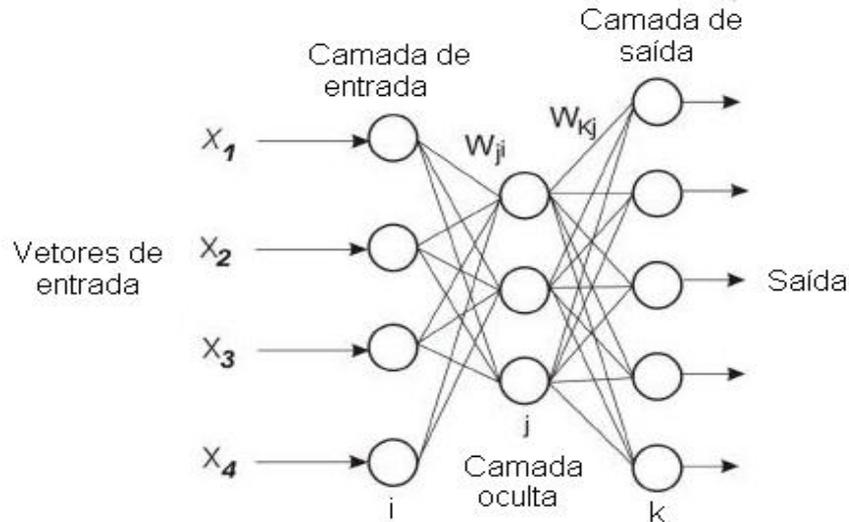


Figura 5: Rede de múltiplas camadas.
Fonte: Adaptada de Bishop (1995).

A classificação de imagens digitais pela técnica de redes neurais é naturalmente adequada, já que suas características intrínsecas possibilitam o seu emprego tanto para a classificação de uma única cena, quanto para a previsão de séries temporais. No entanto, a definição da arquitetura da rede e das regras de aprendizado é bastante trabalhosa e subjetiva. As redes MLP apresentam capacidade de aproximação universal, ou seja, podem aproximar virtualmente qualquer função de interesse para qualquer grau de precisão desejado, sempre que for possível definir uma taxa de convergência aceitável para o algoritmo de treinamento, avaliada pelos erros entre os resultados preditos e esperados (TSO e MATHER, 2001).

1.2.6. Sensores orbitais e a detecção de mudanças do uso do solo e cobertura vegetal.

Os sensores orbitais apresentam características fundamentais para a aplicação nos estudos sobre detecção de mudanças do uso do solo e cobertura vegetal, como a capacidade de observação e monitoramento de forma sinóptica, dinâmica e em diferentes escalas espaço-temporais que possibilita quantificar as taxas de conversão e modificação do uso do solo e cobertura vegetal, avaliar as atividades antrópicas e caracterizar os diferentes sistemas de uso da terra (TURNER II et al., 2007). Desta forma, as imagens dos sensores orbitais são adequadas para a quantificação das mudanças, uma vez que fornecem medidas consistentes e repetíveis em escala regional (KENNEDY et al., 2007; QIN et al., 2006).

Os principais métodos e técnicas aplicados ao uso do solo e cobertura vegetal envolvem a classificação de imagens orbitais por técnicas pixel-a-pixel, árvore de decisão, redes neurais

ou orientada a objetos, análises multitemporais de imagens e produtos derivados (por exemplo, índices de vegetação) para detecção de mudanças e a geração de indicadores sintéticos de fragmentação da paisagem (métricas da paisagem) baseados na classificação de imagens (SALINERA, 2002; LANG & BLASCHKE, 2009).

Dentro dos sensores orbitais disponíveis de forma gratuito para a comunidade científica, os mais utilizados em trabalhos de detecção de mudanças do solo e cobertura são: A série Landsat e o sensor MODIS. A série Landsat (*Land Remote Sensing Satellite*), iniciou em 1972 com o lançamento do satélite ERTS-1. Ela teve sequência com os Landsat 2,3,4 e sobretudo com o 5 e 7 (USGS, 2014). Em 2013 foi lançado o Landsat 8, que atualmente está em atividade. O principal objetivo do sistema Landsat foi o mapeamento multiespectral em alta resolução da superfície da Terra. Algumas características da série Landsat são importantes de serem mencionadas, o Landsat 8 conta com uma resolução espacial de 15 metros na banda pancromático (Banda 8); na multiespectral 30 metros (bandas 1-7 e 9) e na banda do termal conta com uma resolução de 100 metros (bandas 10 e 11). Possui uma resolução temporal de aproximadamente 16 dias, dependendo da latitude.

As imagens Landsat-TM representam registros valiosos e contínuos da superfície terrestre nas últimas 3 décadas, o que representa uma riqueza de informações para identificar e monitorar mudanças no uso do solo e cobertura vegetal em escala global (CHANDER et al., 2009; EL BASTAWESY, 2014). Destaque para alguns trabalhos que utilizaram dados Landsat para realização de análises precisas e confiáveis de detecção de mudanças do uso do solo e cobertura vegetal (MAS, 1999; LU et al., 2004; JENSEN, 2005; SCHEIDT et al., 2008; EL BASTAWESY et al., 2013; WHITE et al., 2014; HERMOSILLA et al., 2015).

Outro sensor orbital muito utilizado em trabalhos que envolvem a detecção de mudanças de uso do solo é o sensor MODIS (*MODerate Resolution Imaging Spectroradiometer*). Este sensor está a bordo dos satélites *Terra* e *Aqua*, lançados pela NASA em 18 de dezembro de 1999 e 4 de maio de 2002, respectivamente. Estes Satélites fazem parte do programa EOS (*Earth Observing System*), formado por diversos países, constituindo uma série de plataformas para monitoramento terrestre em várias áreas de conhecimento em diversas escalas (EODIS, 2013).

O objetivo principal é fornecer uma série de observações globais da superfície terrestre, oceano e atmosfera nas regiões do visível e do infravermelho do espectro eletromagnético, cobrindo a Terra a cada 2 dias. O sensor MODIS possui alta sensibilidade radiométrica (12 bits) em 36 bandas espectrais contidas no intervalo de 0,4 a 14,4 μm do

espectro eletromagnético. Duas bandas são adquiridas na resolução espacial de 250 m, outras cinco bandas na resolução de 500 m e as demais 29 bandas na resolução de 1 km.

Como forma de disponibilizar os dados para diferentes usuários, além das imagens, foram desenvolvidos produtos específicos para estudos voltados da atmosfera, do oceano e da superfície terrestre. Com relação à superfície terrestre, os produtos MODIS fornecem base de dados para estudos relativos ao uso e ocupação do solo, além de permitirem monitorar a cobertura vegetal do planeta, possibilitando identificar quais as mudanças da vegetação e suas relações com o clima e tempo (JUSTICE et al., 2002).

Com relação aos dados voltados para a superfície terrestre denominada MODLAND, contém o produto MOD13Q1 referente aos índices de vegetação NDVI (*Normalized Difference Vegetation Index*) e EVI (*Enhanced Vegetation Index*). Eles são produzidos globalmente com resolução de 1 km, 500 m e 250 m, em composições de imagens ou mosaico de 16 ou 8 dias (EODIS, 2013). O algoritmo seleciona o pixel de melhor qualidade em relação à geometria de visada e menor interferência atmosférica dentre todas as passagens do período, que então é utilizado na geração das imagens compostas.

Atualmente a série temporal do sensor MODIS, possui aproximadamente 18 anos de dados da superfície terrestre, dentro das diversas aplicações com os dados do sensor, estão os estudos de detecção e monitoramento do uso do solo e cobertura vegetal, podemos destacar como um dos primeiros estudos a nível global de mapeamento do uso do solo (FRIEDL et al., 2002), em mudanças de uso e ocupação do solo (GIRIRAJ et al., 2008; LIU et al., 2011; FENSHOLT & PROUD, 2012), no monitoramento agrícola (WARDLOW & EGBERT, 2008; ALCANTARA et al., 2012; ZHOU et al., 2013).

Importante destacar que o uso de dados orbitais do Landsat (a cada 16 dias) apresenta algumas limitações devido à dificuldade de aquisição de imagens livres da cobertura de nuvens, impedindo a aquisição de várias imagens ao longo do ano, impedindo a interpretação e mapeamento de algumas classes de uso do solo e cobertura vegetal, principalmente as classes vegetais que apresentam padrões espectrais distintos devido a sazonalidade climática (PARUELO, 2001; ROSEMBACK et al., 2010; KUPLICH et al., 2013). Uma alternativa é a utilização de dados do sensor MODIS, que adquire imagens da superfície a cada 1-2 dias (JUSTICE et al., 2002), já que suas séries temporais possuem uma cobertura temporal contínua e apropriada para caracterizar as dinâmicas de cada tipo de paisagem.

Uma das dificuldades no mapeamento das classes de uso do solo e cobertura vegetal com dados orbitais é a correta classificação de algumas classes, como por exemplo, áreas urbanas de outros usos do solo (rochas, solo exposto e corpos d'água) que possuem similaridade

espectral. Uma das alternativas encontradas para a correta classificação é a utilização do sensor OLS do *Defence Meteorological Satellite Program* (DMSP). São imagens de iluminação noturna e conta com uma resolução espacial de 550 metros. Diversos trabalhos já utilizam os dados do DMSP-OLS para estudos de mapeamentos de áreas urbanas (IMHOFF et al., 1997; ELVIDGE et al., 2001; LO 2002; SMALL et al., 2005).

A seguir será discutido sobre os dados do índice de vegetação do sensor MODIS e os dados do DMSP-OLS aplicados a estudos de detecção de mudanças do uso do solo e cobertura vegetal.

1.2.7.1. Imagens de Índices de Vegetação do sensor MODIS

Os índices de vegetação são medidas radiométricas adimensionais e podem ser utilizados com o intuito de realçar a contribuição das propriedades da vegetação e permitir comparações espaciais e temporais da atividade fotossintética e das variações estruturais do dossel. Estes índices estão correlacionados com o índice de área foliar, a biomassa e com a percentagem de cobertura da vegetação e permitem monitorar as variações sazonais, interanuais e em longo prazo da vegetação no que se refere a parâmetros estruturais, fenológicos e biofísicos (HUETE et al., 2002).

Dentro os produtos derivados do MODIS existem dois índices de vegetação: o NDVI e o EVI. Esses dois índices complementam em estudos globais de vegetação, tanto na detecção de mudanças na vegetação como na extração de parâmetros biofísicos do dossel. Enquanto o NDVI é mais sensível à clorofila, o EVI responde mais às variações estruturais do dossel, incluindo índice de área foliar, tipo de dossel, fisionomia da planta e arquitetura do dossel (GAO et al., 2000; HUETE et al., 2002).

A seguir será apresentada uma breve descrição do índice de vegetação EVI. O EVI (Índice de Vegetação Melhorado), proposto por Huete et al. (1994), foi desenvolvido para melhorar o sinal da vegetação, já que ele reduz a influência do solo e os efeitos atmosféricos. O EVI pode ser calculado através da Equação (01).

$$EVI = G \frac{\rho_{IVP} - \rho_{vermelho}}{\rho_{IVP} + C1 \times \rho_{vermelho} + C2 \times \rho_{azul} + L} \quad (01)$$

Onde: G é o ganho; ρ é a reflectância de superfície corrigida ou parcialmente corrigida da absorção das bandas do infravermelho próximo, do vermelho e do azul, respectivamente; L é o fator de ajuste do substrato do dossel; C1 e C2 são coeficientes da resistência de aerossóis,

que utiliza a banda do azul para atenuar a influência dos aerossóis na banda vermelha (KAUFMAN & TANRÉ, 1992). Os coeficientes adotados no algoritmo do EVI/MODIS são: $L=1$, $C1=6$, $C2=7,5$ e ganho $G=2,59$ (HUETE et al., 1994)

O índice de vegetação EVI foi idealizado para realçar o sinal da vegetação através da otimização na sensibilidade em regiões com altos valores de biomassa e permite realizar um melhor monitoramento da vegetação através da redução dos efeitos de substrato do dossel e da influência da atmosfera (HUETE et al., 1994; HUETE et al., 1997). Em áreas que possuem maior densidade de biomassa, o EVI apresenta melhor sensibilidade às alterações no dossel em relação ao NDVI. O uso dos dados de EVI surge como alternativa ao efeito de saturação do NDVI.

A grande vantagem da utilização dos produtos MOD13Q1 referentes aos índices de vegetação NDVI e EVI, são suas composições de imagens ou mosaico de 16 dias ou 8 dias (com a utilização simultânea das duas plataformas TERRA e AQUA). Nesta perspectiva, o uso dos índices de vegetação de séries temporais do Sensor MODIS, pode ser considerado de grande valia para a detecção rápida de alterações do uso do solo e da cobertura vegetal, em especial pela faixa relativamente larga de imageamento (2.330 km) e sua alta resolução temporal (1-2 dias) (JUSTICE et al., 2002). Neste aspecto, o desenvolvimento dos índices de vegetação, elaborados com o propósito de explorar as propriedades espectrais da vegetação, possibilitou a inferência de parâmetros biofísicos referentes à vegetação de extensas áreas da superfície da Terra, bem como de suas respostas frente à influência antrópica (GINCIENE & BITENCOURT, 2011).

Desta forma, para estudos em escala regional, para detecção e monitoramento do uso do solo em diversos biomas, é possível realizar análises das mudanças no uso do solo e da cobertura vegetal por meio dos índices de vegetação, o quais são capazes de evidenciar variações sazonais, interanuais e de longo tempo de parâmetros estruturais, fenológicos e biofísicos da vegetação (HUETE et al., 2002; CORREIA et al., 2006).

I.2.7.2. Imagens Noturnas DMSP-OLS para classificação de áreas urbanas.

As imagens noturnas do *Defence Meteorological Satellite Program* (DMSP) fazem parte de um programa de satélites que entrou em operação na década de 60. Teve início para fins militares com seus dados destinados a defesa do território, mais tarde seus dados foram disponibilizados a comunidade civil, com pesquisas voltadas para as áreas de meteorologia e geofísica. Atualmente o programa está sob responsabilidade do *Air Force Space And Missile Systems Center* (SMC) (USA, 2015). O satélite tem como característica imagear objetos que

refletem pouca luz, possuem órbitas sol-síncrona, quase polar, com altitude de 830 km. Entre os sensores disponíveis na série de satélites destacam-se:

- OLS – *Operational Linescan System*
- SSM/I – *Microwave Imager*
- SSMT/2 – *Atmospheric Water Vapor Profiler*
- SSJ/4 – *Precipitating Electron and Ion Spectrometer*
- SSM/T – *Atmospheric Temperature Profiler*
- SSIES – *Ion Scintillation Monitor*
- SSM – *Magnetometer*

Entre estes sensores, destaca-se para fins de detecção de fontes de iluminação, os dados do sensor OLS, que podem ser obtidos através do *National Oceanic and Atmospheric Administration* (NOAA) e *National Geophysical Data Center* (NGDC). O sensor OLS coleta informações na faixa do visível e infravermelho, numa largura de faixa de 3000 km. A resolução temporal do sensor é duas vezes ao dia, com combinação dia/noite e amanhecer/anoitecer. Os telescópios são calibrados a bordo em cada varredura e os pixels do visível têm valores relativos. As imagens utilizadas são do tipo *Stable Lights*, são imagens compostas por uma média anual das imagens noturnas colhidas pelo sensor. Dessa forma são eliminadas todas as fontes eventuais de iluminação, mantendo somente as fontes de iluminação permanentes. A iluminação permanente é característica de áreas urbanas, desta forma é possível identificar e mapear essas áreas através do sensor OLS.

Diversos trabalhos utilizaram imagens noturnas do DMSP-OLS para identificar e mapear áreas urbanas, inclusive mapear sua dinâmica de crescimento ao longo do tempo. No entanto, existem alguns problemas relacionados com a saturação dos dados do sensor OLS em áreas urbanas, um problema que afeta significativamente a precisão do mapeamento nesse tipo de alvo (ELVIDGE et al., 2007). Métodos baseados na definição de limiares para classificação da área urbana, podem não só superestimar a extensão da área urbana em torno das grandes cidades devido ao efeito “*blooming*”, mas também pode omitir os pequenos núcleos urbanos (HENDERSON et al., 2003; SMALL et al., 2005).

Para resolver esse problema de saturação do sensor OLS Lu et al. (2008) propuseram um método que combina os dados de outros sensores para identificar de forma mais refinada a área urbana, já que a resolução espacial do sensor OLS é de 550 m e existe ainda o efeito da saturação do brilho noturno. Para melhorar a performance diversos estudos combinam dados de outros sensores com melhor resolução espacial com os dados do sensor OLS, como por

exemplo, dados de índice de vegetação do sensor MODIS ou da série Landsat. Podemos destacar os trabalhos que utilizaram uma combinação de imagens de iluminação noturna (OLS) com índices de vegetação NDVI do sensor MODIS (LU et al. 2008; CAO et al. 2009; LIN et al. 2014).

I.2.8. Principais causas das mudanças do uso do solo e cobertura vegetal

Ao longo dos últimos anos, estudos com a temática de modelagem da dinâmica dos processos de uso do solo e cobertura vegetal tem se tornado um dos principais objetivos de pesquisa sobre mudanças ambientais. (LAMBIN et al., 1997; OLIVEIRA et al 2014). Desde os anos de 1980, tem-se despendido um enorme esforço de pesquisa no sentido de tentar identificar e explicar os fatores que causam mudanças no uso do solo, principalmente o desmatamento. (ALLEN & BARNES, 1985; LAMBIN, 1994; SPONSEL et al., 1996; MATHER & NEEDLE, 2000; GEIST & LAMBIN, 2001; FREITAS et al 2013).

Basicamente existem dois tipos de abordagem nos estudos realizados. A primeira abordagem tenta identificar um único fator como causa principal da conversão de áreas florestais em outros usos do solo. Esta abordagem tem privilegiado o crescimento populacional e a pobreza, em particular dos pequenos agricultores itinerantes, como as principais causas do desmatamento (ALLEN & BARNES, 1985; MATHER & NEEDLE, 2000). Já o outro tipo de abordagem predominantes considera que as causas do desmatamento são tão diversas, complexas e específicas a cada situação particular, que não é possível identificar padrão comum de causas da conversão das áreas florestais em outros usos do solo (RUDEL & ROPER, 1996).

Geist e Lambim (2001) construíram uma tipologia, na qual a enorme gama de causas e vetores de desmatamento foi classificada em três grandes grupos de causas diretas e cinco grandes categorias de causas indiretas. As causas diretas relacionadas com mudanças do uso do solo, em especial o desmatamento, são atividades de uso do solo que afetam diretamente o meio físico e, portanto, constituem-se em fontes de mudança do uso do solo. As causas diretas operam na escala local, e conectam as mudanças da cobertura do solo (atributos biofísicos da superfície terrestre) com o uso do solo (atividades humanas que provocam alterações no meio físico).

As causas diretas são classificadas em três grandes grupos: expansão de culturas agrícolas e pastagens, corte e extração de madeira, e expansão de infra-estrutura. Ainda que esta última, principalmente a construção de estradas, não seja exatamente uma atividade de uso do solo, os seus inúmeros impactos nos processos de desmatamento fizeram com que os autores a classificassem como causa direta da conversão de áreas florestais em outros usos (GEIST & LAMBIN, 2001).

Conforme Alves (2004) as causas indiretas da conversão de áreas florestais em outros usos são fatores que determinam o contexto no qual as atividades de uso do solo (causas diretas) vão se dar. Podem ser definidas como um conjunto de fatores sociais, econômicos, políticos, tecnológicos, demográficos e culturais, que contextualizam os processos de conversão das áreas florestais. Em termos de escala espacial, elas podem operar desde o nível local, passando pelos níveis regional, nacional, até o global. As causas indiretas (vetores) podem ser classificadas em cinco grandes categorias: fatores demográficos (tamanho e densidade da população, crescimento populacional, migração), fatores econômicos (crescimento econômico, mercados), fatores tecnológicos (mudança ou progresso tecnológico), fatores políticos institucionais (políticas públicas, estrutura agrária) e fatores sócio-culturais (valores, atitudes, crenças, ideologia, comportamento individuais e coletivos) (GEIST & LAMBIN, 2001).

Existem outros fatores que podem ser determinantes para o desmatamento, além das causas diretas e indiretas, são as características iniciais do meio físico (tipo de solo, topografia, clima, grau de fragmentação das áreas florestais). Estas características influenciam o ritmo, intensidade e configuração espacial do desmatamento, atuando como incentivadores ou barreiras para os processos de mudanças no uso do solo e cobertura vegetal (ALVES, 2004).

No estudo de Geist & Lambin (2001) é a interação entre os diversos fatores diretos e indiretos que causa as mudanças do uso do solo, na maioria dos estudos de caso revistos pelos autores, existe uma combinação de três a quatro fatores indiretos e dois a três fatores diretos que estavam presentes nos processos de mudanças do uso do solo. A expansão de áreas para agricultura e pastagem é de longe a principal causa direta para a conversão de áreas florestais, estando presente em quase todos os estudos de caso revistos por Geist e Lambin (2001).

Em nenhum dos casos revistos, fatores demográficos aparecem como causa isolada do desmatamento, mas sempre interligados com outros fatores econômicos, político-institucionais, sócio-culturais etc. A grande maioria dos fatores associados ao desmatamento opera através de uma cadeia de relações causais, em que um primeiro fator influencia um segundo e assim sucessivamente, até causar diretamente a conversão de áreas florestais (GEIST & LAMBIN, 2001).

É muito complicado estabelecer relações entre as causas indiretas e a conversão de áreas florestais. Muitos fatores econômicos, políticos e demográficos operam nas escalas regional, nacional ou global, e influenciam o desmatamento através de etapas complexas, sendo que a maioria das relações causais é indireta (ANGELSEN & KAIMOWITZ, 1999).

I.2.9. Modelo de regressão linear local (GWR) aplicados na detecção de mudanças do uso do solo e cobertura vegetal

Conhecendo a distribuição espacial dos processos de USCV do Bioma Pampa e os padrões espaciais que representam as diferenças regionais na área de estudo, é possível explorar quais fatores (ambientais, socioeconômicos, etc) estão associados aos processos de mudanças da paisagem no Bioma Pampa. A técnica de Regressão Geograficamente Ponderada (*Geographically Weighted Regression - GWR*) proposta por Brunsdon, Fotheringham e Charlton (1996), incorpora os efeitos espaciais locais, podendo explorar as diferenças regionais dentro do território de estudo.

Nos modelos de regressão global, podem-se esconder variações nas associações entre as variáveis ao longo do território, uma vez que os processos são considerados estacionários (CASTRO; SINGER, 2001). Já a GWR é mais indicada para modelar processos heterogêneos (não-estacionários) espacialmente, isto é, processos que variam (seja na média, mediana, variância etc.) de região para região. Portanto, métodos de regressão global podem ser inadequados para grandes áreas geográficas, como o território do Bioma Pampa Brasileiro, onde existe heterogeneidade de variáveis ambientais, socioeconômicas, etc, provavelmente mascarando interações locais dentro dos fatores explicativos. Ao utilizar o modelo GWR diversos autores (FREITAS et al 2013; OLIVEIRA et al 2014; NUNES et al 2016) observaram que o poder explicativo da regressão linear global aumentou consideravelmente depois que foi considerado as variações locais dos diferentes coeficientes, em vez de utilizar apenas uma única constante. De fato, o modelo GWR melhora a performance preditiva da regressão linear global, considerando a regressão com um processo espacial não-estacionário. Portanto, o modelo GWR é uma técnica que inclui especificamente o componente espacial em procedimentos de regressão, não só capturando a variabilidade espacial dos processos de mudança do USCV, mas também determinando suas contribuições e erros (RODRIGUES et al., 2014).

O princípio básico da GWR é ajustar um modelo de regressão para cada região do conjunto de dados utilizando a localização geográfica das demais observações para ponderar as estimativas dos parâmetros, com o intuito de localizar as variações locais das variáveis existentes na área de estudo. Conforme Fotheringham et al. (2002), dado um modelo de regressão global (OLS), a expressão equivalente para a GWR (local), Equação 02, é dada por:

$$y_i = \beta_0(u_i, v_i) + \sum_k \beta_k(u_i, v_i)x_{ik} + \varepsilon_k \quad (02)$$

Onde: β_0 é o intercepto, β_k é o parâmetro estimado pela variável independente e (ε_k) é o erro. Nota-se pela expressão acima que os parâmetros do modelo, representados pela função $\beta_k(u_i,$

v_i) variam de acordo com os valores de (u_i, v_i) , que representam as coordenadas geográficas latitude e longitude de cada setor censitário (i), resultando em um modelo distinto para cada região do estudo. Desta forma o modelo GWR realiza regressões localmente usando o centróide de cada região mais próxima, baseados na distância Euclidiana entre os pontos. Importante mencionar que os pressupostos do modelo clássico de regressão linear (OLS) permanecem para a GWR.

A aplicação da técnica GWR pode ser observada em diferentes áreas de pesquisa, tais como Saúde (OGNEVA & HIMMELBERGER et al., 2009; GILBERT & CHAKRABORTY, 2011) e Economia (HUANG & LEUNG, 2002) e em especial mudanças de uso do solo (GAO & LI, 2010; TU, 2011; FREITAS et al 2013; SEE et al., 2015).

Bibliografia

ALCANTARA, C.; KUEMMERLE, T.; PRISHCHEPOV, A.V.; RADELOFF, V.C. Mapping abandoned agriculture with multi-temporal MODIS satellite data. **Remote Sensing of Environment** 124, 334–347. 2012.

ALLEN J. C. & BARNES D. F. (1985). “The causes of deforestation in developing countries”. *Annals of the Association of American Geographers* 75, pp. 163–184.

ALLEN, J. D.; HANUSCHAK, G. A. **The remote sensing applications program of the National Agricultural Statistical Service: 1980-1987**. USDA/NASS, Research and Applications Division. Washington, p. 43. 1988.

ALMEIDA, C.; MONTEIRO, A. M.; CAMARA, G.; SOARES-FILHO, B. S.; CERQUEIRA, G.; PENNACHIN, C.; BATTY, C. GIS and remote sensing as tools for simulation of urban land use change. In: **Third International Symposium Remote Sensing Of Urban Areas**. Istambul, tu: Istanbul Tech. Un. And Regensburg Um. pp. 387-394, 2002.

ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L.M.; SPAROVEK, G. Köppen’s climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728. 2013.

ALVES, H. P. F. Análise dos fatores associados às mudanças na cobertura da terra no Vale do Ribeira através da integração de dados censitários e de sensoriamento remoto. **Tese**. 337 p. Universidade Estadual de Campinas, Campinas, SP. 2004.

ANGELSEN, A. & KAIMOWITZ, D. "Rethinking the Causes of Deforestation: Lessons from Economic Models". **The World Bank Research Observer** 14, no. 1, pp. 73-98. 1999.

APAN, A.; POTGIETER, A. **Using satellite imagery in determining winter crop area planted in support of regional commodity forecasting: a case study of the Darling Downs, Queensland**. Australia: University of Southern Queensland/Faculty of Engineering and Surveying, 2002.

ATKINSON, P. M.; TATNALL, A.R. Neural networks in remote sensing. **International Journal of Remote Sensing**, v. 18, n. 4, p. 699-709, 1997.

- ATKINSON, P. M.; TATNALL, A.R. Neural networks in remote sensing. **International Journal of Remote Sensing**, v. 18, n. 4, p. 699-709, 1997.
- BATTY, M. GeoComputation using cellular automata. In: OPENSHAW, S.; ABRAHART, R. J. (Ed.). **GeoComputation**. London: Taylor and Francis, p.96-126. 13, 14, 2000.
- BETTOLLI, M. L.; et al. Pastura natural de salto (Uruguay): relación con la variabilidad climática y análisis de contextos futuros de cambio climático. **Revista Brasileira de Meteorologia**, v.25, n.2, 2010. p.248 - 259.
- BOLDRINI, I. I. A flora dos campos do Rio Grande do Sul. In: PILLAR, V.P.; MÜLLER, S.C.; CASTILHOS, Z.M.S; JACQUES, A.V.A. (ed). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, 2009. 403p.
- BREIMAN, L., FRIEDMAN, J. H., OLSHEN, R. A., & STONE, C. J. Classification and Regression Trees. Wadsworth, 1984.
- 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**, 130, 39-50. 2013
- BRUNSDON, C.; FOTHERINGHAM, A. S.; CHARLTON, M. E. Geographically weighted regression: a method for exploring spatial nonstationarity. **Geographical Analysis**, 28(4), 281-298, 1996
- CAO, X.; J. CHEN, H.; IMURA, O.; HIGASHI. "A SVM-Based Method to Extract Urban Areas from DMSP-OLS and SPOT VGT Data." **Remote Sensing of Environment** 113 (10): 2205–2209. 2009.
- CASTRO, M.C.; SINGER, B. **Malaria foci and colonization processes on the Amazon frontier: new evidence and GIS approach**. XXIV General Population Conference (IUSSP). Salvador, Bahia, Brasil, 2001.
- CHANDER, G.; MARKHAM, B.L.; HELDER, D.L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Rem. Sen. Envi.** 113 (5), 893–903, 2009.
- CHANG, J.; HANSEN, M.C.; PITTMAN, K.; CARROLL, M.; DIMICELI, C. Corn and soybean mapping in the United States using MODN time-series data sets. **Agronomy Journal**, 99, 1654-1664. 2007.
- CHOMENKO, L. BENCKE, G.A. (org.) *Nosso Pampa desconhecido*. Porto Alegre: Fundação Zoobotânica do Rio Grande do Sul, 2016. 208 p
- CLARK, M.I.; AIDE, T.M.; GRAU, H.R.; RINER, G.A scalable approach to mapping annual land cover at 250 m using MODIS time series data: a case study in the dry chaco ecoregion of South America. **Remote Sensing of Environment** 114, 2816–2832. 2010.
- CLARKE, K. C.; GAYDOS, L. J. Long term urban growth prediction using a cellular automaton model and GIS: Applications in San Francisco and Washington/Baltimore. *International Journal of Geographical Information Science*, (12):699-714, 1998.
- COLDITZ, R.R.; SALDAÑA, G.L.; MAEDA, P.; ESPINOZA, J.A.; TOVAR, C.M.; VICTORIA, A. Generation and analysis of the 2005 land cover map for Mexico using 250 m MODIS data. **Remote Sensing of Environment** 123, 541–552. 2012.
- CORDEIRO, J.L.P.; HASENACK, H. Cobertura vegetal atual do Rio Grande do Sul. In: Pillar, V.D., Müller, S.C., Castilhos, Z.M.S., Jaques, A.V.A. (eds.). *Campos Sulinos. Conservação e uso sustentável da biodiversidade*. MMA, Brasília. 2009.

- CORDEIRO, A. P. A.; BERLATO, M. A.; FONTANA, D. C.; MELO, R. W.; SHIMABUKURO, Y. E.; FIOR, C. S. Regiões homogêneas de vegetação utilizando a variabilidade do NDVI. **Ciência Florestal**, Santa Maria, v.27, n.3, p.883-896, jul.-set., 2017.
- CORREIA, A. H.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E.; DUARTE, V. “Avaliação de índices de vegetação MODIS para detecção de desmatamentos na Amazônia.” **Ambiente & Água** 1: 52-64. 2006.
- COSTANZA, R.; VOINOV, A. Introduction: spatially explicit landscape simulation models. In: COSTANZA, R.; VOINOV, A. (Ed.). **Landscape simulation modeling: a spatially explicit, dynamic approach**. New York: Springer-Verlag, p. 3-20. 12, 71, 2004.
- DIAS, L. T. **Modelagem dinâmica espacial do uso e ocupação do solo na Bacia Hidrográfica do Lago Paranoá – DF: 1998 – 2020**. 2011. 144f. Dissertação (Mestrado em Geociências) Universidade de Brasília: Brasília, 2011.
- EASTMAN, J. R. IDRISI 32.2 – Guide to GIS and image processing. Clark Labs, Clark University, Worcester, USA. 2001.
- EL BASTAWESY, M. Hydrological Scenarios of the Renaissance Dam in Ethiopia and Its Hydro-Environmental Impact on the Nile Downstream. **J. Hydro. Engin.** 2014.
- EL BASTAWESY, M.; RAMADAN ALI, R.; FAID, A.; EL OSTA, M. Assessment of water logging in agricultural megaprojects in the closed drainage basins of the Western Desert of Egypt. **J. Hydro. Earth Sys. Sci.** 17, 1493–1501. 2013.
- ELVIDGE, C. D.; IMHOFF, K. E.; BAUGH, V. R.; HOBSON, I.; NELSON, J.; SAFRAN, J. B.; DIETZ, B. T. “Night-Time Lights of the World: 1994–1995.” **ISPRS Journal of Photogrammetry and Remote Sensing** 56 (2): 81–99. 2001.
- ELVIDGE, C. D.; P. CINZANO, D.; PETTIT, J.; ARVESEN, P.; SUTTON, C.; SMALL, R.; NEMANI, T.; LONGCORE, C.; RICH, J.; SAFRAN, J.; WEEKS, S. “The Nightsat Mission Concept.” **International Journal of Remote Sensing**. 28 (12): 2645–2670. 2007.
- EODIS. Earth Observing System Data and Information System. Earth Observing System Clearing House (ECHO)/Reverb. 2013.
- EIPHANIO, J. C. N. Joint China-Brazil remote sensing satellites. **GIM Int**, Lemmer, 19, n. 2, 2005. 68-71.
- EIPHANIO, R.D.V.; FORMAGGIO, A.R.; RUDORFF, B.F.T.; 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**, 45, 72-80. 2010.
- FABRICANTE, I.; OESTERHELD, M.; PARUELO, J.M.. Annual and seasonal variation of NDVI explained by current and previous precipitation across Northern Patagonia. **J. Arid Environ.**, v. 73, p. 745–753, 2009.
- FENSHOLT, R.; PROUD, S.R. Evaluation of earth observation based global long term vegetation trends — comparing GIMMS and MODIS global NDVI time series. **Remote Sensing of Environment** 119, 131–147. 2012.
- FOTHERINGHAM, A. S.; BRUNSDON, C.; CHARLTON, M. Geographically weighted regression: the analysis of spatially varying relationships. Chichester: John Wiley & Sons. 2002.
- FREITAS, M, W, D.; SANTOS, J. R.; ALVES, S. A. Land-use and land-cover change processes in the Upper Uruguay Basin: linking environmental and socioeconomic variables. **Landscape Ecology**. v. 28 p. 311-327, 2013.

- FREITAS, M. W. D. Estudo integrado e modelagem da dinâmica da paisagem no Alto Uruguai (RS/SC) / Marcos Wellausen Dias de Freitas. – São José dos Campos: INPE, 2013. xxvi 149 p.; (<http://mtc-m16d.sid.inpe.br/col/sid.inpe.br/mtc-m19/2013/03.27.14.41/doc/publicacao.pdf>). **Tese** (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.
- FREITAS, R. M.; ADAMI, M.; SUGAWARA, L. M.; SHIMABUKURO, Y. E.; MOREIRA, M. A. Dinâmica da resposta espectral de duas sub-regiões do Pantanal Sul– Matogrossense. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13. (SBSR), 2007, Florianópolis. **Anais.**, São José dos Campos, 2007. 3921-3928.
- FREITAS, R. M.; ADAMI, M.; SUGAWARA, L. M.; SHIMABUKURO, Y. E.; MOREIRA, M. A. Dinâmica da resposta espectral de duas sub-regiões do Pantanal Sul– Matogrossense. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13. (SBSR), 2007, Florianópolis. **Anais.**, São José dos Campos, 2007. 3921-3928.
- FREUND, Y. & MASON, L. The alternating decision tree learning algorithm. In Proc. 16th International Conf. on Machine Learning, pag. 124-133. Morgan Kaufmann, San Francisco, CA. 1999.
- FRIEDL, M. A.; MCIVER, D.K.; HODGES, J.C.F.; ZHANG, X.Y.; MUCHONEY, D.; STRAHLER, A.H.; WOODCOCK, C.E.; GOPAL, S.; SCHNEIDER, A.; COOPER, A.; BACCINI, A.; GAO, F.; SCHAAF, C. Global land cover mapping from MODIS: algorithms and early results. **Remote Sensing of Environment** 83, 287 – 302, 2002.
- FRIEDL, M.A.; BRODLEY, C.E. Decision tree classification of land cover from remotely sensed data. **Remote Sensing of Environment**, v.61, p.399-409, 1997.. 2012
- GAO, J.; LI, S. Detecting spatially non-stationary and scale-dependent relationships between urban landscape fragmentation and related factors using geographically weighted regression. **Applied Geography**. v.31, p.292-302, 2011.
- GAO, X.; HUETE, A. R.; NI, W.; MIURA, T. Optical-biophysical relationships of vegetation spectra without background contamination. **Remote Sensing of Environment**, 74, 609 – 620, 2000.
- GATRELL, A. C. et al. Spatial point pattern analysis and its application in geographical epidemiology. **Transactions of the Institute of British Geographers**, v. 21, p. 256– 274, 1996.
- GEIST, H. & LAMBIN, E. F. What drives tropical deforestation? A meta-analysis of proximate causes and underlying sources of deforestation based on subnational case study evidence. **LUCC Report Series** No. 4. 2001.
- GILBERT, A.; CHAKRABORTY, J. Using geographically weighted regression for environmental justice analysis: Cumulative cancer risks from air toxics in Florida. **Social Science Research**, 40(1), 273-286, 2011.
- GINCIENE, B. R.; BITENCOURT, M. D. “Utilização do EVI (Enhanced Vegetation Index) para maior sensibilidade na detecção de mudanças temporais em fragmentos de floresta estacional semidecidual.” Paper presented at the **Simpósio Brasileiro de Sensoriamento Remoto**, Curitiba, PR, April 30-May 5, 2011.
- GIRIRAJ, A.; IRFAN-ULLAH, M.; MURTHY, MSR.; BEIERKUHNLEIN, C. Modelling spatial and temporal forest cover change patterns (1973–2020): a case study from South Western Ghats (India). **Sensors** 8, 6132–6153, 2008.

- GOMES, K.E. **Dinâmica e produtividade de uma pastagem natural do Rio Grande do Sul após seis anos da aplicação de adubos, diferimentos e níveis de oferta de MS.** 1996. 223 f. Tese (Doutorado) - Programa de Pós-Graduação em Zootecnia, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 1996.
- HAGAN, M. T.; DEMUTH, H.B.; BEALE, M. **Neural network design.** Boston: PWS Publishing Company, 1996. 637 p.
- HAGAN, M. T.; DEMUTH, H.B.; BEALE, M. **Neural network design.** Boston: PWS Publishing Company, 1996. 637 p.
- HARGROVE, W. W.; GARDNER, R. H. TURNER, M. G. ROMME, W. H.; DESPAIN, D. G. Simulating fire patterns in heterogeneous landscapes. **Ecological Modelling**, (135): 243-263, 2000.
- HASENACK, H.; FERRARO, L. W. Considerações sobre o clima da região de Tramandaí, RS. **Pesquisas**, Porto Alegre, n. 22, p. 53-70, 1989.
- HAYKIN, S. **Redes Neurais: princípios e práticas.** 2ed. Porto Alegre: Bookman, 2001. 900 p.
- HAYKIN, S. **Redes Neurais: princípios e práticas.** 2ed. Porto Alegre: Bookman, 2001. 900 p.
- HENDERSON, M. E. T.; YEH, P.; GONG, C.; ELVIDGE, K. "Validation of Urban Boundaries Derived from Global Night-Time Satellite Imagery." **International Journal of Remote Sensing** 24. (3): 595–609. 2003.
- HERMOSILLA, T.; WULDER, M.A.; WHITE, J.C.; COOPS, N.C.; HOBART, G.W. Regional detection, characterization, and attribution of annual forest change from 1984 to 2012 using Landsat-derived time-series metrics. **Remote Sens. Environ.** 170, 121–132. 2015.
- HOUSTON, A. G.; HALL, F.G. Use of satellite data in agricultural surveys. **Communications in Statistics: theory and methods**, Hamilton, 13, n. 23, 1984. 2857-2880.
- HUANG, Y.; LEUNG, Y. Analysing regional industrialisation in Jiangsu province using geographically weighted regression. **Journal of Geographical Systems**, 4(2), 233-249, 2002.
- HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; VAN LEEUWEN, W. J. D. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, 59, 1997. 440 - 451. 1997.
- HUETE, A.; DIDAN, K; MIURA, T.; RODRIGUEZ, E. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, 195 - 213, n. Special Issue, 2002.
- HUETE, A.; JUSTICE, C.; LIU, H. Development of vegetation and soil indices for MODIS-EOS. **Remote Sensing of Environment**, 49, 1994. 224-234, 1994..
- IBGE. Folha SH.22 Porto Alegre e parte das Folhas SH.21 Uruguaiana e SI.22 Lagoa Mirim. Rio de Janeiro: IBGE, 1 CD-ROM. (Levantamento de Recursos Naturais, v. 33), 1986.
- IMHOFF, M. L. W. T.; LAWRENCE, D. C.; STUTZER, C. D. "A Technique for Using Composite DMSP/OLS "City Lights" Satellite Data to Map Urban Area." **Remote Sensing of Environment** 61 (3): 361–370. 1997.
- JENSEN, J.R. Digital change detection. Introductory Digital Image Processing. **A Remote Sensing perspective.** Pearson Prentice Hall, New York, pp. 467–494. 2005.
- JENSEN, J.R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres.** Tradução: Epiphany et al. São José dos Campos: Parêntese, 2009.

- JESUS, S. C.; EPIPHANIO, J. C. N. Sensoriamento remoto multissensores para a avaliação temporal da expansão agrícola municipal. **Bragantia**, Campinas, v. 69, n. 4, p. 945-956, 2010.
- 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. **Pesq. agropec, bras.**, Brasilia, 47, n. 9, 1295-1306, 2012.
- 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**, 83, n. 1-2, 2002. 3-15.
- KANELLOPOULOS, I.; WILKINSON, G.G. Strategies and best practice for neural network classification. **International Journal of Remote Sensing**, v. 18, n. 4, p. 711-725, 1997.
- KANELLOPOULOS, I.; WILKINSON, G.G. Strategies and best practice for neural network classification. **International Journal of Remote Sensing**, v. 18, n. 4, p. 711-725, 1997.
- KARAFYLLIDIS, I; THANAILAKIS, A. A model for predicting forest fire spreading using cellular automata. *Ecological Modelling* (99): 87-89. 1997.
- KAUFMAN, Y. J.; TANRÉ, D. Atmospherically resistant vegetation index (ARVI) for EOSMODIS. **IEEE Transactions on Geoscience and Remote Sensing**, 30, 1992. 261 - 270.
- KENNEDY, R. E.; COHEN, W. B.; SCHROEDER, T. A. Trajectory-based change detection for automated characterization of forest disturbance dynamics. **Remote Sensing of Environment**, v. 110, p. 370-386, 2007.
- KLERSY, R. The work and role of the Commission of the European Communities. **International Journal of Remote Sensing**, London, 13, n. 6-7, 1992. 1035-1058.
- KOHAVI, R. Scaling up the accuracy of Naive-Bayes classifiers: a decision-tree hybrid. In *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, pag. 202-207. 1996.
- KUPLICH, T.M., MOREIRA, A., FONTANA, D.C. Série temporal de índice de vegetação sobre diferentes tipologias vegetais no Rio Grande do Sul. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 10 n. 17, p. 11161123, 2013
- LAMBIN et al. "Modelling and Monitoring Land-Cover Change Processes in Tropical Regions". **Progress in Physical Geography** 21, no. 3, pp. 375-393. 1997.
- LAMBIN, E. F. Modelling Deforestation Process. JRC-ESA, TREES Research Report # 1. 1994.
- LANDWEHR, N., HALL, M., & FRANK, E. Logistic model trees. **Machine Learning**, 59(1-2):161-205. 2005.
- LANG, S.; BLASCHKE, T. Análise da paisagem com SIG. São Paulo: Oficina de Textos, 424 p. 2, 10, 38, 70, 2009.
- LETT, C.; SILBER, C.; BARRET, N. Comparison of a cellular automata network and na individual-based model for the simulation of forest dynamics. **Ecological Modelling**. (121): 277-293, 1999.
- LIN, J.; LIU, X.; LI, K.; LI, X. A maximum entropy method to extract urban land by combining MODIS reflectance, MODIS NDVI, and DMSP-OLS data. **International Journal of Remote Sensing**. V. 35 N 18 6708-6727, 2014.
- LIPMANN, R. P. An introduction to computing with neural nets. **IEEE ASSP Magazine**, v. 4, n. 2, p. 4-22, 1987.

- LIPMANN, R. P. An introduction to computing with neural nets. **IEEE ASSP Magazine**, v. 4, n. 2, p. 4-22, 1987.
- LIU, Y.; WANG, X.; GUO, M.; TANI, H.; MATSUOKA, N.; MATSUMURA, S. Spatial and temporal relationships among NDVI, climate factors, and land cover changes in Northeast Asia from 1982 to 2009. **GIScience and Remote Sensing**. 48 (3), 371– 393, 2011.
- LO, C. “Urban Indicators of China from Radiance-Calibrated Digital DMSP-OLS Nighttime Images.” **Annals of the Association of American Geographers** 92 (2): 225–240. 2002.
- LU, D.; H. TIAN, G.; ZHOU, H. “Regional Mapping of Human Settlements in Southeastern China with Multisensor Remotely Sensed Data.” **Remote Sensing of Environment** 112 (9): 3668–3679. 2008.
- LU, D.; MAUSEL, P.; BRONDIZIO, E.; MORAN, E. Change detection techniques. **Inter. J. Rem. Sen.** 25 (12), 2365–2407. 2004.
- LU, D.; TIAN, H.; ZHOU, G.; GE, H. “Regional Mapping of Human Settlements in Southeastern China with Multisensor Remotely Sensed Data.” **Remote Sensing of Environment** 112 (9): 3668–3679, 2008.
- MACHADO, L. A. Z. **Manejo da pastagem nativa**. Guaíba: Agropecuária, 1999. 158 p.
- MARASCHIN, G. E. Manejo do campo nativo, produtividade animal, dinâmica da vegetação e adubação de pastagens nativas do sul do Brasil. *In*: PILLAR, V.P.; MÜLLER, S.C.; CASTILHOS, Z.M.S; JACQUES, A.V.A. (ed). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, 2009. 403p.
- MAS, J.F. Monitoring land-cover changes: a comparison of change detection techniques. **Inter. J. Rem. Sen.** 20 (1), 139–152. 1999.
- MATHER, A. S. & NEEDLE, C. L. "The Relationships of Population and Forest Trends". **The Geographical Journal** 166, pp. 2-13. 2000.
- MATHER, P. M. **Computer processing of remotely-sensed images: an Introduction**. England, UK: John Wiley & Sons, 1999. 292 p.
- MATHER, P. M. **Computer processing of remotely-sensed images: an Introduction**. England, UK: John Wiley & Sons, 1999. 292 p.
- NABINGER, C.; FERREIRA, E. D.; FREITAS, A. K.; CARVALHO, P. C. F.; SANT’ANNA, D. M. Produção animal com base no campo nativo: aplicações de resultados de pesquisa. *In*: PILLAR, V.P.; MÜLLER, S.C.; CASTILHOS, Z.M.S; JACQUES, A.V.A. (ed). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, 2009. 403p.
- NUNES, A. N.; LOURENÇO, L. CASTRO MEIRA, A. C. Exploring spacial patterns and drivers of forest fires in Portugal (1980-2014). *Science of the Total Environment*. V 573, p 1190-1202, 2016.
- OGNEVA-HIMMELBERGER, Y.; PEARSALL, H.; & RAKSHIT, R. Concrete evidence & geographically weighted regression: a regional analysis of wealth and the land cover in Massachusetts. **Applied Geography**, 29, 478-487, 2009.
- OLIVEIRA, S.; PEREIRA, J.M.C.; SAN-MIGUEL-AYANZ, J.; LOURENÇO, L. Exploring the spatial patterns of fire density in Southern Europe using Geographically Weighted Regression. **Appl. Geogr.** 51, 143–157. 2014.
- OVERBECK, G. E. Brazil’s neglected biome: The South Brazilian *Campos*. **Perspectives in Plant Ecology, Evolution and Systematics**, v.9, n.1, p. 101-116, 2007.

- PARUELO, J. M.; JOBBÁGY, E. G.; SALA, O. E. Current distribution of ecosystem functional types in temperate South América. *Ecosystems*, v. 4, p. 683-698, 2001.
- PARUELO, J.M.; GARBULSKI, M.F.; GUERSCHMAN, J.P.; OESTERHELD, M.. Caracterización regional de los recursos forrajeros de las zonas templadas de Argentina mediante imágenes satelitarias. **Revista Argentina de Producción Animal**, v. 19, p. 125–131, 1999.
- PEÑA-BARRAGÁN, J. M.; MOFFATT, K.; NGUGI, R. E. Plant, Johan Six Object-based crop identification using multiple vegetation indices, textural features and crop phenology. **Remote Sensing of Environment**, Volume 115, Issue 6, 15 Jun, Pag. 1301–1316, 2011.
- PILLAR, V. P.; LANGE, O. **Os campos do sul**. Porto Alegre: Rede Campos Sulinos - UFRGS, 2015. 192 p.
- QIN, D.; JIANWEN; M.; YUN, O. Y. Remote sensing data change detection based on the CI test of Bayesian networks. **Computers & Geosciences**, v. 32, p. 195-202, 2006.
- QUINLAN, J. R. C4. 5: programs for machine learning. San Francisco, CA: Morgan kaufmann, 1993.
- QUINLAN, J. R. C4.5: programs for machine learning. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 1993.
- QUINLAN, J. R. Induction of decision trees. *Machine Learning*, 1(1):81-106, 1986.
- RIZZI, R.; FONSECA E. L. Análise da variação espacial e temporal do NDVI no Estado do Rio Grande do Sul através de imagens AVHRR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10., 2001, Foz do Iguaçu. **Anais...**São José dos Campos: INPE, 2001. p. 1735-1737.
- RODRIGUES, M.; DE LA RIVA, J.; FOTHERINGHAM, S. Modeling the spatial variation of the explanatory factors of human-caused wildfires in Spain using geographically weighted logistic regression. **Applied Geography**. 48, 52–63. 2014.
- ROSEMBACK, R.; FERREIRA, N. J.; SHIMABUKURO, Y. E.; Conforte, J. C. Análise da dinâmica da cobertura vegetal na região sul do Brasil a partir de dados MODIS/TERRA. *Revista Brasileira de Cartografia*, v.2, p.401-4016, 2010.
- RUDEL, T. K. & ROPER, J. "Regional Patterns and Historical Trends in Tropical Deforestation, 1976-1990: A qualitative comparative analysis". **Ambio** 25, no. 3, pp. 160-166. 1996.
- RUDORFF, B. F. T; SUGAWARA, L. M. Mapeamento da cana-de-açúcar na Região Centro-Sul via imagens de satélites. **Informe Agropecuário**, Belo Horizonte, v. 28, n. 241, p. 79-86, 2007.
- SALINERO, E. C. Teledetecção ambiental: la observación de la Tierra desde el Espacio. Barcelona: Editorial Ariel, 586 p. 2, 10 2002.
- SALOVAARA, K.J.; THESSLERB, S; MALIK, R. N; TUOMISTOA, H. Classification of Amazonian primary rain forest vegetation using Landsat ETM+ satellite imagery. **Remote Sensing of Environment**, New York, 97, n. 1, 2005. 39-51.
- SANTOS, J. S.; FONTANA, D. C.; SILVA, T. S. F.; RUDORFF, F. T. Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 18, 54-63, 2014.

- SCHEIDT, S.; RAMSEY, M.; LANCASTER, N. Radiometric normalization and image mosaic generation of ASTER thermal infrared data: an application to extensive sand sheets and dune fields. **Rem. Sen. Envi.** 112 (3), 920–933. 2008.
- SCOTTÁ, F. C.; FONSECA, E. L. Multiscale Trend Analysis for Pampa Grasslands Using Ground Data and Vegetation Sensor Imagery. **Sensors** (Basel), v. 15, p. 17666-17692, 2015.
- SEE, L.; SCHEPASCHENKO, D.; LESIV, M.; MCCALLUM, I.; FRITZ, S.; COMBER, A.; OBERSTEINER, M. Building a hybrid land cover map with crowdsourcing and geographically weighted regression. **ISPRS Journal of Photogrammetry and Remote Sensing**, 103, 48-56, 2015.
- SHI, H. Best-first decision tree learning. Master's thesis, University of Waikato, Hamilton, NZ. COMP594. 2007.
- SHOWENGERDT, R. A. **Remote sensing: models and methods for image processing.** New York: Academic Press, 1997. 522 p.
- SHOWENGERDT, R. A. **Remote sensing: models and methods for image processing.** New York: Academic Press, 1997. 522 p.
- SILVA, T. S. **Planejamento ambiental na costa da Lagoa dos Patos, planície costeira do Rio Grande do Sul.** 2008. 104f. Tese (Doutorando em Oceanografia Geológica) Programa de pós-graduação em oceanografia física, química e geológica, Universidade Federal de Rio Grande: Rio Grande, 2008.
- SIRAKOULIS, G. C.; KARAFYLLIDIS, I.; THANAILAKIS, A. A cellular automaton model for the effects of population movement and vaccination on epidemic propagation. **Ecological Modelling** (133): 209-223. 2000.
- SMALL, C.; POZZI, F.; ELVIDGE, C. D. "Spatial Analysis of Global Urban Extent from DMSPOLS Night Lights." **Remote Sensing of Environment** 96 (3–4): 277–291. 2005.
- SOARES-FILHO, B. S.; ASSUNÇÃO, R. M.; PANTUZZO, A. Modeling the spatial transition probabilities of landscape dynamics in na Amazonian colonization frontier. **BioScience**, (51): 1039-1046, 2001.
- SOARES-FILHO, B. S.; CORRADI, L.; CERQUEIRA, G. ARAÚJO, W. Simulating the spatial patterns of change through the use of the dinâmica model. In: **XI Simpósio Brasileiro de Sensoriamento Remoto.** Belo Horizonte, Brasil: INPE. CD-Rom, 2003.
- SOARES-FILHO, B. S.; PENNACHIN, C.; CERQUEIRA, G. DINAMICA – a stochastic cellular automata model designed to simulate the landscape dynamics in na Amazonia colonization frontier. **Ecological Modelling**, (154): 217-235, 2002.
- SOSBAI - Reunião Técnica da Cultura do Arroz Irrigado (30. : 2014 : Bento Gonçalves, RS) Arroz irrigado: recomendações técnicas da pesquisa para o Sul do Brasil / **XXX Reunião Técnica da Cultura do Arroz Irrigado**, 06 a 08 de agosto de 2014, Bento Gonçalves, RS, Brasil. – Santa Maria : Sociedade Sul-Brasileira de Arroz Irrigado. Santa Maria, 192 p. 2014.
- SPONSEL, L. et al. Tropical deforestation: The Human dimension. New York: Columbia University Press. 1996.
- STEINER, D. Time dimension for crop surveys from space. **Photogrammetric Engineering**, Falls Church, 36, n. 2, 187-194, 1970.
- TSO, B.; MATHER, P. M. **Classification methods for remotely sensed data.** London: Taylor & Francis, 2001. 332 p.

TSO, B.; MATHER, P. M. **Classification methods for remotely sensed data**. London: Taylor & Francis, 2001. 332 p.

TU, J. Spatially varying relationships between land use and water quality across an urbanization gradient explored by geographically weighted regression. **Applied Geography**. v.31, p.376-392, 2011.

TURNER II, B. L.; LAMBIN, E. F.; REENBERG, A. The emergence of land change science for global environment change and sustainability. **Proceedings of the National Academy of Sciences**, v. 104, n. 52, p. 20666-20671, 2007.

VICTORIA, D. C.; PAZ, A. R.; COUTINHO, A. C.; KASTENS, J.; BROWN, J. C. Cropland area estimates using Modis NDVI time series in the state of Mato Grosso, Brazil. **Pesq. Agropec, bras.**, Brasília, 47, n. 9, 1270-1278. 2012.

VIEIRA, M.; FORMAGGIO, A. R.; RENNÓ, C. D.; ATZBERGER, C.; AGUIAR, D. A.; MELLO, M. P. Object based image analysis and data mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. **Remote Sensing of Environment**, v.123, p. 533-562, 2012.

VOINOV, A.; COSTANZA, R.; WAINGER, L.; BOUMANS, R.; VILLA, F.; MAXWELL, T.; VOINOV, H. Patuxent landscape model: integrated ecological economic modeling of a watershed. *Environmental Modelling & Software* (14): 473-491. 1999.

WAGNER, A. P. Dinâmica temporal de índices de vegetação no Pampa do Rio Grande do Sul e Uruguai e suas relações com os elementos meteorológicos regionais. 2013. 160f. Tese (**Tese em Sensoriamento Remoto**) – Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Porto Alegre, 2013.

WAGNER, A. P. L; FONTANA, D. C; FRAISSE, C; WEBER, E. J; HASENACK, H. Tendências temporais de índices de vegetação nos campos do Pampa do Brasil e do Uruguai. **Pesquisa Agropecuária Brasileira**, Brasília, v. 48, n. 9, 2013.

WARDLOW, B.D.; EGBERT, S.L. Large-area crop mapping using time-series MODIS 250 m NDVI data: an assessment for the US Central Great Plains. **Remote Sensing of Environment** 112, 1096–1116. 2008.

WHITE R.; ENGELEN, G.; ULJEE, I.; LAVALLE, C.; EHRLICH, D. Developing an urban land use simulator for European cities. In Fullerton, K. **5th EC GIS Workshop: GIS of Tomorrow**. European Commission Joint Research Centre, pp. 179-190, 2000.

WHITE, J.C.; WULDER, M.A.; HOBART, G.W.; LUTHER, J.E.; HERMOSILLA, T.; GRIFFITHS, P.; COOPS, N.C.; HALL, R.J.; HOSTERT, P.; DYK, A.; GUINDON, L. Pixel-based image compositing for large-area dense time series applications and science. **Can. J. Remote. Sens.** 40, 192–212. 2014.

WOLFRAN, S. A new kind of science. **Champaign, IL**: Wolfram Media, 1197 p.13, 2002.

WOODCOCK, C.E; MACOMBER, S. A; PAX-LENNEY, M; COHENC, W. B. Monitoring large areas for forest change using Landsat: Generalization across space, time and Landsat sensors. **Remote Sensing of Environment**, New York, 78, n. 2, 2001. 194-203.

WU, F. SimLand: a prototype to simulate land conversion through the integrated GIS and CA with AHP-derived transition rule. **International Journal of Geographical Information Science** (12): 63-82, 1998.

ZANOTTA, D. C.; Uma metodologia adaptativa baseada em objetos para detecção semi-automática de desmatamento na Amazônia por imagens de sensoriamento remoto / Daniel

Capella Zanotta. – São José dos Campos: INPE, 2014. xxvi 113 p.; (sid.inpe.br/mtc-m21b/2014/04.01.05.56-TDI). **Tese** (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

ZHOU, F.; ZHANG, A.; TOWNLEY-SMITH, L. A data mining approach for evaluation of optimal time-series of MODIS data for land cover mapping at a regional level. **Journal of Photogrammetry and Remote Sensing**. 84, 114–129, 2013.

Capítulo II – Resultados na forma de artigos científicos submetidos ou a serem submetidos para publicação

II.2. Artigo 1: DETECÇÃO E PREDIÇÃO DE MUDANÇAS ESPACIAIS RELACIONADAS À EXPANSÃO DA FRONTEIRA AGRÍCOLA SOBRE CAMPOS NATIVOS NO BIOMA PAMPA¹

Detection and Prediction of Spatial Changes Related to the Expansion of the Agricultural Borders Over the Native Grasslands in the Pampa Biome

Vagner Paz Mengue¹
Tatiana Silva da Silva²
Denise Cybis Fontana³
Fernando Comerlato Scottá⁴

¹Universidade Federal do Rio Grande do Sul – UFRGS
Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM)
Caixa Postal 15.074, CEP 91501-970, Porto Alegre, RS, Brasil.
vagnergeo@yahoo.com.br.

²Universidade Federal do Rio Grande do Sul – UFRGS
Departamento de Geodésia, Instituto de Geociências
Caixa Postal 15.001, CEP 91509-900, Porto Alegre, RS, Brasil.
tatiana.silva@ufrgs.br

³Universidade Federal do Rio Grande do Sul – UFRGS
Departamento de Plantas Forrageiras e Agrometeorologia
Avenida Bento Gonçalves, nº7712, CEP 91540-220, Porto Alegre, RS, Brasil.
dfontana@ufrgs.br

⁴Universidade Federal do Rio Grande do Sul – UFRGS
Programa de Pós-Graduação em Geociências, Instituto de Geociências
Caixa Postal 15.001, CEP 91509-900, Porto Alegre, RS, Brasil.
fernando.scotta@ufrgs.br

RESUMO

O objetivo principal deste trabalho é avaliar e prever a expansão da fronteira agrícola sobre campos nativos do bioma Pampa, com base em modelos espaciais em sistema de informação geográfica e dados de sensoriamento remoto. Foi utilizado o módulo *Land Change Modeler* (LCM), do *software* IDRISI, no município de Tupanciretã, RS, para quantificar as mudanças ocorridas e realizar previsões até 2025. Uma classificação híbrida foi realizada com imagens multiespectrais dos satélites Landsat 5 e 8, nos anos de 1985, 2005, 2011 e 2015, para servir de dados de entrada do modelo. Para desenvolver e validar o modelo, foram utilizadas covariáveis explanatórias e computadas a exatidão global e a curva ROC. Foi verificado um aumento de aproximadamente 90.586 hectares da área agrícola entre os anos 1985 e 2015, enquanto a área de campo foi reduzida. O LCM permitiu a geração e validação de um modelo de previsão do uso do solo até o ano de 2025. Foi previsto um contínuo aumento médio de 1.453 ha/ano das áreas agrícolas, substituindo áreas originais de campo a uma taxa de 1.427 ha/ano.

Palavras-chaves: Geoprocessamento, Modelagem Uso do Solo, Bioma Pampa.

¹ Enviado para a Revista Brasileira de Cartografia – Brazilian Journal of Cartography. Submetido em 4 maio de 2016 – aceito em 20 de junho de 2017

ABSTRACT

This study aims to evaluate and predict the agricultural frontier expansion into native grasslands of the Pampa biome, based on spatial models in geographic information system and remote sensing. The Land Change Modeler module (LCM), from the software IDRISI, was used in the Tupanciretã city, RS, to quantify the changes and make predictions until 2025. A hybrid classification was performed with multispectral images of Landsat 5 and 8, in 1985, 2005, 2011 and 2015, to serve as a model input data. To develop and validate the model, explanatory variables were used and computed the overall accuracy and ROC curve. Was recorded an increase of approximately 90,586 hectares of agricultural area between the years 1985 and 2015, while the grassland area was reduced. The LCM allowed the generation and validation of a predictive land use model for the year 2025. Was predicted a continuous agricultural increase areas of an average 1,453 ha / year, replacing original grassland areas at a rate of 1.1427 ha / year.

Keywords: Geoprocessing, land use modeling, Pampa Biome.

1. INTRODUÇÃO

O Bioma Pampa é caracterizado pelo predomínio da fisionomia vegetal campestre e ocorre sobre uma porção de terras do sul do Brasil se estendendo até o Uruguai e Argentina, devido à sua grande diversidade biológica, os campos desse bioma são considerados como área de extrema importância biológica para a conservação da fauna e flora (OVERBECK *et al.*, 2007). Entretanto, os campos já desapareceram em muitas áreas e os remanescentes correm grande risco de serem transformados em novas lavouras, pastagens cultivadas e plantações de árvores (PILLAR & LANDE, 2015).

Diversos trabalhos científicos analisaram séries temporais com imagens orbitais de alta resolução temporal no Bioma Pampa (FABRICANTE *et al.*, 2009; WAGNER *et al.*, 2013; SCOTTÁ & FONSECA, 2015). Esses trabalhos tiveram como objetivo avaliar a dinâmica agrometeorológica dos campos nativos do Bioma Pampa, mas não quantificaram a área convertida para uso agrícola ao longo dos anos. Existem poucos estudos sobre esse tema, que utilizem técnicas de modelagem espacial com sensores orbitais para quantificar transformações do uso do solo causados pelo homem no bioma Pampa. Compreender as transformações ocorridas no uso do solo, para entender melhor a estrutura e dinâmica recente das paisagens, é importante para os gestores públicos identificarem as áreas que sofreram grandes alterações, principalmente áreas prioritárias de planejamento e também as áreas com grande fragilidade ambiental, como o Bioma Pampa.

O padrão de cobertura do uso do solo de uma determinada região é consequência de fatores naturais e socioeconômicos (KUMAR *et al.*, 2015), resultados obtidos em modelos de predição possuem forte relação com os parâmetros físicos (geologia, geomorfologia, relevo, etc). Conforme Lambin *et al.* (2001), mudanças no uso do solo são ocasionadas pela resposta das pessoas a oportunidades econômicas, mediadas por fatores institucionais, sendo as oportunidades e restrições aos novos usos do solo criadas a partir de políticas e mercados locais e nacionais, em que forças globais se tornam as principais determinantes de tais

mudanças, uma vez que amplificam ou atenuam fatores locais.

A prática da agricultura no Brasil é um dos grandes responsáveis pelas transformações do uso do solo, devido, principalmente, à abertura e estabilização da economia e à expansão do crédito rural. Desta maneira, é de fundamental importância o conhecimento das dinâmicas de transformação do uso do solo para compreensão do espaço, o que possibilita inferir tendências de cenários futuros (BRANNSTROM *et al.*, 2008). A busca por técnicas de baixo custo operacional, maior rapidez e precisão são fundamentais para o mapeamento e monitoramento de culturas agrícolas, que são os principais responsáveis pela diminuição dos campos nativos ao longo dos últimos anos.

Os cultivos de primavera-verão são responsáveis pela maior parte da produção de grãos no Brasil, em que o Estado do Rio Grande do Sul se destaca como um dos maiores produtores. Conforme dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2015) a soja, milho e o arroz irrigado são as principais culturas de primavera-verão, o que equivale a 98,1% da área plantada e de 93,32 % da produção total no Estado do Rio Grande do Sul.

Paralelamente, os sistemas de informação geográfica (SIG) surgem como uma ferramenta que possibilita processar dados de diversas origens, como em estudos do meio ambiente, agricultura e novos módulos de modelagem espacial para pesquisas de previsão ou simulação de determinados fenômenos ou no apoio a decisões de planejamento.

O objetivo principal deste trabalho foi avaliar e prever a expansão da fronteira agrícola sobre campos nativos do bioma Pampa com base em modelos espaciais em sistema de informação geográfica e sensoriamento remoto no município de Tupanciretã. Foi utilizado o módulo *Land Change Modeler*, do aplicativo *IDRISI*, para analisar as mudanças ocorridas.

2. MATERIAL E MÉTODOS

A seguir será apresentada a descrição da área de estudo, a base de dados utilizada, bem como a descrição dos processos metodológicos e os *softwares* utilizados no desenvolvimento do trabalho.

2.1 Área e período de estudo

A área de estudo corresponde aos limites político do município de Tupanciretã, localizado dentro da mesorregião Centro Ocidental Rio-Grandense (IBGE) do estado do Rio Grande do Sul, entre as coordenadas 28° 45' 30" e 29° 15' 45" de Latitude Sul e 53° 30' 45" e 54° 30' 30" de Longitude Oeste (Figura 1). O município possui uma área de aproximadamente 225.482,03 (ha). A principal atividade econômica é o agronegócio (IBGE, 2015).

Para quantificar as transformações ocorridas no uso do solo nos últimos trinta anos e identificar se houve avanços das áreas agrícolas ou intensificação sobre as áreas dos campos nativos, foram utilizadas imagens *TM/Landsat 5* e *OLI/Landsat 8* (órbita/ponto 223/80), com resolução espacial de 30 metros. As imagens adquiridas foram de 31/10/1984, 03/01/1985, 07/11/2004, 26/01/2005, 08/11/2011, 16/03/2012, 05/12/2014 e 22/01/2015.

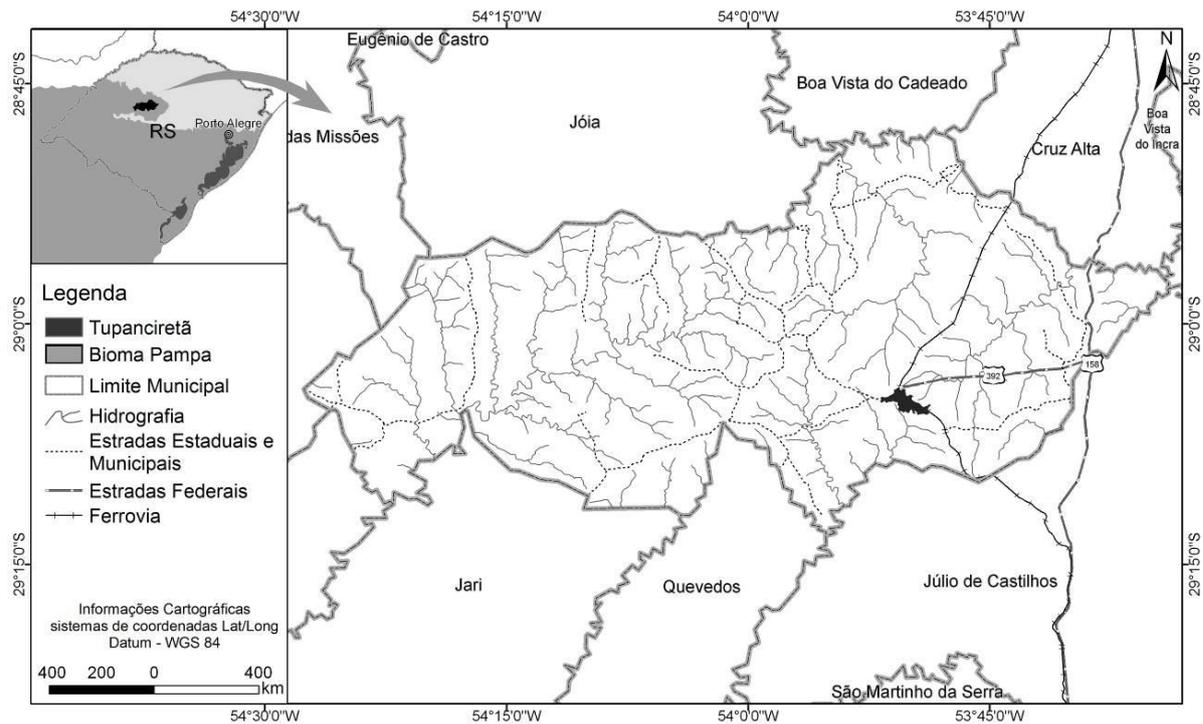


Fig. 1 - Mapa de localização da área de estudo.

2.2 Seleção e classificação de imagens

As imagens *Landsat* foram obtidas através da base de dados do USGS (*United States Geological Survey*), fornecidas no sistema de coordenadas UTM, datum WGS-84 e no formato GeoTIFF. As imagens foram fornecidas com as devidas correções geométricas (USGS, 2013) e atmosféricas pelo método 6S (*Second Simulation of a Satellite Signal in the Solar Spectrum*) (VERMOTE *et al.*, 1997). Também são disponibilizados para download diversos índices de vegetação, na qual no presente trabalho foi utilizado o índice de vegetação realçado -EVI (HUETE *et al.*, 1994).

Os mapas de uso do solo para os anos 1985, 2005, 2011 e 2015 foram gerados a partir de um procedimento de classificação híbrida. A escolha das datas foi importante para o desenvolvimento do trabalho, a data de 1985 foi escolhida devido aos primeiros registros do *Landsat 5*, além de completar o período de 30 anos. Já as datas de 2005 e 2011, foram necessárias para a construção do modelo de predição, também nesse período entre 2005 a 2011, foi onde as

áreas cultivadas com soja começaram a se estabilizar, não ocupando novas áreas do município, conforme dados apresentados pelo IBGE (2015). As categorias de uso do solo foram baseadas nos critérios estabelecidos por Anderson *et al.* (1976), sendo elencadas seis classes de uso do solo para o município de Tupanciretã: agricultura, floresta, campo, área urbana e silvicultura.

Foram utilizadas técnicas distintas de classificação para as diferentes classes de uso do solo. Devido à variabilidade possível de datas de semeadura entre as lavouras de soja e milho presentes no município e também uma semelhança de padrões espectrais entre diferentes alvos, como as classes floresta, silvicultura e campos, optou-se pelo método espectro-temporal para a classe agricultura utilizando imagens índice de vegetação EVI de mínimo valor (relacionada à implantação da cultura) e de máximo valor (relacionada ao máximo vigor vegetativo das lavouras). De posse das imagens EVI que representam o mínimo e o máximo valor de EVI para as áreas agrícolas, utilizou-se o método de classificação supervisionada Máxima Verossimilhança. As amostras

de treinamento do classificador foram coletadas em uma imagem de composição colorida RGB, onde as imagens de mínimo EVI foram associadas as cores verde (*Green* – G) e azul (*Blue* – B) nos canais G e B e a imagem de máximo EVI associada a cor vermelha (*Red* – R). Desta forma foi possível destacar áreas cultivadas com as culturas de primavera-verão (soja e milho).

Para as demais classes de uso do solo foram utilizadas as imagens de reflectância de superfície e adotada uma classificação supervisionada pelo método Máxima Verossimilhança. Por último, uma etapa de análise visual sobre os resultados diretamente na tela do computador para detectar e editar possíveis erros de classificação. Portanto foram gerados quatro mapas de uso do solo de referência (1985, 2005, 2011 e 2015). Todo o processamento e classificação do uso do solo foram realizados no *software ENVI 5.1*.

Para a averiguação da acurácia dos mapas de uso do solo foi utilizado a Exatidão Global (EG). Foram utilizados 200 pontos amostrais, dos quais foram sorteados aleatoriamente sobre a área classificada para os anos de 1985, 2005, 2011 e 2015 e tendo tomado como referência terrestre as imagens de média resolução espacial (*TM/Landsat 5* para os anos de 1985, 2005, 2011 e *OLI/Landsat 8* para o ano de 2015). Sendo realizada uma verificação ponto a ponto, checagem da classificação.

2.3 Análise de mudanças do uso do solo com o *Land Change Modeler*

A quantificação e análise dos processos de transformação do uso do solo nos últimos trinta anos foi efetuada com base em uma tabulação cruzada entre o mapa de uso do solo de 1985 e 2015. A partir deste procedimento foi possível quantificar e mapear as classes de uso do solo que apresentaram ganhos ou perdas de área e identificar as classes mais significativas para as mudanças na paisagem da área de estudo, principalmente aquelas que contribuíram para a diminuição dos campos nativos. Através de gráficos e tabelas gerados pelo módulo *Land Change Modeler – IDRISI Taiga* (LCM) foi possível analisar e quantificar as transformações espaciais ocorridas nos últimos 30 anos na área de estudo.

Para desenvolver o mapa de suscetibilidade a mudança do uso do solo para o ano de 2015, foram utilizados os mapas de uso do solo de 2005 e 2011, o LCM necessita de duas datas distintas para geração dos seus produtos. Além destes, foram utilizadas variáveis que ajudaram na determinação das probabilidades de transição de uma classe de uso do solo para outra. A escolha dessas variáveis é importante para a calibração e sucesso do modelo, já que o LCM utiliza redes neurais para detectar padrões de mudanças com base nestas variáveis e na sua relação com as mudanças do uso do solo nas datas estudadas. Novas perdas de área de campos nativos geralmente estão associadas a

distribuição de terras cultiváveis, redes viárias existentes e previstas, rede hidrográfica, entre outros fatores. Foram utilizadas 7 variáveis, que possuem relação com as transformações do uso do solo para a área de estudo. (Figura 2), a saber:

- Distância linear das estradas, calculada com base na rede viária obtida a partir da vetorização manual sobre imagens do *Google Earth*;
- Distância linear da hidrografia, calculada a partir da hidrografia vetorial na escala 1:100.000, disponibilizada pela Agência Nacional de Águas (ANA) – <http://www2.ana.gov.br>;
- Variáveis do relevo, como altimetria e a declividade, obtidos a partir dos dados SRTM (*Shuttle Radar Topography Mission*) pelo USGS (www.earthexplorer.usgs.gov) com resolução espacial de 30 metros;
- Distância linear da área urbana de Tupanciretã, obtidas a partir dos mapas de referência obtidos com as imagens *Landsat*;
- Distância linear das áreas de transição entre as datas estudadas;
- Distância linear das áreas cultivadas.

O módulo LCM utiliza o V de Cramer para testar e determinar o poder explicativo potencial de uma variável no modelo (Eastman *et al.*, 2005). O V de Cramer é uma medida de associação entre variáveis que podem assumir valores entre 0 e 1, é uma medida estatística baseada no qui-quadrado de Person (CRAMÉR, 1946). Variáveis que possuem valores acima de 0,15 tendem a ser úteis para o modelo e podem ajudar a explicar as mudanças no uso do solo ocorridas no intervalo de tempo analisado. A partir destas variáveis, em conjunto com os mapas de uso do solo gerados na etapa anterior, foi estruturado e calibrado um modelo dinâmico espacial para cenários futuros.

Como produto dessa etapa foi gerado um mapa de cenário futuro para o ano de 2015 e também o mapa de suscetibilidade à conversão dos campos nativos em agricultura. A próxima etapa foi validar esse produto com o mapa de referência do uso do solo de 2015. Foi utilizada uma série de estatísticas, quais sejam: Exatidão Global, Discordância Global e análise da curva ROC - *Receiver Operating Characteristic*, que possibilitam avaliar a acurácia e as discordâncias entre o mapa predito e o mapa de referência.

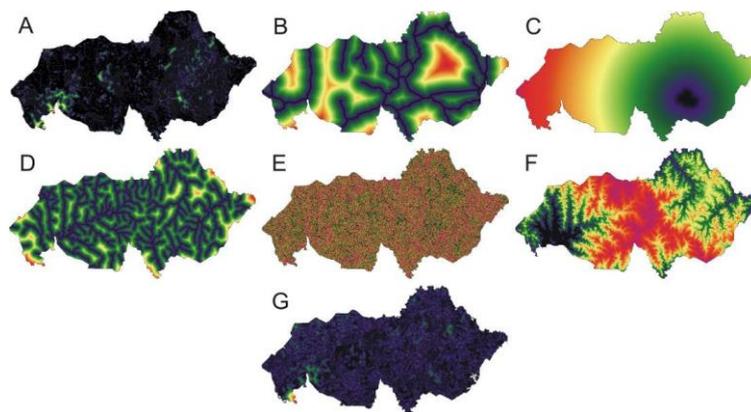


Fig. 2 - (A) mapa de distancias das áreas cultivadas (B) mapa de distâncias das estradas; (C) mapa de distâncias da área urbana; (D) mapa de distâncias da hidrografia; (E) mapa de declividade; (F) mapa de altimetria e (G) mapa de distância das transições.

Utilizando como referência o mapa de uso do solo de 2015, as estatísticas foram computadas pelo módulo *validate* do software *IDRISI*. De posse das matrizes de erro entre as classes de uso do solo do mapa predito e do mapa de referência, calculou-se a Exatidão Global, que corresponde à percentagem de acertos, a discordância de quantidade, que expressa a fração da diferença entre os dados preditos e os de referência devida ao ajuste imperfeito nas proporções das classes, e a discordância de alocação, que expressa a fração da diferença devida ao ajuste imperfeito na alocação espacial das classes, dadas suas proporções nos dados preditos e nos de referência (PONTIUS & MILLONES, 2011).

Para validar o modelo de suscetibilidade à mudança dos campos nativos, foi empregada a análise da curva ROC como discutido por Pontius & Parmentier (2014), que calcula a probabilidade de uma determinada classe ser ocupada por outra classe, como por exemplo, a probabilidade do campo nativo se tornar área agrícola. A imagem de probabilidade é comparada com uma imagem booleana de referência, que mostra as mudanças do uso do solo durante um período de tempo. Os valores da curva ROC expressam a área sob a curva AUC (*Area Under the Curve*) obtida com cada limiar. AUC igual a 1 indica concordância espacial perfeita entre o mapa de suscetibilidade a mudança dos campos nativos e o mapa de referência, enquanto um valor de AUC de 0,5 indica uma tendência de as medidas serem distribuídas aleatoriamente.

Na segunda fase do trabalho, foi gerado um cenário futuro anual a partir de 2016 até 2025, utilizando os parâmetros gerados na etapa anterior. O modelo determina como as mudanças aconteceram entre o primeiro período (2011) e o segundo período (2015), e como essas variáveis influenciam em mudanças futuras, e depois calcula a quantidade relativa de transição para o próximo período.

O *Land Change Modeler* permite integrar limitações ou incentivos de crescimento para o modelo

de projeção. Foram utilizadas como restrição à classe agrícola as áreas de proteção permanente, segundo o código florestal brasileiro, respeitando uma área de proteção de 30 m de cada lado das drenagens e um raio de 50 m em torno das nascentes, além das áreas com declividades superiores a 12°, que é o limite máximo para mecanização na agricultura conforme EMBRAPA (2009). A Figura 3 apresenta o fluxograma simplificado que ilustra os materiais utilizados e as principais etapas metodológicas adotadas para implementação da modelagem dinâmica espacial.

3. RESULTADOS

Nesta seção serão apresentados os resultados obtidos na avaliação da classificação dos mapas de uso do solo, análise das mudanças nos últimos trinta anos, os efeitos e as implicações ambientais dessas mudanças para o Bioma Pampa, modelagem e validação dos modelos e por último a simulação de cenários futuros de uso do solo até o ano de 2025.

3.1 Avaliação da classificação dos mapas de uso do solo

A classificação dos mapas de uso do solo para os anos 1985, 2005, 2011 e 2015, apresentou exatidão global entre 89% e 94% (Tabela 1). Devido a metodologia proposta de utilizar 200 pontos amostrais, dos quais foram sorteados aleatoriamente sobre a área de estudo, as classes com pouca representatividade de área não foram contempladas, como a classe Silvicultura e Área Urbana, apenas as classes Campo, Floresta e Agricultura tiveram pontos de referência. Importante destacar que as três classes que tiveram pontos de referência possuem mais de 99% do total da área de estudo, em todos os mapas de uso do solo, com a metodologia de validação sendo representativa sobre o total da área.

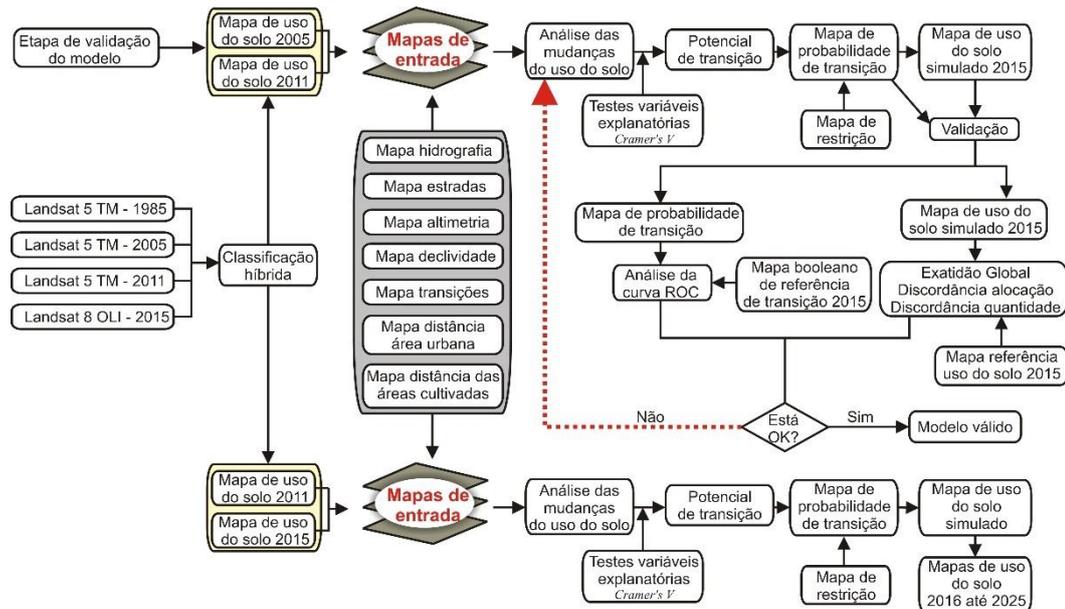


Fig. 3 - Metodologia utilizada para a implementação da modelagem dinâmica espacial.

Tabela 1 – Matriz de confusão e exatidão global (EG) dos mapas de uso do solo

1985 – EG 89,50%					
Classificação	Referência de campo			Total	Acurácia do usuário
	Agricultura	Campo	Floresta		
Agricultura	45	0	0	45	100
Campo	18	121	2	141	85,10
Floresta	0	1	13	14	92,86
Total	63	122	1	200	
Acurácia do produtor	71,43	99,18	86,67		

2005 – EG 94,00%					
Classificação	Referência de campo			Total	Acurácia do usuário
	Agricultura	Campo	Floresta		
Agricultura	123	3	1	127	96,85
Campo	2	53	6	61	86,88
Floresta	0	0	12	12	100
Total	125	56	19	200	
Acurácia do produtor	98,40	94,64	63,15		

2011 – EG 91,50%					
Classificação	Referência de campo			Total	Acurácia do usuário
	Agricultura	Campo	Floresta		
Agricultura	124	1	1	126	98,41
Campo	11	45	4	60	75,00
Floresta	0	0	14	14	100
Total	135	46	19	200	
Acurácia do produtor	91,85	97,82	73,68		

2015 – EG 94,50%					
Classificação	Referência de campo			Total	Acurácia do usuário
	Agricultura	Campo	Floresta		
Agricultura	125	2	0	127	98,42
Campo	3	50	6	59	84,74
Floresta	0	0	14	14	100
Total	128	52	20	200	
Acurácia do produtor	97,65	96,15	70,00		

A partir dos dados apresentados na matriz de confusão é possível analisar quais classes possuem semelhanças espectrais fazendo com que a acurácia em alguns mapas fosse menor, como no mapa do ano de 1985. De acordo com o mapa deste ano, a maior semelhança espectral foi entre as classes agricultura e campo, do total de 63 pontos de referência terrestre, sendo 18 pontos (28,6% do total) referentes à classe campo. A classe Floresta também possui semelhança espectral com a classe campo, esse resultado fica evidente em todos os mapas classificados, com destaque para o ano de 2005, que obteve o maior erro percentual entre a classe floresta e campo.

Na Figura 04 é apresentado os resultados de reflectância de superfície para as 6 bandas do OLI/Landsat 8 com as três classes: Campo, Floresta e Agricultura. A classe Campo e Floresta possuem um perfil espectral muito similar, o que pode explicar os erros nos mapeamentos apresentados através da matriz de confusão. Já a classe Agricultura apresenta uma alta reflectância na banda 5 (infravermelho próximo), que é explicada pelo alto vigor vegetativo da cultura da soja entre os meses de Janeiro e Fevereiro. Conforme Rudorff *et al.* (2007) este período do ano é fundamental para a classificação da soja, pois, a maioria das lavouras se encontra em pleno desenvolvimento no Rio Grande do Sul. Isso explica porque a classe Agricultura possui os maiores valores de EVI entre as classes mapeadas, já que este índice de vegetação utiliza como componentes para sua geração as bandas do vermelho (banda 4) e infravermelho próximo (banda 5) do OLI/Landsat 8 para sua geração.

A utilização do índice de vegetação (EVI) foi fundamental para a metodologia proposta no trabalho para diferenciar classes de mapeamento, principalmente a classe agricultura, que ao longo dos 30 anos foi a classe que obteve o maior aumento de área. Outro fator que também é importante destacar é a utilização de diferentes sensores do Landsat, apesar de possuírem a mesma resolução espacial, o sensor OLI do Landsat 8 possui 16 bits de resolução radiométrica contra 8 bits do sensor TM do Landsat 5. Essa diferença radiométrica é muito significativa e pode ter contribuindo para uma melhor acurácia do mapa de 2015, como mostra a tabela da matriz de confusão.

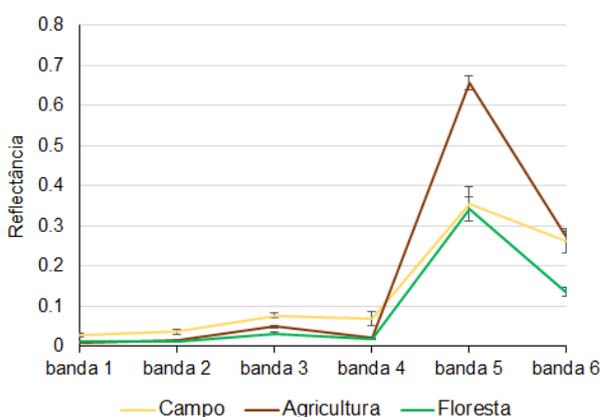


Fig. 4 - Reflectância de superfície do OLI/Landsat 8 para as três classes em estudo. Data da imagem: 22 de Janeiro de 2015.

3. 2 Análise do uso do solo nos últimos trinta anos

Os resultados das áreas em hectares são mostrados na Figura 5 e na Tabela 2. Constata-se a redução da classe campo e o aumento da classe agricultura. A diminuição da classe campo é tão expressiva que reduziu em praticamente três vezes. Para a classe agricultura, é observado o inverso, existindo um aumento de área em praticamente três vezes. As classes área urbana, floresta e silvicultura apresentam um pequeno aumento ao longo dos anos, porém são praticamente estáveis pela magnitude da área.

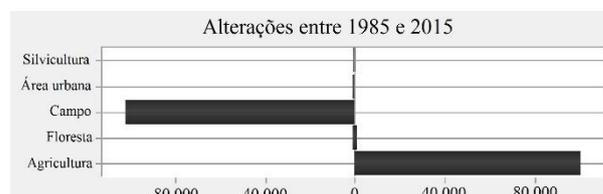


Fig. 5 - Mudanças estimadas em hectares entre 1985 e 2015.

Tabela 2 - Uso do solo nas datas de 1985, 2005, 2011 e 2015, com base na classificação das imagens Landsat 5 e 8. valores em hectares.

Classes	1985	2005	2011	2015
Área urb.	510	656	689	772
Campo	159.14	79.928	71.923	66.992
Floresta	10.081	10.394	11.052	11.213
Agricultur	55.111	133.76	141.09	145.69
Silvicultur	352	466	506	534

O município de Tupanciretã é o maior produtor de soja no estado do Rio Grande do Sul (IBGE, 2015). Conforme Moreira & Medeiros (2014) a partir de 1985 a soja se consolida alicerçada pela modernização do setor agrícola no Centro-Norte e Noroeste Gaúcho, ocupando áreas tradicionais da pecuária, como por exemplo, a região das missões. A Figura 6 evidencia essa mudança do uso do solo, com grande crescimento das áreas de soja, principalmente a partir da década de 90.

A classe agricultura refere-se às culturas de verão no município de Tupanciretã, e as principais culturas são de soja e milho. Conforme dados do IBGE (2015) foram cultivados na safra 2012/2013, 142.000 ha de soja e 1.720 ha de milho.

Cabe destacar a proporção entre as duas culturas teve uma variação ao longo dos anos. Na década de 80, a proporção era de 80% para soja e 20% para o milho. Esta mudança gradual da cultura do milho para a soja ao longo dos anos evidencia o modelo de produção da soja, voltada para a exportação. Conforme

Ferreira *et al.* (2012) a cultura da soja contribuiu para os acelerados processos de mudança do uso do solo, que intervêm na qualidade e na disponibilidade de água, na conservação de habitats naturais e da biodiversidade.

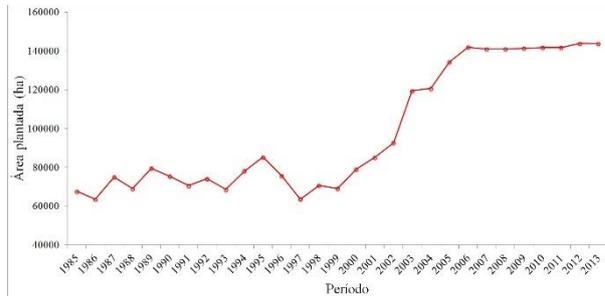


Fig. 6 - Evolução da área plantada de soja no município de Tupanciretã. Fonte: IBGE, 2015.

3.3 Implicações Ambientais para o Bioma Pampa

Através da classificação realizada com as imagens *Landsat* no município de Tupanciretã, foi possível analisar que as áreas de campo estão distribuídas ao longo de todo seu território e, muitas vezes, estão isoladas por áreas agrícolas. Essas áreas

remanescentes de campo possuem tamanhos variados, entre 3 a 11 hectares. Na Figura 07 é possível observar a fragmentação dos campos em meio às áreas agrícolas.

Um dos impactos ecológicos mais importantes da expansão agrícola é a perda e fragmentação de habitats naturais, o que leva à redução e isolamento de populações nativas, aumentando o risco de extinção (EWERS & DIDHAM, 2006). Diversos trabalhos em diferentes biomas brasileiros apontam que a expansão agrícola pode causar a extinção local de espécies nativas e perda de diversidade (CARVALHO *et al.*, 2009; CARVALHO & BATELLO, 2009; PERES *et al.*, 2010), provocando mudanças nas interações biológicas (*e. g.* a polinização e dispersão de sementes) e também em todos os processos ecológicos essenciais.

Conforme comenta Vélez-Martin *et al.* (2015) uma consequência da fragmentação é o isolamento geográfico entre as áreas de campo. Para algumas espécies, a distância pode se tornar intransponível e os indivíduos acabam ficando isolados. Quando todas as manchas de campo que restam são muito pequenas, a qualidade do habitat diminui de um modo geral e muitas espécies não conseguem persistir.

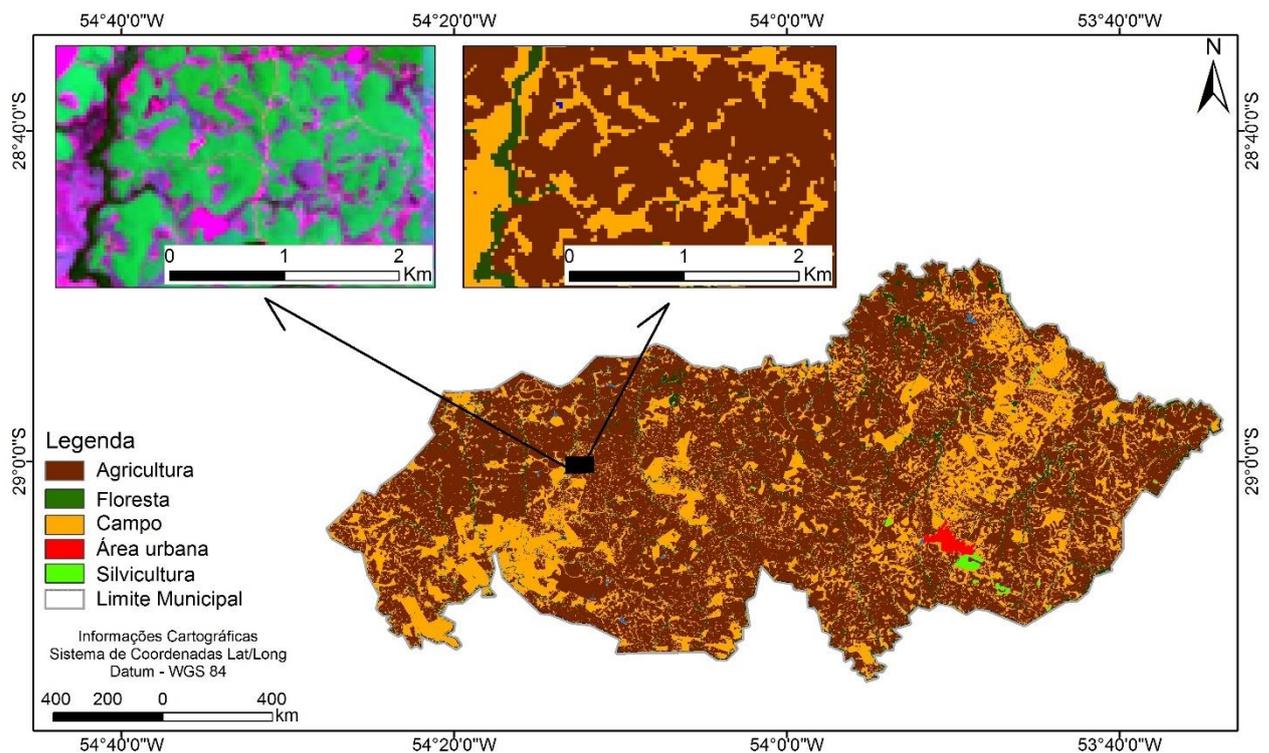


Fig. 7 - Uso do solo do município de Tupanciretã em 2015, ilustrando a fragmentação dos campos. Imagem Landsat 8 OLI data: 22/01/2015, composição RGB 453.

3.4 Modelagem e validação do modelo

Para a análise e modelagem do cenário futuro, foram utilizados mapas de uso do solo de 2005 e 2011 para construir e também validar o modelo. A primeira etapa consistiu em detectar as mudanças ocorridas nesse intervalo e gerar um modelo de potencial de transição da classe campo em agricultura, além da geração do mapa de cenário futuro para o ano de 2015.

Na Figura 08 é possível visualizar a perda de áreas de campo e o aumento das áreas agrícolas ao longo do período de 30 anos. A perda total da classe campo foi aproximadamente 92.152 ha, decorrente do avanço das áreas agrícolas sobre os campos nativos do Bioma Pampa.

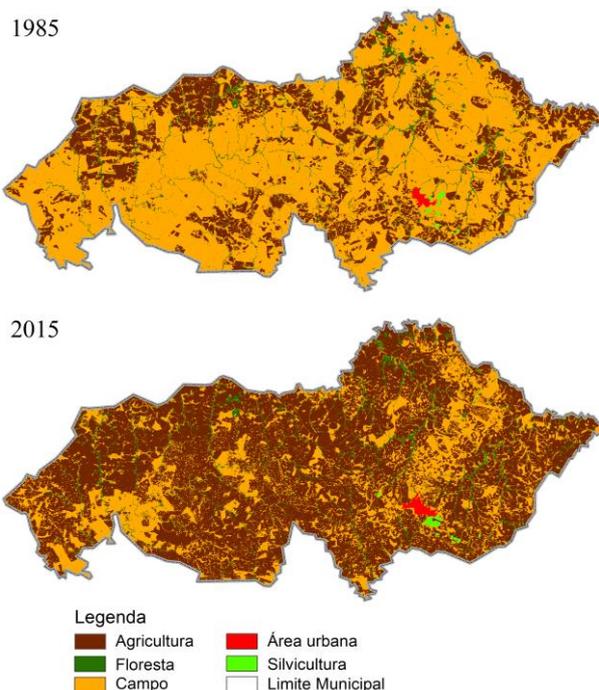


Fig. 8 – Mapa evidenciando a transformação dos campos nativos em áreas agrícolas no município de Tupanciretã.

A rede neural utilizada (*Multi-Layer Perceptron*) aprende a detectar padrões de mudanças com base nas mudanças previamente ocorridas e nas variáveis explanatórias.

Diversos testes foram realizados com diferentes variáveis explanatórias para calibrar a rede neural. O melhor resultado encontrado foi um modelo com aproximadamente 87% de acurácia com 10.000 iterações. Os resultados do V Cramer é apresentado na Tabela 3, os melhores valores encontrados foram para o mapa de distâncias das transições e o mapa de distâncias das áreas cultivadas, com 0,36 e 0,33, respectivamente. Acredita-se que os valores menores V de Cramer para dados oriundos do SRTM, como o mapa de altimetria e declividade, acontecem porque o modelo não encontrou um padrão espacial que se relaciona com as mudanças de uso do solo. Apesar dos valores baixos de V de Cramer, optou-se por utilizar essas variáveis, porque entende-se que elas possuem forte relação espacial com as modificações de uso do solo nos últimos anos.

Tabela 3 - Resultado do V de Cramer para todas as variáveis explanatórias utilizadas no modelo

Variáveis explanatórias	V de Cramer
mapa de distância das transições	0,3640
mapa de distancias das áreas cultivadas	0,3343
mapa de distâncias da área urbana	0,2894
mapa de distâncias da hidrografia	0,1988
mapa de distâncias das estradas	0,1722
mapa de altimetria	0,1208
mapa de declividade	0,0550

Para validação do mapa de suscetibilidade a mudanças dos campos nativos, foi empregada a análise da curva ROC. Para isso a imagem de suscetibilidade a mudanças dos campos nativos para o ano de 2015 foi comparada com a imagem booleana de referência, que aponta a localização geográfica das áreas onde houve as transições de uso do solo no intervalo de tempo entre 2011 e 2015. Foram utilizados 100 limiares de intervalos iguais para calcular a área sob a curva (AUC).

A AUC encontrada na validação foi de 0.852, sendo um valor alto que valida o modelo para o ano de 2015. Caso as medidas do modelo tivessem uma tendência de serem distribuídas uniformemente sobre a diagonal principal ($AUC = 0,50$), os valores seriam atribuídos de forma aleatória (PONTIUS & SCHNEIDER, 2001; PONTIUS e PARMENTIER, 2014).

Também é possível observar a partir da curva ROC, que à medida que aumenta o limiar de corte, o poder discriminante da imagem de suscetibilidade também aumenta, o que confere uma maior área sob a curva ROC e, conseqüentemente, um melhor desempenho. O que também podemos verificar na figura abaixo é a maior probabilidade de conversão dos campos nativos em uso agrícola para os pequenos fragmentos de campos, principalmente os pequenos fragmentos, com áreas inferiores a 5 hectares, com até 66% com probabilidade de serem convertidas para uso agrícola conforme o modelo apresentado. A Sudoeste da área de estudo, próximo à localidade de Santo Agostinho, existe uma grande área de campo onde é possível observar as áreas de borda que possuem a maior probabilidade de conversão em áreas agrícolas, e áreas com menor probabilidade de conversão, que estão mais afastadas das bordas (áreas em verde no mapa) (Figura 9).

Gerado o modelo potencial de transição para o período de 2005 a 2011, procedeu-se à predição para o ano de 2015 e a validação com o mapa de referência do uso do solo de 2015. Esta etapa permitiu testar e calibrar o modelo do *Land Change Modeler* para geração dos cenários futuros até o ano de 2025. Ao analisar os dados da Tabela 4 é possível evidenciar que os valores em termos de área foram muito similares aos encontrados no mapa de referência de 2015. A classe agricultura no mapa de referência totalizou 145.697 ha, e no mapa estimado foi de 149.105 ha, ou seja, uma superestimativa de 2,33%. Já a classe campo, foi

subestimada em 5,18%, 3.471 ha menor do que no mapa de referência.

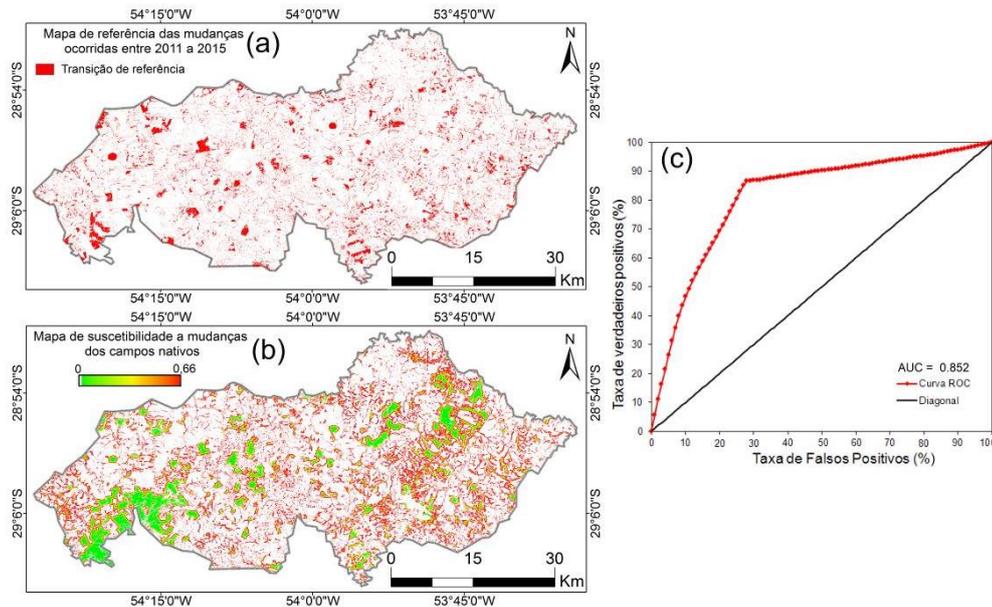


Fig. 9 - Curva ROC entre o mapa de suscetibilidade a mudanças dos campos e a imagem booleana de referência das mudanças ocorridas entre 2011 a 2015.

Tabela 4 - Comparação dos valores entre o mapa de referência de 2015 e o mapa simulado pelo *land change modeler*, valores em hectares

Uso do solo	Mapa de referencia 2015	Mapa simulado 2015	Diferença %
Agricultura	145.697	149.105	2,33
Floresta	11.213	11.387	1,55
Campo	66.992	63.521	-5,18
Área urbana	772	715	-7,38
Silvicultura	534	539	0,93

Como foi observado com o mapa de suscetibilidade a mudanças dos campos, as pequenas áreas isoladas de campo foram convertidas em áreas agrícolas. Para avaliar a acurácia do mapa de uso do solo de 2015 com o mapa estimado, o resultado da classificação alcançou exatidão global de 84,21%. Dessa forma, a discordância total foi de 15,79%; sendo 1,68% da discordância de quantidade e 14,11% da discordância de alocação (Figura 10). Apesar do valor da componente alocação na discordância ter se apresentado alto, quando comparado à componente quantidade, não invalida a utilização dos dados. Conforme Pontius *et al.* (2011), diversos trabalhos que utilizam como linha de corte um valor de 85% de exatidão global para considerar um mapeamento bom, quando na realidade não faz sentido atribuir um valor específico ou linha de corte universal de exatidão global em aplicações práticas, apesar de existir muitos trabalhos que estabelecem tais padrões (LANDIS & KOCH, 1977; MONSERUD & LEEMANS, 1992). Ainda assim, o valor de discordância total encontrado estaria de acordo com os limiares de exatidão comumente adotados.

A componente de quantidade na discordância total implica numa proporção muito baixa (1,68%) quando se compara os valores do mapa estimado com o mapa de referência. A componente de alocação na discordância total implica em valores maiores (14,11%), o que significa distribuição espacial incorreta dos pixels nas classes.

As classes de uso do solo que mais contribuíram para discordância de alocação foram as classes campo e agricultura, uma análise visual entre os dois mapas, esclareceu algumas dúvidas relacionadas com esses erros, boa parte das discordâncias de alocação estão localizadas nas bordas entre as duas classes, onde há inclusive problemas de classificação, decorrentes de pixel mistura.



Fig. 10 - Medidas de acurácia do modelo estimado pelo *Land Change Modeler* e o mapa de uso do solo de referência de 2015.

Tabela 5 - Comparação dos valores entre o mapa de referência de 2015 e o mapa simulado pelo *land change modeler*, valores em hectares

Classe	Mapa de referência 2015		Mapa simulado 2025		Diferença %
	hectares	%	hectares	%	
Agricultura	145.697	64,69	160.229	71,15	9,96
Floresta	11.213	4,98	10.805	4,80	-3,64
Campo	66.992	29,75	52.715	23,40	-21,31
Área urbana	772	0,34	871	0,39	13,82
Silvicultura	534	0,24	585	0,26	9,56

e também as áreas de contato com a área agrícola. Importante destacar que os campos nativos que restam estão praticamente restritos aos locais onde o solo não é muito recomendado para a agricultura, pedregoso ou ainda o relevo é muito ondulado, o que acaba dificultando a implantação de lavouras de soja ou milho. Entretanto, com o advento de novas tecnologias e insumos na área agrônômica, as áreas remanescentes de campos podem ser convertidas em novas áreas agrícolas.

O número de fragmentos de campo diminuiu consideravelmente em 2025, mas ainda permanece um grande número de fragmentos e ilhas de campo cercadas por áreas agrícolas. Conforme Vélez-Martin *et al.* (2015) quando há um grande número de manchas menores de campo, maior é a superfície de contato entre as espécies campestres e os ambientes do entorno. É o denominado efeito de borda. Geralmente, na linha de contato entre o campo e uma lavoura, por exemplo, as condições microclimáticas são distintas com tendência de temperaturas mais elevadas e menor umidade no ar e no solo, o que pode ser prejudicial. As bordas também são locais mais suscetíveis aos efeitos negativos de perturbações das áreas do entorno como ingresso de agrotóxicos, fertilizantes e de espécies invasoras.

A classe floresta, que é formada em sua maior parte por matas ciliares distribuída ao longo dos principais córregos, verifica-se redução de 3,64%, entre o cenário simulado e o período atual (2015). A variação da classe floresta desde o primeiro período analisado neste trabalho (1985) se manteve praticamente estável, a pequena variação é ocasionada provavelmente por algum erro do classificador. Outro

3.5 Simulação do modelo de 2016 a 2025

Validado o modelo, procedeu-se à simulação do cenário para o ano de 2025. A Tabela 5 ilustra os resultados obtidos pela modelagem dos cenários futuros. Analisando o cenário simulado de 2025, verifica-se uma diminuição da área dos campos em 21,31% em relação ao período atual (2015). As áreas de campo com as maiores perdas foram os pequenos fragmentos florestais

elemento que pode ter contribuído para esta possível estabilidade ao longo dos anos da classe floresta foi a criação do antigo Código Florestal Federal (Lei Federal nº 4.771/1965), revogada em 2012 (Lei Federal nº 12.651/2012), que seu capítulo II dispunha sobre as Áreas de Preservação Permanente, onde estabelece critérios de delimitação ao longo dos cursos d'água, nascentes, topo de morros, etc. Além disso, a efetiva fiscalização ambiental por parte do Estado, que no Rio Grande do Sul o primeiro órgão governamental estadual de meio ambiente, surgiu vinculada à Secretaria da Saúde, através do Decreto nº 23.082, de 26/04/1974, que institui a Política Estadual de Proteção Ambiental, compreendendo um conjunto de diretrizes administrativas e técnicas destinadas a fixar a ação governamental no campo da conservação do meio ambiente e da utilização dos recursos naturais (OLIVEIRA & MARTINS, 2010). Portanto, esses fatores foram essenciais para a proteção e conservação das matas ciliares e também nascentes, impedindo o avanço das áreas agrícolas.

Para a classe agricultura, verifica-se um aumento de 9,97% para o ano de 2025 em relação ao mapa de referência de 2015, ocupando aproximadamente 71% da área total do município. Na Figura 11 é ilustrada a evolução anual até o ano de 2025 das classes de uso do solo em Tupanciretã, observando-se as áreas agrícolas distribuídas de forma homogênea pelo município.

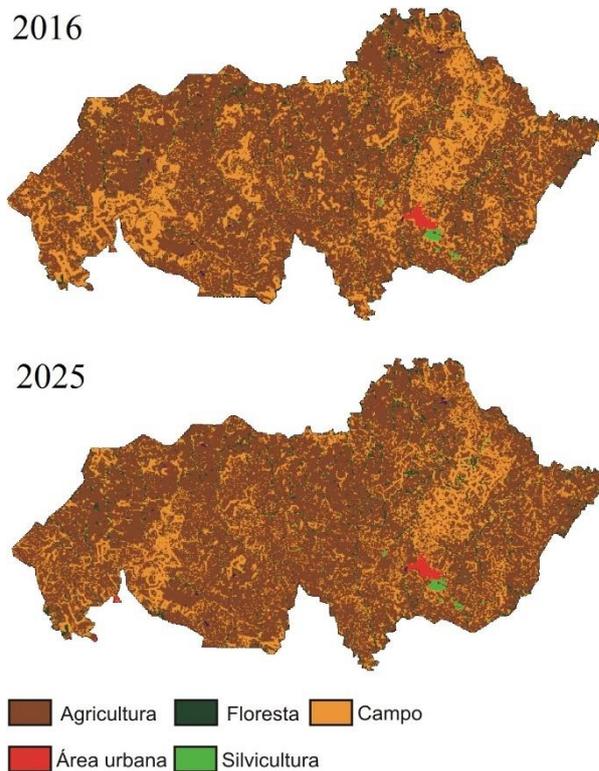


Fig. 11 - Mapas de predição do uso do solo no município de Tupanciretã até o ano de 2025.

O módulo LCM não considera os fatores políticos e econômicos no modelo. Qualquer mudança na ordem desses fatores ao longo dos anos pode provocar implicações no ordenamento territorial. O que o modelo considera como funções condicionantes de força, pode ser descrito através da inserção de camadas restrições e incentivos a uma determinada atividade. O mapa utilizado como restrição permitiu limitar os incentivos de crescimento para o modelo de simulação de cenários futuros, com resultados satisfatórios, colocando como restrição de crescimento as áreas de proteção permanente. Desta maneira, essas áreas de restrições não sofreram mudanças no uso do solo para o modelo de simulação de cenários futuros. O mapa de restrição ocupou um total de 21.956,31 hectares, que corresponde a 9,73% do total da área do município. No contexto deste trabalho, a inserção do mapa de restrição dentro do modelo de previsão para cenários futuros foi fundamental, pois permitiu projetar sobre quais regiões ou locais queremos limitar seu crescimento.

Cabe destacar a atividade da pecuária extensiva em toda a região, principalmente na metade sul do Estado do Rio Grande do Sul, onde é praticada há cerca de quatro séculos. Baseada no aproveitamento direto da vegetação nativa, quando não há sobrepastejo (excesso de carga animal), a flora e a fauna se mantêm em relativa harmonia com os rebanhos, ocorrendo a manutenção da vegetação campestre.

Desta forma é importante o incentivo da atividade da pecuária para toda a região onde a vegetação campestre está presente para impedir a conversão dessa vegetação pela atividade agrícola, mas

especificamente o cultivo de soja. Apesar dos avanços na legislação e iniciativas de conservação, apenas 2,23% da superfície do Bioma Pampa está protegida oficialmente em sete unidades de conservação que compreendem uma área de cerca de 375.000 ha (BILENCA & MIÑARRO, 2004). Na Figura 12 são apresentadas as perdas e ganhos por categoria de uso do solo até o ano de 2025 e a linha de tendência linear para as classes campo e agricultura.

Pode-se inferir que a classe agricultura mantém taxa de crescimento acelerado até o ano de 2005, mas a partir de 2005 essa taxa de crescimento diminui e na simulação até o ano de 2025 essa taxa de crescimento é ainda menor. Para a classe campo, acontece o contrário, a taxa de perda da vegetação campestre é muito acelerada até o ano de 2005, depois a taxa de perda é muito menor. A menor taxa de perda nos últimos anos e também no modelo de simulação, pode ser explicada pela baixa capacidade agrícola das áreas remanescentes, além da legislação ambiental preservando áreas campestres.

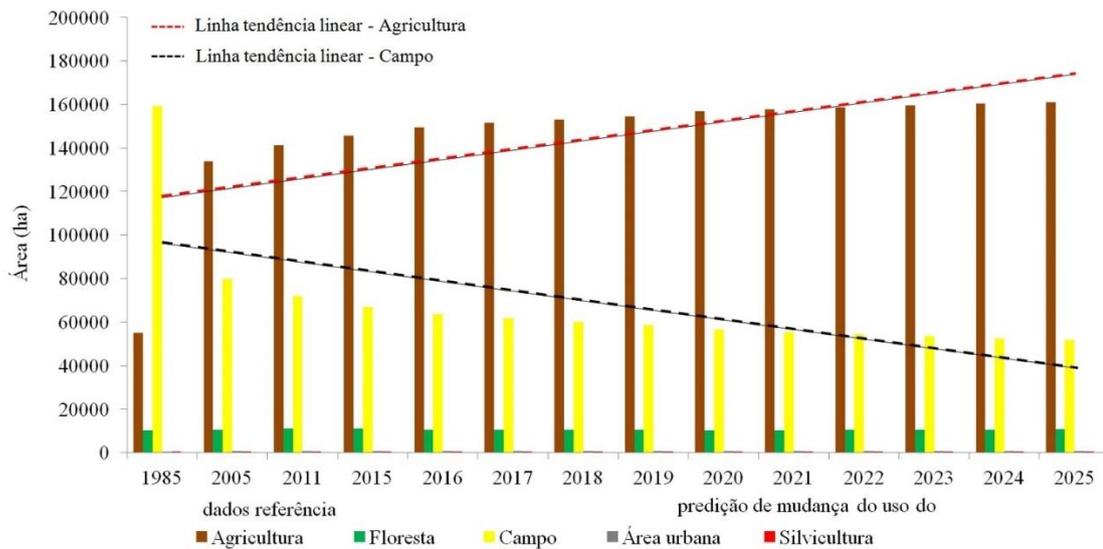


Fig. 12 - Evolução das classes de uso do solo para o município de Tupanciretã estimada até o ano de 2025.

4. CONCLUSÕES

As imagens *TM/Landsat-5* e *OLI/Landsat-8* permitiram identificar e quantificar o aumento de aproximadamente 90.586 hectares da área agrícola entre os anos 1985 e 2015 no município de Tupanciretã, o que corresponde a um incremento na ordem de 164,37%. Em contrapartida, houve diminuição da vegetação campestre de 159.144 em 1985 para 66.992 ha em 2015, uma diferença de 92.152 ha.

O módulo *Land Change Modeler* permitiu a quantificação das mudanças do uso do solo ocorridas entre 1985 e 2015, além de ser uma ferramenta poderosa para planejamento territorial. Através do LCM, foi possível gerar e validar um modelo de previsão do uso do solo até o ano de 2025 no município de Tupanciretã. De 2016 até 2025 o modelo estimou um aumento médio de 1.453 ha/ano para as áreas agrícolas, em contrapartida as áreas de campo uma redução média de 1.427 ha/ano.

Foi possível testar e analisar quais variáveis explanatórias foram as mais importantes e contribuíram para explicar as mudanças ocorridas no uso do solo, sendo: a variável distância das transições entre as datas estudadas, distância das áreas agrícolas, distância área urbana e distância da drenagem, as que obtiveram os melhores resultados de V de Cramer.

Como recomendação para trabalho futuros, seria interessante aplicar esta metodologia em outras escalas, com novas variáveis explanatórias e a utilização de outros sensores orbitais, como por exemplo, o sensor MODIS, para todo o Bioma Pampa, incluindo o Sul do Brasil, Argentina e Uruguai, e avaliar os impactos da agricultura sobre a vegetação campestre que compõe o Bioma Pampa.

REFERÊNCIAS BIBLIOGRÁFICAS

ANDERSON, J. R.; HARDY, E. E.; ROACH, J. T.; WITMER, R. E.. **A Land Use and Land Cover Classification System for Use with Remote Sensor Data**. Washington, D.C.: United States Geological Survey, 1976. 36 p.

BILENCA, D.; MIÑARRO, F. **Identificación de áreas valiosas de pastizal en las Pampas y Campos de Argentina, Uruguay y Sur de Brasil**. Buenos Aires. 2004. 323 p.

BRANNSTROM, C; JEPSON, W; FILIPPI, A. M; REDO, D; XU, S.; GANESH, S. Land change in the Brazilian Savanna (Cerrado), 1986-2002: Comparative analysis and implications for land-use policy. **Land Use Policy**, 25, 579-595. 2008.

CARVALHO, F. M. V.; DE MARCO, P.; FERREIRA, L.G. The Cerrado intopieces: habitat fragmentation as a function of landscape use in the savannas of central Brazil. **Biological Conservation**, 142, 1392-1403. 2009.

CARVALHO, P. C. F.; BATELLO, C. Access to land, livestock production and ecosystem conservation in the Brazilian Campos biome: The natural grasslands dilemma. **Livestock Science**, 120, 158-162. 2009.

CRAMÉR, H. **Mathematical Methods of Statistics**. Princeton: University Press, 1946. 575 p.

EASTMAN, J. R.; SOLORZANO, L; FOSSEN, M. V. Transition Potential Modeling for Land-Cover Change. In: DAVID, J.; MAGUIRE, M. B.; GOODCHILD, M. F **In GIS, Spatial Analysis and Modeling**. Redlands: ESRI Press, 357-385. 2005.

EMBRAPA. CENTRO NACIONAL DE PESQUISA DE SOLOS. **Sistema brasileiro de classificação de solos**. Rio de Janeiro: EMBRAPA-SPI, 2009. 353 p.

EWERS, R. M.; DIDHAM, R.K. Confounding factors in the detection of species responses to habitat fragmentation. **Biological Reviews of the Cambridge Philosophical Society**, 81, 117-142. 2006.

- FABRICANTE, I.; OESTERHELD, M.; PARUELO, J.M.. Annual and seasonal variation of NDVI explained by current and previous precipitation across Northern Patagonia. **Jornal of Arid Environments.**, v. 73, p. 745–753, 2009.
- FERREIRA, J.; PARDINI, R.; METZGER, J. P.; FONSECA, C.R.; POMPEU, P. S.; SPAROVEK, G.; LOUZADA, J. Towards environmentally sustainable agriculture in Brazil: challenges and opportunities for applied ecological research. **Journal of Applied Ecology**, 49, 535-541. 2012.
- FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, 80, 185 – 201. 2002.
- HUETE, A.; JUSTICE, C.; LIU, H. Development of vegetation and soil indices for MODIS-EOS. **Remote Sensing of Environment**, 49, 224-234. 1994.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). @Cidades. Disponível em: <<http://www.ibge.gov.br>>. Acesso em: Maio 2015.
- KUMAR, K.S.; VALASALA, N. V. A. S. S.; SUBRAHMANYAM, J. V.; MALLAMPATI, M.; SHAIK, K.; EKKIRALA, P. Prediction of future land use land cover changes of Vijayawada city using remote sensing and GIS. **International Journal of Innovative Research in Advanced Engineering (IJIRAE)**, 2, n. 3, 91-97. 2015.
- LAMBIN, E.F.; TURNER, B.L.; GEIST, H.J.; AGBOLA, S.B.; ANGELSEN, A.; BRUCE, J.W.; COOMES, O.T.; DIRZO, R.; FISCHER, G.; FOLKE, C.; GEORGE, P.S.; HOMEWOOD, K.; IMBERNON, J.; LEEMANS, R.; LI, X.; MORAN, E.F.; MORTIMORE, M.; RAMAKRISHNAN, P.S.; RICHARDS, J.F.; SKANES, H.; STEFFEN, W.; STONE, G.D.; SVEDIN, U.; VELDKAMP, T.A.; VOGEL, C.; XU, J. The causes of land-use and land-cover change: moving beyond the myths. **Global Environmental Change**, 11, 261–269. 2001.
- LANDIS, J.; KOCH, G. The measurement of observer agreement for categorical data. **Biometrics**, 33, 159–174. 1977.
- MONSERUD, R. A.; LEEMANS, R., 1992, Comparing global vegetation maps with the kappa statistic. **Ecological Modelling**, 62, 1992. 275–293.
- MOREIRA, V. S.; MEDEIROS, R. M. V. As novas configurações do espaço agrário no Rio Grande do Sul / Brasil: da pecuária tradicional ao complexo agroindustrial da soja. **Confins**, n. 20, 2014.
- OLIVEIRA, N.; MARTINS, C. H. B. Política e gestão ambiental no rio grande do sul, brasil: descentralização e participação social. **XI Seminário internacional/ IV Taller RIER - Red Iberoamericana de Investigadores Globalización y Territorio**. Mendoza/Argentina. Out/2010.
- OVERBECK, G. E.; MULLER, S.C.; FIDELIS, A.; PFADENHAUER, J.; PILLAR, V.D.; BLANCO, C. C.; BOLDRINI, I.; BOTH, R.; FORNECK, E.D. Brazil's neglected biome: The South Brazilian Campos. **Perspectives in Plant Ecology, Evolution and Systematics.**, v. 9, p. 101-116, 2007.
- PERES, C.A.; GARDNER, T.A.; BARLOW, J.; ZUANON, J.; MICHALSKI, F.; LEES, A.C.; VIEIRA, I.C.G.; MOREIRA, F.M.S.; FEELEY, K.J. Biodiversity conservation in human-modified Amazonian forest landscapes. **Biological Conservation**, 143, 2010. 2314–2327.
- PILLAR, V. P.; LANGE, O. **Os campos do sul**. Porto Alegre: Rede Campos Sulinos - UFRGS, 2015. 192 p.
- PONTIUS, R. G.; PARMENTIER, B. Recommendations for using the Relative Operating Characteristic (ROC). **Landscape Ecology**, 29, n. 3, 2014. 367-382.
- PONTIUS, R. G.; SCHNEIDER, L. Land-use change model validation by a ROC method for the Ipswich watershed, Massachusetts, USA. **Agriculture, Ecosystems & Environment**, 85 (1-3), 2001. 239-248.
- PONTIUS, R. G.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, 32, n. 15, 2011. 4407-4429.
- RUDORFF, C. M.; RIZZI, R.; RUDORFF, B. F. T.; SUGAWARA, L. M.; 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**. 37, 118-125. 2007.
- SCOTTÁ, F. C.; FONSECA, E. L. Multiscale Trend Analysis for Pampa Grasslands Using Ground Data and Vegetation Sensor Imagery. **Sensors**, Basel, v. 15, p. 17666-17692, 2015.
- VÉLEZ-MARTIN, E.; ROCHA, C. H.; BLANCO, C.; AZAMBUJA, B. O.; HASENACK, H.; PILLAR, V. P. conversão e fragmentação. In: PILLAR, V. P; LANGE, O **Os Campos do Sul**. Porto Alegre: Rede Campos Sulinos – UFRGS, 2015. 192 p.
- VERMOTE, E. F. Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: an overview. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 35, n. 3, p. 675-686, 1997.
- WAGNER, A. P. L; FONTANA, D. C; FRAISSE, C; WEBER, E. J; HASENACK, H. Tendências temporais de índices de vegetação nos campos do Pampa do Brasil e do Uruguai. **Pesquisa Agropecuária Brasileira**, Brasília, v. 48, n. 9, 2013.

II.2. Artigo 2: METODOLOGIA PARA CLASSIFICAÇÃO DE USO E COBERTURA VEGETAL DO BIOMA PAMPA UTILIZANDO SÉRIES TEMPORAIS MODIS-EVI

Vagner Paz Mengue¹
Denise Cybis Fontana²
Tatiana Silva da Silva³
Daniel Zanotta⁴
Fernando Comerlato Scottá⁵

¹Universidade Federal do Rio Grande do Sul – UFRGS
Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM)
Caixa Postal 15.074, CEP 91501-970, Porto Alegre, RS, Brasil.
vagnergeo@yahoo.com.br.

²Universidade Federal do Rio Grande do Sul – UFRGS
Departamento de Plantas Forrageiras e Agrometeorologia
Avenida Bento Gonçalves, nº7712, CEP 91540-220, Porto Alegre, RS, Brasil.
dfontana@ufrgs.br

³Universidade Federal do Rio Grande do Sul – UFRGS
Departamento de Geodésia, Instituto de Geociências
Caixa Postal 15.001, CEP 91509-900, Porto Alegre, RS, Brasil.
tatiana.silva@ufrgs.br

⁴Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul - IFRS
Campus Rio Grande
Rua General Vitorino, Centro CEP 96200- 310, Rio Grande, RS, Brasil
daniel.zanotta@riogrande.ifrs.edu.br

⁵Universidade Federal do Rio Grande do Sul – UFRGS
Programa de Pós-Graduação em Geociências, Instituto de Geociências
Caixa Postal 15.001, CEP 91509-900, Porto Alegre, RS, Brasil.
fernando.scotta@ufrgs.br

Resumo

O objetivo deste trabalho foi verificar a aplicabilidade do uso de séries temporais do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) para o mapeamento do uso e cobertura vegetal no Bioma Pampa no Estado do Rio Grande do Sul, em uma análise em escala regional. O período de estudo compreendeu os meses de junho de 2013 até junho de 2014. Os procedimentos incluíram a utilização de imagens EVI (*Enhanced Vegetation Index*) do Sensor MODIS, dados SRTM (*Shuttle Radar Topography Mission*) e imagens noturnas do DMSP-OLS (*Defence Meteorological Satellite Program - Operational Linescan System*), associados ao classificador hierárquico por Árvore de Decisão (AD), construído utilizando o algoritmo C4.5. A abordagem proposta tem origem na consideração de que a área de estudo apresenta características variadas e, por isso, deve ser tratada simultaneamente por classificadores diferentes e intuitivos, o que justifica a escolha do AD. Além disso, a adição de outras variáveis ao problema, como o modelo de elevação SRTM e as imagens noturnas, conferem um fator determinante nas estimativas feitas pelo classificador. Para avaliar os resultados, foram usados dados de referências extraídos com imagens do satélite Landsat 8- OLI e dados IBGE. Na classificação utilizando a série temporal MODIS, foi encontrada uma Exatidão Global (EG) de 90,09% e o Índice Kappa (IK) de 0,8853. Com relação aos dados de referência do IBGE, a

classe Soja obteve um coeficiente de correlação (r) de 0,94, a classe Arroz 0,97 e a classe Silvicultura obteve o menor valor com 0,78. As maiores similaridades espectrais foram encontradas nas classes com cobertura vegetal, como Campo, Floresta e Silvicultura. Portanto, com o uso de dados multitemporais do sensor MODIS, combinado o uso de dados SRTM e imagens noturnas (DMSP-OLS), é possível a geração de um mapa de uso do solo e cobertura vegetal para o Bioma Pampa com exatidão aceitável dentro dos limites da resolução do sensor MODIS.

Abstract

The objective of this work was to verify the applicability of MODIS (Moderate Resolution Imaging Spectroradiometer) time series for mapping of land use and coverage vegetable in the Pampa biome of Rio Grande do Sul, in a regional scale analysis. The study period comprised the months of June 2013 through June 2014. The procedures included the use of MODIS Sensor EVI (Enhanced Vegetation Index), SRTM data (Shuttle Radar Topography Mission), and DMSP-OLS images (Defense Meteorological Satellite Program) associated with the Hierarchical Tree Classifier Decision (AD), constructed using the algorithm C4.5. The proposed approach stems from the consideration that the study area presents varied characteristics and, therefore, should be treated simultaneously by different and intuitive classifiers, which justifies the choice of AD. The addition of other variables to the problem, such as the SRTM elevation model and the night images, give a determinant factor in the estimates made by the classifier. To evaluate the results, reference data extracted with Landsat 8-OLI satellite images and IBGE data were used. In the classification using the MODIS time series, a Global Accuracy (EG) of 90.09% and the Kappa Index (IK) of 0.8853 were found. Regarding the IBGE reference data, the Soja class obtained a correlation coefficient (r) of 0.94, the Rice class 0.97 and the Silviculture class obtained the lowest value with 0.78. The highest spectral similarities were found in the vegetation cover classes, such as Grassland, Forest and Silviculture. Therefore, with the use of multitemporal data from the MODIS sensor, combined with the use of SRTM data and night images (DMSP-OLS), it is possible to generate a land use and coverage vegetable for the Pampa biome with acceptable accuracy within the limits of the MODIS sensor.

Introdução

O bioma Pampa possui uma área de aproximadamente 176.496 km², ocupando 2,07% do território brasileiro e 63% do Estado do Rio Grande do Sul (OVERBECK et al., 2007). Nos últimos tempos, no entanto, tem se observado uma tendência de mudança de uso do solo e da sua cobertura vegetal neste bioma, marcadamente pela conversão das áreas campestres para a agricultura de grãos ou silvicultura (PILLAR et al., 2009). Existe uma grande preocupação em termos de sustentabilidade ambiental para o Bioma Pampa, principalmente devido à conversão das áreas campestres em áreas agrícolas e silvicultura, podendo causar perdas de solos por erosão, contaminação do lençol freático por agrotóxicos e fertilizantes. Há, portanto, necessidade de monitoramento contínuo das transformações do uso do solo e da sua cobertura vegetal nesse bioma.

O mapeamento do uso do solo e cobertura vegetal do Bioma Pampa tem sido realizado principalmente com base na análise de um mosaico de imagens do satélite Landsat (WEBER et al., 2016; HASENACK et al., 2015). O uso de imagens com periodicidade a cada 16 dias, como é o caso do Landsat, apresenta algumas limitações devido à dificuldade de aquisição de imagens livres da cobertura de nuvens, impedindo a aquisição de várias imagens ao longo do ano, tornando mais complicada a interpretação e mapeamento de algumas classes de uso e cobertura vegetal, principalmente as classes vegetais que apresentam padrões espectrais distintos devido a sazonalidade climática (PARUELO, 2001; ROSEMBACK et al., 2010; KUPLICH et al., 2013).

Desta forma, uma alternativa para contornar essa limitação temporal é o monitoramento do uso do solo e da cobertura vegetal por meio de séries temporais obtidas pelo sensor MODIS (*MODerate Resolution Imaging Spectroradiometer*), que adquire imagens da superfície a cada 1-2 dias (JUSTICE et al., 2002). O sensor MODIS disponibiliza ainda produtos derivados de composição de imagens de 16 dias sob a forma de índices de vegetação, como o NDVI (*Normalized Difference Vegetation Index*), baseado na reflectância do vermelho e do infravermelho (ROUSE et al., 1974) e o EVI (*Enhanced Vegetation Index*), que inclui a reflectância do azul (HUETE et al., 1994), permitindo uma melhor análise da dinâmica do uso do solo e da cobertura vegetal da área de estudo.

Índices de vegetação derivados do sensor MODIS têm sido utilizados em uma ampla variedade de aplicações, cujo o intuito é o monitoramento e o mapeamento do uso e cobertura do solo. Podemos destacar o estudo à nível global (FRIEDL et al., 2002) que foi um dos primeiros trabalhos realizados com dados MODIS mostrando suas potencialidades e limitações. Há também o estudo de Liu et al (2011) que trabalharam com as mudanças do uso do solo entre 1982-2009 no Nordeste da Ásia, utilizando NDVI de três sensores diferentes (AVHRR, SPOT e MODIS). Importante mencionar também o trabalho de Zhou et al (2013) que aplica técnicas de mineração de dados para identificação do uso e cobertura do solo com dados MODIS para uma região agrícola do Canadá. No trabalho mencionado, o objetivo foi testar a acurácia do mapeamento em diferentes combinações dos dados MODIS, como bandas espectrais, NDVI e métricas fenológicas.

Estudos utilizando árvores de decisão têm se mostrado favoráveis no mapeamento do uso do solo e cobertura vegetal, pois permitem realizar classificações e mineração de dados com grande volume de dados, podemos destacar os trabalhos que utilizaram desta técnica para o mapeamento da cobertura florestal com dados MODIS na Ásia (WU et al., 2002), na identificação de culturas e uso do solo utilizando índices de vegetação e uso do solo (PEÑA-

BARRAGÁN et al., 2011; BROWN et al., 2013), no mapeamento de cana-de-açúcar em grandes áreas (VIEIRA et al., 2012) e em estudo de detecção de desmatamento na Amazônia (ZANOTTA, 2014).

Neste sentido, o presente trabalho busca contribuir para avançar no conhecimento acerca do potencial de tais métodos de mapeamento e monitoramento do uso e cobertura vegetal para o Bioma Pampa. A hipótese norteadora é que classes de uso do solo e cobertura vegetal podem ser detectadas e mapeadas devido a variação espectro-temporal dos índices de vegetação, através de classificadores intuitivos como a AD.

Nesse contexto, o objetivo do trabalho foi propor uma metodologia para classificação do uso do solo e cobertura vegetal em grandes áreas utilizando séries temporais EVI do sensor MODIS, modelo de elevação SRTM e imagens noturnas (DMSP-OLS), através da utilização do classificador hierárquico por AD, construído utilizando o algoritmo C4.5 para todo o Bioma Pampa localizado no Estado do Rio Grande do Sul.

Metodologia

Área de estudo

O estudo foi realizado no Bioma Pampa (IBGE, 2004) dentro dos limites do Estado do Rio Grande do Sul, localizado no extremo sul do Brasil, entre as latitudes 28°08's e 33°45's e longitudes 49°80'w e 56°20'w. A área de estudo (Figura 01) abrange um total de 106 municípios pertencentes ao Bioma Pampa, possui uma área total de 16.579.332 hectares e uma população total de 5.373.216 habitantes, que corresponde a 50,24% do total da população do Estado do Rio Grande do Sul.

Com relação ao clima, conforme classificação de Köppen (1948), na maior parte do Bioma Pampa predomina o tipo Cfa (subtropical chuvoso com verões quentes), sendo que apenas a região da Serra do Sudeste, com altitudes mais elevadas (~400 m de altitude), apresenta o clima tipo Cfb (subtropical chuvoso com verões amenos).

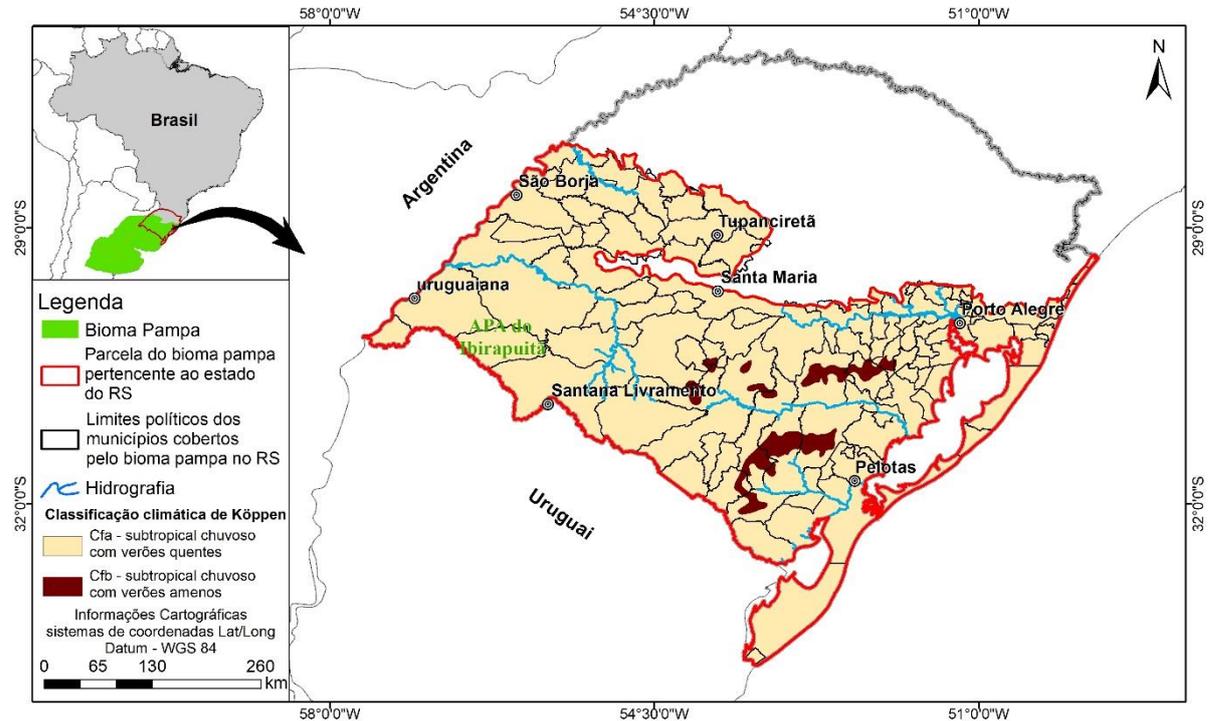


Figura 01: Mapa de localização da área de estudo.

Dados MODIS e pré-processamento

Neste estudo foram testadas imagens do satélite TERRA, sensor MODIS, produto MOD13Q1, coleção 6, que contém composições de imagens de 16 dias sob forma de índices de vegetação EVI, com uma resolução espacial de 250 metros. Foram utilizadas 23 imagens MODIS, de junho de 2013 a julho de 2014, para compor a série temporal EVI.

Também foram obtidas as 23 imagens de confiabilidade do pixel (*Pixel Reliability*) para o mesmo período, as quais foram utilizadas para filtragem visando diminuir a interferência de ruídos oriundos da presença de nuvens, falhas do detector, geometria de visada, dentre outros, e suavizar a curva espectro-temporal. Este procedimento foi realizado no software TIMESAT (JÖNSSON & EKLUNDH, 2002, 2004). O software TIMESAT permite a filtragem dos dados da série temporal para a remoção dos ruídos por meio de três algoritmos de suavização *Savitzky–Golay*, *Gaussian Asymmetric*, *Double Logistic*.

A série temporal EVI foi ponderada com as imagens de *Pixel Reliability*, utilizado o algoritmo *Savitzky–Golay* (Equação 1). O algoritmo *Savitzky–Golay* é um método de filtragem adaptativa, baseado em média móvel, cujo valor da janela é pré-estabelecido conforme a natureza do ruído. Pode ser considerado um algoritmo menos agressivo, em relação à suavização da curva espectro-temporal, quando comparado aos demais implementados no TIMESAT, como *Gaussian Asymmetric* e *Double Logistic*. (BORGES, 2014).

$$Y_j^* = \frac{\sum_{i=-m}^{i=m} C_i Y_{j+i}}{N} \quad (1)$$

Onde Y é o valor do EVI original; Y^* é o resultado do valor do EVI filtrado; C_i é o coeficiente para o i da janela de suavização; N é o número inteiro da convolução, que é igual ao tamanho da janela de suavização ($2m+1$); j representa o índice de processamento da data ordenada na tabela original dos dados; e m representa metade da largura da janela de suavização (SAVITZKY & GOLAY, 1964).

As imagens de *pixel reliability* contêm informações sobre os pixels contaminados por nuvens. O TIMESAT identifica tais pixels e seu respectivo período para realizar as filtrações na série temporal. Os dados relativos às imagens de *pixels reliability* foram categorizados no TIMESAT e a eles atribuídos pesos. Os parâmetros utilizados para a filtragem da série dos dados foram: *Savitzky–Golay* com janela móvel 4, Força de adaptação de 2 (*Adaptation strength*), Método de corte de pico (*Spike Method*) igual a 3 e Número de interações igual a 2 (*N° of Envelope Iterations*).

Amostras de treinamento

As amostras de treinamento e validação foram selecionadas a partir das imagens *Landsat 8/OLI* com resolução espacial de 30 metros (Figura 2). Ao total, foram utilizadas 13 cenas com datas entre outubro de 2013 e fevereiro de 2014. As cenas foram adquiridas com nível de processamento que incluem correções radiométricas e geométricas finas. Com o objetivo de evitar intervenções antrópicas durante o período de estudo, algumas classes de vegetação, especialmente a classe Campo, a aquisição das amostras se concentrou dentro dos limites da Área de Proteção Ambiental (APA) do Ibirapuitã. A APA do Ibirapuitã possui um relevo plano, suavemente ondulado, a vegetação caracteriza-se como estepe gramíneo lenhosa (campo nativo) e floresta estacional decidual aluvial (mata ciliar), sendo a fisionomia caracterizada por extensas planícies de campo limpo (IBAMA, 2010). Por último, as amostras foram conferidas com a ferramenta SATVeg da EMBRAPA (<https://www.satveg.cnptia.embrapa.br>) sendo gerada para cada polígono uma curva espectral-temporal, para verificar a consistência da amostra.

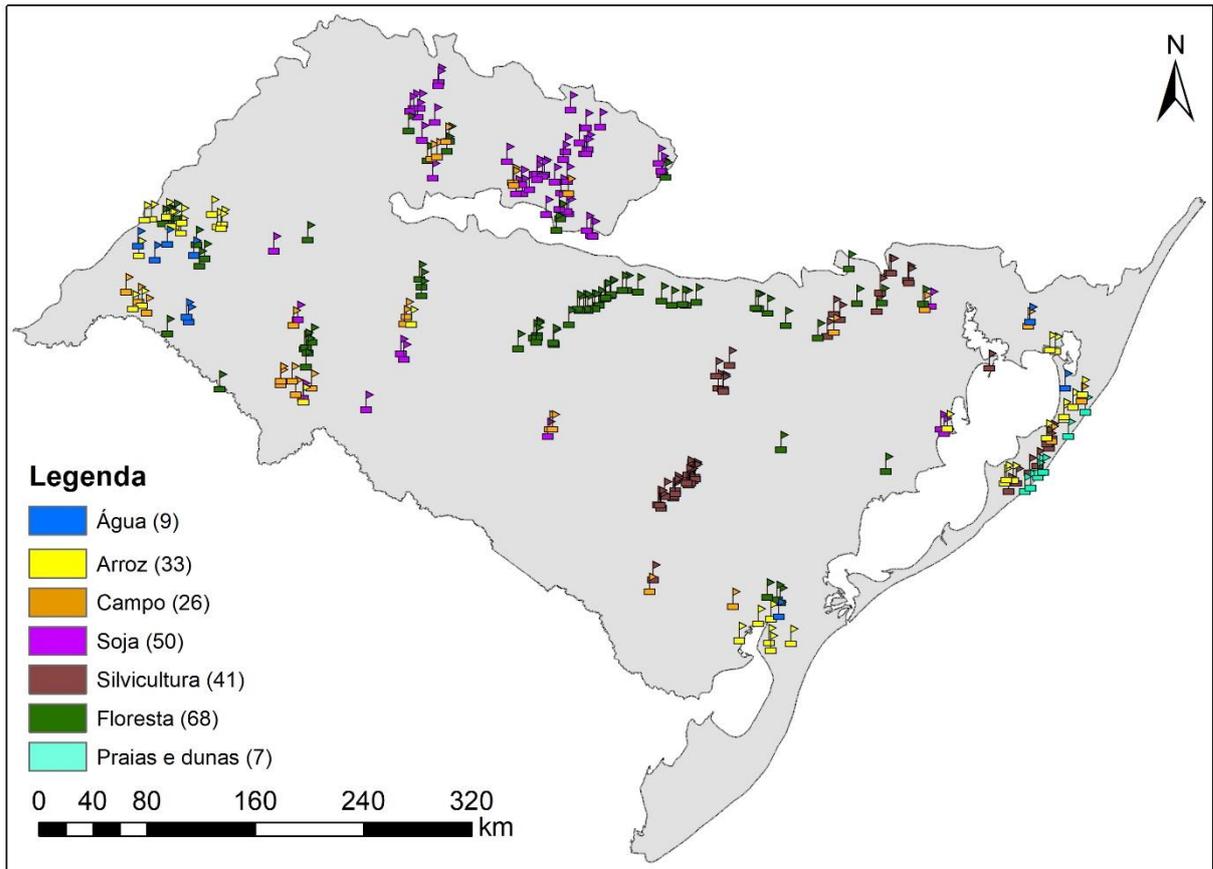


Figura 2: Bandeiras mostrando a distribuição das áreas de treinamento e o número de amostras que foram usadas para a classificação.

Classificação de uso e cobertura vegetal

As categorias de uso do solo e cobertura vegetal foram baseadas nos critérios estabelecidos por Anderson et al (1976), sendo elencadas nove classes para o Bioma Pampa gaúcho: Áreas agrícolas (Arroz, Soja, e Mosaico de Culturas), Floresta, Campo, Praias e Dunas, Água, Área Urbana e Silvicultura. A etapa de classificação levou em consideração as pequenas diferenças e características específicas de cada região, adotando um classificador treinado exclusivamente para atuar em cada uma delas.

Para as classes Água, Praias e Dunas, Floresta, Silvicultura e Campo, o classificador utilizado foi Árvore de Decisão (AD), enquanto que para as classes agrícolas (Arroz, Soja, e Mosaico de Culturas) foi gerado uma máscara de cultivo e utilizado o classificador por AD dentro dessa máscara e, por fim, para a classe Área Urbana, foi utilizado uma combinação entre imagens noturnas (DMSP-OLS) e EVI.

O classificador utilizado foi Árvore de Decisão (AD) para as classes de uso do solo e cobertura vegetal (água, praias e dunas, floresta, silvicultura e campo), sendo utilizada a série temporal MODIS filtrada pelo *Timesat*, composta por 23 imagens do índice de vegetação EVI. As AD testadas foram construídas utilizando o algoritmo C4.5 (QUINLAN, 1993) em ambiente

MatLab®. Os dados de entrada do classificador foram a própria série temporal e as amostras de treinamento das classes de uso do solo e cobertura vegetal, extraídas a partir de polígonos selecionados em imagens *Landsat 8/OLI*.

Para gerar a máscara de cultivo foi utilizado o método limiar empírico, reconhecidamente eficiente nessa tarefa (SANTOS et al., 2014). O método utiliza imagens de índice de vegetação EVI de mínimo e de máximo valor, selecionando os pixels de menor e de maior valor de EVI encontrados nas imagens dos meses (setembro, outubro, novembro e dezembro) e de máximo desenvolvimento vegetativo da soja e do arroz (dezembro, janeiro, fevereiro, março e abril). Uma imagem de diferenças é então produzida pela subtração da imagem de máximo pela imagem de mínimo valor de EVI. A partir da limiarização da imagem de diferenças, foi possível identificar os pixels que apresentaram a maior variação no período de setembro a abril, comportamento típico de lavouras de verão (WAGNER et al., 2007). O limiar escolhido foi de 0,35 de EVI (limiar de EVI), obtido a partir de interpretação visual na imagem diferença.

A última etapa corresponde à classificação espectro-temporal por AD e posterior cruzamento da classificação com a área de inundação, gerada com o modelo HAND, obedecendo-se à seguinte regra: áreas classificadas como arroz irrigado dentro das áreas de inundação foram mantidas, enquanto áreas classificadas como arroz, mas que estavam fora da área de inundação, foram convertidas para a classe soja. O Modelo HAND utiliza dados topográficos na forma de Modelos Digitais de Elevação – MDE para mapear a superfície, baseando-se na distância vertical à drenagem mais próxima. Para a implementação foram utilizados dados do SRTM (NASA, 2000). Para processar os dados SRTM e gerar o modelo HAND utilizou-se o Sistema para Modelagem Hidrológica Distribuída, também chamado de *TerraHidro*, que está inserido dentro da plataforma *TerraView*, desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE, 2010). Neste estudo foi adotada a altura de 25 metros, conforme proposto por Mengue & Fontana (2016).

A classe Mosaico de Culturas, representa áreas destinadas à agricultura, mas que no ano específico (safra 2013/2014) não estavam sendo utilizadas. Estas são áreas que têm uso agrícola e que alternam o arroz e pousio com campos ou rotação de culturas com cultivo de sequeiro. Foram produzidas máscaras de cultivos para os anos safras anterior e posterior (2012/2013 e 2014/2015) e somadas as áreas das máscaras de cultivo. A metodologia utilizada para geração da classe mosaico de culturas foi a mesma da etapa anterior para as classes arroz e soja, com posterior limiarização da imagem de diferenças entre o máximo e mínimo EVI.

A classe Área Urbana foi delimitada utilizando a metodologia proposta por Lu et al (2008), que utilizaram uma combinação de imagens de iluminação noturna com índices de vegetação. As imagens de iluminação noturna *Defence Meteorological Satellite Program - Operational Linescan System* (DMSP-OLS), com resolução espacial de 550 metros, foram obtidas através do endereço <https://ngdc.noaa.gov/eog/dmsp/downloadV4composites.html>. Foram utilizadas as imagens do tipo *stable lights*, que são compostas por uma média anual de imagens colhidas pelo sensor, e eliminadas todas as fontes eventuais de iluminação, mantendo apenas as fontes de iluminação permanente, que são características de áreas urbanas. Nas imagens noturnas DMSP-OLS para identificar as áreas urbanas, foi definido um limiar, maior do que 40, que corresponde às áreas com altas luminosidades. A Imagem de EVI e noturna foram reclassificadas de forma a separar em uma imagem booleana as áreas urbanas e não urbanas. A próxima etapa foi realizar uma operação *overlay* com as duas imagens booleanas, resultando em uma imagem que possui para as áreas urbanas apenas valores diferentes de zero.

Para a detecção das áreas urbanas nas imagens EVI do sensor MODIS foi definido um limiar menor que 0,40 de EVI, dado que valores baixos de EVI representam áreas urbanas, corpos d'água, solo exposto e etc. A data da imagem EVI foi a segunda quinzena de dezembro de 2013.

Validação dos resultados

O processo de validação dos experimentos se deu a partir de dois conjuntos de informações: dados oficiais do IBGE (IBGE, 2017) e amostras de referência independentes das amostras de treinamento coletadas diretamente nas imagens Landsat 8 OLI. Os dados oficiais do IBGE incluem área cultivada de arroz irrigado, soja e área plantada de silvicultura por espécie florestal (eucalipto, pinus e outras espécies) para os 106 municípios que compõem a área de estudo, no ano de 2014. Os dados do IBGE foram usados apenas para estas três classes porque são as únicas que possuem dados de referência em nível municipal, aplicando os testes estatísticos de: análise de correlação (r), coeficiente de concordância (d) Willmott et al. (1985), coeficiente de concordância refinado (dr) Willmott et al. (2012), erro médio (ME) e a raiz quadrada do erro médio quadrático (RMSE).

Por fim, foram utilizadas amostras de referência selecionadas a partir das imagens *Landsat 8 OLI* para todas as classes da classificação MODIS. As análises estatísticas utilizadas foram índice *Kappa* (IK) e a exatidão global (EG), além da geração da matriz de confusão com a análise detalhada da acurácia do produtor e do usuário por classe de uso do solo e cobertura vegetal. Não foi realizado trabalho de campo na área de estudo, principalmente por motivos financeiros, já que a área possui uma extensão muito ampla e entendemos que as amostras de

validação obtidas com as imagens Landsat fornecem as informações necessárias para a etapa de validação.

A Figura 3 apresenta o fluxograma de funcionamento detalhado da metodologia empregada em suas diferentes etapas.

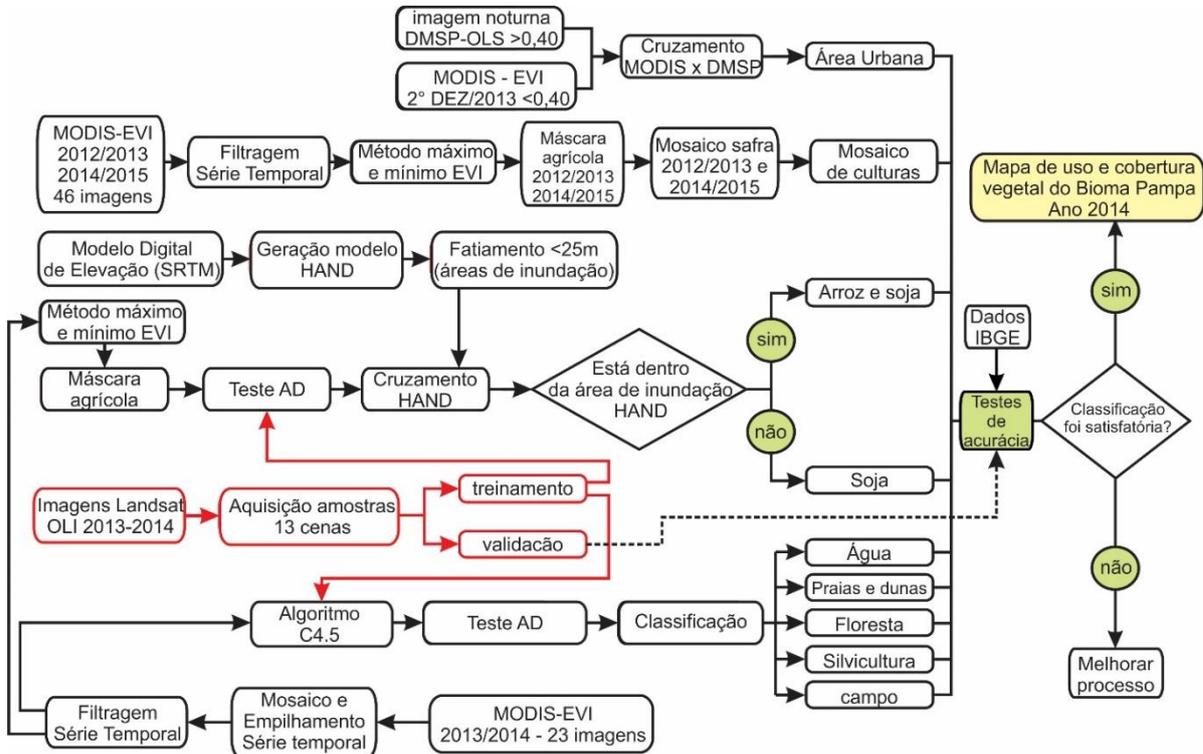


Figura 3: Fluxograma descrevendo as etapas do processamento da classificação do mapa de uso do solo e cobertura vegetal.

Resultados

Dados de treinamento

Parte importante do mapeamento do uso e cobertura vegetal foi a seleção das amostras de treinamento com as imagens Landsat. Os dados utilizados neste trabalho, conforme nomenclatura do *United States Geological Survey* (USGS) Tier 1 (T1), são adequados para análise de séries temporais, com considerável qualidade radiométrica e um RMSE de registro posicional $<0,5$ pixel (VERMOTE et al., 2016).

Os tamanhos das amostras ficaram no intervalo entre 12 a 3271 hectares, distribuídos ao longo de toda a área de estudo, sendo que cada polígono de treinamento gerado por interpretação visual foi conferido com a ferramenta do SATVeg (Figura 04) e sua curva espectro temporal foi comparada com a curva típica esperada para determinada classe. Esse procedimento garantiu que nenhuma amostra tenha sido coletada erroneamente, erro muito

comum nesse tipo de procedimento, já que muitas vezes o analista não consegue identificar com clareza um tipo de feição apenas pelo atributo visual.

É importante mencionar que algumas classes de treinamento ficaram restritas a sua área de abrangência, como a classe Praias e Dunas, onde sua aquisição foi basicamente ao longo da faixa litorânea. As amostras da classe Floresta ficaram praticamente restritas ao longo dos principais cursos d'água como os Rios Jacuí, Ibicuí e Vacacaí, principalmente por apresentarem áreas com manchas mais homogêneas e com menos interferência antrópica, devido especialmente às Áreas de Preservação Permanente (APP), conforme código florestal.

As amostras da classe Silvicultura foram coletadas principalmente nos municípios de Piratini e de Mostardas, que são grandes produtores de madeira, principalmente a espécie *Pinus elliottii*. Conforme dados IBGE (2017), Piratini possui mais de 72% de sua área de silvicultura plantada com essa espécie de pinus, enquanto o município de Mostardas possui apenas espécie pinus na sua produção de madeira. Como esses dois municípios apresentam áreas uniformes e homogêneas da classe Silvicultura, a aquisição das amostras foi parte importante neste trabalho para garantir a correta separação e identificação das classes Silvicultura da classe Floresta, já que esta atividade vem aumentando sua área plantada, principalmente sobre áreas campestres, inclusive onde o solo é mais raso (PILLAR & LANGE, 2015).



Figura 04: Exemplo de conferência de um polígono de treinamento da classe arroz na interface SATVeg, em laranja polígono gerado pela interpretação com imagens Landsat e em amarelo o tamanho do pixel do sensor MODIS.

Resultado da classificação

A Figura 05 apresenta o mapa de uso e cobertura vegetal elaborado com as imagens MODIS para o ano de 2014, evidenciando que a região norte da área de estudo apresenta uso

agrícola mais intenso, principalmente para a classe Soja. As áreas destinadas a produção de arroz irrigado se concentram ao longo dos principais rios e nas áreas baixas ao longo da Lagoa dos Patos. Também é possível visualizar que as áreas classificadas como Campo estão distribuídas em todo o Bioma Pampa, principalmente na metade Oeste no entorno da APA do Ibirapuitã. A classe Silvicultura está concentrada principalmente na Serra do Sudeste, Baixo Jacuí e Litoral, próximo ao município de Mostardas.

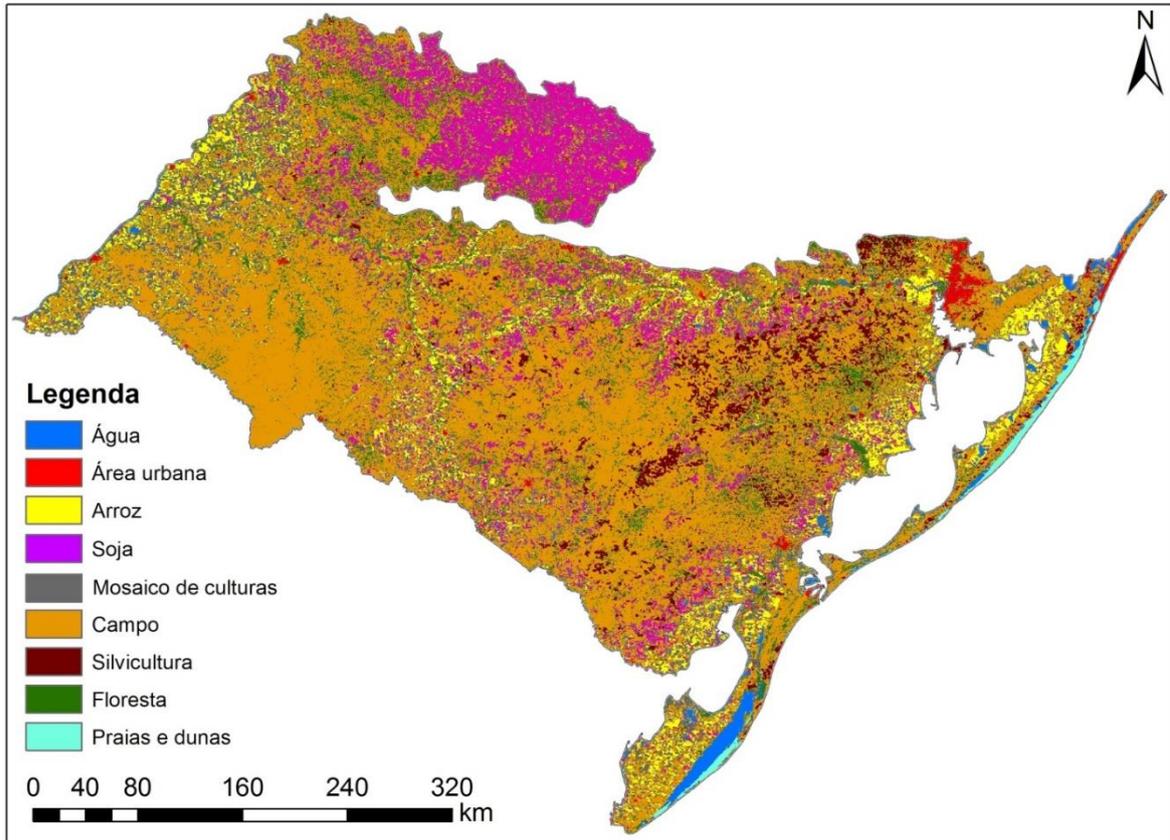


Figura 05: Mapa de uso e cobertura vegetal para o Bioma Pampa no ano de 2014, gerado a partir dos dados do sensor MODIS.

A Tabela 01 apresenta a quantificação das classes em termos de área e percentual de cobertura, onde pode-se verificar que a classe Campo ocupa a maior área com 51,05 % e a menor é a classe Área urbana com 0,77 % da área total. Importante destacar a grande área destinada para atividades agrícolas e silvicultura (somando as classes silvicultura, arroz, soja e mosaico de culturas) representa 33,96 % do total da área.

Tabela 01: Quantificação das áreas classificadas com o sensor MODIS para o Bioma Pampa para o ano de 2014.

Classes	Área (ha)	(%)
Água	419.452	2,54
Área Urbana	127.232	0,77
Arroz	1.194.922	7,25
Campo	8.419.738	51,05
Soja	1.981.675	12,02
Silvicultura	730.442	4,43
Floresta	1.756.916	10,65
Praias e dunas	88.077	0,53
Mosaico de culturas	1.774.540	10,76
Total	16.492.994	100

A Exatidão Global (EG) foi de 90,09% e o Índice Kappa (IK) foi de 0,8853, sendo que o menor acerto para acurácia do produtor foi para a classe Silvicultura com 76,24% (Tabela 2) e o maior acerto foi para a classe Área Urbana com 98,49%. Trabalhos que utilizaram metodologia similar para classificação de área urbana com imagens MODIS e dados DMSP-OLS, tiveram resultados positivos. Lin et al (2014) encontraram valores superiores a 75% de acurácia, classificando áreas urbanas na China, com o uso combinado de NDVI e imagens reflectância do MODIS e dados DMSP-OLS, concluindo que o resultado da classificação é muito similar ao classificado com Landsat e muito melhor do que o produto MODIS (MCD12Q1) de cobertura terrestre. A partir dos dados apresentados na matriz de confusão foi possível analisar e saber quais classes possuem semelhanças espectrais. A seguir será apresentado de forma detalhada dados da avaliação por classes de uso do solo e cobertura vegetal.

Tabela 2 – Matriz de confusão do mapa de uso e cobertura vegetal para o ano de 2014.

Classificação	Referência de campo									Total	Ac. do us. (%)
	Água	Área Urb.	Arroz	Campo	Soja	Silvic.	Floresta	Praias e dunas	Mos. culturas		
Água	672	9	8	1	11	0	8	18	24	751	89,48
Área Urb.	0	1766	0	0	0	0	0	0	0	1766	100
Arroz	5	2	1297	1	37	1	12	0	4	1359	95,37
Campo	16	4	34	2408	32	155	57	0	50	2756	87,37
Soja	0	0	48	3	843	1	16	0	6	917	91,93
Silvic.	0	0	0	10	4	767	1	0	1	783	97,96
Floresta	17	8	21	40	15	57	773	0	12	943	81,97
Praias e dunas	4	0	0	1	1	0	2	227	0	235	96,60
Mos. Culturas	26	4	129	32	76	25	25	0	1020	1337	75,17
Total	740	1793	1537	2496	1019	1006	894	245	1117	10847	
Ac. do prod. (%)	90,81	98,49	84,38	96,47	82,73	76,24	86,47	92,65	91,32		

A análise da acurácia do produtor e do usuário mostrou que as maiores semelhanças espectrais foram entre as classes Silvicultura, Campo e Floresta. Do total de 1006 pontos (pixels) de referência terrestre para a classe Silvicultura, 155 pontos (15,40% do total) foram alocados à classe Campo e 57 pontos (5,67% do total) foram alocados à classe Floresta. A alocação de pontos de forma errônea realizada pelo classificador principalmente das classes com cobertura vegetal, evidencia a similaridade espectral e temporal das classes com cobertura vegetal e a dificuldade de separar essas classes. Portanto, se fosse utilizado apenas como critério o atributo espectral para separação entre classes vegetais, os índices de acerto seriam mais baixos.

A Figura 06 apresenta os perfis temporais de EVI extraídos das amostras de treinamento das classes em estudo. Para a classe Floresta percebe-se uma tendência de aumento do EVI na primavera e verão, o que é esperado já que nesse período existe o crescimento da vegetação (KUPLICH et al. 2013), com o aumento de biomassa e seus períodos específicos de brotação e um aumento acentuado nos valores de reflectância na banda do infravermelho próximo (NIR), fazendo com que o índice de vegetação EVI aumente nesse período.

Para a classe Silvicultura não foram verificadas diferenças marcantes entre inverno e verão, apenas um pequeno aumento no EVI no período do verão, mas menos acentuado do que observado na classe Floresta. É importante salientar que na seleção das datas para separar as Classes Floresta e Silvicultura foram escolhidas principalmente imagens do período de inverno (2013/193, 2013/209 e 2013/225). Neste período é quando existem as maiores diferenças de EVI entre as classes Floresta e Silvicultura, o que está associado à ocorrência Floresta Estacional Decidual (distribuída por quase todo o Bioma, principalmente ao longo dos cursos d'água) e a Floresta Estacional Semidecidual (porção leste do Bioma, conforme IBGE (2004)). Estas classes de Florestas, portanto, pelo caráter decíduo, têm como característica a perda de folhas no período de inverno. Por outro lado, a classe Silvicultura, por se tratar na maior parte por plantações da espécie pinus, não possuem essa característica de perda de folhas, o que explica a diferença nos valores de EVI no período de inverno, se constituindo, portanto, em data importante para a separação espectral e posterior mapeamento.

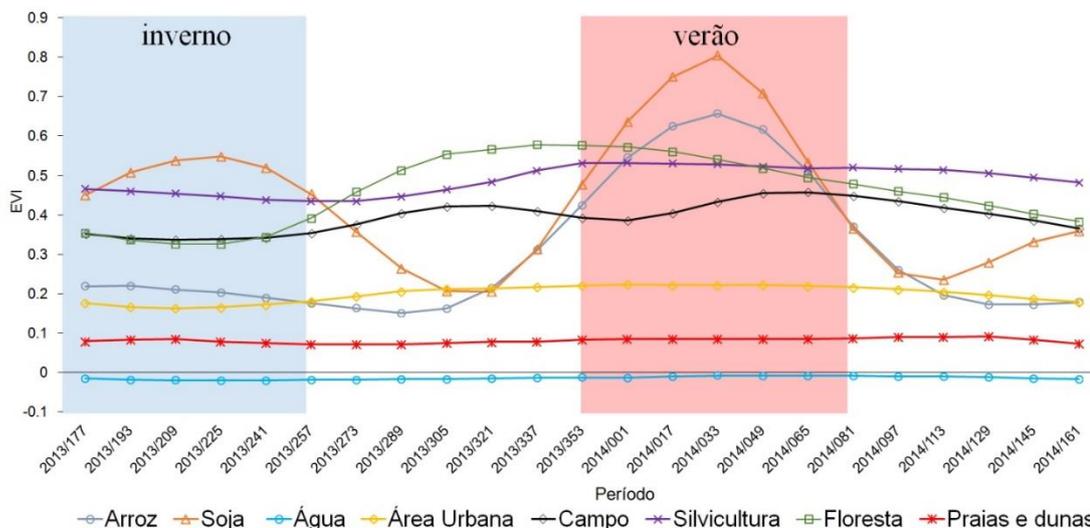


Figura 06: Perfis temporais de EVI-MODIS para as classes de uso e cobertura vegetal do ano de 2014.

Já a classe Campo possui a curva temporal de EVI com uma diferença entre inverno e verão menos acentuada e valores de EVI menores quando comparada com a Floresta. A variação da curva temporal da classe Campo ao longo do período de inverno e verão, conforme Boldrini (1997), estão associados com a maior disponibilidade de energia (radiação e temperatura do ar), bem com o crescimento de espécies C4 nas pastagens naturais do Bioma Pampa. A curva espectro-temporal da classe Campo se assemelha aos trabalhos encontrados por Jacobsen et al. (2004), Wagner et al (2013), e Scottá e Fonseca (2015). As imagens do período do verão foram utilizadas para separar espectralmente a classe Campo das classes Silvicultura e Floresta, já que este período (principalmente nas datas de aquisição das imagens 2013/353, 2014/001 e 2014/017) possui as maiores diferenças de EVI.

Para a classe Área Urbana foram observados os melhores resultados de acurácia do produtor, com 98,49% de acerto. A combinação das imagens noturnas (DMSP-OLS) com a imagem de EVI <0,40 conseguiu eliminar a chance de classificar erroneamente classes com similaridade espectral, como as classes Água e Praias e Dunas.

A Figura 07 apresenta a reflectância em diferentes bandas do sensor MODIS para os períodos de inverno e verão, para as três classes que abrangem grupos vegetais com as maiores semelhanças espectro-temporais. Fica evidente que a similaridade espectral entre as classes é muito grande, sendo as diferenças de valores entre inverno e verão marcantes, o que está associado ao ciclo fenológico de primavera e verão, acompanhados de maiores valores de biomassa. As maiores reflectâncias são observadas no verão para a banda do infravermelho próximo (NIR) para as três classes, conforme esperado (ROSEMBACK et al., 2010). Já na região do infravermelho médio (MIR) os menores valores são para as classes Silvicultura e Floresta (verão), resultado que parece coerente, já que essas classes apresentam maior biomassa

e espera-se maior quantidade de folhas e, conseqüentemente, maior quantidade de água no dossel, reduzindo a reflectância, quando comparada com a classe Campo (JENSEN, 2009).

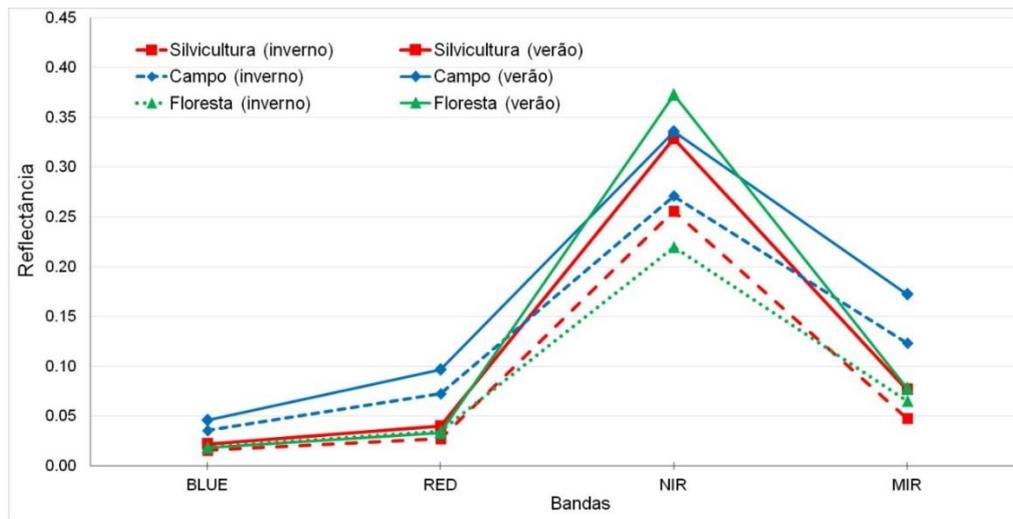


Figura 07: Reflectância de superfície do sensor MODIS para as três classes, imagem do período de inverno 2013/209 (referente ao mês de julho) e imagem do período de verão 2014/001 (referente ao mês de janeiro).

Os erros de classificação observados para as Classes Silvicultura e Campo, podem estar relacionados com a forma e organização espacial das áreas florestais de silvicultura, principalmente nas áreas localizadas na Serra do Sudeste, próximos dos municípios de Bagé, Encruzilhada do Sul e Piratini, onde a concentração desta classe é muito alta. O formato e distribuição entre áreas de campo ou vegetação rasteira (Figura 08) pode ser um dos indicativos da similaridade espectral entre classes. Observando a figura 08, fica clara a degradação espacial da imagem MODIS, com resolução espacial de 250 metros, uma vez que o afastamento entre áreas florestais de silvicultura é em torno de 200 a 300 metros. Nesses casos, sensores com uma melhor resolução espacial seriam mais indicados, como o Landsat que possui resolução espacial de 30 metros, mas, por outro lado, não contam com boa resolução temporal, o que é fundamental para a aplicação aqui investigada.

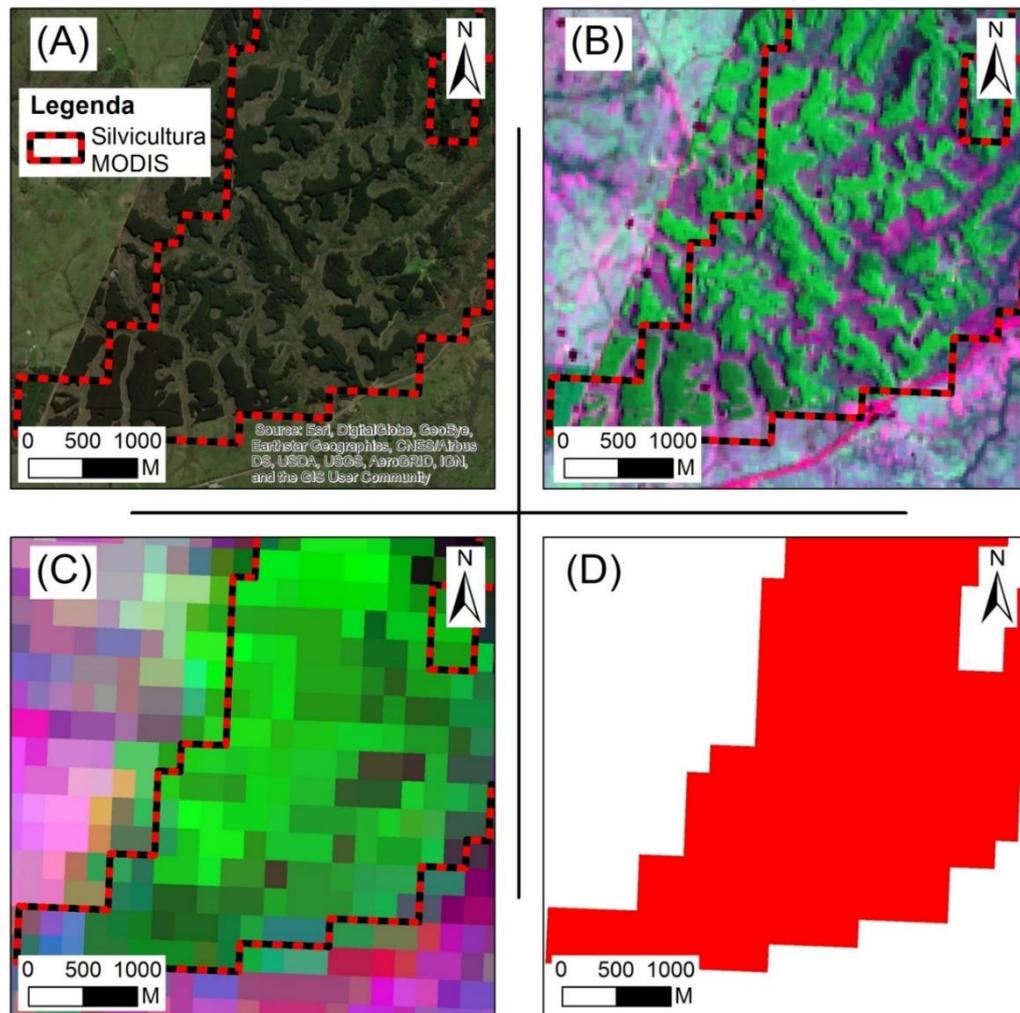


Figura 08: Representação em uma área teste no município de Bagé (A) Imagem GeoEye de 28/12/2013 créditos (ESRI), (B) Imagem Landsat 8 OLI RGB456 de 28/01/2014 (C) Imagem Reflectância MODIS RGB234 de 2014/001(D) Classificação da classe silvicultura com MODIS.

As classes de uso agrícola, como Arroz e Soja, apresentaram uma acurácia do produtor de 84,38% e 82,73%, respectivamente. As maiores semelhanças espectrais foram entre as classes Mosaico de Culturas, Soja e Arroz. Quanto à metodologia proposta, verificou-se que a geração da máscara agrícola e utilização desta no processo classificatório foi etapa fundamental para o acerto na separação das culturas anuais do restante das classes. A elaboração das imagens de máximos e mínimos EVI durante o período da safra de verão e a posterior geração da imagem diferença foi igualmente capaz de selecionar corretamente as áreas onde a variação de EVI, o que é característico de culturas anuais de verão. Diversos trabalhos já comprovaram que esta metodologia de identificação das máscaras agrícolas, que usa o atributo temporal em séries MODIS sequencialmente arranjadas, tem alto potencial de acerto (JOHANN et al., 2012; VICTORIA et al., 2012; MENGUE & FONTANA, 2015).

A Figura 09 apresenta a AD para as classes Arroz e Soja, aplicada na área selecionada pela máscara agrícola, definida pela limiarização da imagem de máximos e mínimos EVI. Foram selecionados três importantes períodos. A raiz da árvore (parte superior) seleciona uma imagem que representa o período que antecede o início do ciclo (2013/225) no mês de agosto, indicando que o registrado nesse período é determinante para a separação entre as duas culturas. O preparo da terra para o cultivo de arroz exige maior sistematização da área em função do uso de irrigação por inundações. Isto impede o cultivo no período de inverno, determinando valores de EVI baixos e estáveis no período, típico de solo descoberto. O segundo período que o algoritmo selecionou é referente ao mês de fevereiro (2014/033), período em que a soja e o arroz apresentam grande acúmulo de biomassa, mas com maiores valores associados à soja. Isto é típico de leguminosas, mas também decorre da influência da água de irrigação no arroz, que contribui para a diminuição do índice. O terceiro período selecionado foi no mês de maio (2014/145), período posterior à colheita para as duas culturas, e que as áreas de soja apresentam valores de EVI superiores quando comparadas com as áreas de arroz. Os valores de EVI utilizados para o critério de separação espectral ficaram entre 0,32 a 0,35, ambos no período que antecede o início e no final do ciclo das culturas. Nas áreas destinadas à cultura da soja, principalmente na porção norte da área do Bioma Pampa, a curva temporal de EVI da cultura de soja possui dois picos por ano: no verão, associado ao cultivo de soja, e no período de inverno associado ao cultivo dos cereais. Já nas áreas de arroz não existe o segundo ciclo no período de inverno.

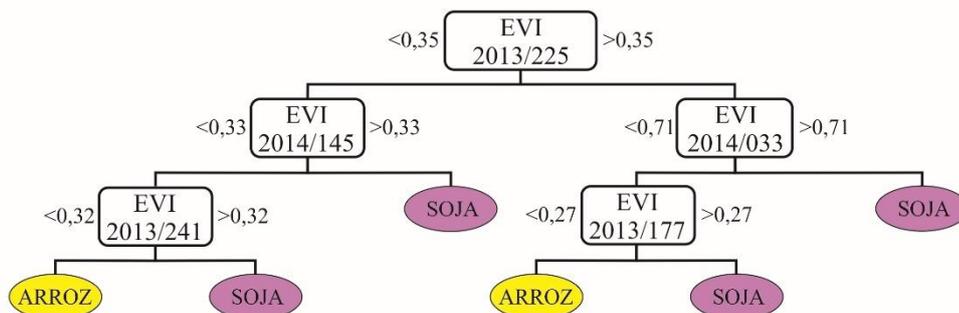


Figura 09: Árvore de decisão definida pelo algoritmo C4.5 para as classes arroz e soja.

Importante salientar ainda que a área de inundações gerada com o modelo HAND foi um importante critério para separar as áreas baixas (várzeas) das áreas mais altas. A área de várzea (<25 m) mapeada com o modelo HAND ocupa 9.834.202,52 ha, o que representa 59,62% do total da área do Bioma Pampa. Portanto, em grande parte do Bioma Pampa, onde o relevo é suavemente ondulado e onde existe a viabilidade de obtenção de água para a irrigação, as condições são apropriadas para o cultivo de arroz irrigado. Destaca-se também que somente

parte da área de várzea mapeada com o modelo HAND é efetivamente utilizada para o cultivo com arroz irrigado. Klering et al (2013), utilizando uma série de 10 safras, identificaram com imagens MODIS uma área potencial de uso com o arroz irrigado de 3.322.037 ha. Este dado é coerente com SOSBAI (2012), que apontou que as áreas de arroz irrigado abrangem cerca de 5,4 milhões de hectares de terras baixas, dos quais, em torno de 3,0 milhões de hectares são utilizados com arroz irrigado, sendo que anualmente cultiva-se pouco mais de um milhão de hectares, o que pode ser justificado pela adoção do sistema de pousio e rotação de culturas que é, em média, de dois anos.

O cruzamento das áreas de inundação (HAND) com a classe Arroz gerou uma área total cultivada de 1.134.972 ha (Tabela 03) para a safra 2014. Apesar do resultado ter superestimado em 12,83% o dado oficial do IBGE de 1.005,915 ha, chegou mais próximo do que o valor inicial sem o cruzamento com o modelo HAND, que foi de 1.260.271 ha. O mesmo aconteceu com a classe Soja que, depois do cruzamento com a área de inundação, gerou uma área de 1.601.685 ha, subestimando em 11,37% os dados oficiais do IBGE de 1.807,109 ha, e chegando mais próximo do valor inicial sem o cruzamento com o modelo HAND, que foi de 1.477.139 ha. Portanto, se aceitarmos como corretas as estimativas oficiais, a superestimativa para a classe Arroz e a subestimativa para a classe Soja, pode ser um indicativo de que parte da área cultivada com soja no Bioma Pampa esteja localizada nas áreas de várzea mapeadas com o modelo HAND.

Tabela 3 – Área oficial (IBGE, 2017) e áreas obtidas com a classificação MODIS-EVI para as três classes com dados oficiais municipais.

Variáveis	Soja	Arroz irrigado	Silvicultura
Área oficial IBGE (ha)	1.807.109	1.005.915	491.707
Área MODIS (ha)	1.601.685	1.134.972	561.835
Diferença (MODIS-IBGE) (ha)	-205.424	129.057	70.128
Diferença (%)	-11,37	12,83	14,26
Erro Médio - ME (ha)	-1.937,97	1.217,52	661,58
RMSE (ha)	8.821,3	3.935,9	4.098,1
Coef. Concordância Willmott – (d)	0,9783	0,9893	0,9293
Coef. Concordância Aprimorado Willmott – (dr)	0,8704	0,8822	0,7406
Coef. de correlação – (r)	0,9452	0,9766	0,7870

Do ponto de vista metodológico, salienta-se, portanto, que o critério de variabilidade do EVI ao longo do ciclo não deve ser utilizado de forma isolada para separação entre arroz e soja na região. O contexto do cultivo, introduzido neste trabalho pela localização das áreas em relação a drenagem mais próxima (HAND), foi fundamental para obtenção de melhores resultados.

Quando comparamos os dados da classificação MODIS para as três classes (soja, arroz e silvicultura) com os dados de referência do IBGE em nível municipal (106 municípios incluídos dentro do Bioma Pampa), os resultados mostram alta concordância e baixa dispersão em ambas as classes Soja e do Arroz (Figura 10). Para a classe Silvicultura os dados apresentam uma dispersão mais alta, o que é coerente com o aspecto apresentado anteriormente do tipo de ocupação das áreas e a provável inadequação das imagens MODIS nas áreas dos hortos. A distribuição foi uniforme dos dados em torno da linha 1:1 para a classe Arroz e para a classe Soja, enquanto que a classe Silvicultura apresentou uma distribuição mais dispersa dos dados. A classe Arroz apresentou um coeficiente de correlação (r) de 0,9766, maior do que para a classe Silvicultura com $r=0,7870$. O erro médio (ME) a nível municipal obteve uma superestimativa para as classes Arroz e Silvicultura, com 1.217,52 ha e 661,58 ha respectivamente, e uma subestimativa para a classe Soja de 1.937,97 ha. O RMSE, mais sensível aos grandes erros, por elevar as diferenças individuais ao quadrado e apresentar valores do erro nas mesmas dimensões da variável analisada, foi menor para a classe Arroz, com 3.935,9 ha, e maior para a classe Soja, com 8.821,3 ha.

Por fim, é importante lembrar que os dados oficiais do IBGE são estimativas que carregam certo grau de incerteza e não podem, no contexto deste trabalho, serem considerados como dados de verdade de campo. Quando ocorrem diferenças entre dados obtidos pela metodologia proposta e os dados oficiais, difícil concluir qual metodologia se aproxima mais da realidade.

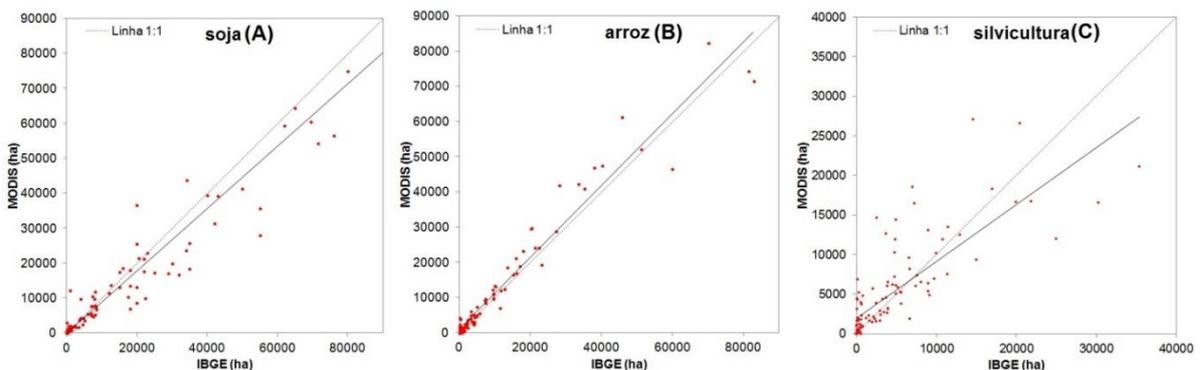


Figura 10: Gráfico de dispersão entre os dados de área das classes Soja (A), Arroz (B) e Silvicultura (C) MODIS -EVI com os dados oficiais (IBGE, 2017)

Conclusões

Neste trabalho, a capacidade de séries temporais de EVI do sensor MODIS foi avaliada para o mapeamento do uso e cobertura vegetal no Bioma Pampa no Estado do Rio Grande do Sul. O período de estudo compreendeu os meses de junho de 2013 até junho de 2014. A análise proposta leva em conta as especificidades das regiões. Além dos dados MODIS, os processos incluíram ainda dados SRTM e imagens noturnas (DMSP-OLS) para avaliar questões de irrigação e localização de áreas urbanas, associados ao classificador hierárquico por Árvore de Decisão (AD), treinada automaticamente pelo algoritmo C4.5.

O mapa de uso do solo e cobertura vegetal para o Bioma Pampa produzido para o ano de 2014 mostrou quantificação compatível com os dados registrados pelo IBGE. A metodologia para estimação da área de inundação através do modelo HAND mostrou-se eficiente para separar as áreas de várzea, aumentando a exatidão da classificação por AD entre a classe Arroz de outras Classes com ciclos coincidentes, como a classe Soja.

Apesar da limitação dos dados DMSP-OLS, devido à resolução espacial de 550 metros, o seu uso combinado com as imagens EVI do sensor MODIS de 250 metros gerou resultados com considerável qualidade no mapeamento, principalmente em áreas urbanas maiores e mais densamente ocupadas onde a iluminação noturna é maior.

A utilização dos dados MODIS é uma escolha adequada para geração desse tipo de produto para o Bioma Pampa. O potencial da série temporal MODIS, do produto MOD13Q1 (composição de 16 dias livre de nuvens) pode fornecer uma série de mapas de uso do solo e cobertura vegetal, desde o início da série temporal MODIS (2000) e analisar as mudanças de uso ao longo de quase duas décadas. Importante destacar que, embora promissora, a metodologia de utilização da série temporal MODIS para a identificação do uso do solo e cobertura vegetal também depende do tipo da paisagem a ser classificada, e do seu grau de homogeneidade ou heterogeneidade. Isto é, o grau de mistura dentro de um pixel MODIS. No caso do Bioma Pampa, as parcelas de terra em relação ao tamanho do pixel MODIS são compatíveis com a resolução do sensor, principalmente na porção oeste do Bioma.

O classificador por AD foi importante como um identificador dos melhores períodos para separar as classes, conhecer melhor a dinâmica temporal e quais são os períodos onde existe a melhor separabilidade espectral. A utilização da classificação por AD mostrou resultados de qualidade quando associada aos outros dados utilizados neste estudo. Como recomendação para trabalhos futuros, seria interessante a utilização combinada de outros índices de vegetação, como o NDVI, imagens de reflectância e também métricas fenológicas

como tentativa de mineração de dados. Desta maneira, existe a possibilidade de melhorar a acurácia entre classes, principalmente as com cobertura vegetal, que são aquelas onde as similaridades espectrais utilizando apenas as imagens EVI foram maiores, como as classes Silvicultura, Floresta e Campo.

Bibliografia

ANDERSON, J. R.; HARDY, E. E.; ROACH, J. T.; WITMER, R. E.. **A Land Use and Land Cover Classification System for Use with Remote Sensor Data**. Washington, D.C.: United States Geological Survey, 1976. 36 p.

BOLDRINI, I. I. A flora dos campos do Rio Grande do Sul. *In*: PILLAR, V.P.; MÜLLER, S.C.; CASTILHOS, Z.M.S; JACQUES, A.V.A. (ed). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, 2009. 403p.

BORGES, E. F.; SANO, E. E.; MEDRADO, E. “Radiometric quality and performance of TIMESAT for smoothing moderate resolution imaging spectro radiometer enhanced vegetation index time series from western Bahia State, Brazil.” **Journal of Applied Remote Sensing 8**, Paper 083580-1, 2014.

BROWN, J.C., KASTENS, J.H., COUTINHO, A.C., VICTORIA, D.D.C., BISHOP, C.R. Classifying multiyear agricultural land use data from Mato Grosso using timeseries MODIS vegetation index data. *Remote Sensing of Environment* 130, 39– 50. 2013.

FRIEDL, M. A.; MCIVER, D.K.; HODGES, J.C.F.; ZHANG, X.Y.; MUCHONEY, D.; STRAHLER, A.H.; WOODCOCK, C.E.; GOPAL, S.; SCHNEIDER, A.; COOPER, A.; BACCINI, A.; GAO, F.; SCHAAF, C. Global land cover mapping from MODIS: algorithms and early results. **Remote Sensing of Environment** 83, 287 – 302, 2002.

HASENACK, H.; CORDEIRO, J.L.P; WEBER, E.J. (Org.). 2015. *Uso e cobertura vegetal do Estado do Rio Grande do Sul–situação em 2002*. Porto Alegre: UFRGS IB Centro de Ecologia. 1a ed. ISBN 978-85-63843-15-9

HUETE, A., JUSTICE, C., & LIU, H. Development of vegetation and soil indices for MODIS-EOS. *Remote Sensing of Environment*, 49, 224-234. 1994.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. 2004. *Mapa da Vegetação do Brasil*. Ministério do Planejamento, Orçamento e Gestão. Rio de Janeiro.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. Banco de Dados Agregados: Sistema IBGE de Recuperação Automática – SIDRA. 2017. Disponível em: <<http://www.sidra.ibge.gov.br>>. Acesso em: 23 jan. 2017.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. Sistema IBGE de recuperação automática: banco de dados agregados. Rio de Janeiro: IBGE. Recuperado em 02 de fevereiro de 2017, de [http:// www.sidra. ibge.gov.br/bda/agric/](http://www.sidra.ibge.gov.br/bda/agric/). 2017.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. 2004. *Mapa de Biomas do Brasil, primeira aproximação*. Rio de Janeiro: IBGE. Acessível em www.ibge.gov.br.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS – INPE . TerraView 4.5.0. São José dos Campos: INPE. Recuperado em 12 de novembro de 2016, de [http:// www.dpi.inpe.br/terraview](http://www.dpi.inpe.br/terraview) 2010

INSTITUTO NACIONAL DO MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS - IBAMA (Brasil). Ecossistemas Brasileiros - Campos Sulinos. Disponíveis em: <http://www.ibama.gov.br/ecossistemas/campos_sulinos.htm>. Acesso em: 21 Out. 2016.

JACÓBSEN, L. O.; FONTANA, D. C.; SHIMABUKURO, Y. E. Efeitos associados a El Niño e La Niña na vegetação do Estado do Rio Grande do Sul, observados através do NDVI/NOAA. **Revista Brasileira de Meteorologia**, v. 19, n. 1, p.129-140, 2004.

JACÓBSEN, L. O.; FONTANA, D. C.; SHIMABUKURO, Y. E. Efeitos associados a El Niño e La Niña na vegetação do Estado do Rio Grande do Sul, observados através do NDVI/NOAA. **Revista Brasileira de Meteorologia**, v. 19, n. 1, p.129-140, 2004.

JENSEN, J. R. Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres. Tradução: Epiphany et al. São José dos Campos: Parêntese, 2009.

JOHANN, J. A., ROCHA, J. V., DUFT, D. G., & LAMPARELLI, R. A. C. (2012). Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. **Pesquisa Agropecuária Brasileira**, 47, 1295-1306. <http://dx.doi.org/10.1590/S0100-204X2012000900015>.

JÖNSSON, P.; EKLUNDH, L. Seasonality extraction from time-series of satellite sensor data. In: *Frontiers of Remote Sensing Information Processing*, CHEN, C.H. (Ed.), p. 487-500. (World Scientific Publishing), 2003.

JÖNSSON, P.; EKLUNDH, L. TIMESAT: a program for analyzing time-series of satellite sensor data. **Computers & Geosciences**, v. 30, n. 1, p. 833-845, 2004.

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*, v.83, n. 1-2, p.3-15. 2002.

KLERING, E. V.; FONTANA, D. C.; ALVES, R.; ROCHA, J.; BERLATO, M. A. Estimativa de área cultivada com arroz irrigado para o estado do rio grande do sul a partir de imagens Modis. **Ciência e Natura**, Santa Maria, v.35, n.2, p.126-135, dez. 2013.

KÖPPEN, W. Climatología. México, DF : Fondo de Cultura Económica, 1948. 71 p.

KUPLICH, T.M., MOREIRA, A., FONTANA, D.C. Série temporal de índice de vegetação sobre diferentes tipologias vegetais no Rio Grande do Sul. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 10 n. 17, p. 11161123, 2013

LIN, J.; LIU, X.; LI, K.; LI, X. A maximum entropy method to extract urban land by combining MODIS reflectance, MODIS NDVI, and DMSP-OLS data. **International Journal of Remote Sensing**. V. 35 N 18 6708-6727, 2014.

LIU, Y., WANG, X., GUO, M., TANI, H., MATSUOKA, N., MATSUMURA, S. Spatial and temporal relationships among NDVI, climate factors, and land cover changes in Northeast Asia from 1982 to 2009. **GIScience and Remote Sensing**. 48 (3), 371– 393, 2011.

LU, D.; TIAN, H.; ZHOU, G.; GE, H. “Regional Mapping of Human Settlements in Southeastern China with Multisensor Remotely Sensed Data.” **Remote Sensing of Environment** 112 (9): 3668–3679, 2008.

MARASCHIN, G. E. Manejo do campo nativo, produtividade animal, dinâmica da vegetação e adubação de pastagens nativas do sul do Brasil. In: PILLAR, V.P.; MÜLLER, S.C.; CASTILHOS, Z.M.S; JACQUES, A.V.A. (ed). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, 2009. 403p.

- MENGUE, V. P.; FONTANA, D. C. Avaliação da dinâmica espectro-temporal visando o mapeamento dos principais cultivos de verão no Rio Grande do Sul. **Bragantia**, Campinas, v. 74, n. 3, p. 331-340, Sept. 2015.
- MENGUE, VAGNER P.; FONTANA, DENISE C.. Identification of suitable areas for irrigated rice cropping using MODIS images and HAND model. **Eng. Agríc.**, Jaboticabal, v. 36, n. 2, p. 329-341, abr. 2016.
- NATIONAL AERONAUTICS AND SPACE ADMINISTRATION – NASA. Jet Propulsion Laboratory. California Institute of Technology. The Shuttle Radar Topography Mission collected topographic data over nearly 80 percent of Earth's land surfaces, creating the first-ever near-global data set of land elevations. NASA. Recuperado em 13 de outubro de 2016, de <http://www2.jpl.nasa.gov/srtm/mission.htm> 2000.
- OVERBECK, G. E. Brazil's neglected biome: The South Brazilian *Campos*. **Perspectives in Plant Ecology, Evolution and Systematics**, v.9, n.1, p. 101-116, 2007.
- OVERBECK, G. E.; BOLDRINI, I. I.; CARMO, M. R. B.; GARCIA, E. N.; MORO, R. S.; PINTO, C. E.; TREVISAN, R.; ZANNIN, A. Fisionomia dos Campos. In: PILLAR, V. D. P.; LANGE, O. **Os campos do Sul**. Porto Alegre: Rede Campos Sulinos. 2015. Cap 3, p. 31-41.
- PARUELO, J. M.; JOBBÁGY, E. G.; SALA, O. E. Current distribution of ecosystem functional types in temperate South América. *Ecosystems*, v. 4, p. 683-698, 2001.
- PEÑA-BARRAGÁN, J. M.; MOFFATT, K.; NGUGI, R. E. Plant, Johan Six Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*, Volume 115, Issue 6, 15 Jun, Pag. 1301–1316, 2011.
- QUINLAN, J. R. C4. 5: programs for machine learning. San Francisco, CA: Morgan kaufmann, 1993.
- ROSEMBACK, R.; FERREIRA, N. J.; SHIMABUKURO, Y. E.; Conforte, J. C. Análise da dinâmica da cobertura vegetal na região sul do Brasil a partir de dados MODIS/TERRA. *Revista Brasileira de Cartografia*, v.2, p.401-4016, 2010.
- ROUGHGARDEN, J.; RUNNING, S.W.; MATSON, P.A. What does remote sensing do for ecology. **Ecology**, 72, 1918–1922. 1991.
- ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; Deering, D.W. Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ.* **1974**, 351, 309.
- SANTOS, J. S., FONTANA, D. C., SILVA, T. S. F., & RUDORFF, F. T. Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 18, 54-63. 2014.
- SAVITZKY, A.; GOLAY, M. J. E. 1964. Smoothing and Differentiation of Data by Simplified Least-Squares Procedures. **Analytical Chemistry**, 36, 1627-1636. 1964. <http://dx.doi.org/10.1021/ac6024a047>
- SCOTTÁ, F. C.; FONSECA, E. L. Multiscale Trend Analysis for Pampa Grasslands Using Ground Data and Vegetation Sensor Imagery. **Sensors** (Basel), v. 15, p. 17666-17692, 2015.
- SOSBAI (Sociedade Sul-Brasileira de Arroz Irrigado) Arroz Irrigado- Recomendações técnicas da pesquisa para do Sul do Brasil. Sociedade Sul- Brasileira de Arroz Irrigado. Itajaí, SC, 179p. 2012.
- VERMOTE, E., JUSTICE, C., CLAVERIE, M., & FRANCH, B. (2016). Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. *Remote Sensing of Environment*. <http://dx.doi.org/10.1016/j.rse.2016.04.008>.

VICTORIA, D. C., PAZ, A. R., COUTINHO, A. C., KASTENS, J., & BROWN, J. C. (2012). Cropland area estimates using Modis NDVI time series in the state of Mato Grosso, Brazil. **Pesquisa Agropecuária Brasileira**, 47, 1270-1278. <http://dx.doi.org/10.1590/S0100-204X2012000900012>.

VIEIRA, M.; FORMAGGIO, A. R.; RENNÓ, C. D.; ATZBERGER, C.; AGUIAR, D. A.; MELLO, M. P. Object based image analysis and data mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. *Remote Sensing of Environment*, v.123, p. 533-562, 2012.

WAGNER, A. P. L.; FONTANA, D. F.; FRAISSE, C.; WEBER, E. J.; HASENACK, H. Tendências temporais de índices de vegetação nos campos do Pampa do Brasil e do Uruguai. **Pesq. agropec. bras.**, Brasília, v.48, n.9, p.1192-1200, set. 2013.

WAGNER, A. P. L.; WEBER, E.; FONTANA, D. C.; DUCATI, J. R.; KLERING, E. Estimativa de área de soja no Rio Grande do Sul utilizando imagens NDVI/MODIS. In: Simpósio Brasileiro de Sensoriamento Remoto, 13, 2007, Florianópolis. Anais... São José dos Campos: INPE, 2007. p.457-464

WEBER, E.J.; HOFFMANN, G.S.; OLIVEIRA, C.V.; HASENACK, H. (Org.). Uso e cobertura vegetal do Estado do Rio Grande do Sul—situação em 2009. Porto Alegre: UFRGS IB Centro de Ecologia, 2016. 1aed. ISBN978-85-63843-20-3

WILLMOTT, C. J., ACKLESON, S. G., DAVIS, R. E., FEDDEMA, J. J., KLINK, K. M., LEGATES, D. R., O'DONNELL, J., & ROWE, C. M. Statistics for the evaluation and comparison of models. **Journal of Geophysical Research**, 90, 8995-9005, 1985.

WILLMOTT, C. J., ROBESON, S. M., & MATSUURA, K. A refined index of model performance. *International Journal of Climatology*, 32, 2088-2094, 2012.

WU, S., J. HUANG, X. LIU, AND G. MA. “Forest Cover Classification from Multi-temporal MODIS Images in Southeast Asia Using Decision Tree.” In *Computer and Computing Technologies in Agriculture V*, edited by D. L. Li and Y. Y. Chen, 400–414. 5th IFIP TC 5/SIG 5.1 Conference. CCTA 2011. Proceedings, Part II. Beijing, October 29–31, 2011. Berlin: Springer. doi:10.1007/978-3-642-27278-3_43. 2012.

ZANOTTA, D. C.; Uma metodologia adaptativa baseada em objetos para detecção semi-automática de desmatamento na Amazônia por imagens de sensoriamento remoto / Daniel Capella Zanotta. – São José dos Campos: INPE, 2014. xxvi + 113 p. ; (sid.inpe.br/mtc-m21b/2014/04.01.05.56-TDI). Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

ZHOU, F.; ZHANG, A.; TOWNLEY-SMITH, L. A data mining approach for evaluation of optimal time-series of MODIS data for land cover mapping at a regional level. **Journal of Photogrammetry and Remote Sensing**. 84 114–129, 2013.

IL.3. Artigo 3: MUDANÇAS DO USO DO SOLO E COBERTURA VEGETAL NO BIOMA PAMPA E A RELAÇÃO COM DADOS AMBIENTAIS E SOCIOECONÔMICOS

Vagner Paz Mengue¹
Marcos Wellausen Dias de Freitas²
Tatiana Silva da Silva³
Denise Cybis Fontana⁴
Fernando Comerlato Scottá⁵

¹**Universidade Federal do Rio Grande do Sul – UFRGS**
Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM)
 Caixa Postal 15.074, CEP 91501-970, Porto Alegre, RS, Brasil.
vagnergeo@yahoo.com.br.

²**Universidade Federal do Rio Grande do Sul – UFRGS**
Departamento de Geografia, Instituto de Geociências
 Caixa Postal 15.001, CEP 91509-900, Porto Alegre, RS, Brasil.
marcoswfreytas@gmail.com

³**Universidade Federal do Rio Grande do Sul – UFRGS**
Departamento de Geodésia, Instituto de Geociências
 Caixa Postal 15.001, CEP 91509-900, Porto Alegre, RS, Brasil.
tatiana.silva@ufrgs.br

⁴**Universidade Federal do Rio Grande do Sul – UFRGS**
Departamento de Plantas Forrageiras e Agrometeorologia
 Avenida Bento Gonçalves, nº7712, CEP 91540-220, Porto Alegre, RS, Brasil.
dfontana@ufrgs.br

⁵**Universidade Federal do Rio Grande do Sul – UFRGS**
Programa de Pós-Graduação em Geociências, Instituto de Geociências
 Caixa Postal 15.001, CEP 91509-900, Porto Alegre, RS, Brasil.
fernando.scotta@ufrgs.br.

RESUMO

O bioma Pampa nos últimos anos tem passando por um processo de mudança de uso do solo, principalmente pela conversão da vegetação campestre para agricultura de grãos e silvicultura. O objetivo principal deste trabalho é analisar os processos de uso do solo e cobertura vegetal no Bioma Pampa Brasileiro, gerados a partir de séries temporais do sensor MODIS, incluindo os principais processos de transformação da paisagem. O período de estudo foi de 2000 e 2014, sendo utilizadas imagens MODIS-EVI e imagens noturnas DMSP-OLS, para geração dos mapas de uso do solo e cobertura vegetal, através de classificação por árvore de decisão. Foram utilizados os limites dos setores censitários do IBGE. Para investigar os processos de transformação da paisagem do Bioma Pampa, foram utilizadas variáveis ambientais, que incluem dados geomorfométricos, métricas da paisagem e dados climáticos e variáveis socioeconômicas. Foram usados modelos de regressão linear local (GWR) e global, além de procedimentos de agrupamentos espaciais (SKATER). Foi verificada uma diminuição em torno de 25% da classe Campo num intervalo de 15 anos, de 10.252.740 ha para 7.676.208 ha. Em contrapartida áreas agrícolas, como a classe Soja, obtiveram um aumento de 145,56% do total de sua área, de 855.087 ha em 2000, para 2.099.837 ha em 2014. A classe Silvicultura também teve um aumento de mais de 167 % da sua área total. Os principais fatores que contribuíram no modelo de regressão global para o processo de degradação do campo, de forma negativa são: densidade populacional, altura em relação à drenagem mais próxima (Modelo HAND) e

manchas de degradação do campo. De forma positiva são: população residente em domicílios, média do número de moradores em domicílios, manchas de expansão da soja e distância do processo de expansão da soja. Conclui-se que dados orbitais em conjunto com técnicas de geoprocessamento propiciam ferramentas para o monitoramento das mudanças de uso do solo e cobertura vegetal.

ABSTRACT

The Pampa biome in recent years is undergoing a process of land use change, mainly by converting from the grassland to grain farming and silviculture. The main objective of this work is to analyze the processes of land use and vegetation cover in the Brazilian Pampa Biome, generated from time series of the MODIS sensor, including the main transformation processes of the landscape. The study period was 2000 and 2014, we used the images EVI of MODIS sensor and DMSP-OLS night images, for the generation of maps of land use and vegetation cover, by classification by decision tree. The limits of the census tracts of IBGE were used. To investigate the landscape transformation processes of the Pampa Biome, we used environmental variables, which include geomorphometric data, landscape metrics and climatic data, and socioeconomic variables. Through local linear regression (GWR) and global models, in addition to spatial grouping procedures (SKATER). There was a decrease of around 25% of the grassland over a 15-year period, from 10.252.740 ha to 7.676.208 ha, in contrast to agricultural areas, such as the Soja class, which increased by 145.56% of the total its area from 855.087 ha in 2000 to 2.099.837 ha in 2014. The Silviculture class also had an increase of more than 167% of its total area. The main factors that contributed to the overall regression model for the grassland degradation process are: population density, height above the nearest drainage (HAND model), and grassland degradation patches. In a positive way are: population living in households, average number of residents in households, soybean expansion spots and distance from the soybean expansion process. Finally, orbital data in conjunction with geoprocessing techniques may be important for monitoring changes in land use and vegetation cover.

1. INTRODUÇÃO

A crescente demanda por recursos terrestres (alimentos, água, combustível) em conjunto com práticas ambientais insustentáveis, resultaram numa crescente degradação ambiental dos principais ecossistemas naturais, ameaçando tanto a capacidade de produção de alimentos, quanto a degradação de ambientes ecologicamente frágeis (NELLEMANN et al., 2009). Conforme projeção da Organização das Nações Unidas para Alimentação e Agricultura (FAO, 2006) até o ano de 2050 a população mundial irá aumentar e o consumo de carne praticamente duplicará, aumentando também a necessidade por *commodities* agrícolas.

A agricultura é um dos maiores agentes transformadores do uso da terra (CASSMAN et al., 2005). Embora a agricultura seja importante, pois constitui um dos principais fornecedores de alimentos para a população humana (SMITH & MCDONALD, 1998), a expansão agrícola nos ecossistemas naturais leva à perda de serviços ecossistêmicos, como habitat necessário para manter a biodiversidade, armazenamento de carbono, mitigação de enchentes, fertilidade do solo, qualidade do lençol freático, entre outros (DEFRIES et al., 2004.;

FOLEY et al., 2005; GIBBS et al., 2010; LAMBIN & MEYFROIDT, 2011). Portanto, entender as transformações da paisagem induzidas pelo homem, fornecendo subsídios confiáveis, como, por exemplo, o monitoramento de tais atividades ao longo do tempo, tornam-se cruciais para a tomada de decisão das entidades governamentais.

O Bioma Pampa, que inclui a parte Sul do Brasil, todo território do Uruguai e a porção nordeste da Argentina, possui uma área de aproximadamente 176,496km² (ALLEN et al., 2011). É uma das maiores e mais ricas zonas de pastagens do mundo, com uma enorme diversidade de espécies e uma coexistência única de várias plantas C₃ e C₄, possuindo como fisionomia característica a presença de gramíneas e apresentando diversidade na ordem de 2200 espécies (BOLDRINI, 2009). Nos últimos tempos, no entanto, tem se observado uma tendência de mudança de uso do solo neste bioma, marcadamente pela conversão da vegetação campestre para a agricultura de grãos (especialmente a cultura da soja) e silvicultura (PILLAR et al., 2009). Neste Bioma, portanto, são importantes os estudos sobre a dinâmica e monitoramento dos processos de uso do solo e cobertura vegetal (USCV).

Estudos realizados em diversas partes do mundo apontam a viabilidade de uso de imagens de satélite para o monitoramento da dinâmica de USCV. FRIEDL et al (2002) conduziram o que pode ser considerado um dos primeiros trabalhos de mapeamento de uso e cobertura do solo usando séries temporais de imagens do sensor MODIS (*MODerate Resolution Imaging Spectroradiometer*) e analisaram as potencialidades e limitações do método. Posteriormente, Liu et al (2011) trabalharam com a mudanças do uso do solo entre 1982-2009 no Nordeste da Ásia, mas agora utilizando o índice NDVI (*Normalized Difference Vegetation Index*) proveniente de três sensores diferentes (AVHRR, SPOT e MODIS). Importante mencionar também o trabalho de ZHOU et al. (2013) que trabalhou com técnicas de mineração de dados para identificação do uso e cobertura do solo com dados MODIS. Para uma região agrícola do Canadá. Os autores testaram a acurácia do mapeamento em diferentes combinações dos dados MODIS, como bandas espectrais, NDVI e métricas fenológicas.

Nos biomas brasileiros alguns trabalhos se destacam ao utilizarem sensoriamento remoto e geoprocessamento para analisar os processos de transformações do uso do solo com enfoque no desmatamento. Alves (2002); Espindola et al. (2012) analisaram as taxas de desmatamento na Amazônia e avaliaram os fatores que influenciaram tais processos, Grecchi et al. (2014) usaram geotecnologias para avaliar os impactos da expansão agrícola ao longo do tempo no Cerrado Brasileiro e analisaram a influência de indicadores de vulnerabilidade à erosão. Na Bacia do Alto Uruguai Freitas et al (2013) analisaram os processos de uso do solo e

cobertura vegetal, vinculando variáveis ambientais e socioeconômicas entre os anos de 2002 e 2008.

Mais especificamente na área brasileira do Bioma Pampa, diversos estudos de sensoriamento remoto analisaram séries temporais com imagens orbitais de alta frequência temporal focando na relação agrometeorológica do sistema (JACÓBSEN et al., 2003; JACÓBSEN et al., 2004; WAGNER et al., 2013; SCOTTÁ & FONSECA, 2015). Jacobsen et al. (2003) observaram que o padrão de variação dos valores de NDVI ao longo do ano são semelhantes aos da disponibilidade de radiação solar e da temperatura do ar, apresentando valores máximos no verão e mínimos no inverno. Wagner *et al* (2013) observaram as tendências negativas nas séries temporais MODIS-EVI e NDVI para o período de 2000 a 2011, relacionado à combinação da ocorrência de déficit hídrico em solos rasos com o sobrepastoreio. Scottá & Fonseca (2015) relacionaram os dados de biomassa aérea em escala local com os dados em escala regional de NDVI provenientes do sensor *Vegetation*.

Entretanto, estudos sobre o monitoramento e dinâmica dos processos de USCV no Bioma Pampa Brasileiro ainda são escassos, principalmente nas duas últimas décadas, onde a paisagem está sofrendo um processo de conversão da vegetação campestre em áreas agrícolas, especialmente para o cultivo de soja. Neste sentido, o presente trabalho busca contribuir para avançar no conhecimento acerca dos principais processos de uso do solo no Bioma Pampa e identificar quais variáveis têm maior influência nas mudanças na paisagem. A hipótese norteadora é que as mudanças de USCV podem ser mapeadas através de técnicas de classificação digital de imagens que expressam a variação temporal dos índices de vegetação, e que existem variáveis indutoras das mudanças (socioeconômicas, climáticas, métricas da paisagem e geomorfométricas), as quais podem ser descritas através de modelos de regressão globais e locais.

O objetivo do trabalho é analisar os processos de uso do solo e cobertura vegetal no Bioma Pampa Brasileiro e identificar os principais processos de transformação da paisagem e seus fatores condicionantes. Foram relacionados 7 processos de mudanças de USCV na área de estudo (urbanização, regeneração, expansão da silvicultura, expansão da soja, degradação campo, degradação da floresta e intensificação). O trabalho consistiu em duas etapas: A primeira etapa foi de classificação do USCV com imagens MODIS e DMSP-OLS para os anos de 2000 e 2014 e a identificação dos principais processos de transformação da paisagem. A segunda etapa, foi de investigação dos processos USCV com variáveis ambientais, que incluem dados geomorfométricos, métricas da paisagem, dados climáticos e variáveis socioeconômicas

do último censo do IBGE (2010), realizada através dos modelos de regressão linear global e local (GWR), além de procedimentos de agrupamento espacial (SKATER).

2. METODOLOGIA

2.1 Área de estudo

A área de estudo compreende os limites do Bioma Pampa (IBGE, 2004) dentro do Estado do Rio Grande do Sul, localizado no extremo sul do Brasil, totalizando uma área de 16.579.332 hectares e uma população total de 5.373.216 habitantes, que corresponde a 50,24% do total da população do Estado do Rio Grande do Sul (Figura 01).

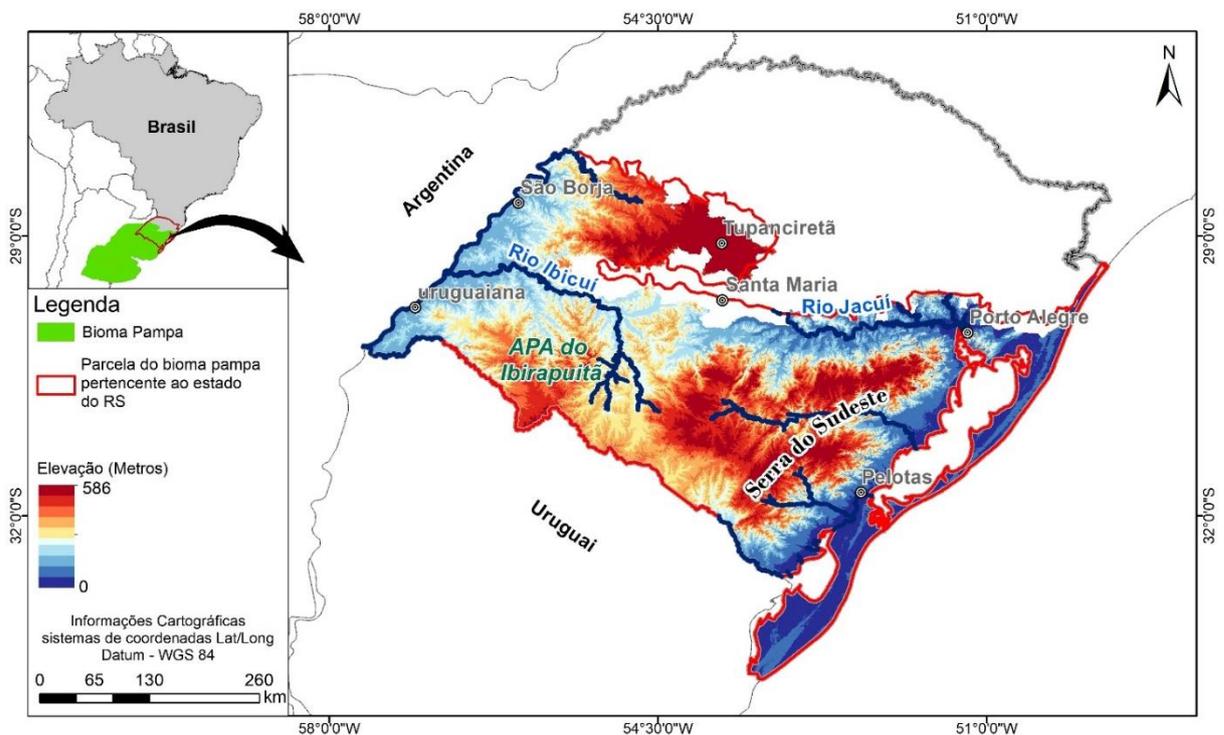


Figura 01: Mapa de localização da área de estudo.

Conforme classificação de Köppen (ALVARES et al., 2013), na maior parte do Bioma Pampa predomina o tipo Cfa (subtropical chuvoso com verões quentes), sendo que apenas a região da Serra do Sudeste, com altitudes mais elevadas (~400 m de altitude), apresenta o clima tipo Cfb (subtropical chuvoso com verões amenos).

2.2 Classificação do uso do solo e cobertura vegetal e preparação dos dados.

Para avaliação das mudanças de uso do solo no Bioma Pampa, o período de estudo foi de 2000-2014. O ano de 2000 foi escolhido como referência devido ao fato de que foi o período no qual a série temporal do sensor MODIS tem suas primeiras imagens. Para analisar as mudanças na área de estudo foram gerados dois mapas de uso do solo, a partir de imagens do

satélite TERRA, sensor MODIS, produto MOD13Q1, coleção 6, que contém composições de imagens de 16 dias sob forma de índices de vegetação EVI, com uma resolução espacial de 250 metros. Para cada ano (2000 e 2014), foram utilizadas 23 imagens MODIS.

As categorias de uso do solo e cobertura vegetal foram baseadas nos critérios estabelecidos por Anderson et al (1976), sendo elencadas nove classes para o Bioma Pampa gaúcho: Áreas agrícolas (Arroz, Soja, e Mosaico de Culturas), Floresta, Campo, Praias e Dunas, Água, Área Urbana e Silvicultura. A etapa de classificação levou em consideração as pequenas diferenças e características específicas de cada região, adotando um classificador treinado exclusivamente para atuar em cada uma delas.

O classificador utilizado foi Árvore de Decisão (AD) para as classes de uso do solo e cobertura vegetal (água, praias e dunas, floresta, silvicultura e campo), sendo utilizada a série temporal MODIS filtrada pelo *Timesat*, composta por 23 imagens do índice de vegetação EVI. As AD testadas foram construídas utilizando o algoritmo C4.5 (QUINLAN, 1993) em ambiente MatLab®. Os dados de entrada do classificador foram a própria série temporal e as amostras de treinamento das classes de uso do solo e cobertura vegetal, extraídas a partir de polígonos selecionados em imagens *Landsat 8/OLI*, que por possui resolução espacial de 30 metros permitiu a identificação visual e delimitação das classes.

Para as classes Água, Praias e Dunas, Floresta, Silvicultura e Campo, o classificador utilizado foi Árvore de Decisão (AD), enquanto que para as classes agrícolas (Arroz, Soja, e Mosaico de Culturas) foi gerada uma máscara de cultivo e utilizado o classificador por AD dentro dessa máscara e, por fim, para a classe Área Urbana, foi utilizada uma combinação entre imagens noturnas (*Defence Meteorological Satellite Program - Operational Linescan System-DMSP-OLS*) e EVI (WU et al., 2012).

Finalizados os mapas de USCV para os anos de 2000 e 2014, a próxima etapa foi de quantificação e análise das transformações do USCV nos últimos 15 anos. Para isso, foi efetuada a tabulação cruzada entre o mapa de USCV de 2000 e 2014, a quantificação e mapeamento das áreas das classes de USCV que apresentaram ganhos ou perdas e a identificação, por exemplo, se existe avanço da cultura da soja e da silvicultura sobre áreas de campo. Através de gráficos e tabelas gerados pelo módulo *Land Change Modeler - IDRISI Taiga (LCM)* foi então analisadas e quantificadas as transformações espaciais ocorridas no bioma Pampa nos últimos 15 anos.

O processo de validação da acurácia dos mapas de USCV dos anos 2000 e 2014 foi feito a partir de amostras de referência selecionadas das imagens *Landsat 5/TM* (2000) e

Landsat 8/OLI (2014) para todas as classes da classificação MODIS. Como análise estatística, foi utilizada a exatidão global (EG) e o índice Kappa (k).

O procedimento de tabulação cruzada entre o mapa de 2000 e 2014, permitiu identificar 29 transições de USCV de interesse deste estudo. Posteriormente as 29 transições foram agrupadas em 7 processos (Figura 02) usando métodos semelhantes de agrupamentos conforme (BATISTELLA & VALLADARES, 2009.; FREITAS et al., 2013). Estes métodos de agrupamento dos processos foram adaptados para atender demandas específicas na área de estudo: (1) Urbanização, definida como qualquer USCV para classe Área Urbana; (2) Regeneração, definida como a transição das classes de uso agrícola para a classe Floresta; (3) Expansão da silvicultura, caracterizada pelas transições ocorridas de qualquer classes de USCV para a classe Silvicultura; (4) Expansão da soja, definida como as transições ocorridas de qualquer classe (menos Silvicultura) para a classe Soja; (5) Degradação campo, definida como as mudanças da classe Campo, para as classes de USCV de finalidade agrícola e silvicultura; (6) Degradação floresta, definida como as mudanças da classe Floresta, para as classes de USCV de finalidade agrícola; e (7) Intensificação, caracterizada como as mudanças da classe Silvicultura para áreas agrícolas, definida como mudança de tecnologia no processo de produção agrícola, incluindo altos níveis de mecanização e uso de fertilizantes e outros insumos com o objetivo de aumentar a produtividade por unidade de área de monoculturas.

Os processos apresentados foram utilizados como variáveis dependentes, enquanto as variáveis independentes preditivas foram os fatores socioeconômicos, climáticas, métricas da paisagem e geomorfométricas.

		2014 USCV								
		ARR	SOJ	MOS	SIL	CAM	FLO	PRA	URB	AGU
2000 USCV	ARR		4		3		2		1	
	SOJ				3		2		1	
	MOS		4		3		2		1	
	SIL	7	7	7					1	
	CAM	5	4/5	5	3/5				1	
	FLO	6	4	6	3				1	
	PRA				3				1	
	URB									
	AGU									

Figura 02: Matriz de transição utilizada para identificar os processos ocorridos entre os mapas de USCV de 2000 e 2014. Abreviaturas: (1) Urbanização (2) Regeneração (3) Expansão da silvicultura (4) Expansão da soja (5) Degradação campo (6) Degradação floresta (7) Intensificação. ARR (arroz) SOJ (soja) MOS (mosaico de culturas) CAM (campo) FLO (floresta) PRA (praias e dunas) URB (área urbana) AGU (água)

2.3 Processamento das variáveis geomorfométricas, socioeconômicas e ambientais.

Foi utilizado como unidade de análise os limites dos setores censitários do Instituto Brasileiro de Geografia e Estatística (IBGE) do ano de 2010. A área de estudo apresenta 1766 setores censitários, dos quais 37 setores foram retirados por falta de informações censitárias, restando 1729 setores.

O presente trabalho utilizou variáveis de diferentes fontes, incluindo dados sociais, educacionais, econômicos, geomorfométricos, climáticos, de rede viária e de hidrografia (Tabela 01). Os dados geomorfométricos foram obtidos a partir dos dados de elevação SRTM (*Shuttle Radar Topographic Mission*) com resolução espacial de aproximadamente 30 metros. Os dados socioeconômicos utilizados foram do último censo realizado no Brasil, no ano de 2010. Os dados climáticos foram obtidos a partir do *WorldClim - Global Climate Data* (<http://www.worldclim.org/>), com resolução espacial de 1 km. Para geração dos mapas de distâncias da rede viária e hidrográfica, foi utilizada a base cartográfica vetorial contínua do Rio Grande do Sul, em escala 1:50.000 (Hasenack & WEBER 2010). As métricas da paisagem, como o número de manchas (polígonos) dos processos analisados, foram processados em ambiente SIG.

A próxima etapa foi a criação de um banco de dados espacial para agregar todas as informações e a realização das operações de geoprocessamento, nas variáveis independentes. Os setores censitários contíguos classificados como área urbana pelo IBGE foram reclassificados e agregados em um único setor, a fim de diminuir o número de setores em áreas urbanas, já que o número de setores censitários classificados como urbano é muito elevado e com dimensão reduzida (<1 ha), não sendo compatíveis com a resolução espacial do sensor MODIS.

Tabela 01: Variáveis independentes usadas nas análises dos modelos de regressão global (OLS) e local (GWR)

Tipo	Variável	Sigla	Descrição
Geomorfométrica	HAND	HAND	Altura em relação à drenagem mais próxima (m)
	Declividade	SLOPE	Declividade (graus)
	Elevação	ELEV	Dados SRTM (resolução espacial 30m)
Climática	Precipitação Anual	P_YRS	Precipitação anual (mm) - Dados <i>Worldclim</i> (resolução espacial 1km)
	Sazonalidade da Precipitação	C_YRS	Sazonalidade da Precipitação (coeficiente de variação) (mm) Dados <i>Worldclim</i> (resolução espacial 1km)
	Manchas de expansão soja	P_1	Número de manchas (polígonos) para o processo de expansão da soja
	Manchas de degrad. campo	P_2	Número de manchas (polígonos) para o processo de degr. do campo
	Manchas de expansão silvicultura	P_3	Número de manchas (polígonos) para o processo de expansão da silvicultura

Densidade/Área	Manchas de intensificação	P_4	Número de manchas (polígonos) para o processo de intensificação
	Manchas de degradação florestal	P_5	Número de manchas (polígonos) para o processo de degradação florestal
	Manchas de regeneração	P_6	Número de manchas (polígonos) para o processo de regeneração
Econômico	Rendimento médio mensal	V009	Valor do rendimento nominal médio mensal das pessoas de 10 anos ou mais de idade (com e sem rendimento) (R\$)
	Variância do rendimento médio mensal	V010	Variância do rendimento nominal mensal das pessoas de 10 anos ou mais de idade (com e sem rendimento) (R\$)
Demográfico	Percentual de jovens	<14A	(População de 0 a 4 anos / População total com idade conhecida)*100
	Percentual de adultos	15_59	(População de 0 a 14 anos / População total com idade conhecida)*100
	Percentual de adultos	>60A	(População de 15 a 59 anos / População total com idade conhecida)*100
	Pop. residente em domicílios	V002	Moradores em domicílios particulares permanentes ou população residente em domicílios particulares permanentes
	Média do número de moradores em domicílios	V003	Média do número de moradores em domicílios particulares permanentes
	Densidade populacional	P_DE	População residente / Área (em km ²)
	População total	P_TO	População residente total
Educação	Taxa de analfabetismo	ILL_R	(População de 10 anos ou mais que não sabem ler e escrever um bilhete simples, no idioma que conhecem / População total desta faixa etária) * 100
Distância Euclidiana	Distância das estradas	D_ROA	Distância das estradas (m)
	Distância da Hidrografia	D_RIV	Distância da hidrografia (m)
	Distância da expansão da soja	D_1	Distância do processo de expansão da soja (m)
	Distância da degradação do campo	D_2	Distância do processo de degradação do campo (m)
	Distância da expansão da silvicultura	D_3	Distância do processo de expansão da silvicultura (m)

2.4 Modelos de regressão global OLS (*Ordinary least squares*) e local GWR (*Geographically weighted regression*)

A elaboração dos modelos se inicia com o procedimento de seleção das variáveis independentes. No conjunto de variáveis independentes pode haver variáveis que pouco influenciam o conjunto de variáveis dependentes (processos). Foi utilizado o *software IBM SPSS Statistics 20*, para seleção das variáveis e proposição do modelo de regressão a ser utilizado. Para tal, foi utilizado o procedimento *best subset* (NETER et al., 1996) por meio do critério R^2 e do R^2 ajustado, através do método *backward stepwise* com nível de significância de 0,05.

Depois de selecionado os melhores conjuntos de variáveis, o modelo de regressão global (OLS) foi executado, gerando 7 modelos de regressão. A equação (1) utilizada no modelo OLS é definida da seguinte forma:

$$y_k = \beta_{k0} + \sum \beta_{kj} x_{ij} + \varepsilon_k \quad (1)$$

Onde Y_i é a variável de resposta de localização i , β_0 é o intercepto, β_k é o parâmetro estimado pela variável independente k , X_{ik} é o valor da variável independente k na localização i e ε_i é o erro. Para avaliar a dependência espacial dos modelos OLS, foi analisada a autocorrelação espacial dos resíduos utilizando o teste Moran's I, partindo da hipótese nula de nenhuma presença de autocorrelação espacial nos resíduos. Os testes foram utilizados para avaliar a necessidade de uso de técnicas de regressão espacial para os 7 diferentes processos de USCV baseados nestes testes que indicam a presença de autocorrelação espacial nos modelos.

A técnica de Regressão Geograficamente Ponderada (*Geographically Weighted Regression - GWR*), proposta por Brunson, Fotheringham e Charlton (1996), foi utilizada para modelar processos heterogêneos (não estacionários) espacialmente, isto é, processos que variam (seja na média, mediana, variância, etc.) de região para região. Foi ajustado um modelo de regressão para cada região do conjunto (setores censitários) de dados utilizando a localização geográfica das demais observações para ponderar as estimativas dos parâmetros, com o intuito de localizar as variações locais das variáveis existentes na área de estudo. Conforme Fotheringham et al. (2002), dado um modelo de regressão global (OLS), a expressão equivalente para a GWR (local) é dada por:

$$y_i = \beta_0(u_i, v_i) + \sum_k \beta_k(u_i, v_i)x_{ik} + \varepsilon_k \quad (2)$$

Nota-se pela expressão acima que os parâmetros do modelo, representados pela função $\beta_k(u_i, v_i)$ variam de acordo com os valores de (u_i, v_i) , que representam as coordenadas geográficas latitude e longitude de cada setor censitário (i), resultando em um modelo distinto para cada região do estudo. Desta forma o modelo GWR realiza regressões localmente usando o centróide dos polígonos dos setores censitários mais próximos, baseados na distância Euclidiana entre os pontos. Importante mencionar que os pressupostos do modelo clássico de regressão linear (OLS) permanecem para a GWR.

No presente estudo foi utilizado a versão GWR4 desenvolvido pela *National Centre for Geocomputation*, da *National University of Ireland Maynooth*, a função de ponderação utilizada foi a Gaussiana com base na minimização do *Akaike Information Criterion (AIC)*, com *Kernel* de tamanho variável, o que é mais indicado em situações onde os dados não são

igualmente distribuídos entre as regiões na área de estudo (GATTREL et al., 1996). Para cada um dos 7 processos de USCV os modelos GWR e OLS foram comparados usando o procedimento dos melhores subconjuntos, com base na AIC, que é uma medida mais apropriada para comparar modelos do que o R^2 (FOTHERINGHAM et al., 2002). Para estimar a dependência espacial dos resíduos nos modelos de regressão GWR foi aplicado o teste de Moran's I.

2.5 Agrupamento espacial dos processos de Uso do solo e Cobertura Vegetal

Para geração do agrupamento espacial dos processos de USCV foi utilizado o algoritmo SKATER (Assunção et al. 2006), do software *Terra View* 4.2.2. Os 1729 polígonos dos setores censitários do IBGE foram utilizados para geração dos agrupamentos espaciais. O algoritmo de agrupamento espacial SKATER utiliza o conceito de árvore geradora mínima. Sua ideia foi baseada no *Spatial Clustering Analysis Through Edge Remova* (ASSUNÇÃO et al., 2006), que é um método de agrupamento espacial para dados de área.

As variáveis utilizadas para geração dos agrupamentos dos processos de USCV foram os coeficientes estimados pelas variáveis independentes (β) nos modelos de regressão local (GWR). A geração de agrupamentos foi utilizada para melhor visualização dos resultados para as diferentes variáveis dos processos de USC, tendo sido plotados nos mapas os gráficos em forma de barras para cada coeficiente estimado pelo modelo GWR. Foi adotado o número de 5 regiões espaciais para cada processo, conforme metodologia de Freitas et al (2013). Para o processo de USCV Urbanização, não foi realizado o agrupamento espacial nesta etapa do trabalho por tal processo não apresentar dependência espacial nos resíduos do modelo OLS.

3. RESULTADOS E DISCUSSÃO

3.1 Mudanças no uso do solo

A Exatidão Global (EG) foi de 89,71% e Kappa (k) de 0,8778 para o ano de 2000 e (EG) de 90,09% e (k) de 0,8857 para o ano de 2014. Em ambos mapas, os maiores acertos foram para a classe Área Urbana e os menores acertos foram para a classe Silvicultura. As maiores semelhanças espectrais nos mapas de USCV ficaram restritas às classes Silvicultura, Campo e Floresta, a alocação de pontos (pixel) de forma errônea realizada pelo classificador, principalmente nas classes com cobertura vegetal, evidencia a similaridade espectral e temporal dessas classes com cobertura vegetal e a dificuldade de separá-las.

Os mapas de USCV do ano de 2000 e 2014 (Figura 03) são a base para identificar as principais áreas onde os processos de transformação do uso do solo sofreram mudanças. A

região norte da área de estudo, localizada no planalto médio, nas proximidades do município de Tupanciretã, apresentou grandes mudanças, principalmente da conversão da classe Campo para a classe Soja. Essa região se caracteriza por apresentar altitudes acima de 350 m, relevo com declividade baixas, e solos mais férteis quando comparados com outras áreas do Bioma Pampa. Conforme Moreira & Medeiros (2014) a partir de 1985, a soja se consolida alicerçada pela modernização do setor agrícola no Centro-Norte e Noroeste Gaúcho, ocupando áreas tradicionais da pecuária. Portanto, na região norte do Bioma Pampa, nas proximidades de Tupanciretã, o processo de expansão da soja, se deu de forma mais tardia, quando comparado com a região Noroeste do Estado do Rio Grande do Sul.

Também é possível identificar a expansão da soja em outras áreas, como ao longo do Rio Jacuí e a Sudoeste da cidade de Pelotas, locais tradicionais de cultivo de arroz irrigado nas áreas de várzea. A Serra do Sudeste, região com declividades mais acentuadas e com solos rasos, com menos fertilidade, quando comparado com outras regiões, está sofrendo grandes mudanças na sua paisagem nesses últimos 15 anos, em especial a conversão da vegetação campestre (classe Campo) por áreas de silvicultura.

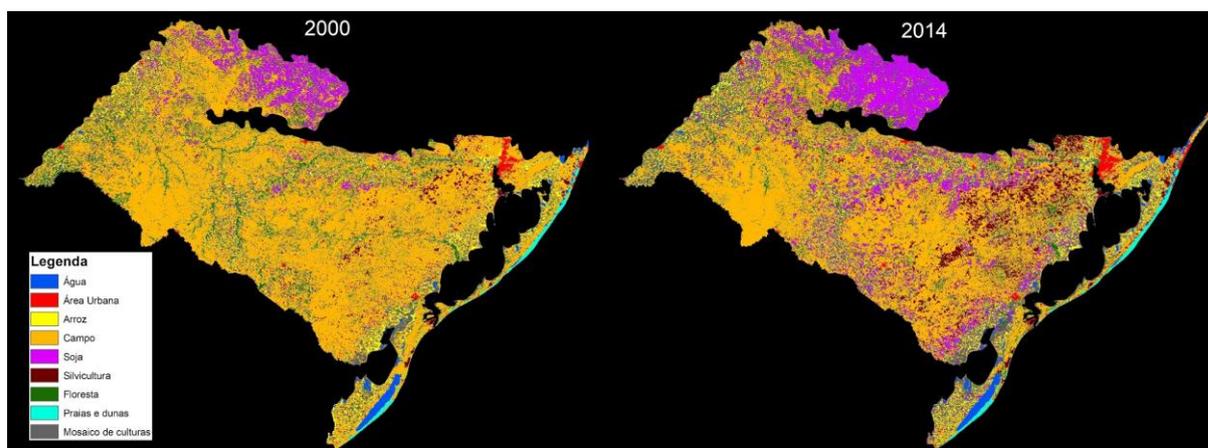


Figura 03: Mapa de USCV do Bioma Pampa para o ano de 2000 e 2014.

A Tabela 2 compara os valores obtidos na classificação de 2000 e 2014, constata-se a redução da classe Campo e aumento das classes de agricultura (soja, arroz e mosaico de culturas) e da classe Silvicultura. A diminuição da classe Campo é muito expressiva, com diminuição de aproximadamente 25 % da sua área total num intervalo de apenas 15 anos, de 10.252.740 ha para 7.676.208 ha. Já a classe Soja, no mesmo intervalo de tempo, obteve um aumento de 145,56% do total de sua área, de 855.087 ha em 2000, para 2.099.837 ha em 2014. A classe Silvicultura também teve um aumento de mais de 167 % da sua área total, distribuídos principalmente na Serra do Sudeste e na faixa litorânea. As classes Praias e Dunas e Água,

apresentaram diferenças entre os anos estudados, porém praticamente estáveis pela magnitude da área e resolução do sensor MODIS.

Tabela 2: Comparação dos valores entre o mapa classificado do ano de 2000 o mapa de 2014, para o Bioma Pampa, valores em hectares.

Classes	2000	2014	Diferença	Diferença (%)
Água	411.746	405.649	-6.096	-1,48
Área Urbana	103.980	127.232	23.252	22,36
Arroz	879.256	1.075.861	196.604	22,36
Campo	10.252.740	7.676.208	-2.576.532	-25,13
Soja	855.087	2.099.837	1.244.749	145,56
Silvicultura	331.694	887.428	555.734	167,54
Floresta	2.226.523	1.731.016	-495.507	-22,25
Praias e dunas	97.802	111.231	13.429	13,73
Mosaico de culturas	1.334.161	2.378.527	1.044.365	78,27
Total	16.492.994	16.492.994		

Quando analisados os ganhos e perdas por classes (Figura 04-A) os dados mostram que na classe Campo, 98,02% do total de redução da sua área em 15 anos, está relacionada com atividades antrópicas, como agricultura e silvicultura. A soja foi responsável por mais de 30,1% do total da conversão da vegetação campestre, com mais de 777.645 ha, avançando sobre a classe Campo, a classe Mosaico de Culturas com 31,33% com 807.337 ha, lembrando que essa classe representa áreas destinadas à agricultura, mas no ano específico da classificação (safras 2000/2001 e 2013/2014) não estavam sendo utilizadas para este fim. Estas são áreas que têm uso agrícola e que alternam arroz irrigado e pousio com campos ou rotação de culturas com cultivo de sequeiro. Portanto, esta classe pode conter áreas com o cultivo de soja, o que reforça a ideia de que a expansão das áreas de soja está avançando sobre a vegetação campestre. Conforme dados da classificação, a expansão da soja avança principalmente sobre a classe campo, 62,47% das novas áreas cultivadas ocorrem sobre a classe Campo (Figura 4-B).

Outra atividade antrópica responsável pela redução da classe Campo é a silvicultura, sendo que aproximadamente 520 mil hectares foram convertidos da classe Campo para Silvicultura. Quando analisamos a Figura 04-C, identificamos que praticamente todo o avanço da classe Silvicultura foi sobre áreas de vegetação campestre, mais especificamente, 93,56% do total do avanço foi sobre áreas da classe Campo. Importante destacar que em 2004 o governo do Estado do Rio Grande do Sul, a fim de propiciar desenvolvimento à metade Sul do Estado e expandir a produção da silvicultura, lançou políticas públicas para atrair os investimentos das empresas do setor florestal. O objetivo socioeconômico seria transformar a matriz econômica

conservadora e concentrada de renda, histórica e culturalmente pastoril, em região de produção de madeira e celulose (BINKOWSKI, 2009).

A expansão de novas áreas da classe Silvicultura pode alterar drasticamente a paisagem da região da Serra do Sudeste, já que o avanço desta atividade tem se dado em áreas predominantemente campestres. De acordo com informações disponibilizadas pelo IBGE (2017), em relação a produção de madeira, lenha e carvão, os dados indicam que houve um aumento significativo nos últimos 15 anos na região do Bioma Pampa, com aumento gradual a cada ano.

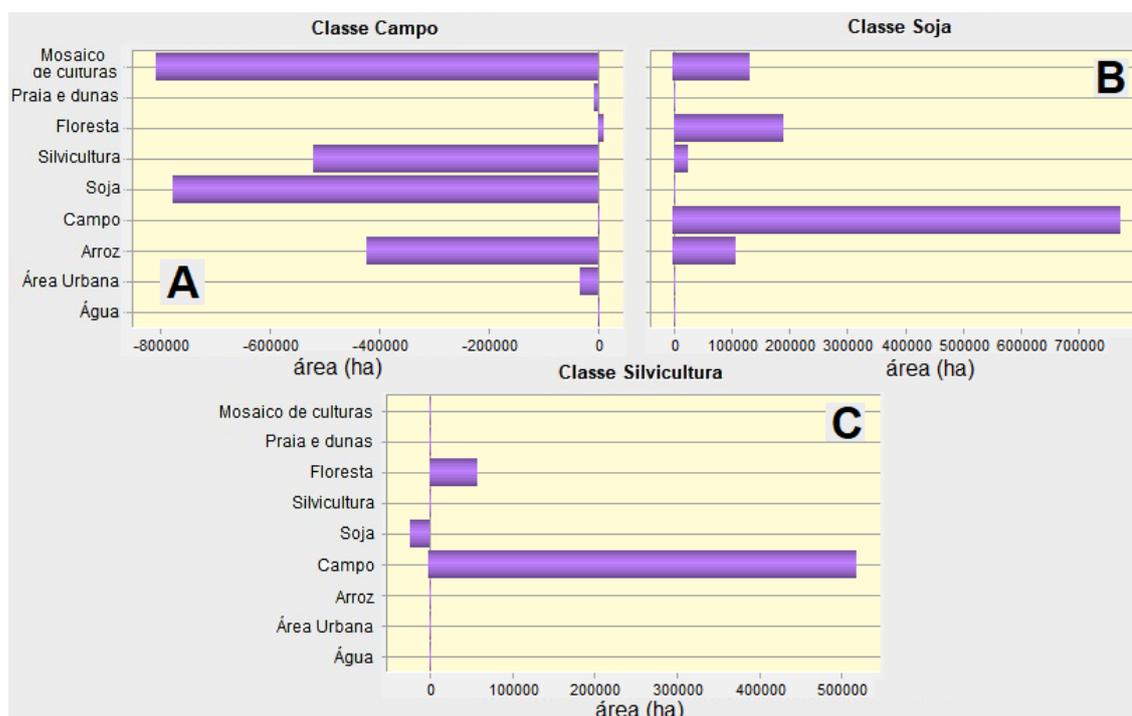


Figura 04: Tabulação cruzada para as classes Campo (A), Soja (B) e Silvicultura (C) entre 2000 e 2015, valores em hectares.

A Figura 05 ilustra o quanto as classes de USCV foram modificados no intervalo de 15 anos (2000-2014) em cada setor censitário. Em geral os processos de degradação do campo, expansão da soja e expansão da silvicultura são os mais importantes processos de transição analisados, com relação ao tamanho da área convertida. Importante destacar que a APA do Ibirapuitã, localizada a sudoeste da área de estudo foi importante para conservação da vegetação campestre, pois impediu o avanço da expansão da soja e da silvicultura. A expansão da soja foi maior na porção norte e ao longo do rio Jacuí, já a degradação da floresta foi maior na porção oeste e ao longo do rio Jacuí.

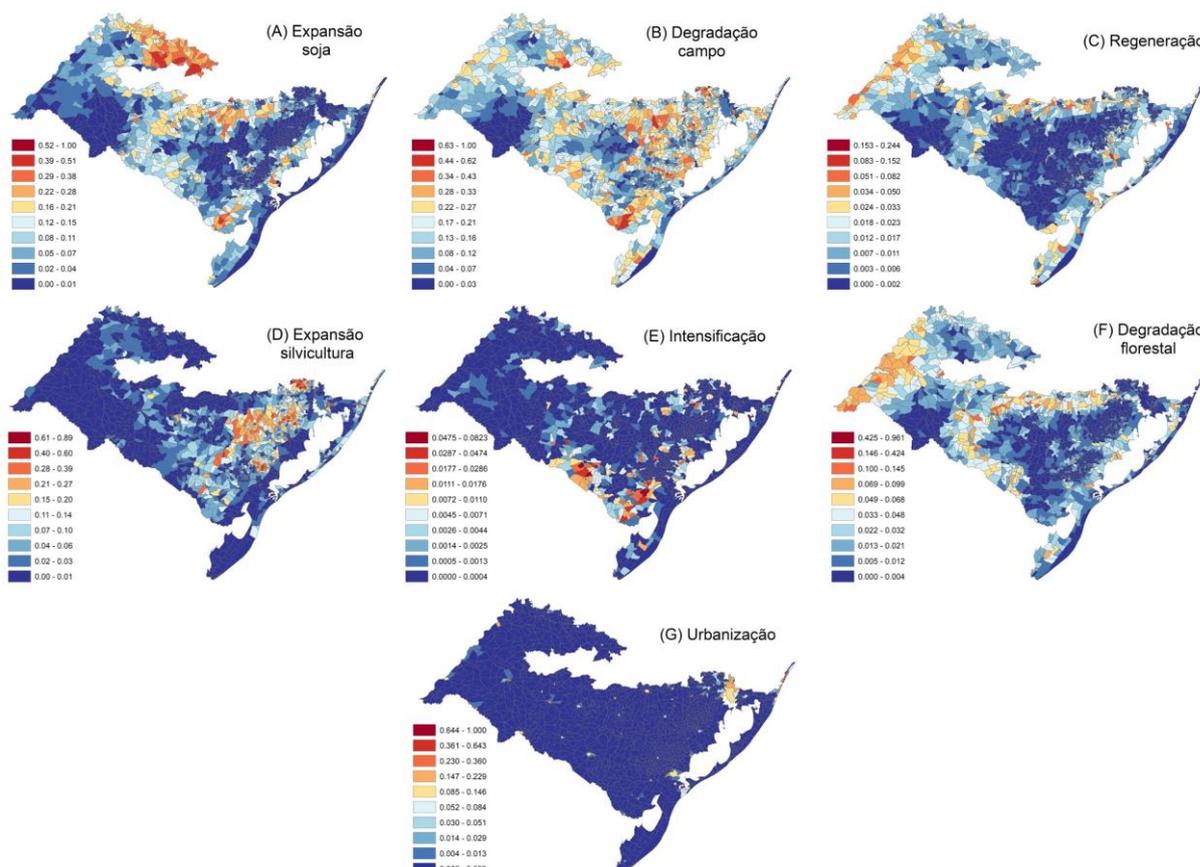


Figura 05: Mudança para todos os processos de USCVC ocorridos entre os anos 2000 e 2014 para cada setor censitário

3.2 Modelos de regressão global e local

Nesta etapa serão apresentados os resultados dos modelos de regressão global e local (GWR) para cada processo de USCVC, sendo primeiramente mostrada a relativa importância ou contribuição de cada variável para cada um dos processos, resumidos nas tabelas 3 e 4. Apenas os três principais processos (degradação do campo, expansão da soja e da silvicultura) serão discutidos nesta etapa, já que estes são os principais transformadores em termos de quantidades de área convertida no Bioma Pampa. Para melhor entendimento, o estimador (β) de cada variável foi dividido pelo erro padronizado, e calculada a importância de cada variável no modelo de regressão global dos processos de USCVC.

Tabela 03: Parâmetros (β) estimados pelos modelos de regressão (média dos valores) para os modelos globais (OLS) e locais (GWR).

Parâmetro	Expansão Soja		Degr. Campo		Exp. Silvicultura		Intensificação		Degr. Florestal		Regeneração		Urbanização	
	OLS	GWR												
Intercept	0.058	0.034	0.146	0.126	0.052	9,4e ⁻³	1,4e ⁻³	9,1 ^{+*}	0.017	0.021	8,3e ⁻³	9,6e ⁻³	7,7e ⁻³	0.014
HAND	-0.013	-3,7e ⁻³	-7,3e ⁻³	-4,5e ⁻³							-3,1e ⁻³	-3,3e ⁻³	-3,6e ⁻³	-7,3e ⁻³
SLOPE	-7,5e ⁻³	-2,6e ⁻³			0.032	0.011 [*]								
ELEV	0.028	7,4e ⁻³			-5,7e ⁻³	0.014								
P_YRS	0.012	-2,4e ⁻³			-2,4e ⁻³	-4,9e ⁻³	-1,0e ⁻³	-1,0e ⁻³					1,7e ⁻³	8,3e ⁻³
C_YRS	-0.013	-0.014	-6,5e ⁻³	-0.013			5,5 ⁻⁴	3,8 ^{+*}	2,6e ⁻³	1,7e ^{-3*}				
P_1			0.013	0.025 [*]	-3,5e ⁻³	-1,0e ^{-3*}	1,9e ⁻³	2,6e ⁻³						
P_2	0.016	0.014					-6,8 ⁻⁴	-1,1e ⁻³			3,1e ⁻³	4,2e ⁻³		
P_3	-0.010	-4,6e ^{-3*}	4,0e ⁻³	1,2e ^{-3*}					-3,6e ⁻³	-2,8e ^{-3*}	-1,0e ⁻³	-1,0e ^{-3*}		
P_4			0.01	5,6e ^{-3*}							-1,3e ⁻³	-9,5e ⁻⁴		
P_5					-6,8e ⁻³	-0.015 [*]								
P_6			-8,4e ⁻³	-3,4e ^{-3*}			-9,3 ⁻⁴	-1,1e ⁻³	8,1e ⁻³	4,5e ⁻³				
V009					4,8e ⁻³	-1,0e ^{-3*}	4,5 ⁻⁴	2,5 ^{+*}	-3,8e ⁻⁴	2,1e ^{-4*}			6,2e ⁻³	-6,6e ^{-4*}
V010													-2,3e ⁻³	-5,4e ^{-3*}
<14A	-4,1e ⁻³	-5,1 ^{+*}											1,4e ⁻³	-5,7e ^{-4*}
15_59			-9,1e ⁻³	-5,8e ⁻³					-1,2e ⁻³	-9,1e ⁻⁴				
>60A											-1,1e ⁻³	-7,3e ^{-4*}	-1,9e ⁻³	-7,0e ^{-4*}
V002			5,1e ⁻³	0.015										
V003	3,3e ⁻³	4,1e ⁻³	4,2e ⁻³	1,7e ⁻³	3,4e ⁻³	4,0e ⁻³	-2,3e ⁻⁴	-2,0e ⁻⁴						
P_DE			-0.012	-8,1e ⁻³			-3,5e ⁻⁴	-3,5e ⁻⁴					0.021	0.020
P_TO													-5,1e ⁻³	0.066
ILL_R	3,3e ⁻³	3,2e ⁻³			-4,7e ⁻³	-2,1e ^{-3*}					9,7e ⁻⁴	7,4e ⁻⁵		
D_ROA					8,2e ⁻³	1,6e ^{-3*}			1,4e ⁻³	5,0e ⁻⁴			-3,9e ⁻³	-7,1e ^{-4*}
D_RIV									-2,2e ⁻³	1,3e ⁻³	9,2e ⁻⁴	5,7e ⁻³		
D_1	-0.019	-0.037	0.012	0.01	0.029	0.029	-6,6 ⁻⁴	-4,5 ⁻⁴						
D_2	-0.02	-0.038	-0.067	-0.140	-0.038	-0.056			-7,7e ⁻³	-0.014	-1,6e ⁻³	-4,6e ⁻⁴	4,8e ⁻³	4,9e ⁻³
D_3	5,6e ⁻³	0.021			-0.010	-0.059	-3,8e ⁻⁴	-4,3e ^{-4*}	4,9e ⁻³	0.012				

*Parâmetros não significativos de acordo com estatística t para hipótese $\beta = 0$ ($\alpha = 0,05$)

O modelo de regressão global para o processo de expansão da soja apontou que o fator topográfico possui forte associação com esse processo. Os dados de elevação têm a maior importância positiva dentro do modelo (11,66), o que faz sentido, se pensarmos que a expansão da soja possui os maiores valores de área convertida na porção norte, com altitudes mais elevadas. Outro fator foi a declividade, desta vez com associação negativa (-1,93), uma vez que setores cêntricos com terrenos mais planos favorecem a agricultura mecanizada. Conforme Rudel & Ropper (1997) locais com topografia mais plana favorecem o desmatamento, e países ou regiões com pequenas extensões de florestas ou com remanescentes florestais geralmente possuem uma grande proporção de suas florestas em áreas montanhosas, com menores atrativos econômicos para serem desmatadas, particularmente para agricultura, devido às altas declividades e má qualidade do solo.

Outro fator topográfico com relativa importância negativa (-3,52) para o modelo foi o modelo HAND, que representa a altitude vertical em relação à drenagem mais próxima. Estudos apontam que a expansão da soja na metade sul do Rio Grande do Sul está avançando também sobre áreas de várzea, que são tradicionais no cultivo de arroz irrigado no estado (SANTOS et

al., 2014; MENGUE et al., 2016), com as planícies de inundação dos Rios Jacuí e Ibicuí e nas áreas do entorno da Lagoa dos Patos, o que corrobora com os resultados obtidos.

Fatores demográficos também possuem relação direta com a expansão da soja, sendo que os setores censitários com população jovem (<14A) apresentam importância negativa (-2,09). Uma hipótese para este caso é que nos setores censitários rurais a população adulta é maior e que a população jovem estaria em maior concentração nos grandes centros urbanos, como a Região Metropolitana de Porto Alegre (RMPA). Fatores educacionais como taxa de analfabetismo (ILL_R) apresenta relação positiva com a expansão da soja (1,68), indicando que a expansão da soja avança sobre setores ou regiões onde a escolaridade é menor o que reflete um caráter de menor desenvolvimento econômico com terras menos valorizadas.

Outro fator importante para o modelo de regressão global da expansão da soja foi o fator climático, sendo que a precipitação anual apresenta relação positiva (6,76), evidenciando que a áreas onde a soja está avançando está localizada sobre áreas com precipitação mais elevada. Isto faz sentido, já que a expansão está mais concentrada na região norte, região com os maiores volumes de precipitação, em torno de 1.800 mm/ano. Já a sazonalidade da precipitação apresenta relação negativa (-7,45). Uma das razões é que áreas novas de soja estão localizadas onde a variação da precipitação é baixa, mais estável, localizadas nas região central e norte do Bioma Pampa, já a fronteira oeste e na região sul, próxima a cidade de Pelotas, a variação da precipitação é muito alta, não favorecendo o cultivo de soja.

Fatores de proximidade com áreas degradadas, como distância das áreas de soja (D_1) apresentam forte relação negativa com áreas de soja (-9,08), evidenciando que áreas mais próximas ou áreas de bordas das áreas agrícolas já consolidadas estão mais propícias à expansão da soja.

Para o processo de degradação do campo, os fatores demográficos possuem relação negativa, principalmente a variável densidade populacional (-4,33). Talvez a variável mais citada e controversa, como vetor de degradação de áreas florestais, seja a população ou o crescimento populacional ou, ainda, a noção de 'pressão demográfica' (ALVES, 2004). Isso acontece porque a forte associação entre fatores demográficos e degradação de áreas florestais, encontradas em modelos globais e regionais, geralmente diminui ou até desaparece quando outras variáveis independentes são acrescentadas. Em diversos modelos regionais, isto acontece porque a densidade demográfica está altamente correlacionada com a rede de estradas, com a proximidade de mercados urbanos, com a qualidade dos solos e com a distribuição espacial das atividades econômicas. Assim, a alta correlação entre densidade demográfica e degradação de áreas florestais pode estar apenas refletindo o efeito de outros fatores sobre a degradação

florestal (KAIMOWITZ & ANGELSEN, 1998). No bioma Pampa, os baixos valores de densidade populacional estão associados aos setores censitários rurais e, principalmente, aos que estão localizados na fronteira oeste e sul.

Importante destacar sobre fatores topográficos, que dados do modelo HAND possuem importância negativa para o modelo de regressão (-2.73), indicando que a degradação do campo no período estudado possui forte associação com locais baixos, como áreas de várzeas e próximas dos principais sistemas hídricos.

Fatores de proximidade com as manchas de degradação do campo, apresentam a maior relação negativa para o modelo (-25.86), ou seja, explicam grande parte do ajuste do modelo. Fatores de estrutura da paisagem, como número de manchas dos processos de expansão da soja, expansão da silvicultura e intensificação tiveram valores positivos para o modelo. Os setores censitários com grandes números de manchas têm maior índice de degradação do campo. Conforme Vélez-Martin et al. (2015) problemas ecológicos associados à supressão dos campos podem ser ainda mais graves quando a redução em área é acompanhada de fragmentação dos remanescentes na paisagem. Quando há um grande número de manchas menores de campo, maior é a superfície de contato entre as espécies campestres e os ambientes do entorno. É o denominado efeito de borda. Na Figura 06 comparando a classificação da classe Campo do ano de 2000 para 2014, a frequência de pixels da classe campo mais próximas das áreas de soja com distâncias de até 1250 metros é duas vezes superior, como hipótese para esse fenômeno de que as manchas florestais de campo estão muito mais fragmentadas, aumentando desta maneira a proximidade com áreas de soja.

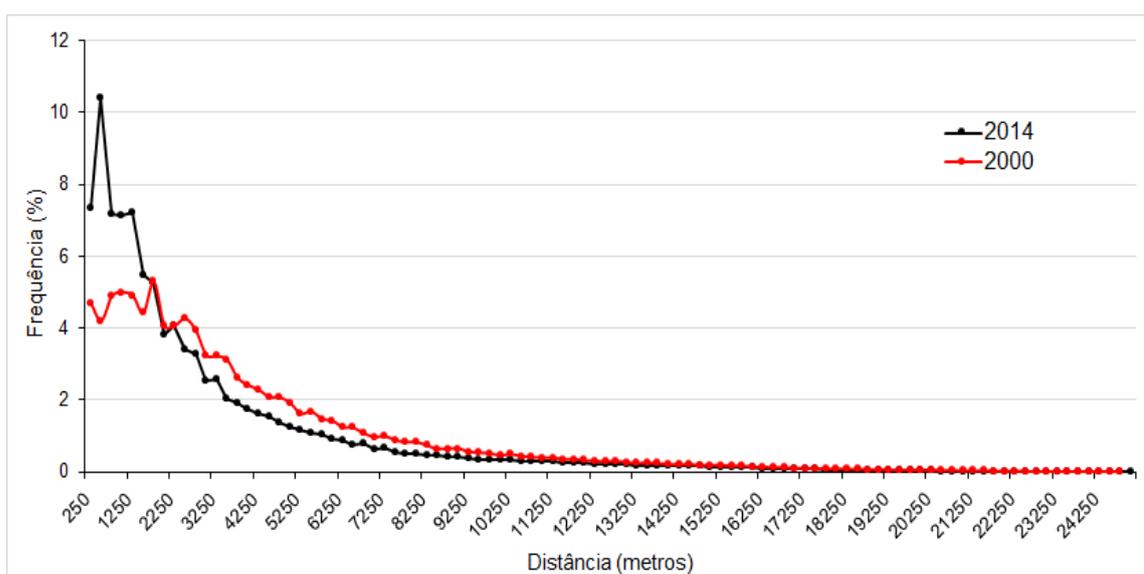


Figura 06: Distância em metros das áreas de campo mapeadas com o sensor MODIS em relação às áreas de soja para os anos 2000 e 2014.

Os fatores que possuem relação positiva no modelo global para o processo de degradação do campo são: População residente em domicílios (1,89), média do número de moradores em domicílios (1,76), manchas de expansão da soja (3,75) e distância do processo de expansão da soja (4,64).

O modelo de regressão global para o processo de expansão da silvicultura apontou que o fator topográfico possui forte associação com a declividade possuindo maior importância positiva dentro do modelo (10,92). A expansão da silvicultura está concentrada na Serra do Sudeste, numa faixa sudoeste-nordeste, região caracterizada pelo predomínio de uma topografia ondulada com declives moderados. A expansão de novas áreas de silvicultura se dá em áreas com declives mais acentuados, como a Serra do Sudeste, talvez por isso o fator declividade teve grande influência no modelo de regressão global.

Dados econômicos, como o rendimento médio mensal, apontaram relação positiva (2,52) refletindo que os setores censitários com maior nível de renda possuem relação direta com a expansão da silvicultura. Uma justificativa que pode sustentar esse parâmetro é que maiores níveis de renda na região significam uma maior demanda por produtos agrícolas e florestais e maior disponibilidade de recursos para investir em atividades voltadas à silvicultura. A variável educacional (taxa de analfabetismo) possui relação negativa com a expansão da silvicultura (-2,45), indicando que os setores censitários com maior escolaridade possuem maior importância no modelo, corroborando a relação da silvicultura com regiões mais desenvolvidas.

O Fator climático precipitação anual possui relação negativa (-1,23) no modelo, devido à região da Serra do Sudeste, onde a expansão da silvicultura é maior, possuir média inferior (1.426 mm/ano) quando comparada com a região norte. Fatores de proximidade como distâncias de estradas possuem relação positiva (3,86) com o modelo de regressão global, setores censitários com altas taxas de expansão da silvicultura no período estudado estão mais afastados das principais rodovias ou quando a malha rodoviária é menos densa. A relação à proximidade com áreas degradadas de campo, se mostrou possui fortemente negativa (-16,35) no modelo, indicando que novas áreas de silvicultura estão ocupando áreas remanescentes de vegetação campestre.

Analisando a Tabela 4, o melhor desempenho do modelo local (GWR) para todos os processos em comparação com o modelo global é demonstrados valores de R^2 significativamente mais altos e pelos baixos valores de AICc. Através do uso do GWR foi possível identificar a existência de variações espaciais nas variáveis preditivas, permitindo relações não estacionárias entre os processos e as variáveis independentes de serem detectadas. A grande vantagem do método GWR foi a capacidade de explorar a variabilidade espacial nas

relações dos processos de USCV e das variáveis explicativas através do mapeamento da variação dos parâmetros dos coeficientes locais.

Tabela 4: Resultados dos modelos de regressão global (OLS) e local (GWR)

Processos	Regressão Modelo	R ²	AICc	DF	Nº Variáveis
1 - Expansão Soja	Global OLS	0,4216	-4325,86	1729	13
	GWR	0,8323	-5511,18	1239,66	
2 - Degradação Campo	Global OLS	0,3766	-3315,73	1729	12
	GWR	0,7677	-4177,80	1288,87	
3 - Expansão Silvicultura	Global OLS	0,3984	-3977,57	1729	12
	GWR	0,8029	-4866,42	1209,91	
4 - Intensificação	Global OLS	0,1056	-12987,88	1729	10
	GWR	0,2325	-13159,91	1657,90	
5 - Degradação Florestal	Global OLS	0,2828	-8171,63	1729	9
	GWR	0,7233	-8831,07	1234,47	
6 - Regeneração	Global OLS	0,2194	-10427,52	1729	8
	GWR	0,4654	-10693,62	1490,47	
7 - Urbanização	Global OLS	0,2719	-6528,85	1729	10
	GWR	0,7048	-7272,50	1303,71	

O GWR apesar de oferecer muitas vantagens, quando comparado ao modelo global, alguns parâmetros como o tamanho da largura da banda (Kernel), utilizada para o cálculo espacial dos vizinhos (setores censitários) deve ser cuidadosamente analisado, devido ao seu impacto significativo nos resultados da análise. Em geral, larguras de bandas muito pequenas resultam em estimativas dos parâmetros altamente localizados e têm grande grau de variação na área de estudo. Por outro lado, quando o comprimento da banda é muito elevado (por exemplo, maior que o tamanho da área de estudo), os resultados da regressão local podem ser idênticos de uma regressão global (WHEELER E TIEFELSDORF, 2005). No presente trabalho foi utilizado para escolher a melhor largura de banda o método adaptativo Gaussiano, onde a largura de banda para o modelo GWR nos processos de USCV variou entre 112 e 129 km.

Na Figura 07 estão os resultados da GWR, na qual o R² apresenta o quão ajustado é o modelo para os processos de USCV. Pode-se observar que os setores censitários em vermelho e laranja são as regiões onde o modelo apresenta os melhores ajustes. Para o processo de expansão da soja (A), os melhores ajustes do modelo ocorrem na porção sul, central e norte, onde o R² tem uma variação de 0,02 a 0,86. Já no modelo local do processo de degradação do campo, os melhores ajustes estão localizados na porção extremo norte, divisa com Argentina,

ao Sul e ao longo do Rio Jacuí, onde a variação do R^2 ficou entre 0,54 a 0,87. Para o processo de expansão da silvicultura os melhores ajustes do modelo ficaram concentrados na Serra do Sudeste, na porção sudoeste-nordeste, nas porções leste e oeste o modelo não explicou muito bem a partir das variáveis independentes, a variação foi de 0,01 a 0,93.

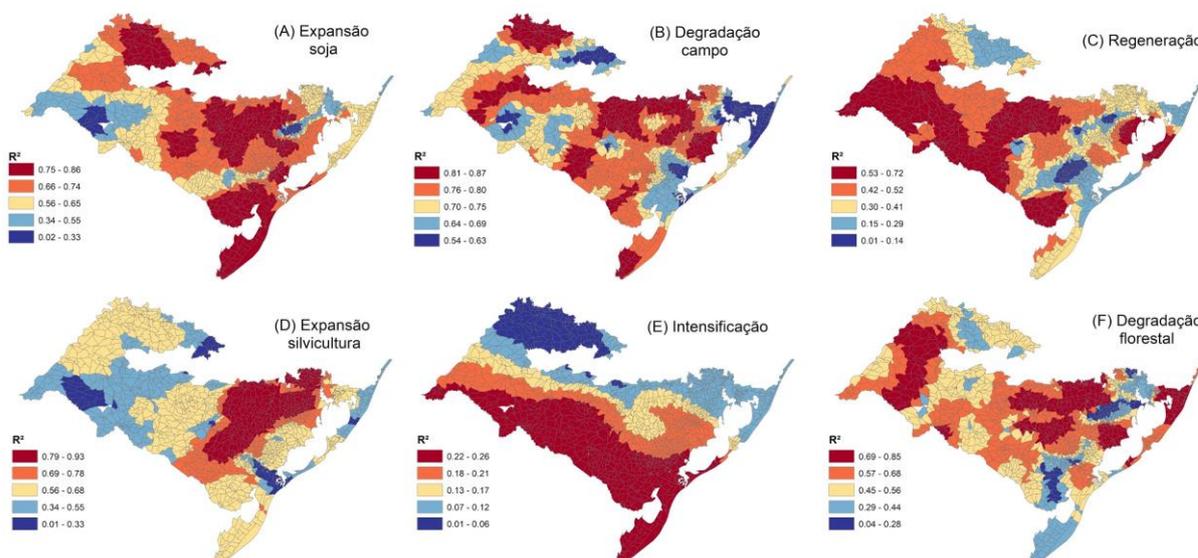


Figura 07: Distribuição dos resultados dos ajustes locais de R^2 GWR entre os processos de USCV e as variáveis independentes.

Quando comparamos os coeficientes (β) dos parâmetros globais e locais (Tabela 03) é possível perceber que são muito similares, mas quando analisamos os dados da regressão local, as diferenças são bem significativas entre diversas regiões na área do Bioma Pampa, revelando a grande vantagem em utilizar modelos locais para explicar fenômenos peculiares de cada região. Devido à grande quantidade de variáveis independentes no modelo GWR para cada processo de USCV, na próxima seção sintetizamos os resultados dos parâmetros locais por agrupamentos de regiões pelo método SKATER, afim de analisar a variabilidade existente dentro da área de estudo.

3.3 Agrupamento espacial (SKATER) dos parâmetros locais

Analisando os agrupamentos espaciais gerados pelo método SKATER (Figura 08) para todos processos de USCV, alguns agrupamentos são similares, principalmente entre o processo de expansão da soja e degradação do campo na porção norte da área de estudo. Na região da fronteira com o Uruguai e Oeste com Argentina os agrupamentos espaciais formaram grandes grupos com grandes áreas, explicado pelo fato desta região apresentar algumas características similares, como o tamanho médio das áreas agrícolas e o relevo (suavemente ondulado).

O processo de expansão da soja exibiu diferentes parâmetros no modelo GWR para os diferentes agrupamentos espaciais, isso evidencia que existe uma grande variabilidade das

variáveis independentes na área de estudo para este processo. Na porção norte (agrupamentos 4 e 5), os fatores que mais contribuem positivamente são a precipitação anual, a distância da expansão da silvicultura, o modelo HAND e a média do número de moradores em domicílios. Já os fatores que contribuem negativamente são a declividade, o coeficiente de variação da precipitação, a distância de expansão da soja e a distância de degradação de campo. O agrupamento espacial 2, localizado na porção mais baixa do relevo em comparação com os agrupamentos 4 e 5, apresenta outros fatores. Positivamente o principal fator é o número de manchas de degradação do campo, negativamente são a precipitação anual, o coeficiente de variação da precipitação, a distância de expansão da soja e a distância de degradação de campo. O agrupamento espacial 1, é o maior em tamanho de área, no sentido leste-oeste, e não apresenta nenhuma variável de grande importância para o modelo de regressão. Já o agrupamento espacial 3, localizado no extremo sul do Estado do RS, possui alguns fatores de grande importância para o modelo de expansão da soja, sendo os principais positivamente a declividade e a precipitação anual e os negativamente o modelo HAND e a distância do processo de expansão da soja.

O processo de degradação do campo, apresentou padrões de agrupamentos espaciais similares aos padrões do processo de expansão da soja. Os agrupamentos 1 e 2 apresentam como fatores positivos a população residente e a distância do processo de expansão da soja, e como valores negativos o coeficiente de variação da precipitação e a distância de degradação do campo. A variável que possui grande mudança entre os dois agrupamentos foi de população residente, enquanto no agrupamento 1 esta variável apresentou forte relação negativa, no agrupamento 2 apresentou relação positiva devido ao fato de os setores censitários localizados no agrupamento 2 possuírem maior população. O agrupamento espacial 3 possui a maior área entre os agrupamentos e tem como principal fator positivo a população residente e o número de manchas de degradação de campo. O agrupamento 4 engloba boa parte do litoral do RS e também a RMPA, uma região onde o processo de degradação da vegetação campestre se iniciou há muito mais tempo, marcado pela forte presença do cultivo de arroz irrigado nas planícies de inundações dos principais sistemas de drenagem existentes.

O processo de expansão da silvicultura apresenta padrões de agrupamentos espaciais bem distintos: dois grandes grupos (1 e 2) dividindo a área de estudo em duas partes leste-oeste, e outros três agrupamentos menores nas proximidades da Serra do Sudeste, onde existe a maior concentração de expansão da silvicultura. Nos agrupamentos 1 e 2 praticamente não temos nenhuma variável com peso significativo para o modelo de regressão. O agrupamento espacial 3, localizado nas proximidades do município de Encruzilhada do Sul apresenta como fator positivo para expansão da silvicultura a variável precipitação anual e como fator negativo a

distância do processo de degradação do campo e a distância da expansão da silvicultura. O agrupamento 4, localizado nas proximidades do município de Camaquã, possui como principal fator positivo a elevação e como fatores negativos a precipitação anual, a distância do processo de degradação do campo e a distância da expansão da silvicultura. O agrupamento 5, localizado nas proximidades do município de Canguçu, possui como principal variável positiva a precipitação anual e como fatores negativos o número de manchas no processo de degradação florestal, a distância do processo de degradação do campo e a distância da expansão da silvicultura. Variáveis comuns para os três agrupamentos (3,4 e 5) foram a distância do processo de degradação do campo e a distância da expansão da silvicultura

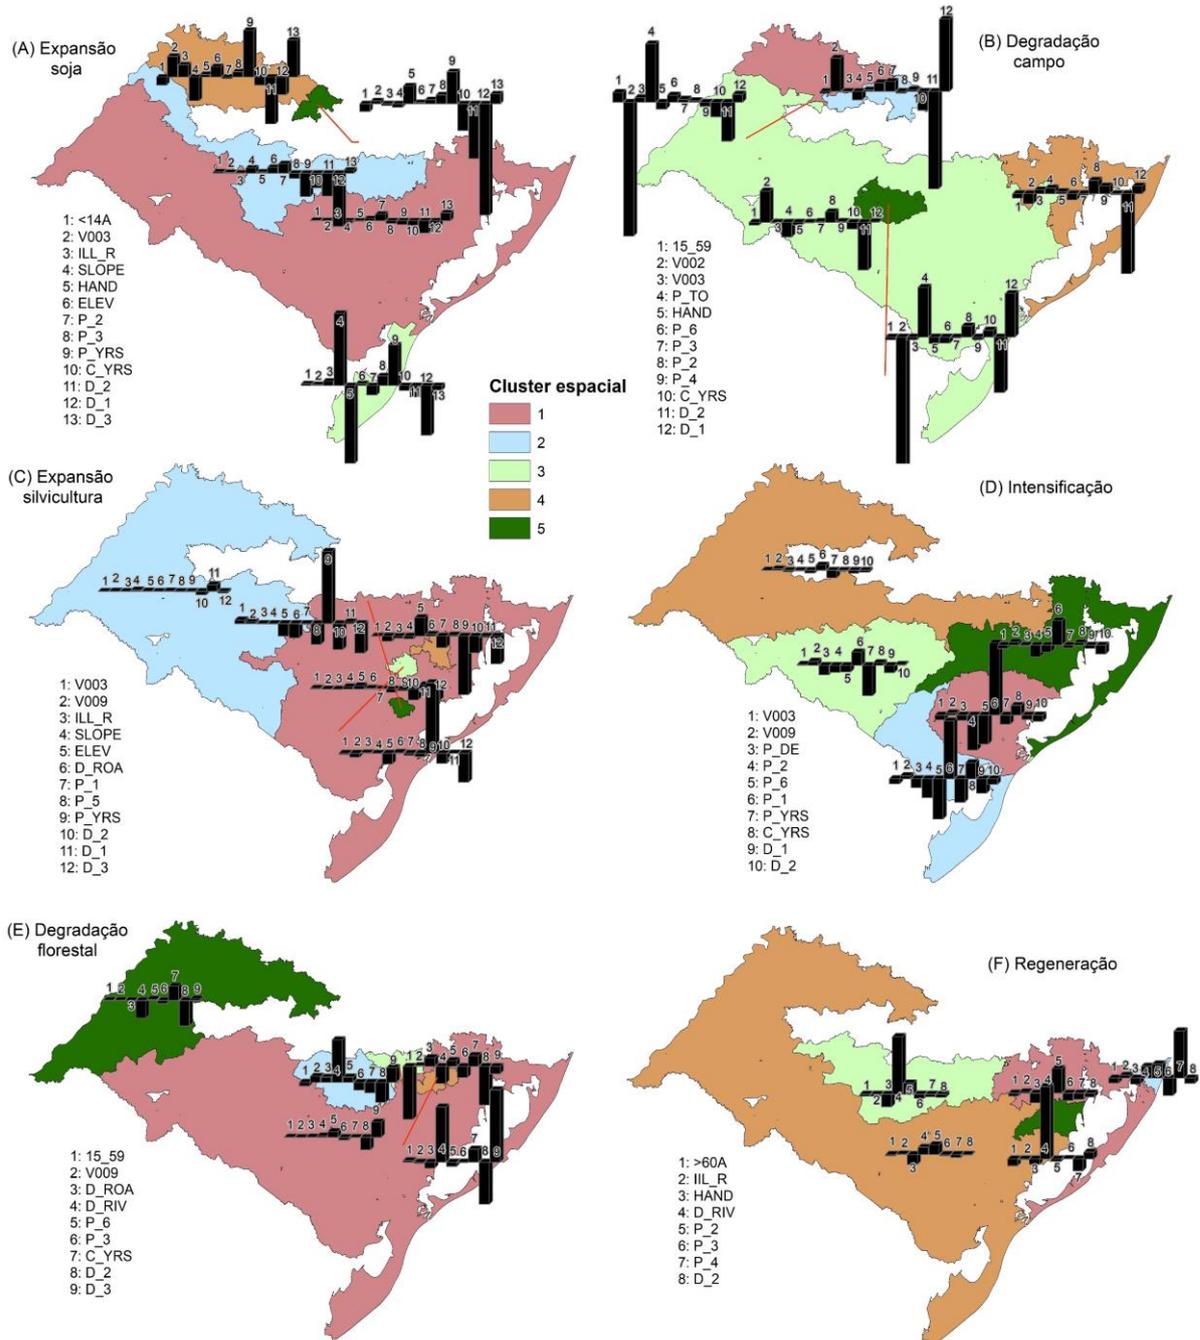


Figura 08: Mapa dos agrupamentos espaciais utilizando os parâmetros locais obtidos com o GWR para os processos de USC.

4. CONCLUSÕES

Os principais processos que tem contribuído para a degradação da vegetação campestre nestes últimos 15 anos foram a expansão das áreas de soja e silvicultura. Através da utilização de técnicas de sensoriamento remoto e geoprocessamento é possível identificar que o padrão de degradação da vegetação campestre é um processo complexo e que envolve uma série de fatores, e que tende a ocorrer muito próximo de áreas já previamente degradadas. O principal

processo de degradação da vegetação campestre é a atividade antrópica, em especial a agricultura mecanizada, com o cultivo de soja e áreas de silvicultura.

A combinação das imagens MODIS/EVI com as imagens de iluminação noturna (DMSP-OLS) permitiram identificar e quantificar o aumento de aproximadamente 1.244.750 ha das áreas cultivadas com soja no Bioma Pampa, o que corresponde a um incremento na ordem de 145,56%. As áreas de silvicultura também tiveram um aumento significativo de área, com 555.734 ha, um incremento de mais de 167 % da sua área total. Em contrapartida, houve diminuição da vegetação campestre em torno de 25% de sua área total num intervalo de 15 anos, perdendo um total de 2.576.536 ha.

Os resultados dos modelos de regressão local (GWR) e global mostram que os processos de USCV no Bioma Pampa estão relacionados com variáveis geomorfométricas, climáticas, de distância das áreas já degradadas e socioeconômicas. Para o processo de USCV de expansão da soja, os principais fatores identificados foram: topográficos (elevação, declividade e modelos HAND), população jovem, fatores educacionais (como a taxa de analfabetismo), fatores climáticos (precipitação anual e sazonalidade da precipitação), e fatores de proximidade com áreas degradadas.

No processo de USCV de expansão da silvicultura, os principais fatores identificados são: declividade, rendimento médio mensal, taxa de analfabetismo, precipitação anual e proximidade com áreas degradadas de campo. No processo de USCV de degradação do campo, os principais fatores identificados foram: densidade populacional, população residente em domicílios, modelo HAND, manchas de degradação do campo, média do número de moradores em domicílios, manchas de expansão da soja e distância do processo de expansão da soja.

O modelo de regressão local (GWR) é importante para entender o alto nível de complexidade da paisagem do Bioma Pampa, caracterizada por um grau considerável de heterogeneidade, fragmentação e agregação espacial, especialmente na porção norte e na Serra do Sudeste. A regionalização pelo método SKATER permite analisar a variabilidade existente das variáveis independentes nas diferentes regiões da área de estudo, para os processos de USCV, agrupando em 5 grupos espaciais, melhorando desta forma o entendimento sobre a dinâmica dos processos sobre do território do Bioma Pampa.

REFERÊNCIA BIBLIOGRÁFICA

- ALLEN, V. G.; BATELLO, C.; BERRETA, E. J.; HODGSON, J.; KOTHMANN, M.; LI, X.; MCIVOR, J.; MILNE, J.; MORRIS, C.; PEETERS, A.; SANDERSON, M. An international terminology for grazing lands and grazing animals. **Grass and Forage Science**, v. 66, n.1, p. 2-28, 2011.
- ALVES, D. S. Space-time dynamics of deforestation in Brazilian Amazonia. **International Journal of Remote Sensing**, 23(14), 2903-2908, 2002.
- ALVES, H. P. F. Análise dos fatores associados às mudanças na cobertura da terra no Vale do Ribeira através da integração de dados censitários e de sensoriamento remoto. Tese (Doutorado em Ciências Sociais). IFCH: UNICAMP, Campinas. 2004.
- ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L.M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728. 2013.
- ANDERSON, J. R.; HARDY, E. E.; ROACH, J. T.; WITMER, R. E.. **A Land Use and Land Cover Classification System for Use with Remote Sensor Data**. Washington, D.C.: United States Geological Survey, 1976. 36 p.
- ASSUNÇÃO, R.M.; NEVES, M.C.; CÂMARA, G.; FREITAS, C. C. Efficient regionalization techniques for socio-economic geographical units using minimum spanning trees. **Int J Geogr Inf Sci** 20(7):797–811, 2006.
- BATISTELLA, M.; VALLADARES, G.S. Farming expansion and land degradation in Western Bahia, Brazil. **Biotaneotropica** 9(3):61–76, 2009.
- BINKOWSKI, P. Conflitos ambientais e significados sociais em torno da expansão da silvicultura de eucalipto na “Metade Sul” do Rio Grande do Sul. 2009. 212 f. Dissertação (Mestrado em Desenvolvimento Rural) - UFRGS, Porto Alegre, 2009.
- BOLDRINI, I. I. A flora dos campos do Rio Grande do Sul. *In*: PILLAR, V.P.; MÜLLER, S.C.; CASTILHOS, Z.M.S; JACQUES, A.V.A. (ed). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, 2009. 403p.
- BRUNSDON, C.; FOTHERINGHAM, A. S.; CHARLTON, M. E. Geographically weighted regression: a method for exploring spatial nonstationarity. **Geographical Analysis**, 28(4), 281-298, 1996.
- CASSMAN, K. G.; WOOD, S.; CHOO, P. S.; COOPER, H. D.; DEVENDRA, C.; DIXON, J. Cultivated systems. In **Ecosystems and human well-being: Current state and trends** (pp. 745e794). Washington DC: Island Press. 2005.
- DEFRIES, R. S.; FOLEY, J. A.; ASNER, G. P. Land use choices: balancing human needs and ecosystem function. **Frontiers in Ecology and the Environment**, 2, 249-257, 2004.
- ESPINDOLA, G. M.; AGUIAR, A. P. D.; PEBESMA, E.; CÂMARA, G.; FONSECA, L. Agricultural land use dynamics in the Brazilian Amazon based on remote sensing and census data. **Applied Geography**. v. 32, p. 240-252, 2012.
- FOLEY, J. A., DEFRIES, R., ASNER, G. P., BARFORD, C., BONAN, G., CARPENTER, S. R.. Global consequences of land use. **Science**, 309(5734), 2005. 570-574. <http://dx.doi.org/10.1126/science.1111772>.
- FOOD AND AGRICULTURE ORGANIZATION. The state of food and agriculture, 2006: Food aid for food security? (No. 37), 2006.

- FOTHERINGHAM, A. S.; BRUNSDON, C.; CHARLTON, M. Geographically weighted regression: the analysis of spatially varying relationships. Chichester: John Wiley & Sons. 2002.
- FREITAS, M, W, D.; SANTOS, J. R.; ALVES, S. A. Land-use and land-cover change processes in the Upper Uruguay Basin: linking environmental and socioeconomic variables. **Landscape Ecology**. v. 28 p. 311-327, 2013.
- FRIEDL, M. A.; MCIVER, D.K.; HODGES, J.C.F.; ZHANG, X.Y.; MUCHONEY, D.; STRAHLER, A.H.; WOODCOCK, C.E.; GOPAL, S.; SCHNEIDER, A.; COOPER, A.; BACCINI, A.; GAO, F.; SCHAAF, C. Global land cover mapping from MODIS: algorithms and early results. **Remote Sensing of Environment** 83, 287 – 302, 2002.
- GAO, J.; LI, S. Detecting spatially non-stationary and scale-dependent relationships between urban landscape fragmentation and related factors using geographically weighted regression. **Applied Geography**. v.31, p.292-302, 2011.
- GATRELL, A. C. et al. Spatial point pattern analysis and its application in geographical epidemiology. *Transactions of the Institute of British Geographers*, v. 21, p. 256– 274, 1996. ISSN 00202754.
- GIBBS, H. K.; RUESCH, A. S.; ACHARD, F.; CLAYTON, M. K.; HOLMGREN, P.; RAMANKUTTY, N. (2010). Tropical forests were the primary sources of new agricultural land in the 1980s and 1990s. **Proceedings of the National Academy of Sciences**, 107(38), 16732-16737, 2010. <http://dx.doi.org/10.1073/pnas.0910275107>
- GILBERT, A.; CHAKRABORTY, J. Using geographically weighted regression for environmental justice analysis: Cumulative cancer risks from air toxics in Florida. **Social Science Research**, 40(1), 273-286, 2011.
- GRECCHI, R. C.; GWYN, Q. H. J.; BÉNIÉ, G. B.; FORMAGGIO, A. R.; FAHLC, F. C. Land use and land cover changes in the Brazilian Cerrado: A multidisciplinary approach to assess the impacts of agricultural expansion. **Applied Geography**. v. 55, p. 300-312, 2014.
- HASENACK, H.; WEBER, E.(org.) Base cartográfica vetorial contínua do Rio Grande do Sul - escala 1:50.000. Porto Alegre: UFRGS Centro de Ecologia. 2010. 1 DVD-ROM. (Série Geoprocessamento n.3). ISBN 978-85-63483-00-5 (livreto) e ISBN 978-85-63843-01-2 (DVD). 2010.
- HUANG, Y.; LEUNG, Y. Analysing regional industrialisation in Jiangsu province using geographically weighted regression. **Journal of Geographical Systems**, 4(2), 233-249, 2002.
- Instituto Brasileiro de Geografia e Estatística – IBGE (2017) Sistema IBGE de recuperação automática: banco de dados agregados. Rio de Janeiro: IBGE. Recuperado em 12 de Setembro de 2017, de [http:// www. sidra. ibge. gov. br/](http://www.sidra.ibge.gov.br/).
- JACÓBSEN, L. O.; FONTANA, D. C.; SHIMABUKURO, Y. E. Alterações na vegetação em macrozonas do Rio Grande do Sul associados a eventos El Niño e La Niña, usando imagens NOAA. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 11, n. 2, p.361-374, 2003.
- JACÓBSEN, L. O.; FONTANA, D. C.; SHIMABUKURO, Y. E. Efeitos associados a El Niño e La Niña na vegetação do Estado do Rio Grande do Sul, observados através do NDVI/NOAA. **Revista Brasileira de Meteorologia**, v. 19, n. 1, p.129-140, 2004.
- KAIMOWITZ, D. & ANGELSEN, A. Economic models of tropical deforestation: a review. Bogor, Indonesia: CIFOR. 1998.

- LAMBIN, E. F.; MEYFROIDT, P. Global land use change, economic globalization, and the looming land scarcity. **Proceedings of the National Academy of Sciences**, 108(9), 3465-3472, 2011. <http://dx.doi.org/10.1073/pnas.1100480108>.
- LIU, Y.; WANG, X.; GUO, M.; TANI, H.; MATSUOKA, N.; MATSUMURA, S. Spatial and temporal relationships among NDVI, climate factors, and land cover changes in Northeast Asia from 1982 to 2009. **GIScience and Remote Sensing**. 48 (3), 371– 393, 2011.
- MENGUE, VAGNER P.; FONTANA, DENISE C. . IDENTIFICATION OF SUITABLE AREAS FOR IRRIGATED RICE CROPPING USING MODIS IMAGES AND HAND MODEL. *Engenharia Agrícola (Online)*, v. 36, p. 329-341, 2016.
- MENNIS, J. Mapping the Results of Geographically Weighted Regression. **The Cartographic Journal**. V. 43 N. 2 p 171–179, 2006.
- MOREIRA, V. S.; MEDEIROS, R. M. V. As novas configurações do espaço agrário no Rio Grande do Sul / Brasil: da pecuária tradicional ao complexo agroindustrial da soja. **Confins**, n. 20, 2014.
- NABINGER, C.; FERREIRA, E. D.; FREITAS, A. K.; CARVALHO, P. C. F.; SANT'ANNA, D. M. Produção animal com base no campo nativo: aplicações de resultados de pesquisa. In: PILLAR, V.P.; MÜLLER, S.C.; CASTILHOS, Z.M.S; JACQUES, A.V.A. (ed). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, 2009. 403p.
- NELLEMANN, C.; MACDEVETTE, M.; MANDERS, T.; EICKHOUT, B.; SVIHUS, B.; PRINS, A. G. The environmental food crisis e the environment's role in averting future food crises. In A UNEP rapid response assessment. Arendal: United Nations Environment Programme, GRID. 2009.
- NETER, J.; KUTNER, N. H.; NACHTSSHEIM, C. J.; WASSERMAN, W. **Applied Linear Statistical Models**. 4 ed. Boston: McGraw Hill, 1996.
- NOBRE, A. D.; CUARTAS, L. A.; HODNETT, M.; RENNO, C. D.; RODRIGUES, G.; SILVEIRA, A.; WATERLOO, M.; SALESKA, S. Height above the Nearest Drainage, a hydrologically relevant new terrain model. **Journal Hydrology**. v. 404, n. 1-2, p.13–29, 2011. doi:10.1016/j.jhydrol.2011.03.051
- OGNEVA-HIMMELBERGER, Y.; PEARSALL, H.; & RAKSHIT, R. Concrete evidence & geographically weighted regression: a regional analysis of wealth and the land cover in Massachusetts. **Applied Geography**, 29, 478-487, 2009.
- OVERBECK, G. E. Brazil's neglected biome: The South Brazilian *Campos*. **Perspectives in Plant Ecology, Evolution and Systematics**, v.9, n.1, p. 101-116, 2007.
- QUINLAN, J. R. C4. 5: programs for machine learning. San Francisco, CA: Morgan kaufmann, 1993.
- Rio de Janeiro: IBGE, 1986. 1 CD-ROM. (Levantamento de Recursos Naturais, v. 33)
- ROUGHGARDEN, J.; RUNNING, S.W.; MATSON, P.A. What does remote sensing do for ecology? **Ecology**, 72, 1918–1922. 1991.
- RUDEL, T. K. & ROPER, J."Regional Patterns and Historical Trends in Tropical Deforestation, 1976-1990: A qualitative comparative analysis". *Ambio* 25, no. 3, pp. 160-166. 1996.
- SANTOS, J. S.; FONTANA, D. C.; SILVA, T. S. F.; RUDORFF, F. T. Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. *Rev. Bras. Eng. Agríc. Ambient*, v.18, n.1, p.54-63, 2014.

- SCOTTÁ, F. C.; FONSECA, E. L. Multiscale Trend Analysis for Pampa Grasslands Using Ground Data and Vegetation Sensor Imagery. **Sensors** (Basel), v. 15, p. 17666-17692, 2015.
- SEE, L.; SCHEPASCHENKO, D.; LESIV, M.; MCCALLUM, I.; FRITZ, S.; COMBER, A.; OBERSTEINER, M. Building a hybrid land cover map with crowdsourcing and geographically weighted regression. **ISPRS Journal of Photogrammetry and Remote Sensing**, 103, 48-56, 2015.
- SMITH, C. S.; & MCDONALD, G. T. Assessing the sustainability of agriculture at the planning stage. **Journal of Environmental Management**, 52, 15-37, 1998.
- TU, J. Spatially varying relationships between land use and water quality across an urbanization gradient explored by geographically weighted regression. **Applied Geography**. v.31, p.376-392, 2011.
- VÉLEZ-MARTIN, E.; ROCHA, C. H.; BLANCO, C.; AZAMBUJA, B. O.; HASENACK, H.; PILLAR, V. P. conversão e fragmentação. In: PILLAR, V. P; LANGE, O **Os Campos do Sul**. Porto Alegre: Rede Campos Sulinos – UFRGS, 2015. p. 192.
- WAGNER, A. P. L.; FONTANA, D. F.; FRAISSE, C.; WEBER, E. J.; HASENACK, H. Tendências temporais de índices de vegetação nos campos do Pampa do Brasil e do Uruguai. **Pesq. agropec. bras.**, Brasília, v.48, n.9, p.1192-1200, set. 2013.
- WHEELER, D.; TIEFELSDORF, M. Multicollinearity and correlation among local regression coefficients in geographically weighted regression. *J. Geogr. Syst.* 7, 161–187. 2005. <http://dx.doi.org/10.1007/s10109-005-0155-6>.
- WU, S.; J. HUANG, X.; LIU, AND G. MA. Forest Cover Classification from Multi-temporal MODIS Images in Southeast Asia Using Decision Tree. In *Computer and Computing Technologies in Agriculture V*, edited by D. L. Li and Y. Y. Chen, 400–414. 5th IFIP TC 5/SIG 5.1 Conference. CCTA 2011. Proceedings, Part II. Beijing, October 29–31, 2011. Berlin: Springer. doi:10.1007/978-3-642-27278-3_43. 2012.
- ZHAO, M.; RUNNING, S.T. Remote sensing of terrestrial primary production and carbon cycle. In *Advances in Land Remote Sensing: System, Modelling, Inversion and Application*; Liang, S., Ed.; Springer: College Park, FL, USA, p. 423–444, 2008.
- ZHOU, F.; ZHANG, A.; TOWNLEY-SMITH, L. A data mining approach for evaluation of optimal time-series of MODIS data for land cover mapping at a regional level. **Journal of Photogrammetry and Remote Sensing**. 84 114–129, 2013.

Capítulo III - Considerações finais

O trabalho experimental no município de Tupanciretã permitiu entender a dinâmica do USCV ao longo de três décadas. A pesquisa no município foi importante no sentido de aprimorar o conhecimento sobre técnicas de classificação com imagens de satélite, além de proporcionar um registro espaço-temporal das mudanças do USCV. Foi possível identificar e quantificar, através de imagens TM/Landsat-5 e OLI/Landsat-8, um aumento crescente ao longo dos anos das áreas agrícolas (especialmente cultivo de soja). Em contrapartida, a vegetação campestre reduziu seu tamanho, sendo convertida principalmente pela agricultura.

A partir da detecção e classificação nos anos de 1985 e 2015 foi possível testar e analisar quais as variáveis explanatórias foram mais importantes e contribuíram para explicar os principais processos de USCV no município de Tupanciretã, podemos destacar alguns fatores: Distância das transições entre as datas estudadas, distância das áreas agrícolas, distância área urbana e distância da drenagem.

A pesquisa contribui para o desenvolvimento da metodologia e entendimento da dinâmica dos processos do USCV, este trabalho foi fundamental e encorajou para o desenvolvimento do próximo artigo. A ideia foi implementar em todo o Bioma Pampa Gaúcho, utilizando um sensor de média resolução espacial. Apesar das limitações espaciais do sensor MODIS, os resultados encontrados foram satisfatórios, já que este sensor possui maior resolução temporal e contínua apropriada para caracterizar as dinâmicas dos variados tipos de USCV do Bioma Pampa. Os resultados mostraram que é possível identificar os principais processos de USCV no Bioma Pampa Gaúcho através de séries temporais MODIS e que os processos que mais contribuíram para a degradação da vegetação campestre são a expansão das áreas de soja e silvicultura.

Na busca por testar diversos métodos de classificação de USCV com maior qualidade do produto final, foi utilizado para isto, além dos dados MODIS, diversos dados em conjunto, como os dados de elevação SRTM e imagens noturnas DMSP-OLS para avaliar questões de irrigação, bem como a localização com maior precisão de áreas urbanas. Este método constituiu um avanço no grau de detalhamento em relação aos trabalhos já desenvolvidos na região, permitindo levar em conta as especificidades de cada região do Bioma Pampa Gaúcho.

A utilização da classificação hierárquica por árvore de decisão (AD) para identificar o USCV foi uma decisão acertada, pois permitiu uma quantificação compatível com a escala em análise. A metodologia proposta para identificar e classificar a soja de outras culturas, como o arroz irrigado, mostrou-se eficiente, empregando técnicas de classificação espectro-temporal com dados de elevação através da criação do Modelo HAND, desta maneira foi possível separar

as áreas de várzea, aumentando a exatidão da classificação por AD entre a cultura do arroz irrigado de outras culturas com ciclos coincidentes, como a cultura da soja. A correta identificação e classificação dos principais cultivos como a soja e o arroz irrigado, foi importante pois permitiu analisar sobre quais áreas a soja está expandido.

O desenvolvimento de uma metodologia que envolva vários tipos de sensores orbitais para a classificação do USCV, apesar de ser um pouco mais complexa, do que a utilização de uma série temporal de um único sensor, se mostrou ser mais eficiente, pois apresentou um resultado final com uma qualidade de mapeamento superior.

Através deste trabalho foi possível analisar o potencial da série temporal MODIS, especialmente do produto MOD13Q1 com composição de 16 dias livre de nuvens, fornecendo uma série de mapas com enfoque para detecção das mudanças do USCV desde o início dos anos 2000. Importante destacar, que embora promissora, a metodologia de utilização de classificação com a série temporal MODIS, imagens noturnas e dados de elevação, depende do tipo de paisagem a ser classificada, e do seu grau de homogeneidade ou heterogeneidade. No caso do Bioma Pampa Gaúcho, existem diferenças (relevo, tipo de vegetação) locais importantes, como a Serra do Sudeste e a parte Nordeste (rebordo do planalto) que devem ser consideradas no momento da classificação.

O trabalho gerou um conjunto de informações que fornecem resultados na forma de perfis temporais e de mapas, identificando através da AD os melhores períodos para separação de diferentes classes de USCV. A grande quantidade de dados gerados pode fornecer informações importantes no âmbito nacional, no aprimoramento e conhecimento da dinâmica das classes de USCV ao longo do tempo, não só do bioma Pampa, mas de outros biomas brasileiros. Fornecendo informações que podem integrar estudos sobre o tema, tornando-os potenciais dados de entrada para detecção e análise do USCV em outros biomas brasileiros.

A metodologia de classificação de USCV construída neste estudo possibilitou a aplicação em outros anos da série temporal do sensor MODIS, permitindo analisar a dinâmica da transformação da paisagem ao longo do tempo na área de estudo, que foi o tema para o desenvolvimento do último artigo desta tese. Foi identificado que o principal processo de degradação da vegetação campestre no Bioma Pampa Gaúcho é a atividade antrópica, em especial a agricultura mecanizada, como o cultivo de soja e áreas de silvicultura. Enquanto as áreas de soja e silvicultura tiveram um aumento de 145% e 167% de suas áreas, respectivamente, em contrapartida, houve diminuição da vegetação campestre em torno de 25% de sua área total num intervalo de 15 anos, perdendo um total de 2.576.536 ha em todo o Bioma Pampa Gaúcho.

Na investigação de quais fatores são responsáveis pelos processos de transformação da paisagem na área de estudo, os modelos de regressão local e global mostraram que os processos de USCV no Bioma Pampa estão relacionados com as variáveis geomorfométricas, climáticas, de distância das áreas já degradadas e socioeconômicas. Para o processo de USCV de expansão da soja, os principais fatores identificados foram: topográficos (elevação, declividade e o modelo HAND), população jovem, fatores educacionais (como a taxa de analfabetismo), fatores climáticos (precipitação anual e sazonalidade da precipitação), e fatores de proximidade com áreas degradadas.

Aplicar e testar um modelo de regressão local (GWR) foi importante para entender as especificidades de cada região dentro do Bioma Pampa e que algumas variáveis se mostram mais importantes do que outras dependendo da região. Sendo importante para entender o alto nível de complexidade da paisagem no Bioma Pampa caracterizada por um grau considerável de heterogeneidade, fragmentação e agregação espacial, especialmente na porção norte e na Serra do Sudeste. A elaboração dos agrupamentos espaciais pelo método SKATER permitiu analisar a variabilidade existente das diferentes variáveis independentes para os processos de USCV. Alguns processos de USCV apresentaram padrões de agrupamentos espaciais similares, como a expansão da soja e a degradação do campo. Esta técnica automatizada de agrupamento espacial melhora o entendimento sobre a dinâmica dos processos de USCV no território do Bioma Pampa Gaúcho.

Como recomendação para trabalhos futuros, em relação ao avanço metodológico de classificação do USCV, a utilização combinada de outros índices de vegetação, como o NDVI, imagens de reflectância e também métricas fenológicas como tentativa de mineração de dados. Desta maneira, existe a possibilidade de melhorar a acurácia entre classes, principalmente as com cobertura vegetal, que são aquelas onde as similaridades espectrais são maiores, como as classes Silvicultura, Floresta e Campo. Avanços no âmbito de modelos de regressão locais (GWR) e global como forma de explorar e identificar as especificidades de cada região dentro do Bioma Pampa e aprimorar as técnicas automatizadas de agrupamentos espaciais.

Considerações sobre a metodologia e recomendações de trabalhos futuros

Foram testados diversos métodos para separar as diferentes classes de uso do solo e cobertura vegetal, alguns métodos de classificação como orientado a objetos foi testado com o objetivo de tentar classificar de forma mais precisa as classes de Silvicultura, Floresta e Campo, mas os resultados não foram satisfatórios. Talvez devido a própria resolução espacial do sensor MODIS de 250 metros, não ser suficiente para identificar áreas de silvicultura e Floresta com

uma boa acurácia. Classificadores por árvore de decisão utilizados no trabalho apresentaram resultados mais confiáveis. Do ponto de vista metodológico, utilização de séries temporais com alta resolução temporal, fornecem informações importantes que são a chave para a compreensão dos melhores períodos para separar diferentes classes de uso do solo e cobertura vegetal, além de contribuir para o melhor entendimento da dinâmica ao longo do tempo.

Outros trabalhos de classificação do uso do solo e cobertura vegetal como de Cordeiro & Hasenack (2009) foram importantes para o desenvolvimento e discussão dos principais usos do solo no Estado do RS, utilizando imagens Landsat (30 m de resolução espacial). No âmbito da discussão metodológica de técnicas de classificação, utilizaram procedimentos de classificação visual em tela. Esta técnica de classificação visual em tela, o principal problema é o tempo envolvido para confecção de mapas de usos, diferentes de técnicas de classificação automatizadas, como as empregadas nos trabalhos que compõe esta tese.

Existem outros projetos de mapeamento do uso do solo como o projeto MapBiomas que tem como objetivo o mapeamento anual da cobertura e uso do solo do Brasil é um avanço no sentido de aprimorar técnicas de sensoriamento remoto, SIG e ciência da computação que utiliza processamento em nuvem e classificadores automatizados desenvolvidos e operados a partir da plataforma Google Earth Engine. O principal ponto negativo do projeto MapBiomas é que na utilização das imagens Landsat existe uma maior resolução temporal (16 dias) quando comparada aos dados MODIS, este período maior de revisita acaba dificultando a caracterização e identificação algumas classes vegetais, principalmente as classes com grande variação fenológica ao longo do ano (ex: áreas de cultivo)

Como recomendação para trabalhos futuros, em relação ao avanço metodológico de classificação do USCV, a metodologia desenvolvida nos artigos que compõe esta tese, poderia ser aplicada a outros satélites com diferentes resoluções espaciais, como o Landsat, sendo adaptada para atender os requisitos do sensor, também a utilização de outros índices de vegetação como NDVI, SAVI e a utilização de outros dados como imagens de reflectância e também métricas fenológicas poderia ser uma boa abordagem como tentativa de mineração de dados e melhorar a eficiência da metodologia de mapeamento das classes de uso do solo e cobertura vegetal para o Bioma Pampa. Desta maneira, existe a possibilidade de melhorar a acurácia entre classes, principalmente as com cobertura vegetal, que são aquelas onde as similaridades espectrais são maiores, como as classes Silvicultura, Floresta e Campo. Avanços no âmbito de modelos de regressão locais (GWR) e global como forma de explorar e identificar as especificidades de cada região dentro do Bioma Pampa e aprimorar as técnicas automatizadas de agrupamentos espaciais.